

# Anticiper et prédire les sinistres avec une approche Big Data

**Julien Cabot**

Directeur Big Data Analytics

OCTO

[jcabot@octo.com](mailto:jcabot@octo.com)

[@julien\\_cabot](#)

# Internet comme source de données...

**Bloomberg**

Our Company | Professional | Anywhere

HOME QUICK NEWS OPINION MARKET DATA PERSONAL FINANCE TECH POLITICS SUSTAINABLE

## Hedge Fund Will Track Twitter to Predict Stock Moves

By Jack Jordan - Dec 22, 2010 4:20 PM GMT+0100

f t in +1 0 COMMENTS QUEUE

Derwent Capital Markets, a family-owned hedge fund, will offer investors the chance to use Twitter Inc. posts to gauge the mood of the stockmarket, said co-owner Paul Hawtin.

The Derwent Absolute Return Fund Ltd., set to start trading in February with an initial 25 million pounds (\$39 million) under management, will follow posts on the social-networking website. A trading model will highlight when the number of times words on Twitter such as "calm" rise above or below average.

Enlarge image



A paper published in October said the number of emotional words on Twitter

A paper by the University of Manchester and Indiana University published in October said the number of emotional words on Twitter could be used to predict daily moves in the Dow Jones Industrial Average. A change in emotions expressed online would be followed between two and six days later by a move in the index, the researchers said, and this information let them predict its movements with 87.6 percent accuracy.

The New York Times

Internet

WORLD U.S. N.Y. / REGION BUSINESS TECHNOLOGY SCIENCE HEALTH

Search Technology

Inside Technology


Internet Start-Ups Business Computing

## Google Uses Searches to Track Flu's Spread

By MIGUEL HELFT  
Published: November 11, 2008

SAN FRANCISCO — There is a new common symptom of [the flu](#), in addition to the usual aches, coughs, fevers and sore throats. Turns out a lot of ailing Americans enter phrases like "[flu symptoms](#)" into [Google](#) and other search engines before they call their doctors.

### Multimedia



That simple act, multiplied across millions of keyboards in homes around the country, has given rise to a new early warning system for fast-spreading flu outbreaks, called Google Flu Trends.

Tests of the new Web tool from

# Internet, comme la voix des « mass markets »



## Les sources d'information utilisées en matière de santé

Question : De manière générale, quelles sont parmi les suivantes toutes les sources d'information que vous utilisez lorsque vous cherchez des informations en matière de santé ?

Base : A tous



71% à propos de

- Maladie
- Symptôme
- Médicament
- Avis / opinion

Les principales sources sont les forums, et non les réseaux sociaux

© 2008 Ipsos

Résultats supérieurs à 100, plusieurs réponses possibles

\*Item non suggéré

Ipsos Public Affairs


4

- > **Comprendre** les centres d'intérêt des communautés patients
- > **Anticiper** l'effet psycho-social d'Internet
- > **Prédire** les tendances d'évolution en suivant l'évolution de signaux faibles

# Comment procéder?

- > Comprendre le **champ sémantique** de la Santé ... utilisé sur Internet
- > Identifier les corrélations entre l'évolution des sinistres et des ... **millions de variables externes** non-identifiées
- > Trouver des variables corrélées ... **anticipant les sinistres**

Traiter des millions de corrélations n'est plus possible à l'échelle humaine





Forum

Analyse du langage naturel des messages par date et **interprétation sémantique**



Google Trends LABS

Volume de recherche Google sur des mots clefs de symptômes et de médicaments



data.gouv.fr BETA  
INNOVATION TRANSPARENCE · OUVERTURE

Evolutions des données socio-économiques issues de l'Open Data



Evolution de termes de Santé sur les forums



Evolution des recherches de termes de Santé



Evolution du contexte socio-économique



Sinistres Santé par typologies



**Correlation Search Machine**



**Matrice de corrélations "lagged"**



Analyse des messages par date

Text Mining

Tendances d'évolution de mots clefs santé

Comment tagger les mots clefs du domaine de la santé?



1-Construire manuellement une liste de mots clefs



2-Enrichir la liste avec les mots clefs les plus recherchés




WIKIPEDIA  
L'encyclopédie libre

3-Apprendre automatiquement des catégories Santé

Base de données de mots clefs santé

# Comment trouver des corrélations dans des séries de temps?

- Comparer l'évolution de variables exogènes et des sinistres dans le temps
- Trouver des régressions non linéaires et identifier fonction prédictive polymorphique  $f(x)$  à partir du dataset avec les Support Vector Regressions (SVR)



Problème à résoudre

$$\min_w \frac{1}{2} w^T \cdot w$$

$$\begin{cases} y_i - (w^T \cdot \phi(x) + b) \leq \epsilon \\ (w^T \cdot \phi(x) + b) - y_i \leq \epsilon \end{cases}$$

Résolution

- Descente de gradient stochastique
- Test de la réponse au travers du coef. de détermination  $R^2$

## Les bibliothèques de Machine Learning sont précieuses!

> Le volume de données à analyser n'est pas si important (~ 10 Go)

> Agrégation de données


Ex. Select ... Group By Date



> Recherche corrélation

Ex. SVR computing


$$\sim 5\text{Go} \cdot 12^3 = 8,64 \text{ To}$$



**Le Parallel Computing permet de diviser  
le temps de traitement et le Cloud Computing les coûts !**




Avec quelle plateforme?



# Solutions pour adresser le problème

	IO Elasticity	CPU Elasticity	RAM Elasticity	Commodity Hardware	OSS Software	Cost Elasticity
RDBMS	✗	✗	✗	✓	✓	✗
In Memory analytics	✗	✗	✓	✓	✗	✓
HPC	✗	✓	✓	✗	✓	✓
Hadoop	✓	With repartitioning	With repartitioning	✓	✓	With repartitioning
AWS Elastic MapReduce	✓	Through Task	Through Task	✓	✓	✓



Source: AWS



**Custom App**  
Python, Java, C#, ...

**Dataming tools**  
R, SAS

**BI tools**  
Tableau, Pentaho, ...

**Pig**  
Flow processing

**Streaming**  
MR scripting

**Hive**  
SQL-like querying

**Oozie**  
MR workflow

**Mahout**  
Machine Learning

**Hama**  
Bulk synchronous processing

**MapReduce**  
Parallel processing framework

**Zookeeper**  
Coordination service

**Sqoop**  
RDBMS integration


**Flume**  
Data stream integration

**HBase**  
NoSQL on HDFS

**HDFS**  
Distributed file storage



Grid of commodity hardware – storage and processing



## Num\_of\_messages\_by\_date.pig

```
records = LOAD '/input/forums/messages.txt'  
AS (str_date:chararray, message:chararray,  
url:chararray);  
  
date_grouped = GROUP records BY str_date  
  
results = FOREACH date_grouped GENERATE  
group, COUNT(records);  
  
DUMP results;
```

- > Hadoop streaming exécute des jobs map/reduce écrits en scripts au travers des standard I/O
- > Cela ressemble à cela (sur un cluster) :
  - + `cat input.txt | map.py | sort | reduce.py`

- > Pourquoi Hadoop streaming?
  - + Usage intensif de NLTK pour le Natural Language Processing
  - + Usage intensif de NumPy et Scikit-learn pour le Machine Learning

## Stem\_distribution\_by\_date/mapper.py

```
import sys
import nltk
from nltk.tokenize import regexp_tokenize
from nltk.stem.snowball import FrenchStemmer

# input comes from STDIN (standard input)
for line in sys.stdin:
    line = line.strip()
    str_date, message, url = line.split(";")

    stemmer = FrenchStemmer("french")
    tokens = regexp_tokenize(message, pattern='\w+')
    for token in tokens:
        word = stemmer.stem(token)
        if len(word) >= 3:
            print '%s;%s' % (word, str_date)
```

## Stem\_distribution\_by\_date/reducer.py

```
import sys
import json
from itertools import groupby
from operator import itemgetter
from nltk.probability import FreqDist

def read(f):
    for line in f:
        line = line.strip()
        yield line.split(';')

data = read(sys.stdin)

for current_stem, group in groupby(data, itemgetter(0)):
    values = [item[1] for item in group]
    freq_dist = FreqDist()

    print "%s;%s" % (current_stem, json.dumps(freq_dist))
```



# Conclusions

- La recherche de corrélations identifie
  - **42 variables externes corrélées** à plus de 70% sur une période supérieure à 24 mois sur 2,7 millions de variables
  - un facteur d'**anticipation supérieur à 4 mois**
- L'analyse sémantique permet de répondre à des questions :
  - Quels sont les centres d'intérêt Santé à la date T?
  - Quelle est l'évolution d'un centre d'intérêt dans le temps?
  - Où les internautes se retrouvent-ils pour échanger sur un sujet donné?

Merci de votre attention!

Julien Cabot  
jcabot@octo.com  
@julien\_cabot