

# Des bigrammes au secours de la grammaire

Eric Wehrli, Luka Nerima et Meghdad Farahmand



LATL-CUI Université de Genève

<http://latl.unige.ch>

Présenté par Yves Scherrer – ALPAGE

# Le problème

- ❖ Fips, comme tous les analyseurs syntaxiques basés sur des règles de grammaire, surgénère.
- ❖ La surgénération provient de la combinatoire qui s'exerce du fait de l'ambiguïté lexicale et de la pluralité des règles d'attachement.
- ❖ Des heuristiques sont donc nécessaires pour limiter le nombre d'alternatives et rendre le système utilisable dans des applications pratiques.
- ❖ L'élagage de l'ensemble d'alternatives se fait après l'attachement d'un nouveau mot sur la base des scores attribués à chaque analyse et en fonction du spectre choisi (nombre d'analyse maximal, habituellement entre 40 et 80).

# Analyse Fips

- ❖ Résultats obtenus en fonction du nombre d'alternatives (corpus de l' hebdomadaire The Economist 2012, env. 75' 000 mots)

max. alternatives	temps	analyses complètes	mots/secondes
120	21 :06	77.98%	59
80	13 :28	75.45%	93
40	6 :26	71.80%	198
10	2 :17	59.40%	579
5	1 :39	50.94%	793

- ❖ Ces données montrent que l'élagage permet effectivement d'améliorer considérablement l'efficacité de l'analyseur (quasi-linéaire), mais au détriment du niveau de qualité, estimé sur la base du nombre d'analyses complètes obtenues.

# Analyse complète

- ❖ Par analyse complète on entend une structure syntaxique bien formée couvrant l'intégralité de la phrase.
- ❖ L'analyse complète est un critère de qualité approximatif (complet ne signifie pas nécessairement correct !).
- ❖ Il existe pourtant une forte corrélation entre analyse complète et niveau de qualité (découpage lexical et structure syntaxique)

# Objectifs

- ❖ Améliorer l'élagage de manière à réduire (idéalement éliminer) la perte qualitative actuelle.
- ❖ Remplacer les scores «manuels» actuels par des probabilités statistiques calculées sur de gros corpus de textes.
- ❖ Questions :
  - ❖ Quels types de données statistiques
    - ❖ bigrammes de mots
    - ❖ bigrammes de lexèmes
    - ❖ bigrammes de **mots+catégorie**
  - ❖ À quel moment de l'analyse convient-il de les utiliser
    - ❖ avant l'analyse syntaxique, lors d'un prétraitement lexical?
    - ❖ **pendant l'analyse syntaxique**

# Première expérience

- ❖ Utiliser les bigrammes pour favoriser les lectures les plus probables de mots homographes.
  - ❖ Exemples d'homographes
    - [nom – verbe conjugué] démarche, options, notions, menace, affluent, souris, président, ...
    - [nom – participe] correspondant, étudiant, représentant, élu, initié
    - [conjonction – préposition] à, pour, au lieu de, ...
    - [nom – adjectif] passager, français, patient, ...
    - ...
  - ❖ Quelques exemples anglais:
    - [nom – verbe] record, cost, make, mix, ...

# Première expérience (suite)

- ❖ Au moment où l'analyseur cherche à combiner un terme homographe, pour chacune des possibilités de combinaison, on consulte les bigrammes pour les 2 termes afin d'attribuer un score à la structure résultant de cet attachement.
- ❖ A l'issue du traitement pour un mot donné dans la phrase, on filtre l'ensemble des structures sur la base de leur score.

# Acquisition des bigrammes

## ❖ Extraction des bigrammes

- ❖ Bigrammes de mots avec catégorie  
[marketing N, costs N], [marketing N, costs V]
- ❖ On s'intéresse uniquement aux bigrammes t.q. le deuxième mot est un homographe ( |catégorie lexicale| > 1 )
- ❖ La liste des homographes est obtenue par interrogation de notre base de données lexicale des formes fléchies :

7'022 en français (sur approx. 250'000 formes)

9,675 en anglais (sur approx. 100'000 formes)

# Corpus

## ❖ Corpus

- ❖ Extrait de Wikipedia anglais, ~ 140 Mio de mots

## ❖ Quelques chiffres

- ❖ Taille du corpus anglais : 139'690'263 mots  
nombre d'occurrences d'homographes 37'341'534 (soit 26 %)
- ❖ Taille du corpus français : 82'896'739 mots  
nombre d'occurrences d'homographes 28'969'353 (soit 34 %)

## ❖ Prétraitement

- ❖ Étiquetage POS avec le Stanford Parser (Klein et Manning 2003)

# Calcul de la probabilité

- ❖ Bigramme: (préfixe, homographe)
- ❖ Notation: ( $Pref, H$ )

$C$  : Count

$POS_i^H$  : the  $i^{th}$  POS tag of Homograph  $H$

$Pref$  : Homograph's prefix

$POS^{PREFIX}$  : POS tag of the prefix

$S$  : set of  $i^{th}$  homograph POS tags (for a given  $Pref$  and  $POS^{PREFIX}$ )

$$P(POS_i^H | Pref, POS^{PREFIX}) = \frac{C(POS_i^H \text{ follows } Pref \text{ and } POS^{PREFIX})}{\sum_{j \in S} C(POS_j^H \text{ that follow } Pref \text{ and } POS^{PREFIX})}$$

- ❖ Exemple (Wikipedia)

$$P(N^{costs} | N^{marketing}) = 0.92$$

$$P(V^{costs} | N^{marketing}) = 0.08$$

# Étiquettes Stanford → étiquette Fips

## ❖ Conversion

- ❖ Stanford: 36 étiquettes POS pour l'anglais (Penn Treebank)

- ❖ Fips: 9 étiquettes

- ❖ Par exemple

  - CC Coordinating conjunction → Conj

  - CD Cardinal number → Det

  - DT Determiner → Det

  - etc

## ❖ Problème

- ❖ Pas de correspondance directe entre les jeux d'étiquettes

- ❖ Par exemple:

  - l'étiquette IN "Preposition or subordinating conjunction" →  
Prep ou Conj ?

# Fonction de probabilité pour Fips

## ❖ Fonction

❖ ((Préfixe, catégorie), (Homographe, catégorie)) → probabilité

## ❖ Optimisation

❖ Utilisation des index de formes fléchies de la base lexicale de Fips:

(Préfixe, catégorie) → index de mot du préfixe

(Homographe, catégorie) → index de mot de l'homographe


## ❖ Implémentation

❖ Concaténation des deux index, hachage

❖ Tableau à une entrée → accès  $O(1)$

# Rappel: Les structures syntaxiques de Fips

- ❖ Dans Fips, les structures syntaxiques sont créées par projection
  - ❖ soit à partir d'un item lexical:  
 $X \rightarrow XP$        $X \in \{N, V, A, D, P, Adv, Conj\}$
  - ❖ projection étendue (métaprojection):  
verbe conjugué  $\rightarrow$





pronoms et noms propres  $\rightarrow$  DP

# Utilisation de la fonction

- ❖ La fonction est invoquée lors de l'attachement d'un terme homographe
- ❖ Fips considère des attachements à gauche (attachement du sujet, d'un adjectif prénominal, etc.) et à droite (tous les compléments, etc.)
- ❖ Les attachements à droite peuvent se faire à plusieurs niveau de la structure (transparent suivant)
  - en cas d'attachement à un nœud supérieur au coin droit, le préfixe et l'homographe ne sont pas adjacents
    - ❖ Exemple: ... ne **porte** pas toujours **atteinte** ...

# Attachement de constituants

- ❖ L'algorithme d'analyse combine deux projections adjacentes A et B
  - ❖ attacher A comme sous-constituant gauche de B (=attachement à gauche) ;
  - ❖ attacher B comme sous-constituant d'un nœud actif sur l'arête droite de A (attachement à droite) :



# Exemple

(1) Unit labour **costs** measure the average cost of labour per unit of output.  
les coûts unitaires de la main-d'oeuvre mesurent le coût moyen de la main-d'oeuvre par unité produite.

- ◆ Dans l'exemple ci-dessus, lorsque l'analyseur lit le mot homographe *costs* (substantif ou verbe), il consulte la table des bigrammes pour chacune des deux catégories (N et V), étant donné le verbe *labour*, dans une première analyse, le substantif *labour* dans une deuxième analyse.
- ◆ La probabilité associée au bigramme [labour-N, costs-N] (*coût de la main-d'oeuvre*) est largement supérieure à celle des autres bigrammes. Cette analyse sera donc privilégiée.

# Questions ouvertes

- ❖ Granularité du préfixe
  - ❖ Mot (forme fléchie) ?
  - ❖ Lexème ?
  - ❖ Catégorie lexicale (POS) ?
- ❖ Pertinence de ne s'intéresser qu'aux homographes ?
- ❖ Calculer des bigrammes plus « sophistiqués », de têtes sémantiques de syntagmes ?  
[Le gros **chat** noir] [a **mangé** [une petite **huître**]]

## ❖ Remarque

Notre approche se distingue d'un étiquetage POS en prétraitement, par le fait que les lectures non privilégiées sont conservées jusqu'à un élagage éventuel de l'analyse.