

# Acquisition de collocations verbe + nom à partir de représentations syntaxiques

---

Atelier sur les corpus  
spécialisés en terminologie

présenté par Brigitte Orliac  
28 avril 2003

# Introduction

- Construction d'un modèle d'acquisition automatique de collocations
- Encodage des combinaisons retenues pour des applications en TA
- Approche mixte basée sur des spécifications linguistiques et des méthodes statistiques

## **La collocation : une expression...**

*At the United States military's Central Command headquarters in Doha, Qatar, Navy Capt. Frank Thorp told reporters today: "I would say again that we **fully expect** that there are **fierce battles** ahead, that there continues to be resistance and that the **overall objective** of **bringing down the regime** has not yet been **achieved**. But it will be."*

## **...non libre**

*Navy Capt. Frank Thorp spoke to reporters.*

*Navy Capt. Frank Thorp **let out a cry.***

*Navy Capt. Frank Thorp screamed bloody murder.*

# Les fonctions lexicales : des outils pour représenter les collocations

- Des fonctions, au sens mathématique, qui définissent, pour chaque UL de la langue, l'ensemble des UL qui lui sont sémantiquement et syntaxiquement associées
- Chaque FL représente une signification de base qui ne peut être appréhendée qu'en pratique, lorsque la fonction est appliquée à une UL particulière
- Pour les FL qui modélisent des collocations, cette signification de base est associée à une relation syntaxique profonde

# Exemples de fonctions lexicales

*He let out a cry.*

**Oper**

*He took a question from another reporter.*

*A cry came out.*

**Func**

*A question came up.*

*Reporters bombarded him with questions.*

**Labor**

# Les collocations verbe + nom spécialisées

- La cooccurrence verbale des termes est encore relativement peu décrite
- Les terminologies privilégient la description de la cooccurrence nominale
  - ◆ *cache memory, random access memory, read-only memory, virtual memory, etc.*
  - ◆ *batch file, data file, executable file, source file, etc.*
  - ◆ *anti-virus program, virus detection program, etc.*

# Les collocations verbe + nom spécialisées

- Le discours spécialisé est aussi fait de constructions linguistiques plus larges
  - ◆ *the program executes, runs, terminates, works*
  - ◆ *[to] configure, close, create, download, install, load, remove, run, start, write a program*
  - ◆ *[to] back up, close, create, delete, download, load, name, open, save, upload a file*
  - ◆ *[to] keep, load, store something in memory*

# Les collocations verbe + nom spécialisées

*the program executes, runs, works*

*the program operates?*

*[to] close a file*

*[to] shut a file?*

*[to] load something into memory*

*[to] put something into memory?*

# Les collocations verbe + nom spécialisées

*Cache memory stores both instructions or data.*

*\*La mémoire cache emmagasine les instructions aussi bien que les données.*

*You can enter and run a request.*

*\*Vous pouvez introduire et diriger une demande.*

# Etat de l'art en acquisition automatique

- Les premiers travaux portent sur l'acquisition de chaînes de caractères relativement proches l'une de l'autre (à l'intérieur de fenêtres)
- Développement de mesures d'association pour tester le statut collocationnel de chaque paire extraite (information mutuelle, coefficient de vraisemblance)

# Etat de l'art en acquisition automatique

- De bons résultats en ce qui concerne les groupes nominaux anglais
- De moins bons résultats pour les combinaisons verbe + nom et pour les langues autres que l'anglais
- Les collocations manifestent des variations morphologiques et syntaxiques importantes dans les textes

# Etat de l'art en acquisition automatique

Word can **save files** in Word format (i.e. with macros) under any extension.

Your current **files** are **saved** in \OS2\ARCHIVES\CURRENT.

By **saving** recently accessed **files** from the network, the computer ...

This will allow you to **save** the **file** to your local hard drive in a place other than the cache directory.

Take a look at the services we explored, try a few out, and start **saving** and sharing **files** online.

# Etat de l'art en acquisition automatique

- Les nouveaux programmes extraient les collocations de corpus étiquetés (étiquettes de catégories et de liens grammaticaux)
- Les mesures statistiques ne sont plus appliquées à des chaînes de caractères mais à des données linguistiques (séquences morpho-syntaxiques)

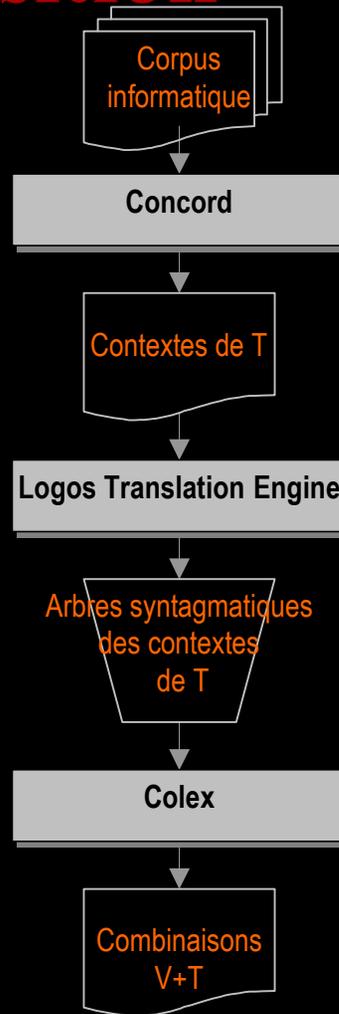
# Notre approche

- Acquérir les combinaisons verbe + nom à partir de corpus analysés
  - ◆ Analyseur du système de TA Logos
- Valider les combinaisons candidates en utilisant une mesure d'association
  - ◆ *[to] boot a computer*
  - ◆ *[to] buy a computer*

# Notre approche

- Nous acquérons les collocatifs verbaux des termes de l'informatique
- Le terme doit remplir l'un des trois rôles syntaxiques définis pour les bases des FL verbales
  - ◆ sujet
  - ◆ objet direct
  - ◆ objet indirect

# Méthode d'acquisition



# Analyse des contextes de T

*All files you add to your Web site should be saved with the suffix .html...*

```
[Punc  BOS    bos
]
[NP    file   pl
]
[Aux   should
]
[V     saved  pass
]
[NP    suffix with
]
[Punc  EOS    un
]
[Punc  CLS-BOS  relCls
]
```

# Extraction des combinaisons V + T

```
if(n_string (aux) v_passive (adv) n_obj*)
```

NP\_file\_pl   Aux\_should\_   V\_saved\_pass   NP\_suffix\_with

```
then {v_passive + n_string + n_obj;}
```

{ } → saved → file → with suffix

# Résultats pour FILE dans le rôle d'objet direct

f:	22	save	file
f:	18	create	file
f:	18	download	file
f:	17	copy	file
f:	14	locate	file
f:	14	send	file
f:	9	store	file
f:	8	access	file
f:	8	delete	file
f:	8	edit	file
f:	8	find	file
f:	8	load	file
f:	8	read	file
f:	7	attach	file
f:	7	back up	file

# Résultats pour OPEN

f:	29	open	file
f:	9	open	it
f:	9	open	window
f:	7	open	icon
f:	6	open	explorer
f:	5	open	program
f:	3	open	browser
f:	3	open	computer
f:	3	open	door
f:	2	open	arm
f:	2	open	copy
f:	2	open	DOS prompt
f:	2	open	page
f:	2	open	site
f:	1	open	address book

# Quelques scores pour les collocatifs verbaux de FILE

	Logl	IM	F
open	16.05	3.77	24
copy	14.15	4.44	17
download	13.03	3.98	18
save	11.62	3.19	22
locate	8.87	3.61	14
back up	6.36	4.75	7
edit	5.74	3.94	8
upload	4.99	5.15	5
delete	3.90	3.00	8
attach	3.69	3.16	7
name	3.40	3.79	5
send	3.29	1.91	14
load	2.73	2.38	8
create	2.72	1.49	18
update	2.50	3.05	5

# Sous forme graphique

