



# Analyse des entités nommées

## Le module du LIPN

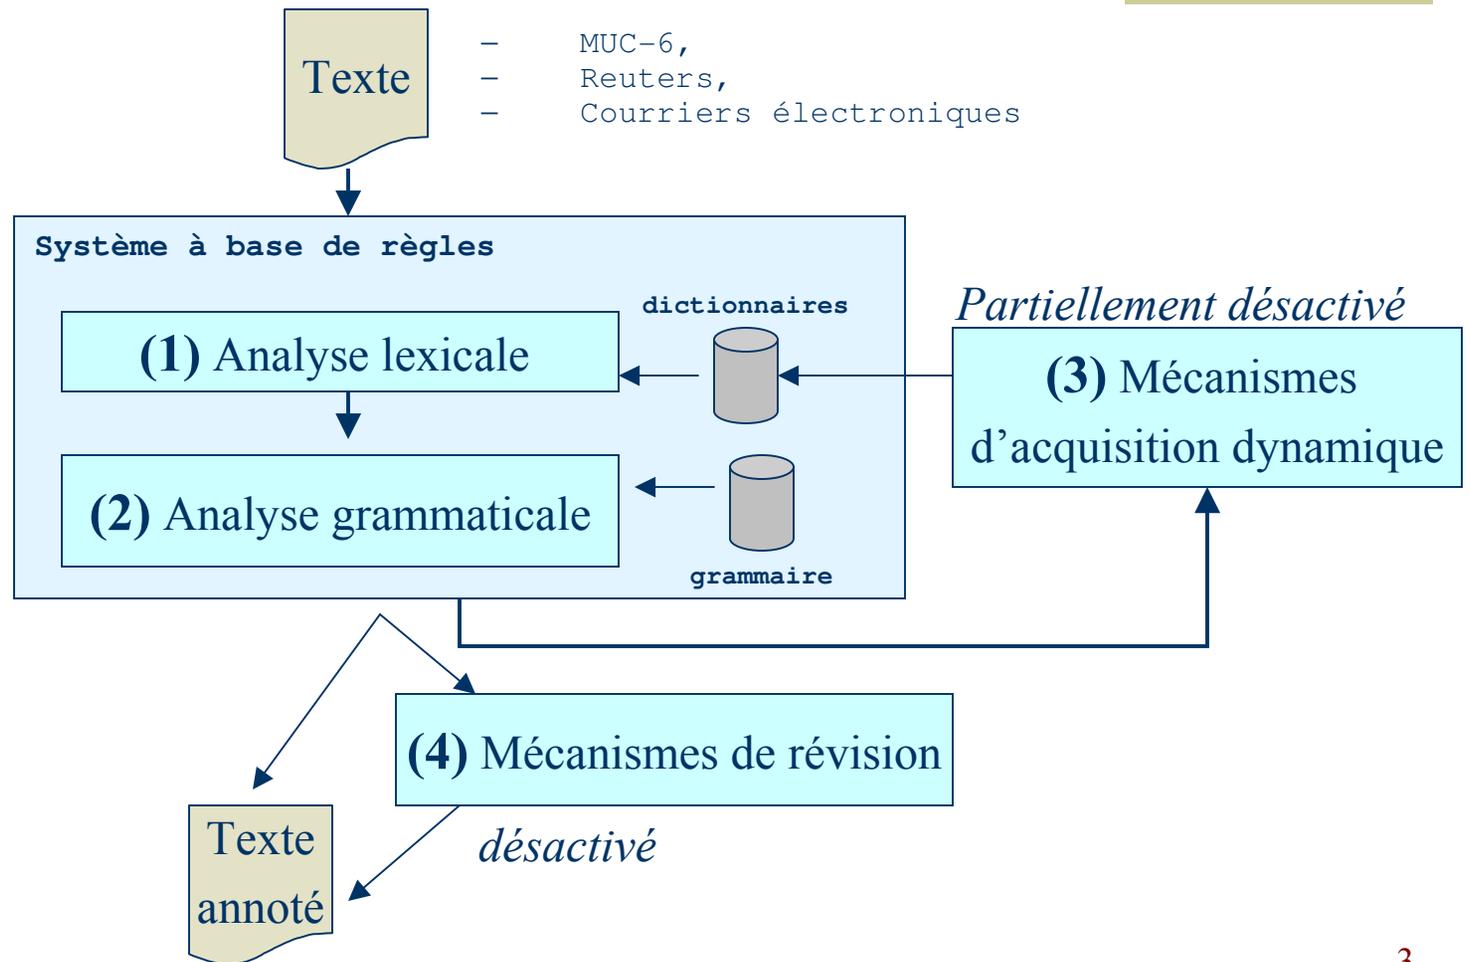
Thierry Poibeau  
LIPN – CNRS UMR 7030

Atelier Ester 2005, Avignon le 31 mars 2005

# Le système développé

- ◆ MAEN, un système initialement développé au LIPN pour l'analyse de documents écrits
- ◆ Analyse fondé sur un ensemble de transducteurs à nombre fini d'états (cf. Unitex, Marne-la-Vallée)
- ◆ Peu d'adaptation à l'oral
- Évaluer les particularités du système sur des transcriptions de parole

# Architecture



# Étiquetage à partir de dictionnaires

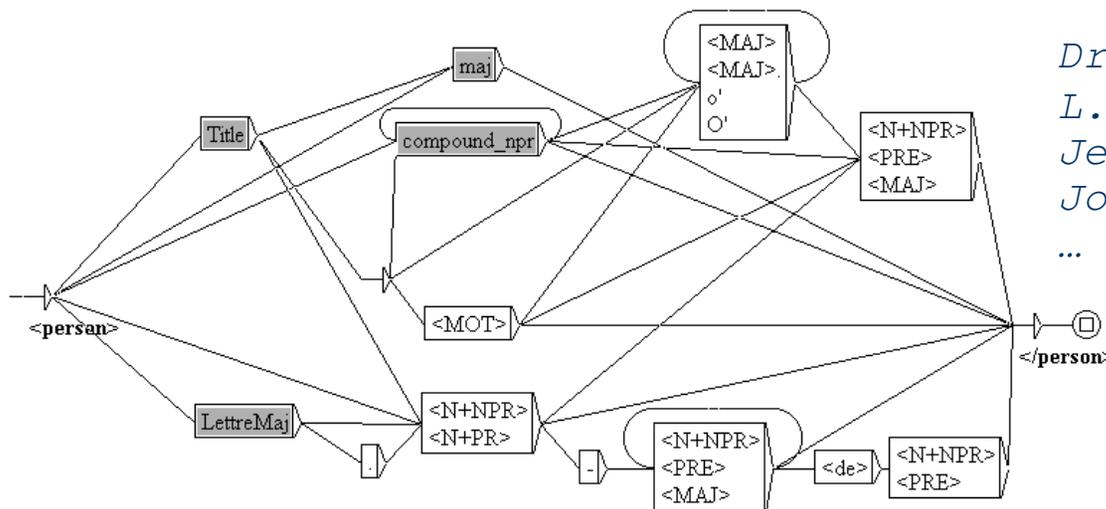
- ◆ De nombreuses sources de données, disponibles ou acquises

Type	Étiquette	Exemple
Nom de personne	<N+NPR>	Dupont
Prénom	<N+PR>	Jacques
Nom de société	<N+Soc>	L'Oréal
Nom de géographie, dont	<N+Loc>	Picardie
Nom de ville <sup>1</sup>	<N+Loc+City>	Paris
Nom de pays	<N+Loc+Country >	France

- ◆ Utilisation de valeurs par défaut (limitation de l'ambiguïté)

# Étiquetage à partir de la grammaire

- ◆ La grammaire est un ensemble de transducteurs récurrents à nombre fini d'états (>1000 états, >25000 transitions)



*Dr Jivago*  
*L. Schweitzer*  
*Jean-Paul Sartre*  
*John M. O'Brien*  
...

# Évaluation du système à base de règles

- ◆ Évaluation sur les transcriptions manuelles uniquement
- ◆ Performances globales médiocres (< 40 %)
  - Plusieurs catégories non couvertes initialement contribuent à faire baisser les performances (artefacts, *etc.*)
  - Distinctions difficiles (gsp/loc)
  - Adaptation insuffisante par rapport aux spécification (cf. *en 1999*)

# Conclusions et perspectives

- ◆ Campagne d'évaluation intéressante
  - ◆ Spécificités de l'oral par rapport à l'écrit
  - ◆ Qualité des ressources fournies
- ◆ Perspectives
  - ◆ Améliorer la couverture du système pour certaines catégories (*artefacts*)
  - ◆ Évaluer le système sur des transcriptions automatiques