Les tables du Lexique-Grammaire
 Le lexique LGLex
 Conversion de LGLex en un lexique au format Alexina
 Intégration dans l'analyseur syntaxique FRMG
 Evaluation et discussion
 Conclusions et perspectives

Utilisation des tables du Lexique-Grammaire pour l'analyse syntaxique automatique

Elsa Tolone¹

1. LIGM, Université Paris-Est (France)

Séminaire du LIPN, Université Paris 13, France 21 septembre 2010 Les tables du Lexique-Grammaire
 Le lexique LGLex
 Conversion de LGLex en un lexique au format Alexina
 Intégration dans l'analyseur syntaxique FRMG
 Evaluation et discussion
 Conclusions et perspectives

Contexte

- Les tables du Lexique-Grammaire du français sont une ressource lexicale très riche
- Elles contiennent des informations syntaxiques et syntaxico-sémantiques
- Ces informations devraient être très utiles pour l'analyse syntaxique automatique
- Mais les tables ne sont pas directement exploitables telles quelles dans un analyseur syntaxique
 - des informations importantes ne sont pas représentées car elles sont considérées comme implicites pour une table donnée
 - le format de représentation des informations lexicales n'est pas formalisé
 - il faut interfacer ces informations avec un analyseur syntaxique symbolique réel

Les tables du Lexique-Grammaire
 Le lexique LGLex
 Conversion de LGLex en un lexique au format Alexima
 Intégration dans l'analyseur syntaxique FRMG
 Evaluation et discussion
 Conclusions et perspectives

Objectifs

Triple objectif:

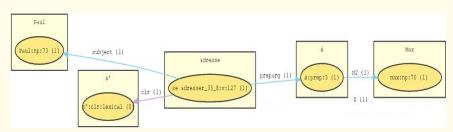
- convertir les tables du Lexique-Grammaire en un format TAL
- coupler le lexique syntaxique obtenu, nommé LGLex_{Lefff}, avec un analyseur syntaxique
- évaluer l'analyseur obtenu

Outils TAL retenus:

- ➤ analyseur syntaxique : FRMG [Thomasset & de La Clergerie 2005]
- formalisme lexical : Alexina, format du lexique Lefff
 [Sagot 2010] utilisé par FRMG
- ightarrow ceci permet une comparaison entre FRMG $_{\mathrm{Lefff}}$ et FRMG $_{\mathit{LGLex}}$

Les tables du Lexique-Grammaire
 Le lexique LGLex
 Conversion de LGLex en un lexique au format Alexina
 Intégration dans l'analyseur syntaxique FRMG
 Evaluation et discussion
 Conclusions et perspectives

Exemple de dépendances avec FRMG



Paul s'adresse à Max

 \rightarrow entrée *s'adresser V_33_8*

Les tables du Lexique-Grammaire
 Le lexique LGLex
 Conversion de LGLex en un lexique au format Alexina
 Hitégration dans l'analyseur syntaxique FRMG
 Evaluation et discussion
 Conclusions et perspectives

- 1. Les tables du Lexique-Grammaire
- 2. Le lexique LGLex
- 3. Conversion de LGLex en un lexique au format Alexina
- 4. Intégration dans l'analyseur syntaxique FRMG
- 5. Évaluation et discussion

1. Les tables du Lexique-Grammaire

- 2. Le lexique LGLex
 3. Conversion de LGLex en un lexique au format Alexina
 4. Intégration dans l'analyseur syntaxique FRMG
 5. Évaluation et discussion
 Conclusions et perspectives
- .1. Tables du Lexique-Grammaire
- 1.2. Tables des classes
- 1.3. Constructions de base

1 Les tables du Lexique-Grammaire

- 1.1. Tables du Lexique-Grammaire
- 1.2. Tables des classes
 - 3. Constructions de base

Tables du Lexique-Grammaire

Développées manuellement depuis plus de 40 ans par le LADL [Gross 1975], puis l'Equipe d'Informatique Linguistique du LIGM (Université Paris-Est)

 Étude de la syntaxe d'une phrase élémentaire (ou cadre de sous-catégorisation)
 ex : N0 V à N1

Conclusions et perspectives

- Catégories concernées : verbes, adverbes, noms et adjectifs prédicatifs et expressions figées pour le français
 - → certaines **propriétés en commun** = **classes**
- Les différents emplois sont distingués (ex : cuisiner)

1.1. Tables du Lexique-Grammaire

1.2. Tables des classes

Principe

Chaque classe est codée dans une table :

5. Évaluation et discussion Conclusions et perspectives

- ► lignes = entrées (mots)
- colonnes = propriétés grammaticales

Propriétés :

- constructions
- autres propriétés (distributionnelles, morphologiques, transformationnelles, sémantiques, etc.)

```
ex : N0 = : Nhum \rightarrow nom humain
```

- Chaque propriété testée pour chaque entrée
 - \rightarrow codage binaire :
 - + : propriété acceptée
 - ▶ : propriété non acceptée
- Propriétés définitoires pour chaque classe dont au moins une construction de base

- 1. Les tables du Lexique-Grammaire
 2. Le lexique LGLex
- Conversion de LGLex en un lexique au format Alexina
 Intégration dans l'analyseur syntaxique FRMG
 Evaluation et discussion
 Conclusions et perspectives
- 1.1. Tables du Lexique-Grammaire
- 1.2. Tables des classes
- 1.3. Constructions de base

Extrait de la table des verbes de la classe 33

	N0 =: Nhum	N0 =: N-hum	N0 =: Nm	Ppv	Ppv ≕ se figé	Ppv ≕ en figé	Ppv ≕ les figé	Nég	<ent></ent>	10 V	N0 être V-ant	N1 =: Nhum	N1 =: N-hum	N1 =: le fait Qu P	Ppv =: lui	Ppv =: y	N0hum V W sur ce point	[extrap]	<opt></opt>
	+	-	-	<e></e>	-	-	-	-	renaître	+	+	-	+	-	-	+	-	-	Max renaît au bonheur de vivre
	+	-	-	se	+	-	-	-	rendre	+	-	+	+	+	-	+	+	+	Max s'est rendu à mon opinion
	+	-	-	se	+	-	-	-	rendre	+	-	+	-	-	-	-	-	-	Le caporal s'est rendu à l'ennemi
-	+	-	-	<e></e>	-	-	-	-	renoncer	-	-	+	+	-	-	+	-	-	Max renonce à son héritage

Construction de base : N0 V à N1

- Les tables du Lexique-Grammaire
 2. Le lexique LGLex
 3. Conversion de LGLex en un lexique au format Alexina
 4. Intégration dans l'analyseur syntaxique FRMG
 5. Évaluation et discussion
- 1.1. Tables du Lexique-Grammaire
- 1.2. Tables des classes
 - Constructions de base

Bilan

- ► Inventaire [Tolone 2009] :
 - ▶ 67 classes de verbes simples

Conclusions et perspectives

- ▶ 13 867 entrées pour 5 738 lemmes distincts
- 78 classes de noms prédicatifs simples et composés (noms avec argument(s) qui sont étudiés avec leur verbes support)
 - ▶ 12 696 entrées pour 8 531 lemmes distincts
 - ex : Luc monte une attaque contre le fort
- 69 classes d'expressions figées, principalement verbales et adjectivales
 - ▶ 39 628 entrées pour 38 658 lemmes distincts ex : arriver à la cheville de qq'un, être à la retraite
- 32 classes d'adverbes simples et (semi-)figés (adverbes en -ment et locutions adverbiales)
 - 10 488 entrées pour 9 326 lemmes distincts ex : [changer] du jour au lendemain

- Les tables du Lexique-Grammaire
 Le lexique LGLex
 Conversion de LGLex en un lexique au format Alexina
 Intégration dans l'analyseur syntaxique FRMG
 Evaluation et discussion
- 1.1. Tables du Lexique-Grammaire
- 1.2. Tables des classes
 - l.3. Constructions de base

Entrées supplémentaires

- noms prédicatifs simples :
 - 24 classes codant également des verbes simples
 - 3 334 entrées pour 2 377 lemmes distincts
 - ex : Max a donné des encouragements à Léa
 - ightarrow Max encourage Léa

Conclusions et perspectives

- ▶ 8 classes codant également des adjectifs prédicatifs simples
 - ▶ 1 408 entrées pour 1 287 lemmes distincts
 - ex : Max a une certaine aptitude à supporter la douleur
 - → Max est apte à supporter la douleur
- adverbes :
 - 2 classes codant également des expressions figées verbales
 - 388 entrées pour 385 lemmes distincts
 - ex : partir comme une fusée
 - 1 classe codant également des adjectifs prédicatifs composés
 - 304 entrées pour 300 lemmes distincts
 - ex : être doux comme un ange

Conversion de LGLex en un lexique au format Alexina
 Intégration dans l'analyseur syntaxique FRMG
 Evaluation et discussion
 Conclusions et perspectives

1.1. Tables du Lexique-Grammaire

1.2. Tal

Constructions de base

Versions

- Lexique riche à large couverture → la version 3.2 contient les tables distribuées actuelles pour chaque catégorie
 - ▶ version 1 = format d'origine
 - version 2 = 1ères tables en ligne (60% seulement)
 - version 3 = depuis ma thèse, dans les différents formats de lexique
 - bientôt, la version 3.3 avec 100% des tables et la documentation de toutes les propriétés des verbes

3. Conversion de LGLex en un lexique au format Alexina
4. Intégration dans l'analyseur syntaxique FRMG
5. Évaluation et discussion
Conclusions et perspectives

1.1. Tables du Lexique-Grammaire

1.2. Tables des

. Constructions de base

Problèmes

- Noms différents pour une même propriété
 - → Harmonisation des intitulés de colonnes
 - ex : [extrap] et il V N0 W
- Propriétés pas définies clairement
 - → Documentation des propriétés
- Propriétés définitoires implicites (littérature)
 - \rightarrow Constante + ou pour l'ensemble de la table
- ► Entrées pas à jour dans les tables
 - → Ajout des entrées manquantes
- ▶ Entrées non codées (~)
 - → Codage d'entrée

- 1.1. Tables du Lexique-Grammaire
- 1.2. Tables des classes
 - 1.3. Constructions de base

Tables des classes

Propriétés définitoires \rightarrow à décrire dans des **tables des classes** (1 par catégorie) :

- colonnes = toutes les propriétés syntaxiques répertoriées pour la catégorie concernée (après harmonisation)
- ▶ lignes = classes définies pour cette catégorie
- ▶ intersection ligne/colonne :
 - ▶ o = propriété explicitement codée dans la table concernée
 - ► + (resp. -) = la propriété correspondante est vérifiée (resp. non vérifiée) par tous les éléments de la classe
 - ? = non encore renseigné

En cours de réalisation au LIGM, bien avancé pour les verbes et les noms prédicatifs [Constant & Tolone 2010], mais aussi pour les expressions figées et les adverbes

- 1. Les tables du Lexique-Grammaire
- 2. Le lexique LGLex
 3. Conversion de LGLex en un lexique au format Alexina
 4. Intégration dans l'analyseur syntaxique FRMG
 5. Évaluation et discussion
 Conclusions et perspectives
- 1.1. Tables du Lexique-Grammaire
- 1.2. Tables des classes
 - 1.3. Constructions de base

Extrait de la tables des classes des verbes

table	N0 =: Nhum	N0 =: N-hum	N0 =: Nm	N0 =: V1-inf W	<ent></ent>	Ppv ≕ se figé	N0 V	N0 V N1	zone 1	N0 V à N1	N1 =: Nhum	N1 =: N-hum	N0 V Prep N1 V0-inf W	N0 V N1 V0-inf W	N0 V V0-inf W
V_2	+	-	-	-	o	o	-	-	-	-	-	+	o	o	+
V_4	-	-	+	+	o	-	o	+	-	-	О	o	-	-	-
V_31R	О	О	-	-	o	О	+	-	-	-	-	-	-	-	-
V_31H	+	-	-	-	o	o	+	-	-	-	-	-	-	-	-
V_33	О	О	o	-	o	О	o	-	-	+	o	o	-	-	-
V_32H	О	-	o	-	o	o	-	+	-	-	+	-	-	-	-

3. Conversion de LGLex en un lexique au format Alexina 4. Intégration dans l'analyseur syntaxique FRMG 5. Évaluation et discussion Conclusions et perspectives

1.3. Constructions de base

Verbes de BGL

Cas des complétives et des infinitives [Tolone 2010]

- ► Simplification des constructions de base [Tolone et al. 2010]
- Exploitation informatique
- Spécification des distributions

Table	Construction de base d'origine	Construction de base actuelle	Autres propriétés définitoires
32CV	N0 V N1 (E+en V-n)	N0 V N1 en N2	N2 être V-n N0 V N1 N2 apparition

- Max a roulé les papiers
- Max a roulé les papiers en un mince rouleau

[Boons et al. 1976a]

- 1. Les tables du Lexique-Grammaire
 2. Le lexique LGLex
- 3. Conversion de LGLex en un lexique au format Alexina
 4. Intégration dans l'analyseur syntaxique FRMG
 5. Évaluation et discussion
 Conclusions et perspectives
- 1.1. Tables du Lexique-Grammaire
- 1.2. Tables des classes
- 1.3. Constructions de base

Verbes de BGL (2)

► Éclatement en plusieurs classes

Table	Construction de base d'origine	Construction de base actuelle
35L	N0 V Loc N1	N0 V Loc N1 source Loc N2 destination

- Paul a bondi du tabouret sur la table
- Paul a bondi du tabouret
- Paul a hondi sur la table

Table	Construction de base actuelle
35LS	N0 V Loc N1 source

▶ Le train a déraillé de la voie

Table	Construction de base actuelle				
35LD	N0 V Loc N1 destination				

Le bateau s'enfonce dans les flots

[Boons et al. 1976a]

Conversion de LGLex en un lexique au format Alexina
 Hintégration dans l'analyseur syntaxique FRMG
 S. Évaluation et discussion
 Conclusions et perspectives

1.1. Tables du Lexique-Grammaire

1.2. Tables des classes

1.3. Constructions de base

Expressions figées (M. Gross)

- Reconstitution des constructions de base à partir des colonnes lexicales
- Modification des intitulés de colonnes pour être harmonisés avec la construction de base
- ► Structure des expressions figées incluse dans la construction de base (N : argument libre, C : argument figé)

Table	Construction de base
EPCPN	N0 être Prép1 Det1 C1 Prép2 N2

<ent>être</ent>	<ent>Prép1</ent>	<ent>Det1</ent>	<ent>C1</ent>	<ent>Prép2</ent>
être	en	< <i>E</i> >	accord	avec
être	de	la même	force	que
être	à	la	frontière	entre

Table: Extrait de la table EPCPN des expressions figées (colonnes lexicales)

- 1. Les tables du Lexique-Grammaire
 2. Le lexique LGLex
- Conversion de LGLex en un lexique au format Alexina
 Intégration dans l'analyseur syntaxique FRMG
 S. Évaluation et discussion
 Conclusions et perspectives
- 1.1. Tables du Lexique-Grammaire
- 1.2 Tables des classes
- 1.3. Constructions de base

Adverbes en -ment : adverbes intégrés à la proposition

- Clarification des constructions de base
 - colonnes entièrement codées + supprimées

Table	Construction de base	Exemple
ADVM	N0 V Adv W	Ce livre est en vente exclusivement sur ce site
		*Exclusivement, ce livre est en vente sur ce site
ADVMP	Adv, N0 V W	Ce livre est en vente régulièrement sur ce site
ADVMS		Régulièrement, ce livre est en vente sur ce site
ADVMTF		*Régulièrement, ce livre n'est pas en vente
		sur ce site
ADVMP	Adv, N0 ne V pas W	Ce concert est musicalement une réussite
		Musicalement, ce concert est une réussite
		Musicalement, ce concert n'est pas une réussite

[Molinier & Levrier 2000]

1.1. Tables du Lexique-Grammaire

1.2. Tables des classes
1.3. Constructions de base

onversion de *LGLex* en un lexique au format Alexina 4. Intégration dans l'analyseur syntaxique FRMG 5. Evaluation et discussion Conclusions et perspectives

Adverbes (semi-)figés

- ► Reconstitution de la structure de l'adverbe à partir des colonnes lexicales
- Modification des intitulés de colonnes pour être harmonisés avec la construction de base

Table	Structure de l'adverbe	Exemple
PCPC	Prép1 Det1 C1 Prép2 Det2 C2	[changer] du jour au lendemain

Définition des constructions de base (approximation)

Table	Construction de base			
P	N0 V Adv W Adv, N0 V W Adv, N0 ne V pas W			

[Gross 1986]

Les tables du Lexique-Grammaire
 Le Lexique LGLex
 Conversion de LGLex en un lexique au format Alexina
 Intégration dans l'analyseur syntaxique FRMG
 Evaluation et discussion
 Conclusions et perspectives

2. Le lexique LGLex

Les tables du Lexique-Grammaire
 Le lexique LGLex
 Conversion de LGLex en un lexique au format Alexima
 Intégration dans l'analyseur syntaxique FRMG
 Evaluation et discussion
 Conclusions et perspectives

LGLex

Table des classes → possibilité d'extraire un **lexique syntaxique** semi-structuré pour chaque catégorie à partir des tables [Constant & Tolone 2010] :

- format textuel ou XML
- ▶ nommé lexique *LGLex*
- conversion depuis les tables Excel grâce à l'outil LGExtract
- version 3.2 contenant LGLex des tables distribuées pour chaque catégorie disponible sur http://infolingu.univ-mlv.fr/

LGLex est le point de départ du processus de conversion vers le format Alexina

Format du lexique LGLex

- ► ID=catégorie_numTable_numEntrée
- ▶ lexical-info=[...] → lemme et ses informations lexicales (auxiliaires, verbes supports, déterminants, prépositions)
- ▶ args=(...) → arguments et leurs distributions accompagnées d'autres informations (traits sémantiques, mode de la complétive, argument contrôlé par l'infinitive, prépositions)
- ▶ all-constructions=[absolute=(...), relative=(...)] → liste des constructions acceptées (soit nommées de façon complète avec tous les éléments dans l'ordre, soit transformations à partir de la construction de base, mais aussi réductions de GN, structures des adverbes figés, etc.)
- ▶ example=[...] → exemple illustrant l'entrée

Les tables du Lexique-Grammaire
 Le lexique LGLex
 Conversion de LGLex en un lexique au format Alexina
 Intégration dans l'analyseur syntaxique FRMG
 Evaluation et discussion
 Conclusions et perspectives

Extrait du lexique LGLex (verbe)

```
ID=V 36SL 28
lexical-info=[cat="verb",verb=[lemma="clouer"],prepositions=[preposition=[id="2",list=(prep="avec")])
   locatifs=(locatif=[id="2".list=()].aux-list=())]
args=(
   const=[pos="0",dist=(comp=[cat="NP",hum="true",introd-prep=(),introd-loc=(),
      origin=(orig="N0 = : Nhum")],
   const=[pos="1",dist=(comp=[cat="NP",nothum="true",introd-prep=(),introd-loc=(),
      origin=(orig="N1 = : N-hum")])])
   const=[pos="2", dist=(comp=[cat="NP", destination="true", introd-prep=(), introd-loc=(prep="à", prep="sur"),
      origin=(orig="Loc N2 = : \(\text{\text{a}}\) N2 destination",orig="Loc N2 = : \(\text{sur N2 destination}\)])],
all-constructions=[absolute=(construction="true::N0 V N1 Loc N2".construction="o::N0 V N1".
   construction="true:: NO V N1 Prép N2", construction="true:: NO V N1 et N2"
   construction="o::N0 V N1 de N3 attache",construction="o::N0 V N1hum Loc N2abs",
   construction="o : :N3 attache V N1",construction="o : :N0 V N1 + 2"),
   relative=(construction='[passif par]")]
example=[example="Max a cloué cette planche(avec+contre+sur)celle-là"]
```

- entrée clouer V_36SL_28
- Reste à faire : interpréter les constructions

Les tables du Lexique-Grammaire
 Le lexique *LGLex* Conversion de *LGLex* en un lexique au format Alexina
 Intégration dans l'analyseur syntaxique FRMG
 5. Evaluation et discussion

3.1. Le Lefff et Alexina

3.2. Conversion de LGLex

3.5. Lexique obtenu : $\textit{LGLex}_{\text{Lefff}}$

3. Conversion de *LGLex* **en un lexique au format Alexina**

Conclusions et perspectives

- Les tables du Lexique-Grammaire
 Le lexique LGLex
 Conversion de LGLex en un lexique au format Alexina
 Intégration dans l'analyseur syntaxique FRMG
 Evaluation et discussion
 Conclusions et perspectives
- 3.1. Le Lefff et Alexina
- 3.5. Lexique obtenu : LGLex_{Lefff}

Le Lefff

- ► Le Lefff (Lexique des Formes Fléchies du Français) est un lexique morphologique et syntaxique pour le français [Sagot 2010]
 - à large couverture (536 375 entrées correspondant à 110 477 lemmes distincts couvrant toutes les catégories)
 - ▶ librement distribué (licence LGPL-LR)
- Il repose sur l'architecture Alexina de modélisation et d'acquisition de lexiques morphologiques et syntaxiques

- Les tables du Lexique-Grammaire
 Le lexique LGLex
 Conversion de LGLex en un lexique au format Alexina
 Intégration dans l'analyseur syntaxique FRMG
 Evaluation et discussion
 Conclusions et perspectives
- 3.1. Le Lefff et Alexina
- 3.2. Conversion de LGLex
- 3.5. Lexique obtenu : LGLexLefff

Alexina

Architecture à deux niveaux

- Le lexique intensionnel
 - associe à chaque entrée (emploi d'un lemme) un cadre de sous-catégorisation canonique
 - ▶ liste les redistributions possibles à partir de ce cadre
- ► Le processus de **compilation** du lexique intensionnel en lexique **extensionnel** construit différentes entrées pour chaque forme fléchie du lemme et chaque redistribution possible

3.1. Le Lefff et Alexina
3.2. Conversion de LGLex

3.5. Lexique obtenu : LGLexLefff

Alexina sur un exemple

Exemple d'entrée intentionnelle :

```
 \begin{array}{ll} \textit{clarifier}_1 & \textit{v-er:std} \\ & \textit{Lemma;v;} \\ < \textbf{Suj:} \textit{cln}|\textit{scompl}|\textit{sinf}|\textit{sn}, \textbf{Obj:}(\textit{cla}|\textit{scompl}|\textit{sn}) >; \\ \textit{\%ppp\_employé\_comme\_adj,\%actif,\%se\_moyen\_impersonnel,} \\ \textit{\%passif\_impersonnel,\%passif} \end{array}
```

- ► Fonctions syntaxiques (cf. Dicovalence) : Suj, Obj, Objà, Objde, Loc, Dloc, Att, Obl/Obl2
- Réalisations: directes (sn, sa, sinf, scompl, qcompl); clitiques (cln, cla, cld, y, en); prépositionnelles (prep+directe, p.ex. par-sn, à-sinf, de-scompl)
- Redistributions: %actif, %passif, %se_neutre, %actif_impersonnel, etc.

Le processus de conversion

- ► La conversion des tables du Lexique-Grammaire vers le formalisme Alexina n'est **pas directe**
 - Cela requiert une definition formelle ou une interprétation dynamique de tous les noms de propriétés
 - Directement ou indirectement, ces propriétés peuvent :
 - specifier un cadre de sous-catégorisation complet
 - spécifier une information partielle à propos d'un cadre de sous-catégorisation (le fait qu'un argument n'est pas obligatoire, une réalisation possible pour un argument, etc.)
 - correspondre à une redistribution
 - mener à une construction d'une entrée additionnelle
 - Des informations additionnelles importantes doivent être complétées grâce à des heuristiques ou à partir d'autres ressources lexicales
 - le nom de chaque fonction syntaxique, les phénomènes d'attribution, les informations morphologiques, etc.

- Les tables du Lexique-Grammaire
 Le lexique LGLex
 Conversion de LGLex en un lexique au format Alexina
 Intégration dans l'analyseur syntaxique FRMG
 Evaluation et discussion
 Conclusions et perspectives
- 3.1. Le Lefff et Alexina
 3.2. Conversion de LGLex
 3.5. Lexique obtenu : LGLexLefff

L'exemple précédent du lexique LGLex (verbe)

```
ID=V_36SL_28
| lexical-info=[cat="verb",verb=|lemma="clouer"],prepositions=(preposition=[id="2",list=(prep="avec")])
   locatifs=(locatif=[id="2".list=()].aux-list=())]
args=(
   const=[pos="0",dist=(comp=[cat="NP",hum="true",introd-prep=(),introd-loc=(),
      origin=(orig="N0 = : Nhum")],
   comp=[cat="NP",introd-prep=(),introd-loc=(),nothum="true",
      origin=(orig="N0 = : N-hum")])],
   const=[pos="1",dist=(comp=[cat="NP",nothum="true",introd-prep=(),introd-loc=(),
      origin=(orig="N1 = : N-hum")])])
   const=[pos="2",dist=(comp=[cat="NP",destination="true",introd-prep=(),introd-loc=(prep="a",prep="sur"),
      origin=(orig="Loc N2 = : à N2 destination",orig="Loc N2 = : sur N2 destination")])],
all-constructions=[absolute=(construction="true::N0 V N1 Loc N2",construction="o::N0 V N1",
   construction="true : :N0 V N1 Prép N2", construction="true : :N0 V N1 et N2"
   construction="0::N0 V N1 de N3 attache".construction="0::N0 V N1hum Loc N2abs".
   construction="o::N3 attache V N1",construction="o::N0 V N1 + 2"),
   relative=(construction='[passif par]")]
example=[example="Max a cloué cette planche(avec+contre+sur)celle-là"]
```

entrée clouer V_36SL_28

```
3.1. Le Lefff et Alexina
3.2. Conversion de LGLex
3.5. Lexique obtenu : LGLex<sub>Lefff</sub>
```

Résultat de la conversion sur l'exemple précédent

```
clouer V_36SL_28 v-er:std 100;Lemma;v; <Suj:cln|sn,Obj:sn,Loc:(à-sn|sur-sn|avec-sn)>; cat=v;@SujNhum;@ObjN-hum; %actif,%passif,%ppp_employé_comme_adj
```

- Max a cloué ces planches au mur
 - ► Max a cloué ces planches

```
3.1. Le Lefff et Alexina
3.2. Conversion de LGLex
3.5. Lexique obtenu : LGLexLefff
```

Résultat de la conversion sur l'exemple précédent (2)

```
clouer V_36SL_28 v-er :std 100 ;Lemma ;v ; 

< Suj :cln|sn,Obj :sn,Loc :(à-sn|sur-sn|avec-sn)> ; 

cat=v ;@SujNhum ;@ObjN-hum ; 

%actif,%passif,%ppp_employé_comme_adj
```

Entrée du lexique intensionnel :

- ▶ identifiant de l'entrée : catégorie_numTable_numEntrée
- classe morphologique, qui définit le modèle qui construit les formes fléchies en reposant sur les classes flexionnelles du Lefff
- catégorie
- cadre de sous-catégorisation initial
- informations supplémentaires représentées par des macros
- ▶ liste des redistributions possibles

```
3.1. Le Lefff et Alexina
3.2. Conversion de LGLex
3.5. Lexique obtenu : LGLexLefff
```

Résultat de la conversion sur l'exemple précédent (3)

```
clouer V_36SL_28 v-er :std
100;Lemma;v;

<Suj :cln|sn,Obj :sn,Loc :(à-sn|sur-sn|avec-sn)>;
cat=v;@SujNhum;@ObjN-hum;
%actif,%passif,%ppp_employé_comme_adj

Une entrée du lexique extensionnel :
clouées 100 v
pred=clouer V_36SL_28
<Suj :sn,Loc :(à-sn|sur-sn|avec-sn),Obl :(par-sn)>;
@passive,@pers,cat=v,@Kfp

► Ces planches ont été clouées au mur par Max
```

- Les tables du Lexique-Grammaire
 Le lexique LGLex
 Conversion de LGLex en un lexique au format Alexina
 Intégration dans l'analyseur syntaxique FRMG
 Evaluation et discussion
 Conclusions et perspectives
- 3.1. Le Lefff et Alexina
 3.2. Conversion de LGLex
 3.5. Lexique obtenu : LGLexLefff

Autre extrait du lexique LGLex (nom)

- ► Max a de la considération pour (ce geste+Luc)
- ► (Ce geste+Luc) a la considération de Max

- Les tables du Lexique-Grammaire
 Le lexique LGLex
 Conversion de LGLex en un lexique au format Alexina
 Intégration dans l'analyseur syntaxique FRMG
 Evaluation et discussion
 Conclusions et perspectives
- 3.1. Le Lefff et Alexina 3.2. Conversion de LGLex 3.5. Lexique obtenu : $LGLex_{Lefff}$

Résultat de la conversion

```
considération N aa 18
                       nc-2f
                       100:Lemma:cf:
                       <Sui:cln|sn,Obl:pour-sn>;
                       cat=nc;@SujNhum;@OblN-hum;@OblNhum;
                       lightverb=avoir ressentir éprouver;
                       %default
considération N aa 18
                       nc-2f
                       100:Lemma:cf:
                       <Suj:cln|sn,Objde:de-sn>;
                       cat=nc:@SuiNhum:
                       lightverb=avoir;
                       %default
```

Version 3.2 contenant les verbes et les noms des tables distribuées disponible sur http://infolingu.univ-mlv.fr/

Reste à convertir : expressions figées et adverbes (en cours)

- 3.1. Le Lefff et Alexina

 - 3.5. Lexique obtenu : LGLexi, efff

Lexique obtenu : LGLex_{Lefff}

- ▶ verbes : LGLex_{Lefff} contient 16 955 entrées pour 5 723 lemmes verbaux différents (2,96 entrées/lemme)
 - ▶ À titre de comparaison, le Lefff contient seulement 7 072 entrées verbales pour 6 818 lemmes verbaux distincts (1,04 entrées/lemme)

Au niveau extensionnel, le Lefff contient 361 268 entrées, alors que le lexique extrait de LGLex en contient 862 546

- noms prédicatifs : LGLex_{Lefff} contient 17 517 entrées pour 8 363 lemmes différents (2,09 entrées/lemme)
 - Le Lefff ne contient que 218 entrées de noms prédicatifs (1 entrée/lemme)

Au niveau extensionnel, LGLex contient 32 389 entrées

- Les tables du Lexique-Grammaire
 2. Le lexique LGLex
 Conversion de LGLex en un lexique au format Alexina
 Hitégration dans l'analyseur syntaxique FRMG
 Evaluation et discussion
 Conclusions et perspectives
- 4. Intégration dans l'analyseur syntaxique FRMG

Intégration dans l'analyseur syntaxique FRMG

- ▶ L'intégration de *LGLex*_{Lefff} dans l'analyseur FRMG est rapide
- ► Le *lexeur* de l'analyseur fait normalement appel à une base de données lexicales construite à partir du Lefff
- Nous allons donc construire un autre lexique, qui repose sur LGLex_{Lefff}, que nous demanderons au lexeur d'utiliser à la place du Lefff

Intégration des verbes et des noms prédicatifs mais évaluation sur les verbes uniquement

Intégration dans l'analyseur syntaxique FRMG (2)

Il faut donc :

- ▶ remplacer les entrées verbales du Lefff par LGLex_{Lefff}
- conserver les autres entrées du Lefff
- compléter le résultat par diverses entrées verbales venant du Lefff, qui ne font pas partie du lexique LGLex
 - entrées pour les auxiliaires et semi-auxiliaires
 - certains verbes à montée
 - les verbes impersonnels
 - les entrées pour les têtes syntaxiques des constructions à verbes support
- construire la base de données lexicales correspondantes
- spécifier à FRMG d'utiliser cette dernière

Le résultat est une variante de l'analyseur FRMG, que nous noterons $FRMG_{LGLex}$, par opposition à la variante standard notée $FRMG_{LGHex}$

1. Les tables du Lexique-Grammaire 2. Le lexique LGLex 3. Conversion de LGLex en un lexique au format Alexina 4. Intégration dans l'analyseur syntaxique FRMG

5. Évaluation et discussion Conclusions et perspectives

5.2. Résultats

5.3. Discussion

5. Évaluation et discussion

- 5.1. Protocole 5.2. Résultats
- 5.3. Discussion

Protocole utilisé

- Nous avons évalué FRMG_{Lefff} et FRMG_{LGLex} en analysant la partie annotée manuellement du corpus EASy [Paroubek et al. 2005]
 - ▶ 4 306 phrases de styles variés (journalistique, médical, oral, questions, littéraire, etc.)
- métriques utilisées : celles de la première campagne EASy d'évaluation des analyseurs syntaxiques, qui a eu lieu fin 2005 [Paroubek et al. 2006]
 - évaluation en chunks et en relations (~ dépendances entre mots pleins)

5.2. Résultats

5.3. Discussion

Précautions

Les résultats de FRMG_{I GLex} seront à interpréter en gardant à l'esprit plusieurs points

- ► FRMG utilise les entrées verbales converties à partir des tables, et non pas les entrées telles qu'elles sont dans les tables
 - → le processus de conversion est sûrement entâché d'erreurs
- ► EASy ne permet pas d'évaluer toutes les informations contenues dans les tables (informations sémantiques par ex.)
- ▶ le Lefff a été développé en parallèle aux campagnes EASy, contrairement aux tables
- ► LGLex_{Lefff} ne contient pas toutes les entrées verbales nécessaires, et il a fallu en rajouter
 - \rightarrow il en mangue encore puisque tous les verbes ne sont pas codés

- Les tables du Lexique-Grammaire
 Le lexique LGLex
 Conversion de LGLex en un lexique au format Alexina
 Intégration dans l'analyseur syntaxique FRMG
 Š. Évaluation et discussion
 Conclusions et perspectives
- 5.1. Protocole 5.2. Résultats
- 5.2. Resultats 5.3. Discussion

Résultats

Résultats comparatifs EASy de $FRMG_{Lefff}$ et $FRMG_{LGLex}$ (pourcentages de f-mesure) :

	Chunks		Relations	
Sous-corpus	$FRMG_{Lefff}$	FRMG _{LGLex}	$FRMG_{Lefff}$	FRMG _{LGLex}
general_lemonde	88.22%	84.60%	62.73%	59.01%
litteraire_2	88.91%	88.46%	65.28%	62.43%
mail_9	82.60%	81.90%	58.55%	56.00%
medical_3	85.04%	85.89%	64.79%	65.26%
oral_delic_4	78.80%	81.79%	51.67%	51.14%
questions_amaryllis	91.30%	90.73%	66.56%	64.77%
total	87.05%	85.53%	63.10%	60.25%

Temps d'analyse plus élevés avec $FRMG_{LGLex}$ qu'avec $FRMG_{Lefff}$: temps médian par phrase de 0,62 s contre 0,26 s

 ceci provient du nombre d'entrées par lemme 3 plus élevé dans LGLex que dans le Lefff

- 5.2. Résultats
- 5.3. Discussion

- ► FRMG_{I GLex} donne de meilleurs résultats que FRMG_{Lefff} pour certaines relations
 - relations « classiques » MOD_A (modifieur-adjectif) et MOD_R (modifieur-adverbe)
 - relations « difficiles » MOD_P (modifieur-préposition) et APP (apposition)
- ▶ la relation ATB_SO (attribut du sujet ou de l'objet) est celle pour laquelle la différence en rappel est la plus importante (34,0% contre 58,4%);
 - les tables du Lexique-Grammaire encodent très peu d'informations sur les phénomènes d'attribution, mais cela peut aussi être dû aux erreurs de la référence EASy

Conclusions et perspectives

À court terme

- ▶ De nombreuses phrases reçoivent une analyse complète par FRMG_{LGLex} mais pas par FRMG_{Lefff}, et inversement
 - par exemple, sur le sous-corpus general_lemonde, 177 phrases sont entièrement reconnues par les deux analyseurs, 85 seulement par FRMG_{Lefff}, 76 seulement par FRMG_{LGLex}, et 111 par aucun des deux
- Les analyses complètes sont souvent bien meilleures que les analyses partielles
- Possibilité d'utiliser les deux analyseurs en même temps, et de ne conserver le résultat que de celui qui a donné une analyse complète

À long terme

Exploiter la complémentarité des deux ressources pour y détecter des erreurs et les améliorer mutuellement

- étudier les différences entre les erreurs faites par chacun des deux analyseurs
- utiliser des techniques automatiques de fouille d'erreurs pour extraire automatiquement des entrées probablement erronées [Sagot et de La Clergerie 2008]
 - ▶ pour *LGLex*_{Lefff}, de nombreuses erreurs que l'on trouverait viendraient probablement du processus de conversion
 - certaines erreurs détectées pourraient provenir d'erreurs dans les tables, que l'on pourrait ainsi corriger

Tester le lexique sur un analyseur syntaxique probabiliste en cours de développement au LIGM (Anthony Sigogne)

Généralisation de la méthode

Optimiser l'utilisation des données lexicales du Lexique-Grammaire pour l'analyse syntaxique

- coder les entrées manquantes ou non codées dans les tables
 - coder en priorité les entrées plus courantes
 - coder en priorité les constructions les plus longues
- coder la table des classes pour chaque catégorie
- améliorer/corriger le processus de conversion
- appliquer cette technique aux tables du Lexique-Grammaire pour les autres catégories
- généraliser cette méthode pour les autres langues pour lesquelles des tables du Lexique-Grammaire à large-couverture sont disponibles (i.e., Grec en cours)

Références

- ▶ [Boons et al. 1976a] Boons J.-P., Guillet A. et Leclère C. La structure des phrases simples en français : Classes de constructions transitives. Rapport interne, LADL, CNRS, Paris 7. 1976.
- ▶ [Constant & Tolone 2010] Matthieu Constant et Elsa Tolone. A generic tool to generate a lexicon for NLP from Lexicon-Grammar tables. Lingue d'Europa e del Mediterraneo, Grammatica comparata, vol. 1, pages 79-93. Aracne. 2010.
- ► [Gross 1975] Maurice Gross. Méthodes en syntaxe : Régime des constructions complétives. Hermann. Paris, France. 1975.
- ► [Gross 1986] Maurice Gross. Grammaire transformationnelle du français: Syntaxe de l'adverbe, volume 3. Paris: ASSTRIL. 1986.
- ▶ [Molinier & Levrier 2000] Molinier C. et Levrier F. Grammaire des adverbes : description des formes en -ment. Genève : Droz. 2000.

Références (2)

- [Paroubek et al. 2005] Patrick Paroubek, Louis-Gabriel Pouillot, Isabelle Robba et Anne Vilnat. Premier bilan de la participation du LORIA à la campagne d'évaluation EASy. Actes de l'atelier EASy de TALN'05. Dourdan, France. 2005.
- ▶ [Paroubek et al. 2006] Patrick Paroubek, Isabelle Robba, Anne Vilnat et Christelle Ayache. Data, Annotations and Measures in EASy: the Evaluation Campaign for Parsers of French. Actes de LREC'06. Gênes, Italie. 2006.
- ▶ [Sagot et de La Clergerie 2008] Benoît Sagot et Éric de La Clergerie. Fouille d'erreurs sur les sorties d'analyseurs syntaxiques. Traitement Automatique des Langues (T.A.L.), vol.49, num.1, pages 41-60. Hermès. Paris, France. 2008.

Références (3)

- ► [Sagot 2010] Benoît Sagot. The Lefff, a freely available and large-coverage morphological and syntactic lexicon for French. Actes de LREC'10, 8 pages. La Valette, Malte. 2010.
- ► [Thomasset & de La Clergerie 2005] François Thomasset et Éric de La Clergerie. Comment obtenir plus des méta-grammaires. Actes de TALN'05. Dourdan, France. 2005.
- ► [Tolone 2009] Elsa Tolone. Les tables du Lexique-Grammaire au format TAL. Actes de MajecSTIC'09, 8 pages. Avignon, France. 2009.

Références (4)

- ▶ [Tolone 2010] Elsa Tolone. Constructions définitoires des tables du Lexique-Grammaire : Le cas des complétives et des infinitives. Actes de MajecSTIC'10 (session poster), 4 pages. Bordeaux, France. 2010. To appear.
- ▶ [Tolone et al. 2010] Elsa Tolone, Stavroula Voyatzi et Christian Leclère. Constructions définitoires des tables du Lexique-Grammaire. Actes de LGC'10, pages 321-331. Belgrade, Serbie. 2010.
- ► [Tolone & Sagot 2009] Elsa Tolone et Benoît Sagot. Using Lexicon-Grammar tables for French verbs in a large-coverage parser. Actes de LTC'09, pages 200-204. Poznań, Pologne. 2009.

L'analyseur syntaxique FRMG

FRMG est un analyseur TAG du français :

- ▶ issu de la compilation d'une méta-grammaire
- ▶ très **compacte** grâce à la factorisation des arbres (1 986 300 arbres défactorisés $\rightarrow \sim 75$ 630 arbres)
- exploitant les fonctionnalités de DyALog
 - → environnement de programmation en logique (langage, compilateur, machine virtuel)

FRMG s'intègre dans une chaîne de traitement :

- en amont, avec SXPipe et le lexique Lefff
 - **SXPipe** : segmentation, token, corrections, entités nommées
 - \rightarrow retourne un **DAG** (graphes de mots)
 - Lefff: lexique morphosyntaxique et syntaxique du français
 - \rightarrow lien lexique/grammaire : ancrage par **hypertag**
- en aval, avec un module de désambiguïsation