

# GLÀFF, un Gros Lexique À tout Faire du Français

UE TAL

7/10/2013

**Franck Sajous, Nabil Hathout et Basilio Calderone**  
CLLE-ERSS, CNRS & Université de Toulouse 2



# introduction | Ncfs | introduction | ẽ.tɔ̃.dyk.sjõ

## GLÀFF est un lexique :

- gros ;
- construit à partir du Wiktionnaire ;
- sous licence libre ;
- qui contient des informations morphosyntaxiques et phonémiques.

talentueuse | Afpfs | talentueux | ta.lã.tyøz

talentueusement | Rgp | talentueusement | ta.lã.tyøz.mã

talentueuses | Afpfp | talentueux | ta.lã.ty.øz

talent | Ncms | talent | ta.lã

talent | Vmip3p- | taler | tal

talent | Vmsp3p- | taler | tal

taleraient | Vmcp3p- | taler | ta.lə.ɛ

# Plan

- 1 Ressources connexes
- 2 Du Wiktionnaire à GLÀFF 1.0
  - Le Wiktionnaire
  - Extraction et construction de GLÀFF
- 3 Caractérisation
  - Couverture
  - Transcriptions phonémiques
- 4 v1.2
  - Mots grammaticaux
  - Psychoglàff
  - GLÀFFi
- 5 Conclusion et perspectives

## Ressources connexes (pour le français)

### Lexiques morphosyntaxiques (gratuits)

- ABU (1999) : 300 000 entrées  
<http://abu.cnam.fr>
- Leff [Clément et al., 2004] : 500 000 entrées
- Morphalou [Romary et al., 2004] : 525 000 entrées  
licence contraignante

### avec transcriptions phonémiques

- BDLex [Pérennou and de Calmès, 1987] : 440 000 entrées  
(ELRA-S0004/Academic-Research : 2000 €)
- Brulex [Content et al., 1990] : 36 000 entrées, gratuit
- ILPho [Boula De Mareuil et al., 2000] : 319 000 entrées  
(ELRA-S0163/Academic-Research : 100 €)
- Lexique [New, 2006] : 135 000 entrées, gratuit

## Ressources connexes

### Une situation encore insatisfaisante

Pas de lexique libre, à large couverture, contenant des transcriptions phonémiques.

Obstacle pour :

- les outils (e.g. large couverture : étiqueteurs, transcriptions : phonétiseurs)
- la recherche
  - morphologie flexionnelle et dérivationnelle (Hathout 2009 ; Boyé 2011)
  - variation phonologique, phonotaxe et structures syllabiques (Goldsmith et Xanthos 2009 ; Maïonchi-Pino et al. 2013)
- la diffusion de travaux exploitant ces ressources (→ œuvres dérivées)

Autre problème : ressources existantes non mises à jour

# Wiktionary et sa branche francophone, le Wiktionnaire

## Bande-annonce

- dictionnaire multilingue libre, accessible en ligne
- projet satellite («*compagnon lexical*») de Wikipédia
- 2 millions d'articles pour le français
- alimenté/mis à jour constamment... par «*les foules*»
- contient (notamment) :
  - des définitions et des exemples
  - des relations sémantiques
  - des traductions
  - des transcriptions phonémiques
- téléchargeable : <http://dumps.wikimedia.org>

# Le Wiktionnaire pour le TAL

## «2 millions d'articles pour le français»

Nomenclature impressionnante, mais sont comptabilisés :

- locutions
- variantes orthographiques
- mots d'autres langues

Restent 1,4 millions d'entrées (monolexicales)

## Qualité ?

- Polémique : [Giles, 2005] vs. [Encyclopaedia Britannica, 2006]
- [Zesch and Gurevych, 2010] : ressources fondées sur la « *sagesse des foules* » sérieusement compétitives

# Le Wiktionnaire pour le TAL

## Qualité : notre point de vue

- Wiktionary  $\neq$  Wikipédia  
«neutralité de point de vue» moins essentielle...  
mais contributeurs actifs «particuliers»...
- Qualité en tant que base de calcul de similarité  
 $\neq$  qualité intrinsèque du dictionnaire
- Notre but : lexique pour le TAL  $\neq$  dictionnaire
- Et par ailleurs...
  - Wiktionary a un large couverture
  - est distribué sous licence libre
  - contient des defs, relations sémantiques, traductions, transcriptions phonémiques
  - est mis à jour constamment ( $\rightarrow$  potentiellement seul à rendre compte des formes néologiques)

# TAL, Wiktionnaire & Wiktionary

## Travaux antérieurs

- [Zesch et al., 2008] : calcul de similarité sémantique
- [Navarro et al., 2009] : potentiel comme source de données primaire (lexique électronique FR+EN)  
→ WiktionaryX [Sajous et al., 2010]  
<http://redac.univ-tlse2.fr/lexiques/wiktionaryx.html>
- [Krizhanovsky, 2010] : extracteur pour le Wiktionary russe
- [Sajous et al., 2011] : tentative de guidage des foules  
→ description détaillée du Wiktionnaire + WiktionaryEN
- [Anton Pérez et al., 2011] : intégration du Wiktionary portugais dans Onto.PT [Gonçalo Oliveira and Gomes, 2010]
- [Sérasset, 2012] : DBnary, extraction d'un réseau multilingue
- [Meyer and Gurevych, 2012] : OntoWiktionary  
[Gurevych et al., 2012] : UBY

# Articles : entrée = url = forme orthographique

http://fr.wiktionary.org/wiki/affluent



Wiktionnaire  
Le dictionnaire libre

Page d'accueil  
Index alphabétique  
Portails thématiques  
Page au hasard  
Page au hasard par langue  
Poser une question

Contribuer

Aide

Boîte à outils

Autres langues

العربية  
Cymraeg  
Deutsch  
Ελληνικά  
English  
Esote  
Euskara  
فارسی  
Suomi  
Galego  
Magyar  
Bahasa Indonesia  
Ido  
Italiano  
Malagasy  
македонски  
Nederlands  
Polski  
پښتو  
Русский  
Svenska

Article Discussion

Lire Modifier Afficher l'historique

## affluent

Français [modifier]

### Étymologie

(1374)Du latin **affluens**(← **affluant**→) → voir **affluer**.

### Adjectif

**affluent**

- (Géographie)Qui se **jette dans** un **autre** en **parlant** d'un **cours** d'eau.  
Le Rhin et les rivières **affluentes**.
- (Médecine)Qui **affluent**, qui se **portent** en **abondance vers** quelque **partie du corps**(se dit des **humeurs**).  
La sérosité, la salive **affluente**.

	Singulier	Pluriel
Masculin	<b>affluent</b> <i>/a.fly.ɑ̃/</i>	<b>affluents</b> <i>/a.fly.ɑ̃/</i>
Féminin	<b>affluente</b> <i>/a.fly.ɑ̃t/</i>	<b>affluentes</b> <i>/a.fly.ɑ̃t/</i>

### Nom commun

**affluent** */a.fly.ɑ̃/* masculin

- (Géographie) **Cours d'eau** qui se **jette dans** un **autre**.  
Voici le Madon, **affluent** de la Moselle, dont les eaux limoneuses invitent peu à la baignade, malgré la grande chaleur.  
(Gustave Fraipont: Les Vosges. 1923)

Singulier	Pluriel
<b>affluent</b>	<b>affluents</b>
	<i>/a.fly.ɑ̃/</i>

### Traductions

anglais : **affluent**<sup>[en]</sup>  
catalan : **afluent**<sup>[ca]</sup>  
espagnol : **afluente**<sup>[es]</sup>  
espéranto : **branĉrivero**<sup>[eo]</sup>  
ido : **enfluanto**<sup>[io]</sup>  
néerlandais : **zijrivier**<sup>[nl]</sup>  
occitan : **afluent**<sup>[oc]</sup>

### Forme de verbe

**affluent** */a.fly/*

1. Troisième personne du pluriel de l'indicatif présent de **affluer**

Conjugaison du verbe **affluer**

# Articles : entrée = url = forme orthographique

<http://fr.wiktionary.org/wiki/affluente>

## affluente

**Français** [modifier]



### Forme d'adjectif

**affluente** féminin /a.fly.ɑ̃t/

1 Féminin singulier de [affluent](#) .

Catégories : [français](#) | [Formes d'adjectifs en français](#)

# Tables de conjugaison

http://fr.wiktionary.org/wiki/Annexe:Conjugaison\_en\_français/affluer



Wiktionnaire  
 Le dictionnaire libre

- Page d'accueil
- Index alphabétique
- Portails thématiques
- Page au hasard
- Page au hasard par langue
- Poser une question

- Contribuer
- Journal des contributeurs
- La Wikidémie
- Communauté
- Discuter sur IRC
- Modifications récentes
- Faire un don

Aide

Boîte à outils

Annexe [Discussion](#)

Lire [Modifier](#) [Afficher l'historique](#)

## Annexe:Conjugaison en français/affluer

[Annexe:Conjugaison en français](#)

Conjugaison de **affluer**, verbe du 1<sup>er</sup> groupe, conjugué avec l'auxiliaire **avoir**

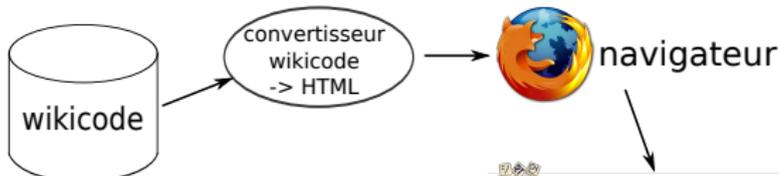
### Modes impersonnels

Mode	Présent	Passé
<b>Infinitif</b>	affluer /a.flʷe/	avoir afflué /a.vvav_a.flʷe/
<b>Gérondif</b>	en affluant /ð.n_a.flʷð/en ayant	afflué /ð.n_ε.jð.t_a.flʷe/
<b>Participle</b>	affluent /a.flʷð/	afflué /a.flʷe/

### Indicatif

	Présent	Passé composé
j'afflue	/ʒ_a.fly/	j'ai afflué /ʒ_e_a.flʷe/
tu afflues	/ty a.fly/	tu as afflué /ty a.z_a.flʷe/
il/elle/øn afflue	/[i e ʃ]a.fly/	il/elle/on a afflué /[i.i ε.l ʃ.n]_a.t_a.flʷe/
nous affluons	/nu.z_a.flʷʒ/	nous avons afflué /nu.z_a.vʒ.z_a.flʷe/
vous affluez	/vu.z_a.flʷe/	vous avez afflué /vu.z_a.ve.z_a.flʷe/
ils/elles affluent	/[i e ]z_a.fly/	ils/elles ont afflué /[i e ].z_ʃ.t_a.flʷe/
	Imparfait	Plus-que-parfait
j'affluais	/ʒ_a.flʷe/	j'avais afflué /ʒ_a.ve.z_a.flʷe/
tu affluais	/ty a.flʷe/	tu avais afflué /ty a.ve.z_a.flʷe/
il/elle/øn affluait	/[i e ʃ]a.flʷe/	il/elle/on avait afflué /[i.i ε.l ʃ.n]_a.ve.t_a.flʷe/
nous affluions	/nu.z_a.fly.jʒ/	nous avions afflué /nu.z_a.vʒ.z_a.flʷe/
vous affluiez	/vu.z_a.fly.je/	vous aviez afflué /vu.z_a.vje.z_a.flʷe/
ils/elles affluaient	/[i e ]z_a.flʷe/	ils/elles avaient afflué /[i e ].z_a.ve.t_a.flʷe/
	Passé simple	Passé antérieur

# Moteur MediaWiki

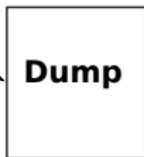
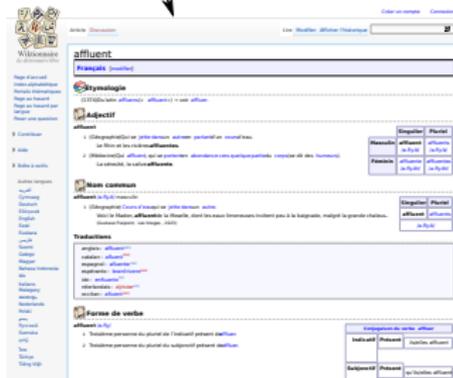


== {{langue|fr}} ==

{{-étym-}}  
 : {{date|1374}} Du {{-étym|la|fr|mot=affluens|sens=[[affluent]]}}.

{{-adj-|fr}}  
 {{fr-accord-cons|a.fly.ð|t}}  
 '''affluent'''  
 # {{géographie|fr}} Qui se [[jeter|jette]] [[dans]] un [[autre]] en [[parlant]] d'un [[cours]] d'eau.  
 #\* "Le Rhin et les rivières '''affluentes'''."  
 # {{médecine|fr}} Qui [[affluer|affluent]].  
 #\* "La sérosité, la salive '''affluente'''."  
 #\* "Voici le Madon, '''affluent''' de la Moselle

{{-nom-|fr}}  
 {{fr-régja.fly.ð}}  
 '''affluent''' {{pron|a.fly.ð|fr}} {{m}}  
 # {{géographie|fr}} [[cours d'eau|Cours d'eau]] qui se [[jeter|jette]] [[dans]] un [[autre]].  
 #\* "Voici le Madon, '''affluent''' de la Moselle



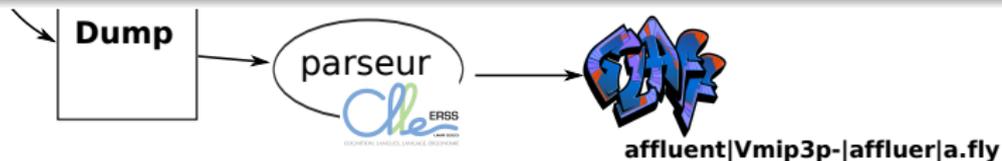
affluent|Vmip3p|affluer|a.fly

# Moteur MediaWiki

## «XML dumps»

microstructure pas encodée en XML, mais en wikicode !

```
<page>
  <title>affluent</title>
  <text>
    == {{langue|fr}} ==
    {{-adj-|fr}}
    {{fr-accord-cons|a.fly.|t}}
    '''affluent'''
    # {{géographie|fr}} Qui se [[jeter|jette]] [...]
  </text>
</page>
```



# Encodage : wikitexte

## MediaWiki

*"The parser serves as the de facto standard for the MediaWiki syntax, as no formal syntax has been defined. Due to this lack of a formal definition, it has been difficult [...] to port the parsing to another language."*

<http://en.wikipedia.org/wiki/Mediawiki>

- pas de vérification automatique lors d'une modification
- syntaxe évolue
- syntaxe différente d'une édition de langue à l'autre

## Extraire, trier, inférer et vérifier l'information

→ nécessité d'un parseur qui prenne en compte les erreurs de syntaxe, les incohérences, les informations lacunaires et la redondance

# Encodage : wikitexte



Page d'accueil  
Index alphabétique  
Portails thématiques  
Page au hasard  
Page au hasard par langue  
Poser une question

Contribuer

Aide

Boîte à outils

Autres langues

العربية  
Cymraeg  
Deutsch  
Ελληνικά  
English  
Eesti  
Euskara  
فارسی  
Suomi  
Galego  
Magyar  
Bahasa Indonesia  
Ido  
Italiano  
Malagasy  
მთარგობა

Article [Discussion](#)

Lire [Modifier](#) [Afficher l'historique](#)

[Créer un compte](#) [Connexion](#)

## affluent

**Français** [\[modifier\]](#)



### Étymologie

(1374)Du latin **affluens** (« **affluent** ») → voir **affluer**.



### Adjectif

#### affluent

- (Géographie) Qui se **jette dans** un**autre** en **parlant** d'un **cours** d'eau.

Le Rhin et les rivières **affluentes**.

- (Médecine)Qui **affluent**, qui se **portent** en **abondance** vers **quelque partie** du **corps** (se dit des **humeurs**).

La sérosité, la salive **affluente**.

	Singulier	Pluriel
Masculin	<b>affluent</b> <i>/a.fly.ô/</i>	<b>affluents</b> <i>/a.fly.ô/</i>
Féminin	<b>affluente</b> <i>/a.fly.ôt/</i>	<b>affluentes</b> <i>/a.fly.ôt/</i>



### Nom commun

**affluent** */a.fly.ô/* masculin

- (Géographie) **Cours d'eau** qui se **jette dans** un **autre**.

Voici le Madon, **affluent** de la Moselle, dont les eaux limonneuses invitent peu à la baignade, malgré la grande chaleur.  
(Gustave Fraipont; Les Vosges, 1923)

### Traductions

anglais : **affluent**<sup>(en)</sup>  
catalan : **afluent**<sup>(ca)</sup>  
espagnol : **afuente**<sup>(es)</sup>  
espéranto : **branĉrivero**<sup>(eo)</sup>  
ido : **enflunto**<sup>(io)</sup>  
néerlandais : **zijrivier**<sup>(nl)</sup>  
occitan : **afluent**<sup>(oc)</sup>

# Encodage : wikitexte



Page d'accueil  
Index alphabétique  
Portails thématiques  
Page au hasard  
Page au hasard par langue  
Poser une question

Contribuer

Aide

Boîte à outils

Autres langues

العربية  
Cymraeg  
Deutsch  
Ελληνικά  
English  
Eesti  
Euskara  
فارسی  
Suomi  
Galego  
Magyar  
Bahasa Indonesia  
Ido  
Italiano  
Malagasy  
მთარგობა

Article Discussion

Lire [Modifier](#) Afficher l'historique

## affluent

**Français** [modifier]



### Étymologie

(1374)Du latin **affluens** (« **affluant** ») → voir **affluer**.



### Adjectif

#### affluent

- (Géographie) Qui se **jette dans** un**autre** en **parlant** d'un **cours** d'eau.

Le Rhin et les rivières **affluentes**.

- (Médecine)Qui **affluent**, qui se **portent** en **abondance** vers **quelque** partie du **corps** (se dit des **humeurs**).

La sérosité, la salive **affluente**.

	Singulier	Pluriel
Masculin	<b>affluent</b> <i>/a.fly.ô/</i>	<b>affluents</b> <i>/a.fly.ô/</i>
Féminin	<b>affluente</b> <i>/a.fly.ôt/</i>	<b>affluentes</b> <i>/a.fly.ôt/</i>



### Nom commun

**affluent** */a.fly.ô/* masculin

- (Géographie) **Cours d'eau** qui se **jette dans** un **autre**.

Voici le Madon, **affluent** de la Moselle, dont les eaux limoneuses invitent peu à la baignade, malgré la grande chaleur.  
(Gustave Fraipont; Les Vosges, 1923)

### Traductions

anglais : **affluent**<sup>(en)</sup>  
catalan : **afluent**<sup>(ca)</sup>  
espagnol : **afuente**<sup>(es)</sup>  
espéranto : **branĉrivero**<sup>(eo)</sup>  
ido : **enflunto**<sup>(io)</sup>  
néerlandais : **zijrivier**<sup>(nl)</sup>  
occitan : **afluent**<sup>(oc)</sup>

[Créer un compte](#) [Connexion](#)



# Encodage : wikitexte

## Modification de « affluent »

Graphique Fichier Avancé Caractères spéciaux Aide

```
== {{langue|fr}} ==
{{-étym-}}
: {{date|1374}} Du {{étym|la|fr|mot=affluens|sens=[[affluent]]}}
{{cf|affluer|lang=fr}}.

{{-adj-|fr}}
{{fr-accord-cons|a.fly.ã|t}}
''affluent''

# {{géographie|fr}} Qui se [[jeter|jette]] [[dans]] un [[autre]] en
[[parlant]] d'un [[cours]] d'eau.
## ''La sérosité, la salive ''affluente''.''

{{-nom-|fr}}
{{fr-rég|a.fly.ã}}
''affluent'' {{pron|a.fly.ã|fr}} {{m}}

# {{géographie|fr}} [[cours d'eau|Cours d'eau]] qui se [[jeter|jette]]
[[dans]] un [[autre]].

{{-flex-verb-|fr}}
{{fr-verse-flexion|affluer|ind.p.3p=oui|sub.p.3p=oui}}
''affluent'' {{pron|a.fly|fr}}

# ''Troisième personne du pluriel de l'indicatif présent de'' [[affluer]].
# ''Troisième personne du pluriel du subjonctif présent de'' [[affluer]].

{{-pron-}}
```

# Encodage : wikitexte

## Modification de « affluent »

Graphique Fichier Avancé Caractères spéciaux Aide

```
== {{langue|fr}} ==
{{-étym-}}
: {{date|1374}} Du {{étyl|la|fr|mot=affluens|sens=[[affluent]]}}
{{cf|affluer|lang=fr}}.

{{-adj-|fr}}
{{fr-accord-cons|a.fly.ã|t}}
"affluent"

# {{géographie|fr}} Qui se [[jeter|jette]] [[dans]] un [[autre]] en
[[parlant]] d'un [[cours]] d'eau.
** "La sérosité, la salive "affluente"."
```

**{{fr-accord-cons|a.fly.ã|t}}** → **{{fr-accord-cons|a.fly.ã|t}}**

```


{{-nom-|fr}}
{{fr-rég|a.fly.ã}}
"affluent" {{pron|a.fly.ã|fr}} {{m}}

# {{géographie|fr}} [[cours d'eau|Cours d'eau]] qui se [[jeter|jette]]
[[dans]] un [[autre]].

{{-flex-verb-|fr}}
{{fr-verbe-flexion|affluer|ind.p.3p=oui|sub.p.3p=oui}}
"affluent" {{pron|a.fly|fr}}

# "Troisième personne du pluriel de l'indicatif présent de" [[affluer]].
# "Troisième personne du pluriel du subjonctif présent de" [[affluer]].

{{-pron-}}
```

# Encodage : wikitexte

## Modification de « affluent »

Graphique Fichier Avancé Caractères spéciaux Aide

```

== {{langue|fr}} ==
{{-étym-}}
: {{date|1374}} Du {{étyl|la|fr|mot=affluens|sens=[[affluent]]}}
{{cf|affluer|lang=fr}}.

{{-adj-|fr}}
{{fr-accord-cons|a.fly.ã|t}}
''affluent''

# {{géographie|fr}} Qui se [[jeter|jette]] [[dans]] un [[autre]] en
[[parlant]] d'un [[cours]] d'eau.
** ''La sérosité, la salive ''affluente''.''

{{-nom-|fr}}
{{fr-rég|a.fly.ã}}
''affluent'' {{pron|a.fly.ã|fr}} {{m}}

# {{géographie|fr}} [[cours d'eau|Cours d'eau]] qui se [[jeter|jette]]
[[dans]] un [[autre]].

{{-flex-verb-|fr}}
{{fr-verbe-flexion|affluer|ind.p.3p=oui|sub.p.3p=oui}}
''affluent'' {{pron|a.fly|fr}}

# ''Troisième personne du pluriel de l'indicatif présent de'' [[affluer]].
# ''Troisième personne du pluriel du subjonctif présent de'' [[affluer]].

{{-pron-}}
    
```

**{{fr-accord-cons|a.fly.ã|t}}**

	Singulier	Pluriel
Masculin	<b>affluent</b> /a.fly.ã/	<b>affluents</b> /a.fly.ã/
Féminin	<b>affluente</b> /a.fly.ãt/	<b>affluentes</b> /a.fly.ãt/

# Encodage : wikitexte

## Modification de « affluent »

Grat@lique    Fichier    ▶ Avancé    ▶ Caractères spéciaux    ▶ Aide

```

== {{langue|fr}} ==
{{-étym-}}
: {{date|1374}} Du {{étym|la|fr|mot=affluens|sens=[[affluent]]}}
{{cf|affluer|lang=fr}}.

{{-adj-|fr}}
{{fr-accord-cons|a.fly.ã|t}}
''affluent''

# {{géographie|fr}} Qui se [[jeter|jette]] [[dans]] un [[autre]] en
[[parlant]] d'un [[cours]] d'eau.
## ''La sérosité, la salive ''affluente''.''

{{-nom-|fr}}
{{fr-rég|a.fly.ã}}
''affluent'' {{pron|a.fly.ã|fr}} {{m}}

# {{géographie|fr}} [[cours d'eau|Cours d'eau]] qui se [[jeter|jette]]
[[dans]] un [[autre]].

{{-flex-verb-|fr}}
{{fr-verse-flexion|affluer|ind.p.3p=oui|sub.p.3p=oui}}
''affluent'' {{pron|a.fly|fr}}

# ''Troisième personne du pluriel de l'indicatif présent de'' [[affluer]].
# ''Troisième personne du pluriel du subjonctif présent de'' [[affluer]].

{{-pron-}}
    
```

**{{ fr-accord-cons|a.fly.ã|t }}**

	Singulier	Pluriel
Masculin	<b>affluent</b> /a.fly.ã/	<b>affluents</b> /a.fly.ã/
Féminin	<b>affluente</b> /a.fly.ãt/	<b>affluentes</b> /a.fly.ãt/

affluent|Afpms|affluent|a.fly.ã  
 affluents|Afpmp|affluent|a.fly.ã  
 affluente|Afpfs|affluent|a.fly.ãt  
 affluentes|Afpfp|affluent|a.fly.ãt

## Information lacunaire, redondance et cohérence

```
http://fr.wiktionary.org/wiki/logicielles  
{-flex-adj-|fr}  
'''logicielles''' {{pron|fr}} {{fplur}}
```

→ logicielles|Afpfp|logiciel (prononciation ?)

## Information lacunaire, redondance et cohérence

```
http://fr.wiktionary.org/wiki/logicielles  
{{-flex-adj-|fr}}  
'''logicielles''' {{pron|fr}} {{fplur}}
```

→ logicielles|Afpfp|logiciel (prononciation ?)

```
http://fr.wiktionary.org/wiki/logiciel  
{{-adj-|fr}}  
{{fr-accord-el|b.zi.sjɛl}}  
'''logiciel''' {{m}}
```

→ génération de :

- logiciel|Afpms|logiciel|b.zi.sjɛl
- logiciels|Afpmp|logiciel|b.zi.sjɛl
- logicielle|Afpfs|logiciel|b.zi.sjɛl
- logicielles|Afpfp|logiciel|b.zi.sjɛl

## Information lacunaire, redondance et cohérence

<http://fr.wiktionary.org/wiki/arrivages>

`{{-flex-nom-|fr}}`

`'''arrivages''' {{pron|a.ʁi.vaʒ|fr}}`

`# Pluriel d' '''[[arrivage]]'''.`

→ `arrivages|Nc ?p|arrivage|a.ʁi.vaʒ` (genre ?)

<http://fr.wiktionary.org/wiki/arrivage>

`{{-nom-|fr}}`

`'''arrivage''' {{pron|a.ʁi.vaʒ|fr}} {{m}}`

→ `arrivage|Ncms|arrivage|a.ʁi.vaʒ`

## Information lacunaire, redondance et cohérence

<http://fr.wiktionary.org/wiki/arrivages>

{{-flex-nom-|fr}}

'''arrivages''' {{pron|a.ʁi.vaʒ|fr}}

# Pluriel d' '''[[arrivage]]'''.

→ arrivages|Nc ?p|arrivage|a.ʁi.vaʒ (genre ?)

<http://fr.wiktionary.org/wiki/arrivage>

{{-nom-|fr}}

'''arrivage''' {{pron|a.ʁi.vaʒ|fr}} **{{m}}**

→ arrivage|Ncms|arrivage|a.ʁi.vaʒ

⇒ arrivages|Ncmp|arrivage|a.ʁi.vaʒ (inférence du genre)

## Information lacunaire, redondance et cohérence

### Verbes avec paradigmes incomplets

Exemple : *responsabiliser*

manquent les entrées pour les étiquettes : Vmip1s-, Vmip3s-, Vmsp1s-,  
Vmsp3s-, Vmmp2s-  
→ utiliser un fléchisseur ?

## Information lacunaire, redondance et cohérence

### Verbes avec paradigmes incomplets

Exemple : *responsabiliser*

manquent les entrées pour les étiquettes : Vmip1s-, Vmip3s-, Vmsp1s-,  
Vmsp3s-, Vmmp2s-

→ utiliser un fléchisseur ?

ou attendre le prochain dump ?

(omission due à une erreur dans le wikitexte, corrigée le 24 mai 2013)

# Information lacunaire, redondance et cohérence

## Verbes avec paradigmes incomplets

Exemple : *responsabiliser*

manquent les entrées pour les étiquettes : *Vmip1s-*, *Vmip3s-*, *Vmsp1s-*,  
*Vmsp3s-*, *Vmmp2s-*

→ utiliser un fléchisseur ?

ou attendre le prochain dump ?

(omission due à une erreur dans le wikitexte, corrigée le 24 mai 2013)

## Oui... mais les verbes défectifs ?

- *pleuvoir* : 9 formes manquantes ;
- *choir* : 10 formes manquantes ;
- *clore* : 12 formes manquantes ;
- *bruire* : 17 formes manquantes ;
- *frire* : 29 formes manquantes.

(sans oublier *neiger*, *reneiger*, *refrire*, *surfrire*, *pluvioter*, *bruinasser*, etc.)

# Information lacunaire, redondance et cohérence

contredisez

**Français** [modifier]



## Forme de verbe

**contredisez** /kɔ̃.tʁə.di.zɛ/

- 1 Deuxième personne du pluriel de l'indicatif présent de [contredire](#).
- 2 Deuxième personne du pluriel de l'impératif de [contredire](#).

Conjugaison en français/contredire

## Impératif

### Présent

<a href="#">contredis</a>	/kɔ̃.tʁə.di/
<a href="#">contredisons</a>	/kɔ̃.tʁə.di.zɔ̃/
<a href="#">contredites</a>	/kɔ̃.tʁə.dit/

# Information lacunaire, redondance et cohérence

contredisez

Français [modifier]



## Forme de verbe

contredisez /kɔ̃.trə.di.zɛ/

- 1 Deuxième personne du pluriel de l'indicatif présent de *contredire*.
- 2 Deuxième personne du pluriel de l'impératif de *contredire*.

## Conjugaison en français/contredire

### Impératif

#### Présent

contredis	/kɔ̃.trə.di/
contredisons	/kɔ̃.trə.di.zɔ̃/
contredites	/kɔ̃.trə.dit/

$\langle \textit{contredire}, V_{mmp2p-} \rangle = \left\{ \begin{array}{l} \textit{contredisez} | kɔ̃.trə.di.zɛ \\ \textit{contredites} | kɔ̃.trə.dit \end{array} \right. ?$

→ détection des couple  $\langle \textit{lemme}, \textit{étiquette} \rangle$  avec plusieurs formes ?

# Information lacunaire, redondance et cohérence

contredisez

Français [modifier]



Forme de verbe

contredisez /kõ.trə.di.ze/

- 1 Deuxième personne du pluriel de l'indicatif présent de *contredire*.
- 2 Deuxième personne du pluriel de l'impératif de *contredire*.

Conjugaison en français/contredire

Impératif

Présent

contredis	/kõ.trə.di/
contredisons	/kõ.trə.di.zõ/
contredites	/kõ.trə.dit/

$\langle \textit{contredire}, Vmmp2p- \rangle = \begin{cases} \textit{contredisez} | k\tilde{o}.tr\grave{e}.di.ze & ? \\ \textit{contredites} | k\tilde{o}.tr\grave{e}.dit \end{cases}$

→ détection des couple  $\langle \textit{lemme}, \textit{étiquette} \rangle$  avec plusieurs formes ? mais :

$\langle \textit{payer}, Vmip1s \rangle \rightarrow \textit{paie} | p\epsilon, \textit{paye} | p\epsilon j$

$\langle \textit{asseoir}, Vmip1s \rangle \rightarrow \textit{assois} | a.swa, \textit{assieds} | a.sje$

$\langle \textit{végéter}, Vmif1s \rangle \rightarrow \textit{végéterai} | ve.ʒ\epsilon.t\grave{e}.\textit{ve}, \textit{végèterai} | ve.ʒ\epsilon.t\grave{e}.\textit{ve}$

(orthographe avant/après réforme 1976)

## Quelques vérifications complémentaires...

Longueur des formes/longueur des lemmes, terminaisons verbales

Vmn----	((er) (ir) (ïr) (re))
Vmps-sm	[ûéiïtus]
Vmps-pm	[ûéiïtus]s
Vmps-sf	[ûéiïtus]e
Vmps-pf	[ûéiïtus]es
Vmpp---	ant
Vmip1s-	[esxi]
Vmip2s-	[sx]
Vmip3s-	[aedct]
Vmip1p-	((ons) (sommes))
Vmip2p-	((ez) (tes))
Vmip3p-	((ent) ([fsv]?ont))
Vmif1s-	rai
Vmif2s-	ras
Vmif3s-	ra

etc.

## Caractérisation...

### ... et pas évaluation

- comparaison possible avec d'autres ressources
- mais pas d'étalon  
(sinon, on ne construirait pas un autre lexique...)
- tâche : laquelle, comment ?  
étiquetage : corpus d'évaluation ? validation manuelle ?  
ne renseignera que sur l'impact du lexique sur l'étiquetage

### Comparaisons à venir

- couverture
- transcriptions phonémiques

# Taille

	Formes fléchies catégorisées			Lemmes catégorisés		
	Simple	Non simple	Total	Simple	Non simple	Total
<b>Lexique</b>	147 912	4 696	152 608	46 649	3 770	50 419
<b>BDLex</b>	431 992	4 360	436 352	47 314	1 792	49 106
<b>Leff</b>	466 668	3 829	470 497	54 214	2 303	56 517
<b>Morphalou</b>	524 179	49	524 228	65 170	7	65 177
<b>GLÀFF</b>	1 401 578	24 270	1 425 848	172 616	13 466	186 082

## Comparaisons à venir

- uniquement noms, verbes, adjectifs et adverbes (pas de mots grammaticaux, pas de locutions)
- uniquement sur les formes graphiques simples

## Couverture inter-lexiques

	Lexique	BDLex	Leff	Morphalou	GLÀFF
Lexique		26,0	25,2	22,5	9,0
BDLex	76,0		79,9	70,4	29,0
Leff	79,5	86,3		72,3	30,0
Morphalou	79,6	85,4	81,2		32,0
GLÀFF	<b>84,8</b>	<b>93,3</b>	<b>90,2</b>	<b>85,67</b>	

(en % de formes fléchies catégorisées)

## Couverture Lexiques/Corpus («taille utile»)

### Projection des 5 lexiques sur les corpus :

- Frantext 20e, 515 romans du XX<sup>e</sup>s. (30 millions de mots)
- LM10, archives 1991-2000 du quotidien *Le Monde* (200 millions de mots)
- Wikipédia2008 (260 millions de mots)
- FrWaC [Baroni et al., 2009] (1,6 milliard de mots)  
corpus de pages Web du domaine .fr

### Utilisation de TreeTagger pour :

- segmenter les corpus ;
- filtrer les catégories syntaxiques N, V, Adj, Adv.  
(pour les formes connues ET inconnues de TreeTagger)  
catégories ensuite ignorées : on s'intéresse aux formes graphiques

On évalue, pour différents seuils de fréquence, le % de formes couvertes par les lexiques

# Couverture Lexiques/Corpus («taille utile»)

Seuil : fréquence $\geq$		1	10	100	1000
Frantext	Nb formes	145 437	43 919	10 767	1 376
	Lexique	66,8	→ 96,9	→ 99,2	→ 99,3
	BDLex	70,9	95,7	99,1	99,2
	Lefff	71,9	96,2	99,1	98,9
	Morphalou	73,9	96,0	98,5	97,1
	GLÀFF	→ 76,9	96,7	98,8	98,8
LM10	Nb formes	300 606	77 936	29 388	7 838
	Lexique	29,6	76,3	93,8	98,6
	BDLex	37,8	80,9	95,5	98,7
	Lefff	39,6	83,2	96,0	→ 98,9
	Morphalou	39,1	80,3	93,3	97,5
	GLÀFF	→ 45,2	→ 86,2	→ 96,5	98,7
Wikipédia	Nb formes	953 920	136 531	35 621	7 956
	Lexique	9,1	43,0	78,6	95,7
	BDLex	12,3	48,0	79,4	95,3
	Lefff	12,9	49,7	80,6	95,7
	Morphalou	13,1	48,9	78,7	94,2
	GLÀFF	→ 16,4	→ 55,5	→ 83,2	→ 96,1
FrWaC	Nb formes	1 624 620	255 718	74 745	22 100
	Lexique	5,8	30,8	66,0	89,5
	BDLex	9,4	37,5	69,6	90,0
	Lefff	9,9	39,2	71,6	91,2
	Morphalou	10,1	38,7	69,4	88,5
	GLÀFF	→ 13,1	→ 45,4	→ 76,4	→ 92,8

## Vocabulaires spécifiques

	Taille vocab. spécifique	Nombre de formes attestées			
		Frantext	LM10	Wikipédia	FrWaC
<b>Lexique</b>	1 509	866	863	1 073	1 320
<b>BDLex</b>	3 981	86	521	1 004	1 496
<b>Lefff</b>	11 050	232	1 479	2 214	3 288
<b>Morphalou</b>	26 881	1 171	1 912	3 995	6 425
<b>GLÀFF</b>	665 290	2 811	13 525	29 230	47 549

Formes spécifiques à GLÀFF, attestées dans LM10 :  
*transversalité, attractivité, brevetabilité, diabolisation,*  
*employabilité, anticorruption, homophobie, institutionnellement,*  
*hébergeur, fatwa, indétrônable*

## Top-10 des différences des transcriptions phonémiques

Diff.	%	∑ %
<b>ɛ/e</b>	48,2	48,2
<b>ɔ/o</b>	32,2	80,4
<b>o/ɔ</b>	11,0	91,4
<b>y/ɥ</b>	1,8	93,2
<b>ə/ø</b>	1,4	94,6
<b>ə/œ</b>	1,4	96,0
<b>u/w</b>	0,8	96,9
<b>b/p</b>	0,7	97,6
<b>s/z</b>	0,5	98,1
<b>j</b>	0,3	98,4

BDLex/Lexique

Diff.	%	∑ %
<b>ɔ/o</b>	60,0	60,0
<b>ə</b>	14,2	74,2
<b>e/ɛ</b>	6,9	81,1
<b>ɛ/e</b>	5,0	86,1
<b>ɑ/a</b>	4,9	91,0
<b>s/z</b>	1,3	92,3
<b>ə/ø</b>	0,9	93,2
<b>œ/ø</b>	0,5	93,7
<b>i</b>	0,4	94,1
<b>o/ɔ</b>	0,4	94,5

GLÀFF/Lexique

Diff.	%	∑ %
<b>e/ɛ</b>	66,5	66,5
<b>ɔ/o</b>	10,6	77,1
<b>ə</b>	5,9	83,0
<b>o/ɔ</b>	4,4	87,4
<b>ɑ/a</b>	3,8	91,2
<b>ɥ/y</b>	1,6	92,8
<b>œ/ə</b>	1,1	93,9
<b>ø/ə</b>	0,9	94,8
<b>i</b>	0,8	95,6
<b>w/u</b>	0,8	96,4

GLÀFF/BDLex

voyelles moyennes et schwa → 90% des divergences

## Exemples de transcriptions divergentes

Diff.	Forme	BDLex	Lexique	GLÀFF	DPF [Martinet and Walter, 1973]
ɛ/e	été	/ɛ.te/	/e.te/	/e.te/	/ete/
s/z	stalinisme	/sta.li.nis,m/	/sta.li.nizm/	/sta.li.nism/	/stalinism/, /stalinizm/
b/p	obturer	/ɔb.ty.ʁe/	/ɔp.ty.ʁe/	/ɔp.ty.ʁe/	/ɔptyre/, /ɔbtyre/
o/ɔ	pomme	/pɔ,m/	/pɔm/	/pɔm/	/pɔm/
ə/ø/œ	heureux	/ə.ʁø/	/ø.ʁø/	/œ.ʁø/	/øʀø, œʀø/
y/ɥ	gradué	/gʁa.dy.e/	/gʁa.dɥe/	/gʁa.dɥe/	/gradɥe/, /gradɥe/, /gradye/
u/w	jouer inouï	/ʒu.e/ /i.nu.i/	/ʒwe/ /i.nwi/	/ʒwe/ /i.nwi/	/ʒwe/, /ʒue/ /inwi/, /inui/
a/ɑ	pâte	/pa,t/	/pat/	/pat/	/pat/, /pat/
i,j	riiez	/ʁi.i.je/	/ʁi.je/	/ʁij.je/	-
ə	contenu	/kɔ̃,tə.ny/	/kɔ̃.tə.ny/	/kɔ̃t.ny/	/kɔ̃t(ə)ny/

- opposition s/z : suffixe *-isme*
- emprunts :
  - *shaker* : /ʃɛi.kæʁ/, /ʃɛj.kœʁ/, /ʃɛ.kœʁ/
  - *chili* : /ʃi.li/, /tʃi.li/
  - *ginseng* : /ʒin.sɑ̃ŋ/, /ʒin.sɑ̃ŋ/, /ʒin.sɛŋ/

## Accord inter-lexiques

Ressources		Intersection	Transcriptions phonémiques		Syllabation
			Identiques	Comparables	Identiques
BDLex	Lexique	112 439	58,31	96,88	98,92
GLÀFF	Lexique	123 630	79,50	97,81	98,48
GLÀFF	BDLex	396 114	61,72	96,88	98,30

## Accord inter-lexiques

Ressources		Intersection	Transcriptions phonémiques		Syllabation
			Identiques	Comparables	Identiques
BDLex	Lexique	112 439	58,31	96,88	98,92
GLÀFF	Lexique	123 630	79,50	97,81	98,48
GLÀFF	BDLex	396 114	61,72	96,88	98,30

Ni Lexique, ni BDLex ne saurait constituer un étalon !

- BDLex : /ɛ.te/ (*été*), /po,m/ (*pomme*), /poʁt/ (*porte*), /oʁ/ (*or* et *hors*), etc.
- Lexique : /ʃa.sje/ (*châtié*), /kã.bvi.jo.le/ et /kã.bvi.o.le/ (resp. *cambriolé* et *cambriolés*)

## Accord inter-lexiques

Ressources		Intersection	Transcriptions phonémiques		Syllabation
			Identiques	Comparables	Identiques
BDLex	Lexique	112 439	58,31	96,88	98,92
GLÀFF	Lexique	123 630	79,50	97,81	98,48
GLÀFF	BDLex	396 114	61,72	96,88	98,30

Ni Lexique, ni BDLex ne saurait constituer un étalon !

- BDLex : /ɛ.te/ (*été*), /po,m/ (*pomme*), /poʁt/ (*porte*), /oʁ/ (*or* et *hors*), etc.
- Lexique : /ʃa.sje/ (*châtié*), /kã.bvi.jo.le/ et /kã.bvi.o.le/ (resp. *cambriolé* et *cambriolés*)

Instabilités, e.g. groupe consonantique /s/ + C  
(*ministère* /mi.nis.tɛʁ/ vs. *monistique* /mɔ̃.ni.stik/) → objet d'étude !

## v1.1.2

### Inclusion des mots grammaticaux

- re-parsing du Wiktionnaire
- révision manuelle

# Fréquences

## V 1.2

Inclusion des fréquences absolues et relatives :

- des formes fléchies catégorisées
- des lemmes catégorisées

dans les corpus :

- Frantext 20<sup>e</sup>
- LM10
- FrWaC
- +/- bientôt Wikipédia 2013

## Merci...

- étiquetage : Talismane [Urieli and Tanguy, 2013]
- lemmatisation des mots inconnus : Nabil

## À venir

### Un gros Lexique.org à tout faire

Ajout d'informations telles que :

- nb de voisins orthographiques
- nb de voisins phonémiques
- etc.

# Interrogation

## Comment chercher...

- 1 Les formes fléchies du verber '*taler*'?
- 2 Les adverbes qui ne se finissent pas par /mã/
- 3 Les formes nominales et adjectivales, au singulier, qui se terminent par un 's' graphique qui se prononce
- 4 Les adjectifs contenant la graphie *ill* qui ne se prononce pas [j]
- 5 Les noms homophones de '*beau*'

# Interrogation

## Comment chercher...

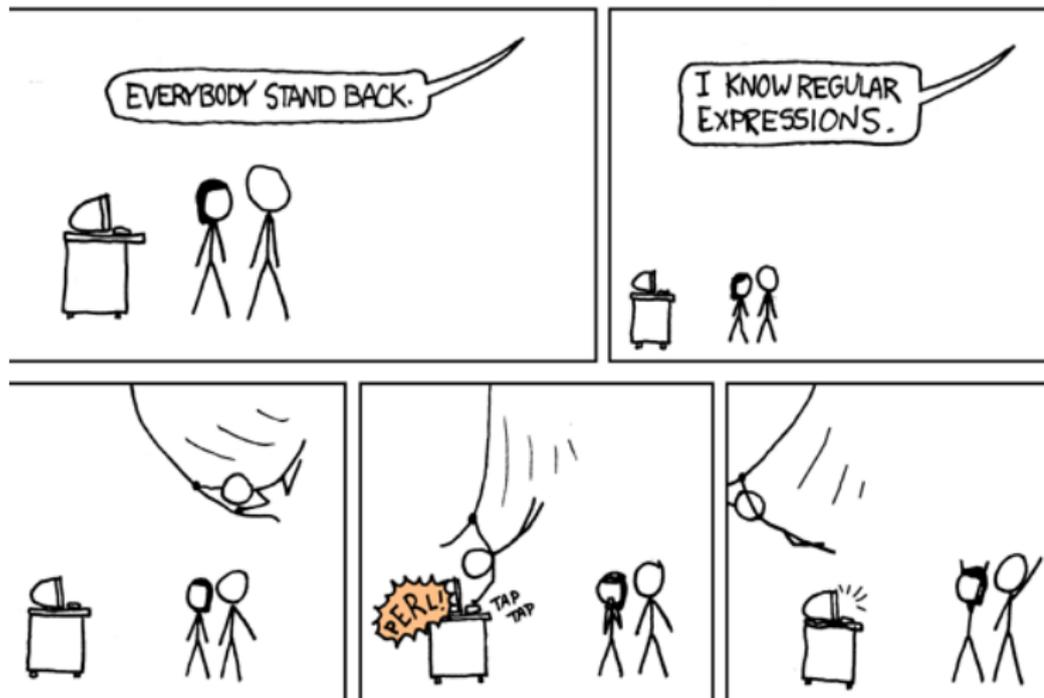
- 1 Les formes fléchies du verber '*taler*'?
- 2 Les adverbes qui ne se finissent pas par /mã/
- 3 Les formes nominales et adjectivales, au singulier, qui se terminent par un 's' graphique qui se prononce
- 4 Les adjectifs contenant la graphie *ill* qui ne se prononce pas [j]
- 5 Les noms homophones de '*beau*'

## Facile! The grep way

- 1 `pcregrep '\|taler\|' glaff1.2.txt | cut -d'|' -f1`
- 2 `pcregrep '\|Rgp\|' glaff-1.2.txt | pcregrep -v 'mA~\|'  
(| pcregrep -v '|')`
- 3 `pcregrep '^[\^]*s\| [AN][\^]*s\| [\^]*\| [\^]*s\|' glaff-1.2.txt`
- 4 `pcregrep '^[\^]*ill[\^]*\| ^A[\^]*\| [\^]*\| [\^]j*\|' glaff-1.2.txt`
- 5

```
pcregrep "^\^*\|N[\^]*\| [\^]*\| 'pcregrep '^beau\|' glaff-1.2.txt | tail -1 | cut -d'|' -f4'[;]" glaff-1.2.txt
```

# Ou bien... Le messianisme



<https://xkcd.com/208/>

Ou alors...



[ Search ] [ Preferences ] [ Help ] [ About ]

interface

Form	<input type="checkbox"/> [s\$]	IPA	<input type="checkbox"/> [s\$]
Lemma	<input type="checkbox"/>	SAMPA	<input type="checkbox"/>
POS	<input type="checkbox"/> [AN].*s\$		
<input type="button" value="Reset"/> <input type="button" value="Search"/>			

Showing results 1-100 of 379 >

Form	POS	Lemma	IPA
<a href="#">aérob<span>us</span></a>	Ncms	<a href="#">aérob<span>us</span></a>	æ.ɛʁ.bys
<a href="#">abies</a>	Ncms	<a href="#">abies</a>	a.bi.ɛs
<a href="#">abraxas</a>	Ncms	<a href="#">abraxas</a>	a.brak.sas
<a href="#">acinus</a>	Ncms	<a href="#">acinus</a>	a.si.nys
<a href="#">acropolis</a>	Ncfs	<a href="#">acropolis</a>	a.kɛʁ.pɔ.li
<a href="#">adénovirus</a>	Ncms	<a href="#">adénovirus</a>	a.de.no.vi.bys
<a href="#">édelweiss</a>	Ncms	<a href="#">édelweiss</a>	e.dɛl.vajs
<a href="#">adonis</a>	Ncms	<a href="#">adonis</a>	a.dɔ.nis
<a href="#">ægilops</a>	Ncms	<a href="#">ægilops</a>	e.ʒi.lɔps
<a href="#">éléphantiasis</a>	Ncfs	<a href="#">éléphantiasis</a>	e.le.fɑ.tja.zis
<a href="#">albatros</a>	Ncms	<a href="#">albatros</a>	al.ba.tʁɔs
<a href="#">alios</a>	Ncms	<a href="#">alios</a>	a.ljos
<a href="#">alkermès</a>	Ncms	<a href="#">alkermès</a>	al.kɛʁ.mɛs

Demander à GLÀFFi  
 (GLÀFF interface)

# Conclusion

## Atouts/craintes *a priori*

- + : taille, licence libre
- - : amateurisme, excentricité ?

## *a posteriori*

- couverture effectivement large (et utile !)
- globalement d'une bonne qualité  
... et de toute façon : autres ressources de moindre taille (et payantes) également imparfaites
- potentiel pour devenir une ressource de référence ?  
(encore un peu d'effort de nettoyage)
- dans tous les cas : au moins une ressource complémentaire à Leffh et Morphalou (transcriptions + couverture)

## Remarque

*«on s'en a pas besoin d'avoir un gros lexique,  
y a plein d'entrées qui servent à rien»*

## Remarque

*«on s'en a pas besoin d'avoir un gros lexique,  
y a plein d'entrées qui servent à rien»*

- enseignement de TALN 2013 : *«la taille, c'est important»*
- oui, mais ça peut introduire de l'ambiguïté

## Remarque

«on s'en a pas besoin d'avoir un gros lexique,  
y a plein d'entrées qui servent à rien»

- enseignement de TALN 2013 : «la taille, c'est important»
- oui, mais ça peut introduire de l'ambiguïté

→ `pcgrep -v '\|0\|0\|.*\|0\|0\|.*\|0\|0\|[0-9]+\|[.0-9]+$', psychoglaaff.txt`

1,4M entrées → 337 572 entrées!

## Remarque

«on s'en a pas besoin d'avoir un gros lexique,  
y a plein d'entrées qui servent à rien»

- enseignement de TALN 2013 : «la taille, c'est important»
- oui, mais ça peut introduire de l'ambiguïté

→ `pcgrep -v '\|0\|0\|. * \|0\|0\|. * \|0\|0\|[0-9]+\|[.0-9]+$', psychoglaaff.txt`

1,4M entrées → 337 572 entrées!

Morphalou : 524 725 → 282 379

Lefff : 472 119 → 281 613

## Remarque

«on s'en a pas besoin d'avoir un gros lexique,  
y a plein d'entrées qui servent à rien»

- enseignement de TALN 2013 : «la taille, c'est important»
- oui, mais ça peut introduire de l'ambiguïté

→ `pcgrep -v '\|0\|0\|. * \|0\|0\|. * \|0\|0\|[0-9]+\|[.0-9]+$', psychoglaaff.txt`

1,4M entrées → 337 572 entrées!

Morphalou : 524 725 → 282 379

Lefff : 472 119 → 281 613

- attention quand même... FT20e, LM10 et FrWaC ne sont que FT20e, LM10 et FrWaC!

# Perspectives

## Court terme

- inclusion des mots grammaticaux et locutions
- ajout d'autres types d'information :
  - fréquences en corpus
  - voisinages graphémiques et phonologiques
  - etc.
- détection d'erreurs et révision semi-manuelle
- interrogation en ligne

# Perspectives

## Court terme

- inclusion des mots grammaticaux ✓  
et locutions 
- ajout d'autres types d'information :
  - fréquences en corpus ✓
  - voisinages graphémiques et phonologiques ✓
  - etc.
- détection d'erreurs et révision semi-manuelle
- interrogation en ligne



# Perspectives

## Court terme

- inclusion des mots grammaticaux ✓  
et locutions 
- ajout d'autres types d'information :
  - fréquences en corpus ✓
  - voisinages graphémiques et phonologiques ✓
  - etc.
- détection d'erreurs et révision semi-manuelle
- interrogation en ligne
- WTFM



## Perspectives

### Moyen terme

- actualiser WiktionaryX et y intégrer GLÀFF
- évaluer l'apport de GLÀFF sur un analyseur syntaxique (e.g. Talismane) :
  - Lefff tout seul
  - GLÀFF tout seul
  - Lefff + GLÀFF
- exploitation de GLÀFF, dans les domaines suivants (au hasard) :
  - mesure de la similarité morphologique
  - phonotaxe distributionnelle
  - découverte automatique d'espaces thématiques utilisés pour la flexion

DL GLÀFF :

[redac.univ-tlse2.fr/lexiques/glaff.html](http://redac.univ-tlse2.fr/lexiques/glaff.html)

et bientôt accessible : GLÀFFi !



# References I



Anton Pérez, L., Gonçalo Oliveira, H., and Gomes, P. (2011).  
Extracting Lexical-Semantic Knowledge from the Portuguese Wiktionary.  
*In Proceedings of the 15th Portuguese Conference on Artificial Intelligence, EPIA 2011*, pages 703–717. APPIA.



Baroni, M., Bernardini, S., Ferraresi, A., and Zanchetta, E. (2009).  
The WaCky wide web : a collection of very large linguistically processed  
web-crawled corpora.  
*Language Resources and Evaluation*, 43(3) :209–226.



Boula De Mareuil, P., Yvon, F., D'Alessandro, C., Aubergé, V., Vaissière, J., and  
Amelot, A. (2000).  
A French Phonetic Lexicon with variants for Speech and Language Processing.  
*In Proc. of the 2nd Intl Conference on Language Resources and Evaluation  
(LREC)*, pages 273–276.



Clément, L., Lang, B., and Sagot, B. (2004).  
Morphology based automatic acquisition of large-coverage lexica.  
*In Proceedings of the Fourth International Conference on Language Resources  
and Evaluation (LREC 2004)*, pages 1841–1844, Lisboa, Portugal.

## References II



Content, A., Mousty, P., and Radeau, M. (1990).

BRULEX : Une base de données lexicales informatisée pour le français écrit et parlé.

*L'Année Psychologique*, 90 :551–566.



Encyclopaedia Britannica (2006).

Fatally Flawed : Refuting the Recent Study on Encyclopedic Accuracy by the Journal Nature.



Giles, J. (2005).

Internet Encyclopaedias go Head to Head.

*Nature*, 438 :900–901.



Gonçalo Oliveira, H. and Gomes, P. (2010).

Onto.PT : Automatic Construction of a Lexical Ontology for Portuguese.

In *Proceedings of 5th European Starting AI Researcher Symposium*, pages 199–211. IOS Press.

## References III



Gurevych, I., Ecker-Köhler, J., Hartmann, S., Matuschek, M., Meyer, C. M., and Wirth, C. (2012).

UBY - A Large-Scale Unified Lexical-Semantic Resource Based on LMF.  
*In Proceedings of the 13th Conference of the European Chapter of the Association for Computational Linguistics (EACL 2012)*, pages 580–590.



Krizhanovsky, A. A. (2010).

Transformation of wiktionary entry structure into tables and relations in a relational database schema.  
*CoRR*, abs/1011.1368.



Martinet, A. and Walter, H. (1973).

*Dictionnaire de la Prononciation Française dans son Usage Réel*.  
France Expansion.

## References IV



Meyer, C. M. and Gurevych, I. (2012).

OntoWiktionary Constructing an Ontology from the Collaborative Online Dictionary Wiktionary.

In Pazienza, M. T. and Stellato, A., editors, *Semi-Automatic Ontology Development : Processes and Resources*, chapter 6, pages 131–161. IGI Global, Hershey, PA, USA.



Navarro, E., Sajous, F., Gaume, B., Prévot, L., Hsieh, S., Kuo, I., Magistry, P., and Huang, C.-R. (2009).

Wiktionary and NLP : Improving synonymy networks.

In *Proceedings of the 2009 ACL-IJCNLP Workshop on The People's Web Meets NLP : Collaboratively Constructed Semantic Resources*, pages 19–27, Suntec, Singapore. Association for Computational Linguistics.



New, B. (2006).

Lexique 3 : Une nouvelle base de données lexicales.

In *Verbum ex machina. Actes de la 13<sup>e</sup> conférence sur le Traitement automatique des langues naturelles*, Louvain-la-Neuve.

## References V



Pérennou, G. and de Calmès, M. (1987).  
BDLEX lexical data and knowledge base of spoken and written French.  
In *Proceedings of the European Conference on Speech Technology, ECST 1987*,  
pages 1393–1396, Edinburgh, Scotland, UK.



Romary, L., Salmon-Alt, S., and Francopoulo, G. (2004).  
Standards going concrete : from LMF to Morphalou.  
In Zock, M. and Saint-Dizier, P., editors, *COLING 2004 Enhancing and using  
electronic dictionaries*, pages 22–28, Geneva. COLING.



Sajous, F., Navarro, E., and Gaume, B. (2011).  
Enrichissement de lexiques sémantiques approvisionnés par les foules : le système  
WISIGOTH appliqué à Wiktionary.  
*TAL*, 52(1) :11–35.

## References VI

-  Sajous, F., Navarro, E., Gaume, B., Prévot, L., and Chudy, Y. (2010). Semi-automatic Endogenous Enrichment of Collaboratively Constructed Lexical Resources : Piggybacking onto Wiktionary. In Loftsson, H., Rögnvaldsson, E., and Helgadóttir, S., editors, *Advances in Natural Language Processing*, volume 6233 of *LNCS*, pages 332–344. Springer Berlin / Heidelberg.
-  Sérasset, G. (2012). Dbnary : Wiktionary as a LMF based Multilingual RDF network. In *Proc. of the 8th International Conference on Language Resources and Evaluation (LREC)*, Istanbul.
-  Urieli, A. and Tanguy, L. (2013). L'apport du faisceau dans l'analyse syntaxique en dépendances par transitions : études de cas avec l'analyseur Talismane. In *Actes de la 20e conférence sur le Traitement Automatique des Langues Naturelles (TALN'2013)*, pages 188–201, Les Sables d'Olonne, France.

## References VII



Zesch, T. and Gurevych, I. (2010).

Wisdom of Crowds versus Wisdom of Linguists - Measuring the Semantic Relatedness of Words.

*Journal of Natural Language Engineering.*, 16(01) :25–59.



Zesch, T., Müller, C., and Gurevych, I. (2008).

Extracting Lexical Semantic Knowledge from Wikipedia and Wiktionary.

In *Proceedings of the Sixth International Conference on Language Resources and Evaluation (LREC 2008)*, Marrakech.