


# LA PLATE-FORME LINGUASTREAM

FRÉDÉRIK BILHAUT  
GREYC - CNRS - UNIVERSITÉ DE CAEN



# PROBLÉMATIQUE

---


- En TAL comme en linguistique, besoin de “projeter” automatiquement des **modèles** sur des **corpus**
  - A des fins de modélisation, observation, automatisation, etc.
- **Besoin d’outils** conceptuels et techniques pour :
  - Exprimer les modèles de façon purement formelle
  - Les appliquer automatiquement sur un corpus
  - Visualiser, mesurer, évaluer les résultats

# “NOUVEAUX” BESOINS

---

- **Résultats probants** sur certaines tâches de TAL, que l'on souhaite pouvoir exploiter pour d'autres tâches
  - Articulation des traitements (cf. journée ATALA)
- De plus en plus de **documents numériques structurés**
  - Prise en compte de la structure du document
  - Transparence relativement aux différents formats existants
  - Gestion de différentes langues, alphabets, ...
- Besoin de **capitaliser et partager les “ressources”**
  - Lexiques, règles, annotations, chaînes de traitements, ...

- Volonté de réduire la distance entre **description** linguistique et **implémentation** informatique
  - Objectif : exprimer la plus grande part possible d'un modèle linguistique avec formalisme exploitable automatiquement
  - Exprimer **uniquement** des règles et des contraintes linguistiques
  - Les règles ont un rôle à la fois **descriptif** et **prescriptif**
- **Perspectives** "nouvelles" en TAL
  - Traitements sémantiques, niveau discursif, ...
  - Besoin d'utiliser et produire des annotations riches, d'injecter des connaissances de domaine, ...



# LA PLATE-FORME LINGUASTREAM

Un atelier d'expérimentation pour le TAL et d'exploration linguistique de corpus, développée au GREYC en collaboration avec l'ERSS.

# CONTRIBUTEURS

---

- GREYC (Caen) : Antoine Widlöcher (plate-forme, DSDL), Gérard Bécher, Arnaud Soulet, Stéphane Ferrari, Djamel Benallen, Patrice Enjalbert (dir), ...
- ERSS (Toulouse) : Marion Laignelet, Mai Ho-Dac, Christophe Pimm, Gérard Tozere, Marianne Vergez, Marie-Paule Pery-Woodley (dir), ...
- LIUPPA (Pau) : Mauro Gaio (dir) & co.

# PLAN DE L'EXPOSÉ

---

- Description générale de la plate-forme
  - Principes “fondateurs”
  - Modèle d’annotation
  - Articulation de traitements
- Modèles d’analyse
  - La notion de “perspective d’analyse”
- Visualisation et évaluation des résultats
- Gestion des chaînes de traitement
- Exemple d’application : cadres de discours temporels

# PRINCIPES MÉTHODOLOGIQUES

---

- Elaboration de **chaînes de traitement**
  - Décomposition de traitements complexes en tâches élémentaires
  - Choix et enchaînement visuels des différents composants dédiés à ces tâches
- **Modularité et réutilisabilité** : isoler et capitaliser les traitements  $\pm$  génériques et réutilisables
  - Composants dont la tâche est fixée (mais paramétrable)
  - Composants dont le comportement est à définir
    - Ecriture de règles dans différents formalismes

- Privilégier les **formalismes déclaratifs**
  - Leur pouvoir descriptif permet de capitaliser des connaissances linguistiques opérationnalisables
- **Simplifier et automatiser** le processus de traitement
  - Sans coût de développement informatique
  - Pour se concentrer sur les modèles et traitements linguistiques
- Exploiter la **complémentarité des modèles d'analyse**
  - Différents modèles pour différents points de vue sur le texte
  - Permettre (et encourager) la cohabitation des formalismes
- Partage d'un **modèle d'annotation commun**

**LinguaStream IDE 2.0.0 alpha**

File View Plugins Help

Explorer Components Properties

Explorer

- /home/fbilhaut/src/linguastream
- /home/fbilhaut/src/geosem
- /home/fbilhaut/tmp
- /home/fbilhaut/src/docs/notes/resume
- /home/fbilhaut/src/linguastream/library
- /home/fbilhaut/src/geosem/analyzers/frames
- /home/fbilhaut/src/geosem/tsa/analysis
- /home/fbilhaut/src/linguastream/test
- /home/fbilhaut/tmp/demo
- /home/fbilhaut/src/linguastream/test/chart
- /home/fbilhaut/src/linguastream/demo/tutorial
  - corpus
  - sample1
  - sample2
  - sample3
    - sample3.ls
    - temporal.pro
  - sample4
    - sample4.cd
    - sample4.ls
    - sample4b.cd
    - temporal.pro
  - sample5
    - sample5.ls
    - RE sentences.re
    - temporal.pro
  - sample6
    - cuePhrases.lsl
    - sample6.ls
    - RE sentences.re
    - temporal.pro
  - sample7
    - cuePhrases.lsl
    - sample7.ls
    - RE sample7.re
    - RE sentences.re
    - temporal.pro
  - sample8
  - sample9
  - view.lsv

Stream Editor - sample3.ls

```

graph LR
    Input[Input] --> Tokenizer[Tokenizer]
    Tokenizer --> TreeTagger[Tree Tagger]
    TreeTagger --> DCGmarker[DCG marker]
    DCGmarker --> WebViewer[Web Viewer]
    WebViewer --> Output[Output]
    View[View] --> WebViewer
    
```

```

graph LR
    Input[Input] --> Tokenizer[Tokenizer]
    Tokenizer --> TreeTagger[Tree Tagger]
    TreeTagger --> RegexpMarker1[Regexp Marker]
    RegexpMarker1 --> LexiconMarker[Lexicon Marker]
    CUEPHRASES[ CUEPHRASES.LSV ] --> LexiconMarker
    LexiconMarker --> DCGmarker[DCG marker]
    DCGmarker --> RegexpMarker2[Regexp Marker]
    RegexpMarker2 --> WebViewer[Web Viewer]
    WebViewer --> Output[Output]
    View[View] --> WebViewer
    
```

Plugin 'SWI Prolog' v. 2.0.0 successfully loaded

Plugin 'Tree Tagger' v. 2.0.0 successfully loaded

Plugin 'GeoSem' v. 0.6.1 successfully loaded

Plugin 'Lexicon Marker' v. 2.0.0 successfully loaded

Plugin 'RegExp' v. 2.0.0 successfully loaded

Plugin 'Markup' v. 2.0.0 successfully loaded

Plugin 'Python Marker' v. 2.0.0 successfully loaded

Plugin 'Token Marker' v. 2.0.0 successfully loaded

Plugin 'Rule Marker' v. 1.0.0 successfully loaded

Plugin 'Markup Charter' v. 2.0.0 successfully loaded

File /home/fbilhaut/src/linguastream/demo/tutorial/sample3/sample3.ls saved.

File /home/fbilhaut/src/linguastream/demo/tutorial/sample3/sample3.ls saved.

File /home/fbilhaut/src/linguastream/demo/tutorial/sample3/sample3.ls saved.

LinguaStream IDE 2.0.0 alpha

File View Plugins Help

Explorer Components Properties

- /home/fbilhaut/src/docs/notes/resume
- /home/fbilhaut/src/linguastream/library
- /home/fbilhaut/src/geosem/analyzers/frames
- /home/fbilhaut/src/geosem/tsa/analysis
- /home/fbilhaut/src/linguastream/test
- /home/fbilhaut/tmp/demo
- /home/fbilhaut/src/linguastream/test/chart
- /home/fbilhaut/src/linguastream/demo/tutor
- corpus
  - sample1
    - sample1.is
    - sample1.pro
  - sample2
    - sample2.is
    - sample2.pro
  - sample3
    - sample3.is
    - temporal.pro
  - sample4
    - sample4.cd
    - sample4.is
    - sample4b.cd
    - temporal.pro
  - sample5
    - sample5.is
    - RE sentences.re
    - temporal.pro
  - sample6
    - cuePhrases.lsl
    - sample6.is
    - RE sentences.re
    - temporal.pro
  - sample7
    - cuePhrases.lsl
    - sample7.is
    - RE sample7.re
    - RE sentences.re
    - temporal.pro
  - sample8
    - sample8.is
    - sample8.xq
    - temporal.pro
  - sample9
    - cuePhrases.lsl
    - sample9.is
    - RE sample9.re
    - RE sample9b.re
    - RE sentences.re
    - temporal.pro
    - view.lsv

Stream Editor - sample2.lsl

Lexicon Editor - cuePhrases.lsl

Words	Forms
ainsi	ainsi
bien-que	en-conséquence
cependant	donc
or	aussi

4 entries

Type	Mode	Colors
sample	highlight	Foreground
temporal	highlight	Foreground
sentence	braces	Foreground
cuePhrase	highlight	Foreground
intro	inlineFrame	Foreground
frame	frame	Foreground

Text Editor

```

root(Sem) --
root(Sem) --

simpleDate(t:
@tag:pre
Year@tag

period(type:
$'de', F
$'à', To

```

Regular Expression Editor - sentences.re

Regular Expression: "phrase"

Rule: "sentence"

- Operator: union
  - (x) Feature set: (type:paragraph, anchor:start)
  - f(x) Sub-Rule call: ponct
- Expression
  - Mark: sentence
  - Expression
    - Operator: positiveClosure
    - Operator: union
- Rule: "ponct" (inactive)
  - Operator: union

`(!(type:paragraph))+ (({anchor:end, type:paragraph} | ponct()))`

Running component: Tree Tagger (00:00:00)

Component Tree Tagger: 3522 token(s) tagged

Running component: SAMPLE4.CD (00:00:04)

Running component: SAMPLE4B.CD (00:00:04)

Running component: DCG marker (00:00:04)

Component DCG marker: Processed 35 segment(s), 3522 token(s) and 74 anchor(s)

Component DCG marker: 45 match(es)

Running component: Dispatcher (00:00:07)


Running component: Dispatcher (00:00:07)

Running component: Chart Maker (00:00:07)

Running component: Chart Maker (00:00:11)

Stream terminated successfully in 13 secs

Stream terminated successfully in 13 secs



LinguaStream IDE 2.0.0 alpha

File View Plugins Help

Properties Explorer Components

Colors

backgroundColor [red]

color [black]

General

mode Highlight (blocks only)

type sn

Quick View Editor - view.lsv

Type	Mode	Colors
sn	highlight	Foreground
phrase	braces	Foreground
introducer	inlineFrame	Foreground
mse	highlight	Foreground
introducer	inlineFrame	Foreground
ttsa	frame	Foreground
ttsa		
cuePhrase		
temporal		
ttsa		
coord		

Stream

Running console

- Running console
- Running console
- Running console
- Running console
- Running console
- Running console
- Running console
- Stream terminated

Standard Expert

Stream terminated successfully in 13 secs

mozilla:toggleSemantics('temporal\_10')

mozilla Firefox

File Edit View Go Bookmarks Tools Help

file:///home/fbilhaut/

aux concours.] [La tendance [a] ete inversee au debut des annees 1980, entrainant la diminution du

temporal:10 [X] du recrutement [expliquent] la surrepresentation actuelle

type: d

periode: debut: annees: type: debut

annee: 1960

1980<intro:1], l'offre de recrutement (bien qu'en forte

andidats se presentant aux concours, ne [sont] plus à la

fait, la proportion de maîtres auxiliaires, personnels non

ans les lycées professionnels, [qui [attirent] le moins],

e:)] [[puis] dans les lycées, alors [que la stagnation des

présence dans les collèges].] [Ce [sont] actuellement les

lycées [qui [absorbent] l'essentiel de l'augmentation des effectifs enseignants].]

[(\*)<intro:2>En trente ans<intro:2], le corps enseignant du second degré s'[est] féminisé,

particulièrement dans les collèges et dans les grades les moins élevés.] [Le taux de féminité s'[est]

stabilisé autour de 55% depuis une dizaine d'années: 42% en lycée professionnel, 50% en lycée,


61% en collège.]

[(\*)<intro:3>Depuis le début des années 1960<intro:3], la composition du corps enseignant [a] été

diversifiée: les disciplines, catégories indiciaires et grades [ont] été multipliés, avec l'apparition de

CAPES et de CAPET artistiques et techniques et la création de certains corps enseignants (PEGC et

plus récemment, PLP1 et PLP2).] [Même si la tendance actuelle [est] à la simplification, les grades



## Explorer

- ▶ LinguaStream/library
- ▶ LinguaStream/demo
- ▶ Home/src/geosem
- ▶ Home/Documents/test/LS
- ▶ Home/Desktop
- ▶ Home/src/linguastream/test
- ▶ Home/Temp/essai
- ▶ Home/Documents/workspace
- ▼ Home/Documents/workspace/ch
  - chinois.rt
  - input.xhtml
  - test.ls
  - test.lsv
  - test.pro
  - RE test.re
  - test.xml

Explorer

Components

Properties

## test.pro (Text Editor)

```

%% Racine de la grammaire

:- encoding('utf8').

root(year:Y) --> ls_token(Y, _, numeral), $('年').
root(from:F..to:T) --> ls_token(F, _, numeral), $('-', ls_token(T, _, numeral), $('年').
root(month:M..day:D) --> ls_token(M, _, numeral), $('月', ls_token(D, _, numeral), $('日').
root(month:M) --> ls_token(M, _, numeral), $('月').

```

```

i Running component: Web Viewer (00:00:07)
i Component Web Viewer: Running component DOC
i Component Web Viewer: Running component SEM
i Component Web Viewer: Running component LSV
i Component Web Viewer: Running component Semantics Integrator
i Component Web Viewer: Running component QuickView Integrator
i Component Web Viewer: Running component Transform Semantics
i Component Web Viewer: Running component DOC
i Running component: Mozilla (00:00:12)
i Stream terminated successfully in 12 secs

```

Stream terminated successfully in 12 secs

---:---:---

**1981年**

**6月**，中共十一届六中全会通过邓小平主持起草的《关于建国以来党的若干历史问题的决议》。决议彻底否定了“文化大革命”，全面评价了毛泽东的历史地位，提出必须坚持和发展毛泽东思想。会议选举邓小平为中央军委主席。

**7月2日**，在中共省、自治区、直辖市委员会书记座谈会上讲话提出，老干部第一位的任务是选拔中青年干部。

**8月**，视察新疆。

**9月19日**，在华北某地检阅军事演习部队，讲话时提出，要建设强大的现代化正规化的革命军队。

**1982年**

**4月10日**，在中共中央政治局会议上讲话，提出坚持社会主义道路的四项必要保证：体制改革；建设社会主义精神文明；打击经济犯罪活动；整顿党的作风和党的组织。强调一手坚持对外开放和对内搞活经济的政策，一手坚决打击经济犯罪活

**5月**，在利比里亚国家元首多伊。谈话时说，我们一方面实行开放政策，一方面仍坚持自力更生为主的方针。

**8月21日**，会见联合国秘书长德奎利亚尔。谈话时重申，中国是第三世界的一员。反对霸权主义，维护世界和平是中国对外政策的纲领。

**9月1日**，在中国共产党第十二次全国代表大会上致开幕词，提出建设有中国特色社会主义的主题。

**9月12日至13日**，中共十二届一中全会召开，选举邓小平为中央政治局常务委员，决定他任中央军委主席。

**9月13日**，在中共中央顾问委员会第一次全体会议上，当选为中央顾问委员会主任。

**9月18日**，陪同朝鲜劳动党中央委员会总书记金日成去四川访问。

**9月24日**，会见英国首相撒切尔夫人，阐述中国对香港问题的基本立场，为以后中英两国政府的谈判定了基调。


**1983年**

**1月12日**，同国家计委、国家经委和农业部门负责人谈话时指出，各项工作都要有助于建设有中国特色社会主义，并强调农业是根本，不忘掉。

# APPLICATIONS

---

- La plate-forme est avant tout un “laboratoire” pour le TAL, et un outil d’aide à l’observation linguistique
- Elle peut également être utilisée dans un cadre applicatif (Ex : prototype moteur de recherche GeoSem)



**MODÈLE  
D'ANNOTATION**

# MODÈLE D'ANNOTATION

accuser . Les croissances ont été générales dans la France du Nord et du Nord-Ouest , ainsi que dans le quart sud-est du pays , Rhône-Alpes et régions méditerranéennes ; dans une quinzaine de départements , la grande banlieue parisienne , la Bretagne orientale et ses marges , la région Rhône-Alpes , etc. , l'augmentation de la population scolaire en vingt ans a été de plus du quart des effectifs de 1965 . En revanche , les chiffres sont stables , ou même en diminution dans la France des petits effectifs scolaires . Sont également en baisse les départements lorrains . Ces évolutions reflètent certes très directement celles de l'ensemble de la population au cours de la même période , mais en les accentuant . L'augmentation des effectifs scolaires a été sensiblement plus marquée que celle de la

*graphie : 'effectifs'*  
*tag : nom*  
*lemme : 'effectif'*

*enum :*  
*zone :* *egn :* *type : banlieue*  
*clef : Paris*  
*zone :* *egn :* *type : région*  
*clef : Bretagne*  
*loc : interne*  
*geo : oriental*


# RELATIONS

---

accuser . Les croissances ont été générales dans la France du Nord et du Nord-Ouest , ainsi que dans le quart sud-est du pays , Rhône-Alpes et régions méditerranéennes ; dans une quinzaine de départements , la grande banlieue parisienne , la Bretagne orientale et ses marges , la région Rhône-Alpes , etc. , l'augmentation de la population scolaire en vingt ans a été de plus du quart des effectifs de 1965 . En revanche , les chiffres sont stables , ou même en diminution dans la France des petits effectifs scolaires . Sont également en baisse les départements lorrains . Ces évolutions reflètent certes très directement celles de l'ensemble de la population au cours de la même période , mais en les accentuant . L'augmentation des effectifs scolaires a été sensiblement plus marquée que celle de la



[ type : 'sujet ' ]



## EXEMPLE DE DOCUMENT ANNOTÉ

“Le dormeur du val” : annotation à partir  
d’un lexique sémantique.

de postes mis aux concours.] [La tendance [a] été inversée au début des années 1980, entraînant la diminution du taux d'auxiliaires.] [Ces phases successives du recrutement [expliquent] la surreprésentation actuelle des 40-50 ans.]

[+] [intro:36] Depuis le milieu des années 1980 [intro:36], l'offre de recrutement (bien qu'en forte augmentation), ainsi [que le nombre de candidats se présentant aux concours, ne [sont] plus à la hauteur des besoins et des objectifs].] [De ce fait, la proportion de maîtres auxiliaires, personnels non titulaires, [augmente] à nouveau.] [C'[est] dans les lycées professionnels, [qui [attirent] le moins], [que leur proportion [est] la plus importante];] [[puis] dans les lycées, alors [que la stagnation des effectifs scolaires [explique] leur plus faible présence dans les collèges].] [Ce [sont] actuellement les lycées [qui [absorbent] l'essentiel de l'augmentation des effectifs enseignants].]

[+] [intro:37] En trente ans [intro:37], le corps enseignant du second degré s'[est] féminisé, particulièrement dans les collèges et dans les grades les moins élevés.] [Le taux de féminité s'[est] stabilisé autour de 55% depuis une dizaine d'années: 42% en lycée professionnel, 50% en lycée, 61% en collège.]

[+] [intro:38] Depuis le début des années 1960 [intro:38], la composition du corps enseignant [a] été diversifiée: les disciplines, multipliés, avec l'apparition de CAPES et de CAPET artistiques et techniques et la C et plus récemment, PLP1 et PLP2).] [Même si la tendance actuelle [est] à la (près d'une quinzaine) de même que les statuts (titulaire, titulaire académique, [Le corps professoral demeure hétérogène.]

ans le public] </>

rés nationalement: les mutations [ont] donc pour cadre le territoire français dans son ensemble.] [LES CERTIFIES et agrégés [sont] recrutés sur concours - avec une licence ou une maîtrise - alors [que les adjoints d'enseignement [sont] d'anciens auxiliaires titularisés].] [Les professeurs de type lycée [représentent] plus de la moitié des




Done

## EXEMPLE DE DOCUMENT ANNOTÉ

“Atlas scolaire de la maternelle au lycée” : annotation des cadres de discours temporels.

# ARTICULATION DES TRAITEMENTS

# CHAÎNES DE TRAITEMENT



# PRINCIPES D'ARTICULATION

---

- Tous les composants partagent la même représentation...
  - ... des documents annotés :
    - Le texte est balisé par différents marquages
    - Un marquage contient un nombre arbitraire de marques
    - Chaque marquage est caractérisé par un type
    - Chaque marque identifie un fragment textuel de taille arbitraire
    - Les chevauchements sont autorisés
  - ... des annotations elles-mêmes :
    - À chaque marque peut être associée une structure de traits

- Tous les modèles d'analyse les exploitent uniformément
- Chaque composant peut exploiter les marquages antérieurs
  - Abstraction progressive des formes de surface
  - Par expression de contraintes :
    - Sur la forme des unités (marques) préalablement balisées
    - Sur les structures de traits qui leur sont associées (par unification)

# TECHNOLOGIES XML

---

- Utilisation systématique du format XML
  - Pour les documents et les annotations
  - Pour tous les autres objets manipulés (chaînes de traitement, règles, etc.)
- Tout document XML peut être traité par la plate-forme
  - Un espace de nom spécifique est utilisé
  - Utilisation d'outils standards pour la visualisation, l'annotation manuelle, etc.

- Mode d'annotation mixte :
  - Le balisage est inséré dans le document (*inline*)
    - Les espaces de noms garantissent la transparence pour les autres applications
    - Si nécessaire, les chevauchements sont gérés à l'aide de jalons (*milestones*)
  - Les annotations sont stockées de façon externe (*stand-off*)
    - Représentation XML des structures de traits
    - Possibilité d'export RDF
  - Tout l'outillage XML "standard" est disponible sous forme de composants XSLT, XQuery, XSL:FO, etc...

# MODÈLES D'ANALYSE

# DÉFINITION

---

- Modèle d'analyse :
  - Formalisme ( $\pm$  générique) de représentation de règles
  - Algorithme d'application des règles aux textes
- Des notions sur l'aspect algorithmique sont facultatives, mais utiles...

# GRAMMAIRES D'UNIFICATION (EDCG)

---

- Grammaires à Clauses Définies Étendues (EDCG)
  - Grammaires locales
  - Chaque non-terminal définit un patron tout en lui associant une représentation symbolique
- Expression de contraintes par unification :
  - Spécification de contraintes sur les unités du texte
  - Construction de représentations symboliques
- Basées sur Prolog
  - Les fonctionnalités logiques du langage sont disponibles
    - Ex : calculs sémantiques complexes

```
date (type:date..mois:M) --> @tag:pre, mois(M).
date (type:date..année:A) --> ...
...
mois (1) --> $ 'janvier' .
mois (2) --> $ 'février' .
...
```

# MACRO-EXPRESSIONS RÉGULIÈRES (MRE)

---

- Automates finis déterministes
  - Les patrons à reconnaître sont spécifiés à l'aide d'un langage analogue aux expressions régulières
  - Spécification de contraintes sur les marquages antérieurs par le biais de structures de traits
  - Spécification libre de la ou des zones à marquer
  - Plus performant (temps linéaire en pratique) mais moins "expressis" que les grammaires EDCG

MRE

```
{type:phrase, anchor:start}
<introduceur>
  {type:connecteur}? {tag:pre} {type:temporel} /as $t
</introduceur> /sem {axe:temps, valeur:$t}
" /"
```

# DISCOURSE STRUCTURE

# DESCRIPTION LANGUAGE

---

- Conçu par Antoine Widlöcher (GREYC)
- Formalisme dédié à l'analyse du discours
  - Niveau de granularité potentiellement élevé
  - Variété combinatoire importante
  - Descriptif : représentation formelle d'un phénomène discursif
  - Prescriptif : paramétrer un analyseur, interroger le texte
- Définition de « grammaires de discours »
  - Permettant l'expression de contraintes :
    - non séquentielles (la notion d'ordre ne prédomine pas)
    - non linéaires (acceptant des discontinuités)

- Exemples de contraintes DSDL :
  - le segment recherché contient plus de  $X\%$  d'expressions de type Y
  - il doit être homogène selon un critère donné
  - il doit commencer / terminer par un élément de type X
  - il doit être le plus long / court possible
  - il doit contenir X éléments en relation de type Y avec un autre segment de type Z
  - ...

DSDL

```

Rule {type:"cadre"}
{
  start({type: "introducteur"})
  end({type : "phrase"})
  homogeneity(comparator:portée)
  size(mode:"longest")
  not presence(pattern : {type : "introducteur"}, amount : 2)
  size(mode : #LONGEST)
}

Comparator portée ({type: "verbe"} as $v1, {type: "verbe"} as $v2)
{
  $v1/temps = $v2/temps
}

Comparator portée ({type: "intro"} as $i, {type: "tempo"} as $t)
{
  (($i/debut >= $t/debut) and ($i/debut <= $t/fin))
  or
  (($i/fin >= $t/debut) and ($i/fin <= $t/fin))
}

```

# EXPRESSIONS RÉGULIÈRES

## “CLASSIQUES”

---

- Patrons au niveau des caractères
  - À partir d'expressions régulières (type Perl)
- Deux modes d'utilisation :
  - Marquage d'unités élémentaires (ex : mots)
    - Permet de remplacer le tokeniseur “par défaut”
  - Attribution de traits sémantiques à des marquages antérieurs, selon des critères purement formels

test.rt (Regex Tokenizer Editor)

Pattern	Is Blank	Feature Set	Specific Markup Type
\s+	true	{}	
(\+ -)?\d+(\.\d+)*	false	{}	
\d[^\s\p{Punct}]*	false	{}	
\.\.\.	false	{punct:yes}	
--	false	{punct:yes}	
\p{Punct}	false	{punct:yes}	
\w+://[^\s]+	false	{}	
etc\.	false	{}	
[^\p{Punct}\s]+'@'?	false	{}	

# EXPLOITATION DE LA STRUCTURE XML

---

- Les analyseurs ne “voient” que les annotations LS
  - Mais il est possible d’écrire des règles permettant d’ajouter ces marques à partir de règles portant sur la structure XML
  - Ex. en XHTML : p/li → paragraphe, h1 → titre [niveau : 1]
- Le passage de balises XML à des annotations correspond à un mode d’analyse parmi d’autres
- Il permet de s’abstraire du schéma XML effectivement utilisé (la suite du traitement ne prendra en compte que les annotations LS)


XML Marker Editor window showing a table of XML markup information for the file xhtml.xml.

XML Namespace URI	XML Tag Name	Markup Type	Markup Layer	Feature Set
http://www.w3.org/...	p	paragraph	0	{}
http://www.w3.org/...	li	paragraph	0	{}
http://www.w3.org/...	h1	title	0	{level:1}
http://www.w3.org/...	h2	title	0	{level:2}
http://www.w3.org/...	h3	title	0	{level:3}

# AUTRES MODÈLES D'ANALYSE

---

- Projection de lexiques sémantiques
  - Interface graphique d'édition de lexiques
  - Composant de marquage dans les documents
  - En développement : schémas et ontologies
- Analyseur de type « système expert »
  - Pseudo-grammaires formées de règles de déduction
  - Basé sur un moteur d'inférence type CLIPS



- Langages de scripts
  - Plusieurs langages sont disponibles pour créer des analyseurs répondant à un tâche très spécifique
  - Python, BeanShell, Groovy
- Développement de composants tiers
  - La plate-forme offre une API permettant de développer ses propres composants.
  - Un système de plugins permet de les distribuer séparément et de les charger dynamiquement

**PERSPECTIVES  
D'ANALYSE**

# LA NOTION DE “PERSPECTIVE D’ANALYSE”


---

- Selon les modèles d’analyse différents types de “grain” doivent être définis :
  - Unité minimale (jeton ou *token*)
  - Espace de recherche (modèles non déterministes)
  - Unités à ignorer, etc.
- La définition de ces grains forme une perspective (ou point de vue) particulière sur un document
- La plate-forme permet de spécifier, **pour chaque module d’analyse**, la perspective à adopter

# DÉFINITION DU GRAIN MINIMAL D'ANALYSE

---

- Unité minimale sur laquelle les patrons agissent (token)
  - Typiquement : le mot
- Chaque composant définit localement le(s) type(s) de marquages qui doivent être considérés comme tokens
  - Chaque occurrence de l'un des types spécifiés forme un token
  - Les autres marquages seront vus comme de simples « jalons »



# AUTRES COMPOSANTES D'UNE PERSPECTIVE

---

- Domaine d'analyse
  - La plupart des modèles permettent de spécifier un espace de recherche auquel ils doivent se limiter
    - Obligatoire pour les modèles non déterministes
  - Donné par un ou plusieurs types de marquage
- Filtrage des marquages
  - Chaque composant peut choisir de ne voir qu'une partie des marquages présents dans le document

# EXEMPLE

---

- Extraction d'information dans des constats d'accidents
  - Identification des événements de type "collision entre véhicules"
  - Analyses préliminaires : mots et phrases

- **Phase 1 : identification des unités pertinentes**
  - Elle procède au marquage :
    - des entités « véhicules » (grammaire EDCG)
    - des verbes de collision (lexique sémantique LSL)
  - Sa perspective est définie par :
    - *token* = mot
    - *filtre* = aucun
    - *espace de recherche* : quelconque

- **Phase 2 : identification des relations de collision**
  - Elle procède au marquage :
    - des séquences entité<sub>1</sub> – verbe collision – entité<sub>2</sub> (expression MRE)
  - Sa perspective est définie par :
    - *token* = véhicule, verbe-collision
    - *filtre* = ne conserver que phrase, véhicule, et verbe-collision
    - *espace de recherche* : phrase

MRE

```

<evnt>
  {type:véhicule} /as $p1
  {type:prédictat-collision}
  {type:véhicule} /as $p2
</evnt> /sem {protag1:$p1, protag2:$p2}

```

Mozilla Firefox  
 file:///home/fbilhaut/maif.xml

[§1] [Texte A1.] [Me rendant à Beaumont sur Oise depuis Cergy, je me suis retrouvée à un carrefour juste après la sortie Beaumont sur Oise.] [J'étais à un stop avec 2 voitures devant moi tournant à droite vers Mours.] [Alors que la première voiture passait ce stop je fis mon contrôle à gauche et je démarrais mais [event~je percutais la deuxième voiture~event] qui n'avait pas encore passé le stop.] [/§]

[§2] [Texte A2.] [Voulant dépasser un semi-remorque clignotant à droite, ce dernier tourna à gauche m'obligeant à braquer à gauche pour l'éviter.] [La voiture a dérapé sur la chaussée mouillée et a percuté un trottoir puis un mur de clôture en face.] [Le conducteur du camion avait bien mis son clignotant à gauche mais sa remorque inversait le signal sur la droite.] [Ne m'ayant pas touché le conducteur s'est déclaré hors de cause et n'a pas voulu établir de constat.] [Ayant quitté ma voiture pour appeler un dépanneur j'ai retrouvé celle-ci avec la portière arrière droite enfoncée sans coordonnées du responsable.] [/§]

[§3] [Texte A3.] [Fort trafic à 17 h 15 Bd Sébastopol.] [Je roulais entre deux files de voitures arrêtées quand l'une des voitures à ma gauche a ouvert sa porte avant droite.] [Pour l'éviter, [event~j'ai fait un écart qui m'a fait toucher le véhicule B~event] avec l'arrière de ma moto ce qui a provoqué ma chute.] [Vu l'importance du trafic à [event/2] échangé nos assurances et noms ce qui explique que mon constat amiable ne soit signé que par moi.] [/§]

[§4] [Texte A4.] [Véhicule B venant de l'arrière, [event~le véhicule B, percuta mon véhicule~event], et me glissant, mon véhicule dérape, et percuta un arbre, d'où un second choc frontal.] [/§]

[§5] [Texte A5.] [J'étais arrêté à l'intérieur de la file, lui laissant libre la première.] [Au moment où je démarrais, j'ai entendu le choc de l'arrière;] [je ne m'attendais pas à ce que [event~le véhicule B, percuta mon véhicule~event] l'arrête.] [/§]

[§6] [Texte A6.] [Mr C.][Delon, abordant le carrefour, n'aurait pas vu que [event~j'étais arrêté et a percuté fortement mon véhicule~event], l'abîmant gravement.] [De ce fait, j'ai subi (C.][Delon) "le coup du lapin";] [le siège conducteur a été endommagé;] [les gendarmes se sont rendus sur place;] [j'ignore s'ils ont établi un rapport.] [/§]


event/2 [X]

protal: type\_ent: personne  
role: redacteur

protal2: type\_ent: vehicule  
type\_vehic: vehicule  
spec: nomAB: B

Done

VISUALISATION ET  
ÉVALUATION DES  
RÉSULTATS



## PROPRIÉTÉS DE VISUALISATION

Chaque type d'annotation peut se voir attribuer des propriétés d'affichages spécifiques.

de postes mis aux concours.] [La tendance [a] été inversée au début des années 1980, entraînant la diminution du taux d'auxiliaires.] [Ces phases successives du recrutement [expliquent] la surreprésentation actuelle des 40-50 ans.]

[+] [intro:36] Depuis le milieu des années 1980 [intro:36], l'offre de recrutement (bien qu'en forte augmentation), ainsi [que le nombre de candidats se présentant aux concours, ne [sont] plus à la hauteur des besoins et des objectifs.]. [De ce fait, la proportion de maîtres auxiliaires, personnels non titulaires, [augmente] à nouveau.]. [C'[est] dans les lycées professionnels, [qui [attirent] le moins], [que leur proportion [est] la plus importante];] [[puis] dans les lycées, alors [que la stagnation des effectifs scolaires [explique] leur plus faible présence dans les collèges.].] [Ce [sont] actuellement les lycées [qui [absorbent] l'essentiel de l'augmentation des effectifs enseignants].]

[+] [intro:37] En trente ans [intro:37], le corps enseignant du second degré s'[est] féminisé, particulièrement dans les collèges et dans les grades les moins élevés.]. [Le taux de féminité s'[est] stabilisé autour de 55% depuis une dizaine d'années: 42% en lycée professionnel, 50% en lycée, 61% en collège.].

[+] [intro:38] Depuis le début des années 1960 [intro:38], la composition du corps enseignant [a] été diversifiée: les disciplines, multipliées, avec l'apparition de CAPES et de CAPET artistiques et techniques et la C et plus récemment, PLP1 et PLP2).]. [Même si la tendance actuelle [est] à la (près d'une quinzaine) de même que les statuts (titulaire, titulaire académique, [Le corps professoral demeure hétérogène.].

ans le public] </§>

rés nationalement: les mutations [ont] donc pour cadre le territoire français dans son ensemble.]. [LES CERTIFIES et agrégés [sont] recrutés sur concours - avec une licence ou une maîtrise - alors [que les adjoints d'enseignement [sont] d'anciens auxiliaires titularisés.].] [Les professeurs de type lycée [représentent] plus de la moitié des

Done

# VISUALISATION DANS LE DOCUMENT

Les annotations (structures de traits, relations) peuvent être affichées. La structure originelle est préservée.



*Leading the Web to Its Full Potential...*

[Activities](#) | [Technical Reports](#) | [Site Index](#) | [New Visitors](#) | [About W3C](#) | [Join W3C](#) | [Contact W3C](#)

The World Wide Web Consortium (W3C) develops interoperable technologies (specifications, guidelines, software, and tools) to lead the Web to its full potential. W3C is a forum for information, commerce, communication, and collective understanding. On this page, you'll find [W3C news](#), links to [W3C technologies](#) and ways to [get involved](#). New visitors can find help in [Finding Your Way at W3C](#). We encourage organizations to learn more [about W3C](#) and [about W3C Membership](#).

**Mobile Web Initiative**

W3C has launched the [Mobile Web Initiative](#) (MWI) to make Web access from a mobile device as simple, easy, and convenient as Web access from a desktop device. Read [about MWI](#) and [MWI sponsors](#) and learn [how to become one of them](#).

**W3C Membership News**

W3C has lowered fees for non-profit and small commercial organizations based in developing countries (see the [press release](#)) and for intermediate-sized companies. Read [about W3C fees](#).

**W3C A to Z**

- [Accessibility](#)
- [Amaya](#)
- [Annotea](#)
- [CC/PP](#)
- [Compound Document Formats](#)
- [CSS](#)

**News**

► **W3C Office Opens in Australia**

2005-10-06: W3C is pleased to announce the [CSIRO ICT Centre](#) in Canberra hosts the [W3C Australian Office](#) effective 10 October. Ross Ackland is Office Manager. "W3C considers Australia a key to global adoption of Web technologies, and we welcome CSIRO as an Office host," said Ivan Herman, W3C Head of Offices. W3C wishes to thank DSTC in Brisbane and staff members Liz Armstrong and Hoylen Sue for hosting the previous Australian Office. Read about [W3C Offices](#). ([News archive](#))

► **Working Group Note: Time Zones**

2005-10-13: Based on discussions with the XQuery and XSL Working Groups, the Internationalization Core Working Group has released [Working with Time Zones](#) as a Working Group Note. The document discusses problems

**Search**

Google™

Search W3C

[Search W3C Mailing Lists](#)

**Members**

**Fundación CTIC (Centro Tecnológico para el Desarrollo en Asturias de las Tecnologías de la Información y la Comunicación)**



The mission of the Information and Communication Technology Centre is the promotion and development of the Information Society within the social, institutional, and business communities. The Centre is committed to use W3C



*[Leading the Web to Its Full Potential...]*

[Activities](#) | [Technical Reports](#) | [Site Index](#) | [New Visitors](#) | [About W3C](#) | [Join W3C](#) | [Contact W3C](#)

[The World Wide Web Consortium (W3C) develops interoperable technologies (specifications, guidelines, software, and tools) to lead the Web to its full potential.] [W3C is a forum for information, commerce, communication, and collective understanding.] [On this page, you'll find [W3C news](#), links to [W3C technologies](#) and ways to [get involved](#).] [New visitors can find help in [Finding Your Way at W3C](#).] [We encourage organizations to learn more [about W3C](#) and [about W3C Membership](#).]

**[Mobile Web Initiative]**

[W3C has launched the [Mobile Web Initiative](#) (MWI) to make Web access from a mobile device as simple, easy, and convenient as Web access from a desktop device.] [Read [about MWI](#) and [MWI sponsors](#) and learn [how to become one of them](#).]

**[W3C Membership News]**

[W3C has lowered fees for non-profit and small commercial organizations based in developing countries (see the [press release](#)) and for intermediate-sized companies.] [Read [about W3C fees](#).]

**[W3C A to Z]**

- [Accessibility](#)
- [Amaya](#)
- [Annotea](#)
- [CC/PP](#)
- [Compound Document Formats](#)
- [CSS](#)

**[News]**

**► W3C Office Opens in Australia**

[2005-10-06: W3C is pleased to announce the [CSIRO ICT Centre](#) in Canberra hosts the [W3C Australian Office](#) effective 10 October.] [Ross Ackland is Office Manager.] ["W3C considers Australia a key to global adoption of Web technologies, and we welcome CSIRO as an Office host," said Ivan Herman, W3C Head of Offices.] [W3C wishes to thank DSTC in Brisbane and staff members Liz Armstrong and Hoylen Sue for hosting the previous Australian Office.] [Read about [W3C Offices](#).] [([News archive](#))]

**► Working Group Note: Time Zones**

[2005-10-13: Based on discussions with the XQuery and XSL Working Groups, the Internationalization Core Working Group has released [Working with Time Zones](#) as a Working Group Note.] [The document discusses problems

**[Search]**



Search W3C

[[Search W3C Mailing Lists](#)]

**[Members]**

**Fundación CTIC (Centro Tecnológico para el Desarrollo en Asturias de las Tecnologías de la Información y la Comunicación)**



[The mission of the Information and Communication Technology Centre is the promotion and development of the Information Society within the social, institutional, and business communities.] [The Centre is committed to use W3C

status-in-enum: amorce  
 status: hyperonyme/holonyme  
 criterion: domain: spatial  
 value: regions de l'Ouest

domain: spatial  
 value: regions de l'Ouest

sem: hypero/hypo  
 type: domain: spatial  
 criterion: area

hyperonymie

hyperonymie

hyperonymie

status-in-enum: item  
 status: hyponyme/meronyme  
 criterion: domain: spatial  
 value: Basse-Normandie

domain: spatial  
 value: Bretagne

Le nombre a augmenté) parmi ses meilleurs scores nationaux. Cette situation est contraire, ce différentiel d'avec la situation nationale, en dehors de l'ouest, est expliqué par l'engagement et politiquement par la présence du Front National. Elle ne s'explique pas que par cela car le Sud-Ouest où le Front National est à son apogée n'est pas le même modèle. La Gauche y domine plus largement.

Les héritages politiques historiques l'expliquent en grande partie. **Les régions de l'Ouest** font coexister ce cocktail : meilleures terres d'influence de Droite coexistant avec points d'ancrage forts de Gauche et des Ecologistes et faiblesse relative du Front National.

A ce premier tour de 1997, la Droite passe rarement au-dessus de la barre des 40 %. **Dans les Pays de la Loire**, élu de premier tour, les reculs des sortants sont considérables, en particulier dans les départements qui restent un des meilleurs de France. François d'Aubert à Laval (UDF) 30 points et Roger Lestas (UDF) 25 points. En Vendée, Philippe de Villiers bien qu'en ballottage favorable perd 18 points. Dans le Maine-et-Loire qui envoie habituellement sept députés de Droite sur sept à l'Assemblée, le recul est de 10 points. Dans la Sarthe, Fillon perd 15 points.

**En Basse-Normandie**, la situation est identique. Un seul député sortant passe au premier tour : René André, RPR à Avranches, mais perd 9 points. Partout la Droite recule, particulièrement dans la moitié nord de la région. Elle est souvent autour de 35 % parfois même en dessous de 30 comme André Fanton à Lisieux. Dans les départements toujours acquis, telle Bayeux voit son député sortant, François d'Harcourt à 34 %, 4 points devant seulement une candidate PS fraîchement implantée.

**En Bretagne**, le balancier est, cette fois encore, poussé plus loin à Gauche dans beaucoup de circonscriptions. Seul Pierre Méhaignerie, UDF, repasse au premier tour avec 51,4 %, en recul de 11 points. Alain Madelin (UDF-PR) à Redon perd 15 points, Charles Miossec, RPR à Landerneau également. Le mieux élu de 1993, Loïc Bouvard à Ploërmel dans le Morbihan perd 10 000 voix. De façon générale, les pertes sont de 10 à 15 points.

# VISUALISATION SÉLECTIVE

---

- Différents composants permettent de produire des “vues” spécifiques d’un document annoté
  - Vue type concordancier classique
  - Vue “macro-concordancier” plus adapté au grain discours
  - ...
- Les propriétés d’affichage sont spécifiées une fois pr ttes
- Facilité de développement de nouvelles “vues”



Menu



## Outils d'évaluation LinguaStream

temporal ▼

Charger un fichier

Recherche : temporal

<<

10

>>

l'imes compléments . Or cette période 1985-1994 correspond à un moment de mu  
Résumée par l'objectif annoncé en 1985, "80% de la classe d'âge au  
formation des jeunes Français. En quelques années, le baccalauréat et les études  
provoqués par le passage, dans les années 1960, à la scolarité obligatoire  
porte à la situation scolaire au début des années 1990. La seconde est à construire  
té française à quelques années de l'an 2000. Cet atlas de la France sco  
EE (résultats des recensements de 1982 et 1990). L'origine de l'informatio  
) . À l'occasion du mouvement de 1988, il fallait par exemple 69 p  
nement nommés sont en activité depuis 1992); depuis 1991, des institu  
nt en activité depuis 1992); depuis 1991, des instituteurs sont prom  
s au recensement de population de 1982 (tableau du RGP 1982, INSEE);  
ège d'après l'enquête réalisée en 1985 par le ministère de l'Éducati  
2e au lycée, d'après l'enquête de 1985 (se reporter au chapitre 7).  
r du collège, dans la décennie des années 1980. Les indices de préscolari  
r pour l'année suivante. Pour la fin des années 1980 à défaut de statistiques donn  
s les enfants de cet âge sont maintenant préscolarisés; leur nombre,  
des quatre, trois et deux ans en 1987-88... Les indices départeme  
r entrée en cours préparatoire en 1978 (panel 1978). Pour chaque en  
On suit ainsi d'année en année depuis dix ans les déroulements des scolarit  
aire dans le cycle élémentaire en 1987-88 (mais aussi dans les études  
i dans les études antérieures, en 1982-83 et 1985-86) avec les cara

Mozilla Firefox

file://localhost/tmp/LinguaStream\_64539.tmp

{cadreman:14}En 1985 ... préparaient ... en trois ans ... en 1991 ... peine ... «cadreman:14}

{frame:6}Entre 1985 et 1992 ... «frame:6}

{cadreman:15}En cinq ans ... la rentrée 1985 ... de 1992 ... en deux ansest ... vont ... sont ... rejoignent ... la rentrée de 1993 ... entreprennent ... en deux ans ... Entre 1985 et 1992 ... ont ... est ... depuis quelques années ... cycle ... accueillentmaintenant ... la rentrée 1992 ... au milieu des années 1980 ... a ... cycle ... «cadreman:15}

{cadreman:16}En 1985 ... «cadreman:16}

{frame:7}En 1985 ... en 1987 ... «frame:7}

{cadreman:17}En 1985 ... ont ... «cadreman:17}

{frame:8}En 1985 ... ont ... «frame:8}

{cadreman:18}En 1990 ... approche ... «cadreman:18}

{frame:9}En 1990 ... approche ... «frame:9}

{cadreman:19}en 1992 ... «cadreman:19}

{frame:10}en 1992 ... «frame:10}

{cadreman:20}En une quinzaine d'années seulement ... est ... puis ... depuis le milieu des années 1980a ... cependant ... est ... sont ... traduit ... tendent ... resserrent ... rattrapent ... dépassent ... font ... caractérisentdepuis des décennies ... «cadreman:20}

{frame:11}En une quinzaine d'années seulement ... est ... puis ... depuis le milieu des années 1980a ... cependant ... est ... sont ... traduit ... tendent ... resserrent ... rattrapent ... dépassent ... font ... caractérisentdepuis des décennies ... mettaient ... sont ... en quelques années ... reste ... estmaintenant ... jouent ... poursuivent ... offrentsont ... entreprennent ... ont ... continuent ... conduisent ... sont ... sont ... sont ... est ... orienté ... offrent ... «frame:11}

{cadreman:21}Depuis 1987 ... est ... a ... a ... est ... «cadreman:21}

{frame:12}Depuis 1987 ... est ... a ... a ... est ... «frame:12}

{cadreman:22}Entre 1988 et 2000 ... a ... en 1980 ... en 1984 ... en 1987 ... en 1990 ... est ... ont ... est ... est ... «cadreman:22}


{frame:13}Entre 1988 et 2000 ... a ... en 1980 ... en 1984 ... en 1987 ... en 1990 ... est ... ont ... est ... est ... «frame:13}

{cadreman:23}Cependant, depuis le début des années 1990 ... est ... rencontrent ... «cadreman:23}


{frame:14}Cependant, depuis le début des années 1990 ... est ... rencontrent ... «frame:14}

Terminé

### Répartition des expressions temporelles



### Critères de clôture des cadres




**VISUALISATION SOUS  
FORME DE GRAPHES**

frameClosure.cd (Chart Descriptor Editor)

Standard Expert

chartTitle	Critères de clôture des cadres
exclusiveltems	True
insertLegend	True
mode	Total Count
segmentTypes	

Name	Markup Type	Feature Set	Value Feature
Nouveau cadre	frame	{closureCriterion:newFrame}	
Sémantique	frame	{closureCriterion:semantics}	
Structure	frame	{closureCriterion:structure}	
Temps verbaux	frame	{closureCriterion:tenses}	
Autres	frame	{}	



test.cd (Chart Descriptor Editor)

Standard Expert

chartTitle	Untitled
exclusiveItems	False
insertLegend	True
mode	Feature Values
segmentTypes	

Name	Markup Type	Feature Set	Value Feature
Dice coefs	paragraph	{}	tfidf/dice
Threshold	paragraph	{}	tfidf/threshold

# GESTION DES CHAÎNES DES TRAITEMENTS

The screenshot shows the Stream Iterator Editor (test.lsi) with the following configuration:

Category	Property	Value
Input	inputFiles	'/Users/fbilhaut/Documents/linquastream/test/i
	inputVariable	input
Output	outputDirectory	/Users/fbilhaut/Documents/linquastream/test/it
	outputVariable	output
	overwrite	True
Stream	streamFileName	//Users/fbilhaut/erc/linquastream/test/iterator/it

The data flow diagram below the configuration shows the following components and connections:

- INPUT** (purple box) connects to **Tokenizer** (purple box).
- Tokenizer** connects to **Regex Marker** (purple box, highlighted with a red border).
- Regex Marker** connects to **Web Viewer** (purple box).
- Web Viewer** connects to **OUTPUT** (purple box).
- Web Viewer** also connects to **TEST.LSV** (purple box).

The status bar at the bottom indicates the current document is `input4.xhtml (4 of 6)`.

**APPLICATION D'UNE CHAÎNE  
SUR UN LOT DE DOCUMENTS**

# SCRIPTS D'AUTOMATISATION

---

```
query = automation.getUserInput("Query:");

google = automation.getGoogle("xxxxxxxxxxxx");
google.maxResults = 10;
google.languages = "lang_fr";

results = google.search(query);

stream = automation.openStream("analysis.ls");

for(res : results)
{
    stream.setParameter("input", res.URL);
    // ...
    stream.run();
}
```

# ASSISTANTS

---

- Interface type “wizard” permettant de créer facilement des chaînes de traitements
- Demande à l'utilisateur de renseigner les paramètres principaux
- Génère la chaîne et tous les documents associés (squelettes)

### Input Format and Location

Please specify the format (raw text or XML), and the path to the input file.

XML document  Raw text

/Users/fbilhaut/input.xml

Browse

Back

Next

Finish

Cancel

### Main Analyser Type

Please specify the kind of analyser you want to use.

Note that it will still possible to replace this analyser or to add new ones after the wizard is completed.

- DCG Marker
- RegExp Marker

◀ Back

▶ Next

Finish

Cancel

### Target Directory

Please specify the target directory for the new processing stream.

This directory will contain the processing stream itself, as well as all the associated files.

/Users/fbilhaut/test

Browse

◀ Back

▶ Next

Finish

Cancel

### Terminated

Congratulations, your processing stream is now configured properly. Please check below that your settings are correct.

Please click on "Finish" to create the stream and exit this wizard. You can still use the "Back" button to change your settings.

Input file type: XML Document  
Input file path: /Users/fbilhaut/input.xml  
Main analyser type: DCG Marker  
Target directory : /Users/fbilhaut/Temp/essai

◀ Back

▶ Next

Finish

Cancel



Explorer ✕ Palette ✕

### Explorer

- ▶ LinguaStream/library
- ▶ LinguaStream/demo
- ▶ Home/src/geosem
- ▶ Home/Documents/test/LS
- ▶ Home/Desktop
- ▶ Home/src/linguastream/test
- ▼ Home/Temp/essai
  - grammar.pro
  - stream.ls
  - struct.xml
  - view.lsv

### Properties

#### Component

cached	True
class	Tree Tagger
comments	
minimized	False
name	Tree Tagger

#### Markup

tokenTypes

#### Tag Set

tagSet

#### Tree Tagger

parameterFilePath


taggerBinaryPath

Standard

Expert

### Working Area

stream.ls (Stream Editor)



### Console

- ❏ Plugin 'Stream Format Converter' v. 2.0.1 successfully loaded
- ❏ Plugin 'Database Tools' v. 2.0.1 successfully loaded
- ❏ Plugin 'Text Editor' v. 2.0.1 successfully loaded
- ❏ Plugin 'Lexicon Editor' v. 2.0.1 successfully loaded
- ❏ Plugin 'Quick View' v. 2.0.1 successfully loaded
- ❏ Plugin 'SWI Prolog' v. 2.0.1 successfully loaded
- ❏ Plugin 'Tree Tagger' v. 2.0.1 successfully loaded
- ❏ Plugin 'Regex Tokenizer' v. 1.0.0 successfully loaded
- ❏ Plugin 'Automation Script Editor' v. 2.0.1 successfully loaded
- ❏ Plugin 'Markup Charter' v. 2.0.0 successfully loaded
- ❏ Plugin 'Evaluation' v. 1.0.0 successfully loaded

**EXEMPLE  
D'APPLICATION :  
ANALYSE DES CADRES  
DE DISCOURS  
TEMPORELS**

# L'ENCADREMENT DU DISCOURS (CHAROLLES 97)

---

- Univers de discours
  - Ensemble de circonstances dans lesquelles une ou plusieurs propositions peuvent être dite “vraies” (critère véridictionnel) → segments textuels délimitables
- Introduceur de cadre
  - Groupe adverbial périphérique : expression détachée en initiale de phrase / en position pré-verbale
  - Cadre véridictionnel = ensemble de propositions soumises au critère d'interprétation spécifié par l'introduceur

- Différents types de cadres :
  - Temporels (“Depuis 1985, ...”),
  - Spatiaux (“En Normandie, ...”)
  - Thématiques (“Concernant X, ...”),
  - Médiatifs (“Selon X, ...”)
  - Praxéologiques (“En Chimie, ...”)
- **Projet GeoSem : analyse automatique des cadres spatiaux et temporels**
  - Indexation tri-partite phénomène / espace / temps
  - Indexation de passages
  - Moteur de recherche multi-critères

**De 1965 à 1985**, le nombre de collégiens et de lycéens a augmenté de 70%, mais selon des rythmes et avec des intensités différents selon les académies et les départements. Faible dans le Sud-Ouest et le Massif central, modérée en Bretagne et à Paris, l'augmentation a été considérable dans le Centre-Ouest, en Alsace, dans la région Rhône-Alpes et dans les départements de la grande banlieue parisienne où les effectifs ont souvent plus que doublé. Les variations de la population et les baisses plus ou moins fortes du nombre des naissances selon les régions ne suffisent pas à expliquer ces différences d'accroissement des effectifs du secondaire. Intervient aussi l'allongement des scolarités, qui a été plus marqué dans les départements où, au milieu des années 1960, la poursuite des études après l'école primaire était loin d'être la règle. [...]

# ANALYSE AUTOMATIQUE

---

- La borne gauche d'un cadre est assez facilement repérable car l'introducteur a une forme caractéristique
- La borne droite en revanche n'est pas signalée explicitement
- Le lecteur humain met vraisemblablement en oeuvre, plus ou moins consciemment, une grande diversité de mécanismes interprétatifs pour évaluer la borne finale
- L'automatisation de ce processus est une question très complexe

- Deux sous-problèmes :
    - Détection des introducteurs (borne gauche)
      - Formes reconnues par les analyseurs d'expr. spat. et temp.
      - Application de critères positionnels (en initiale détachée)
    - Délimitation de la borne droite
      - Nécessité d'établir des critères objectifs et opérationnalisables
      - Plusieurs critères : sémantiques, énonciatifs, structurels, ...
      - Aucun de ces critères n'est vraiment fiable à lui seul
- On cherche à exploiter des faisceaux d'indices

# PRÉ-TRAITEMENTS

---

- Etiquetage morpho-syntaxique
- Délimitation des phrases
- Projection d'un lexique de connecteurs de discours
- Analyse syntaxico-sémantique des expressions temporelles

culturellement les plus défavorisés . Ces enjeux , et la demande des parents qu' ils ont contribué à susciter , ont été largement pris en charge par les pouvoirs publics . Les enfants de trois , quatre et cinq ans sont **maintenant** presque tous scolarisés , alors qu' **au début des années 1960** les taux étaient , respectivement , de 36% , 63% et 91% . Et pour les enfants de deux ans , le taux est passé de 10% à 33% **entre 1960 et 1982** ; il est **maintenant** stabilisé , **depuis le milieu des années 1980** , à 35% . Cependant des inégalités subsistent , selon les milieux socio-économiques d' origine des enfants , comme selon les régions et départements . En ce qui concerne la préscolarisation à deux ans , le Grand Ouest , le Midi toulousain , le sud et l' est du




```
[  
  type : période  
  début : [  
    type : décennie  
    année : 1980  
    delta : milieu  
  ]  
]
```

# CRITÈRES D'ANALYSE DE LA PORTÉE

---

- Critères sémantiques
  - Cohérence temporelle
  - Collaborations espace/temps
- Critères énonciatifs : temps verbaux
- Critères structurels : architecture textuelle
- Perspectives
  - Gestion de zones de “digression”
    - Critères a priori ?
- Chaîne de traitement LinguaStream



```
Rule {type:"cadre"}
{
  start({type: "introducteur"})
  end({type : "phrase"})
  homogeneity(comparator:portée)
  size(mode:"longest")
  not presence(pattern : {type : "introducteur"}, amount : 2)
  size(mode : #LONGEST)
}

Comparator portée ({type: "verbe"} as $v1, {type: "verbe"} as $v2)
{
  $v1/temps = $v2/temps
}

Comparator portée ({type: "intro"} as $i, {type: "tempo"} as $t)
{
  (($i/debut >= $t/debut) and ($i/debut <= $t/fin))
  or
  (($i/fin >= $t/debut) and ($i/fin <= $t/fin))
}
```

**De 1965 à 1985**, le nombre de collégiens et de lycéens **a augmenté** de 70%, mais selon des rythmes et avec des intensités différents selon les académies et les départements. Faible dans le Sud-Ouest et le Massif central, modérée en Bretagne et à Paris, l'augmentation **a été** considérable dans le Centre-Ouest, en Alsace, dans la région Rhône-Alpes et dans les départements de la grande banlieue parisienne où les effectifs **ont** souvent plus que **doublé**.

Les variations de la population et les baisses plus ou moins fortes du nombre des naissances selon les régions **ne suffisent pas** à expliquer ces différences d'accroissement des effectifs du secondaire. Intervient aussi l'allongement des scolarités, qui a été plus marqué dans les départements où, **au milieu des années 1960**, la poursuite des études après l'école primaire était loin d'être la règle. [...]

d'auxiliaires.] [Ces phases successives du recrutement [expliquent] la surreprésentation actuelle des 40-50 ans.]

[+[intro:36> Depuis le milieu des années 1980<intro:36], l'offre de recrutement (bien qu'en forte augmentation), ainsi [que le nombre de candidats se présentant aux concours, ne [sont] plus à la hauteur des besoins et des objectifs].] [De ce fait, la proportion de maîtres auxiliaires, personnels non titulaires, [augmente] à nouveau.] [C'[est] dans les lycées professionnels, [qui [attirent] le moins], [que leur proportion [est] la plus importante];] [[puis] dans les lycées, alors [que la stagnation des effectifs scolaires [explique] leur plus faible présence dans les collèges].] [Ce [sont] actuellement les lycées [qui [absorbent] l'essentiel de l'augmentation des effectifs enseignants].]

[+[intro:37> En trente ans<intro:37], le corps enseignant du second degré s'[est] féminisé, particulièrement dans les collèges et dans les grades les moins élevés.] [Le taux de féminité s'[est] stabilisé autour de 55% depuis une dizaine d'années: 42% en lycée professionnel, 50% en lycée, 61% en collège.]

[+[intro:38> Depuis le début des années 1960<intro:38], la composition du corps enseignant [a] été diversifiée: les disciplines, multipliés, avec l'apparition de CAPES et de CAPET artistiques et techniques et la C et plus récemment, PLP1 et PLP2).] [Même si la tendance actuelle [est] à la (près d'une quinzaine) de même que les statuts (titulaire, titulaire académique, [Le corps professoral demeure hétérogène.]

**intro/38** [X]

sem:	periode:	type: d
	debut:	annees:
		type: debut
		annee: 1960

axis: time

SON ENSEMBLE.] [LES CERTIFIES ET AGREGES [sont] recrutés sur concours - avec une licence ou une maîtrise - alors [que les adjoints

# EVALUATION

---

- Evaluation de la qualité de la mesure de portée
- Comparaison avec une annotation manuelle
  - *Atlas de la France scolaire ...* (R. Hérin, 56 000 mots)
  - *Atlas politique ...* (P. Buléon, ? mots)
  - Journal *Le Monde* (volume à déterminer)
- Avancement :
  - Quelques numéros du monde en cours d'annotation
  - Premiers résultats à partir de l'annotation de (Hérin)
    - Annotation de Marion Laignelet

- Alignement automatique des cadres
  - Exploitation de l'introducteur repéré automatiquement
  - Seuil de tolérance sur la borne gauche de l'intervalle
  - Première évaluation en termes de précision / rappel
- Mesure de l'écart entre les bornes droites uniquement
  - Dénombrement d'unités linguistiques quelconques
  - Modularité de la mesure, établie par exemple en nombre de mots ou de phrases
  - Mesure relative ou absolue

# MÉTHODE D'ANNOTATION ET DE COMPARAISON

---

- En cas d'ambiguïté l'expert peut annoter une "plage de fin" pour un cadre
- Plusieurs méthodes de comparaison sont envisageables :
  - Distance relativement à la borne la plus proche
  - Pseudo-distance nulle si fin comprise dans l'intervalle
  - ...
- Unité de mesure :
  - En nombre de mots ? de phrases ?
  - Les outils de comparaison exploitent le grain variable de LS

[§168][La diversification des possibilités][/§]

[§169][Par orientations successives de la 2e à la Terminale s'offrent ainsi aux lycéens près de trente séries et options du baccalauréat.] [Certaines **préservent** pratiquement toutes les possibilités ultérieures: c'est le cas de la série C et, à un degré moindre, des séries D et E.] [D'autres **sont** déjà très spécialisées, telles les séries F à petits effectifs;] [il en **est** +][qui **sont** peu prisées]: les séries G, voire les séries A.] [Nul ne **conteste** qu'il **existe** ainsi une hiérarchie des séries du baccalauréat et des cursus +][qui y **conduisent**.] [Il **est** bien connu +][que les lycéens **sont** sensiblement différents d'une série à l'autre.] [En G, série à recrutement très majoritairement féminin, les élèves **sont** en moyenne plus âgés, **ont** redoublé une ou deux classes, **font** fréquemment le parcours de la 2e à la Terminale **en quatre ans**, et même plus;] [leurs origines sociales **sont** assez sem-blables à celles des élèves de classes de BEP.] [À l'opposé, les Terminales C **sont** jeunes, **comptent** le plus souvent une forte majorité de garçons, et les familles de cadres supérieurs, d'enseignants, de médecins, avocats et autres professions libérales **sont** de beaucoup les mieux représentées.]

**{cadreman:118}** [ +][**intro:74**» Au milieu des années 1960«**intro:74**}, les Terminales des lycées d'enseignement classique et moderne, ainsi +][que les écoles normales +][qui **recrutaient** encore les futurs instituteurs au niveau de la 2e]], ne **préparaient** qu'à trois baccalauréats: philosophie, sciences expérimentales et mathématiques élémentaires.] [Elles **avaient** au total une centaine de milliers d'élèves.] **{cadreman:118}** [L'enseignement technique et professionnel **conduisait** une vingtaine de milliers de lycéens **soit** aux baccalauréats mathématiques et technique ou technique et économie, ancêtres des actuelles séries F et G, soit aux brevets de

[ **{cadreman:119}**» Depuis, les cursus scolaires dans le deuxième **considérablement diversifiés**;] [dans l'enseignement technique et professionnel, les **formations ont** été spécialisées], dans un effort d'adaptation des **des emplois**.] [De plus, des passerelles **ont** été créées.] [Des élèves **ont** été créées.] [Des élèves **ont** été créées.] [inversement, des élèves de 2e **peuvent** être **admis** dans les classes de CAP et BEP **ont** la perspective de continuer leurs études jusqu'à la fin du cycle professionnel **poursuivent** ainsi, généralement après le cycle long.] **{cadreman:119}** [ ][/§]


frame/65

[X]

sem: | | type: milieu  
annees: | |  
annee: 1960  
axis: time  
closureCriterion: tenses

et technologique **ont** été **introduits** dans l'enseignement général, les **qualifications** et des profils **ont** été créés. Le **premier** de lycée par les **premières** les élèves des classes de **premières** [Près de 30% des élèves **ont** poursuivi des études dans le **cycle long**]


**«cadreAW:2} {cadreSF:3» {cadreFB:3» {cadreAW:3»**A la naissance de son fils Dino, en 1931, Enzo Ferrari raccroche ses gants de pilote pour devenir directeur des courses de l'Alfa-Romeo.**«cadreSF:3} «cadreFB:3}** Entouré d'une quarantaine d'ouvriers, il est chargé de créer chez lui à Modène la " scuderia Ferrari ". Il frappe aussitôt ses voitures à ses armes : le " cheval rampant ", emblème d'un as de la première guerre disparu, au nom faussement prédestiné, le comte Baracca.**«cadreAW:3}** Ce cavallino noir sur champ d'or qui ornera pendant plus d'un demi-siècle les cockpits écarlates va connaître des galops pas ordinaires. Le nouveau style des ces " Alfettes " à la ligne racée tranche avec les Bugatti trapues que nous allons admirer, parmi des foules énormes, roulant à tombeau ouvert sur l'anneau de Montlhéry. Encore fallait-il les tenir en main, ces joujoux magiques ! Or un pilote de grand prix ne se trouve pas sous le pied d'un cheval, même cabré. Antonio Ascari et Campari étant tombés au champ d'honneur des autodromes ? le premier à Montlhéry, le second à Monza, ? le choix prémonitoire d'Enzo Ferrari se porta sur deux futurs championissimi : Tazio Nuvolari, le petit homme au masque de doge émacié, dévoré par la passion d'être toujours devant, forant l'espace, et son vivant contraste, Achille Varzi, un garibaldino méticuleux et peu communicatif, bouclé à double tour sur ses romanesques aventures sentimentales (1).**«cadreSF:3} «cadreFB:3}**



# PREMIERS RÉSULTATS

---

Reference:	cadreman
Evaluated:	frame
Alignment relation:	alignement
Aligned frames:	72
Reference frames:	156
Measured frames:	80
Mean reference frame length:	119.88
Mean evaluated frame length:	174.88
Mean absolute left delta:	0.0
Mean relative left delta:	0.0
Mean positive left delta:	NaN (0.0%)
Mean negative left delta:	NaN (0.0%)
Min left delta:	0 (ref 8 vs. eval 3)
Max left delta:	0 (ref 8 vs. eval 3)
Mean absolute right delta:	47.59
Mean right delta:	47.59
Mean positive right delta:	100.79 (47.22%)
Mean negative right delta:	NaN (0.0%)
Min right delta:	0 (ref 13 vs. eval 5)
Max right delta:	518 (ref 98 vs. eval 51)



# COMPARAISON ENTRE ANNOTATIONS MANUELLES

---

- Confrontation des annotations de trois “experts”
- Une journée du journal *Le Monde*
- Nombres de cadres annotés :
  - $E_1 : 81 ; E_2 : 117 ; E_3 : 147$
- Nombres d’alignements deux à deux :
  - $E_1/E_2 : 76 ; E_1/E_3 : 76 ; E_2/E_3 : 108$
- Gradation dans ce que les experts ont considéré comme “cadre temporel” : plutôt que des différences deux à deux, on trouve l’ensemble des annotations de l’un incluses dans celles de l’autre.

[WWW.LINGUASTREAM.ORG](http://WWW.LINGUASTREAM.ORG)