# L'INGÉNIERIE DES CORPUS

Mokhtar Ben Henda

Université Bordeaux-Montaigne – MICA
Équipe E3D (Études Digitales des Données aux Dispositifs)
(EA 4426)

2017-2018

# L'INGÉNIERIE DES CORPUS

***Méthodes, outils et aspects normatifs***

Séminaire E3D
Master Humanités Numériques

**Mokhtar Ben Henda**

# Plan

- CADRE GÉNÉRAL
- ÉLÉMENTS MÉTHODOLOGIQUES
- ÉLÉMENTS TECHNIQUES

# Le corpus, un point d'orgue dans la recherche

- Le tournant/virage discursif des années70s :
  - *Les objets d'études émergent discursivement ;*
  - *Analyse du discours largement applicable dans la recherche linguistique ;*
  - *Analyse des donnée largement applicable dans les SHS / SIC ;*
  - *Appel au langage quels que soient ses méthodes et ses domaines de recherche (Lahire 1994) ;*
  - *Avènement de la « linguistique de corpus »* (empirisme) ;*
  - *Constructivisme (radical) : démarche empirique par objet corpus ;*
  - *« Considérer que ce qui est dit et écrit médiatise une part de la réalité et y donne une prise » (Le Lay 2013)*

    ➔ Corpus = énoncés construits qu'il faut étudier !

François Rastier. La Mesure et le Grain. Sémantique de corpus, Paris: Editions Honoré Champion, coll. "Lettres numériques" n12, 2011.

# Convergence vers le texte

« Tous les discours étudiés en linguistique et sciences sociales prennent la forme matérielle du texte, mais la dimension discursive d'un même texte fait qu'il est le terrain de différents niveaux d'expression et de représentation, chacun pouvant être étudié [et interprété] suivant l'orientation disciplinaire du chercheur » (Comby, 2016)

La situation centrale occupée par le texte (l'intertextualité) interroge les cloisonnements disciplinaires

**(Inter-multi-trans-disciplinarité).**

# Corpus & SHS : transversalité

Les SHS promeuvent de plus en plus la mise en place de méthodologies ancrées dans le terrain (littérature, sociolinguistique, ethnologie, didactique, sociologie, information et communication, etc.) dans un contexte marqué par :

- La déconstruction des outils méthodologiques de la recherche
- Une porosité des frontières disciplinaires

? 
- Si le corpus apparaît aujourd'hui comme constitutif de toute recherche en SHS, sa conception et son analyse demeurent très variables selon les travaux engagés

?
- Son exploitation dans un processus de recherche prête à de nombreuses pratiques méthodologiques (sa constitution, son analyse, sa place, ses fonctions …)

?
- Comment un chercheur en SHS peut-il s'approprier et s'approprie-t-il l'objet-corpus, depuis le « recueil » jusqu'à l'analyse, à travers l'emploi d'une méthodologie, voire la création d'une méthode ?

# Définitions variées

Corpus ?

**LINGUISTIQUE** : « une collection de données langagières qui sont sélectionnées et organisées selon des critères linguistiques explicites pour servir d'échantillon au langage » (Sinclair, 1996)

**LINGUISTIQUE DE CORPUS** « un regroupement structuré de textes intégraux, documentés, éventuellement enrichis par des étiquetages et rassemblés : (i) de manière théorique réflexive en tenant compte des discours et des genres, et (ii) de manière pratique en vue d'une gamme d'applications » (Rastier, 2011)

**SHS** : « Ensemble d'éléments issus du réel, appelés ‘’**observables**’’ (De Robillard), enregistrés, médiatisés par le chercheur ou préexistants (corpus littéraire, corpus oral, documents vidéos,…) qui sont recueillis puis sélectionnés et organisés pour constituer la base d'une analyse scientifique » (Le Gal, 2011)

**GÉNÉRALITÉ** : « ensemble de documents, artistiques ou non (textes, images, vidéos, etc.), regroupés dans une optique précise. On peut utiliser des corpus dans plusieurs domaines : études littéraires, linguistiques, scientifiques, philosophie, etc. » (Wikipedia)

# Typologie

- Deux conceptions combinées du corpus selon Rastier (2011*)

**Documentaire**
*(logico- grammaticale)*

- Ne tien pas compte de l'intégrité d'un texte
- Ne retient que des variables globales caractérisant les documents (mots, phrases), sans tenir compte de leur caractère textuel, ni de leur structure

***Philologique-herméneutique***
(interprétative)

- Évoque une praxéologie adaptée aux variations des tâches et des applications d'analyse
- Tient compte des rapports de texte à texte (intertextualité)

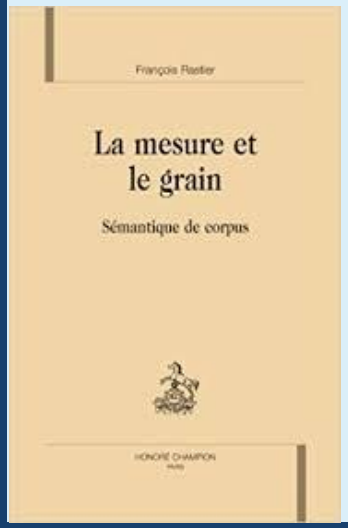


Julien Longhi, « La culture par les corpus : qualité & quantité en sémantique de corpus », Acta fabula, vol. 12, n° 8, Notes de lecture, Octobre 2011, URL : http://www.fabula.org/acta/document6544.php

François Rastier. La Mesure et le Grain. Sémantique de corpus, Paris: Editions Honoré Champion, coll. "Lettres numériques" n12, 2011.

# Typologie

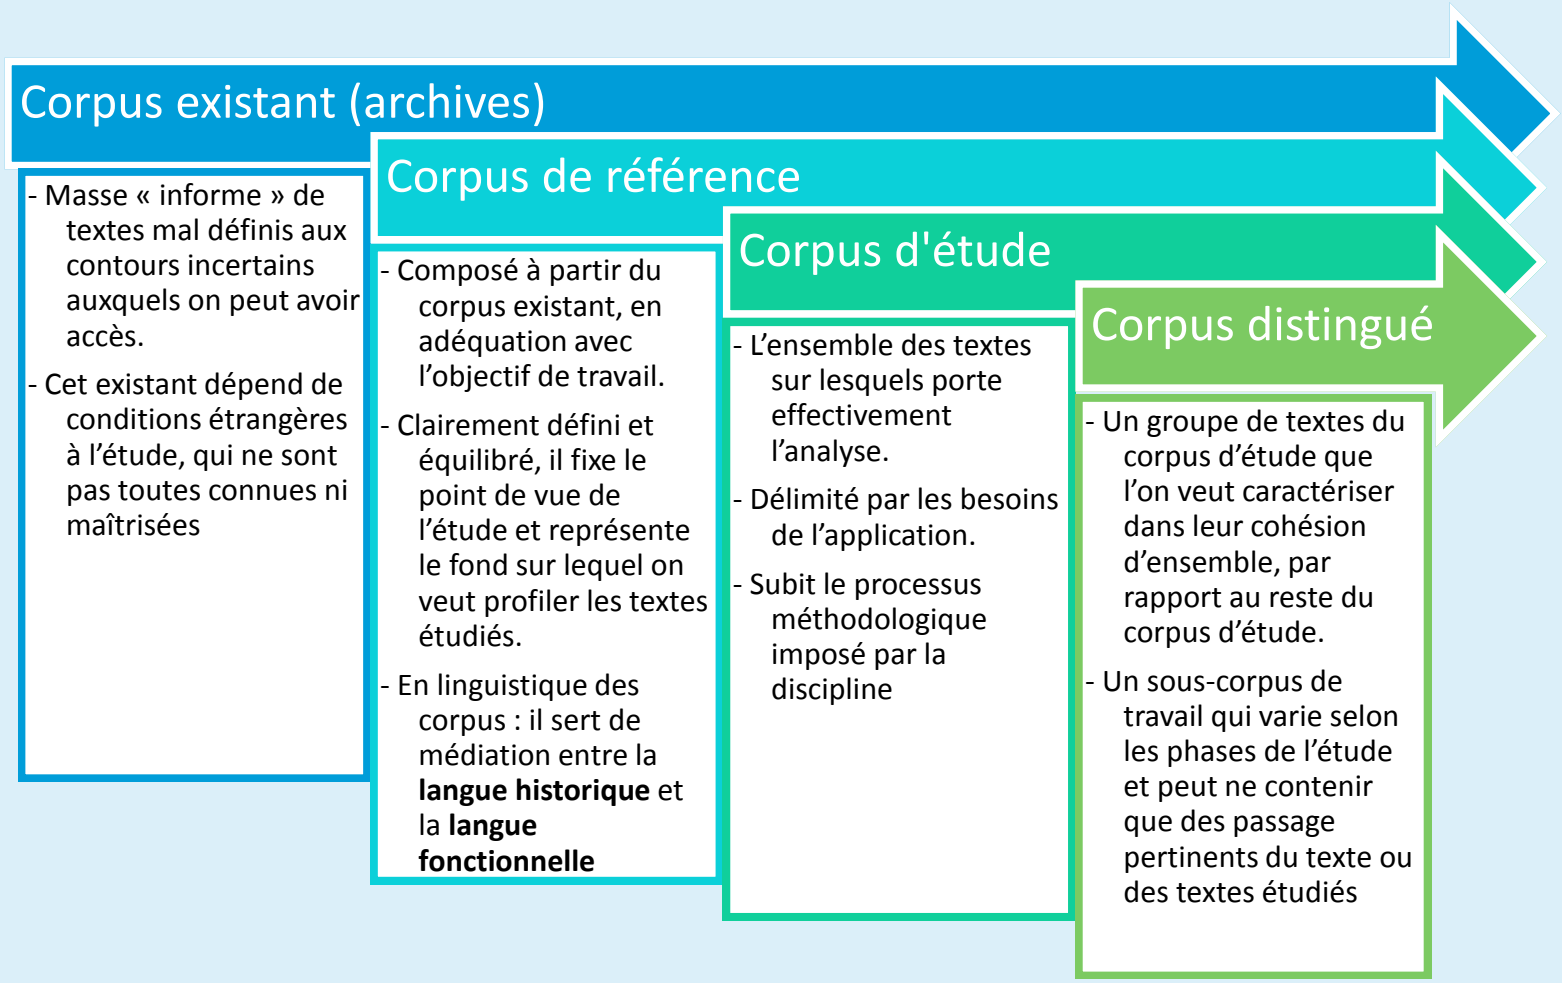
Corpus existant (archives)
- Masse « informe » de textes mal définis aux contours incertains auxquels on peut avoir accès.
- Cet existant dépend de conditions étrangères à l'étude, qui ne sont pas toutes connues ni maîtrisées
Corpus de référence
- Composé à partir du corpus existant, en adéquation avec l'objectif de travail.
- Clairement défini et équilibré, il fixe le point de vue de l'étude et représente le fond sur lequel on veut profiler les textes étudiés.
- En linguistique des corpus : il sert de médiation entre la **langue historique** et la **langue fonctionnelle**
Corpus d'étude
- L'ensemble des textes sur lesquels porte effectivement l'analyse.
- Délimité par les besoins de l'application.
- Subit le processus méthodologique imposé par la discipline
Corpus distingué
- Un groupe de textes du corpus d'étude que l'on veut caractériser dans leur cohésion d'ensemble, par rapport au reste du corpus d'étude.
- Un sous-corpus de travail qui varie selon les phases de l'étude et peut ne contenir que des passage pertinents du texte ou des textes étudiés

# Typologie : exemple

- Frantext : base de données de textes français (1970)
- Maintenue par l'ATILF-CNRS (ex INaLF)
- Corpus d'auteurs, de périodes chronologiques, de genre)

| | corpus existant | corpus de référence | corpus d'étude | corpus distingué |
|---|---|---|---|---|
| Etude d'Etienne Brunet (Brunet 1995) | la base Frantext de l'INaLF | 350 romans entre 1830 et 1970 | phrases de ces romans comportant au moins une des 165 unités lexicales retenues pour définir la thématique du sentiment | les éléments retenus dans les romans d'un romancier |
| Construction des profils pour l'application DECID de diffusion ciblée | textes enregistrés dans la base SPHERE de la DER d'EDF, autres textes électroniques collectés de façon centralisée. | l'ensemble des textes d'Action, en version définitive, à partir de l'année 1990 jusqu'à l'année en cours. | les textes d'Action pour une année (le cas échéant, les textes en version provisoire pour l'année suivante). | les textes d'Action du corpus d'étude, dont le rédacteur (plus exactement le responsable) est rattaché à un Département donné. |

# Caractéristiques

- « Le corpus n'existe pas en soi, mais dépend du positionnement théorique à partir duquel on l'envisage » (Charaudeau, 2013)
  - *Il dépend aussi :*
    - du contexte et du matériel d'étude concerné (terrain : observation sur terrain ou entretien face à face / oral, textuel ou multimodal) ;
    - du domaine concerné (inter/multi/transdisciplinarité) ;
    - de son historicité : ouvert ou clos ;
    - de sa représentativité (envergure) : corpus existant, de référence, d'étude ou distingué
    - De son exploitation : manuelle, automatisée ou les deux,
- « Tout regroupement de textes ne mérite pas le nom de corpus » (Rastier, 2011)
- « Tout ensemble de textes n'est pas un corpus » (Bommier-Pincemin, 1999)
  - *« Collection de textes avec une volonté de **cohérence** »*
  - *« Vérifie des conditions de **signifiance**, **d'acceptabilité** et **d'exploitabilité** »*

# Caractéristiques

- Des conditions de **signifiance** :
  - *porter sur un objet particulier, une réalité telle qu'elle est perçue sous un certain angle de vue*
- Des conditions **d'acceptabilité** :
  - *apporter une représentation fidèle sans contraintes externes dans une ampleur et un niveau de détail adaptés*
- Des conditions **d'exploitabilité** :
  - *être commensurable et pouvoir repérer des faits significatifs*

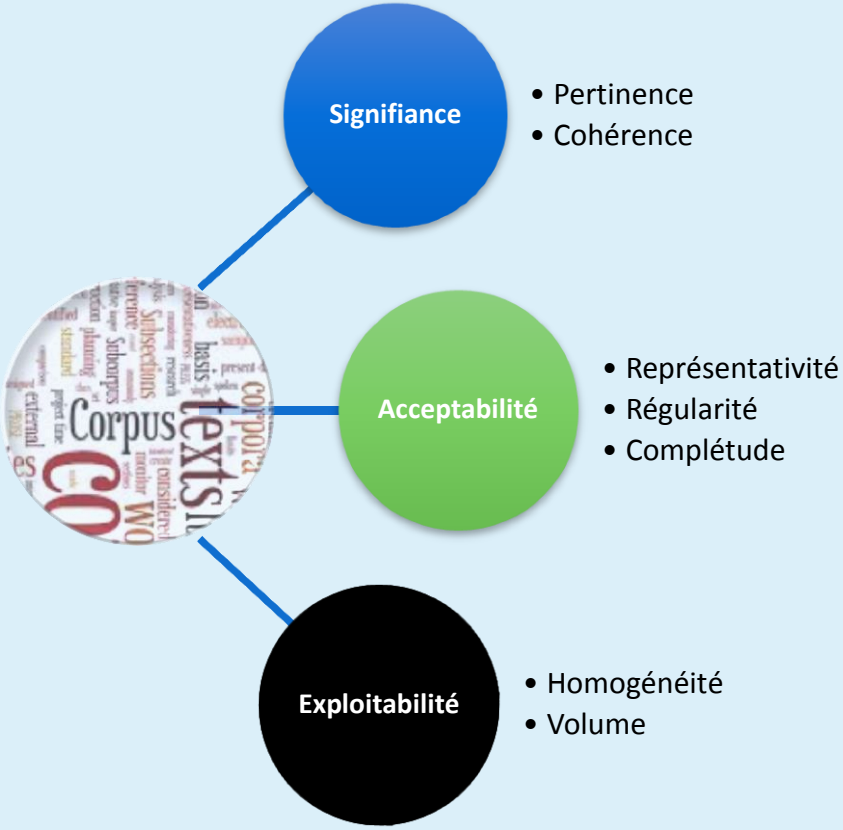


BOMMIER-PINCEMIN Bénédicte (1999) – Diffusion ciblée automatique d'informations : conception et mise en oeuvre d'une linguistique textuelle pour la caractérisation des destinataires et des documents, Thèse de Doctorat en Linguistique, Université Paris IV Sorbonne, 6 avril 1999

# Caractéristiques (règles)

| | |
|---|---|
| Pertinence | **Règle** - « Les documents retenus doivent être adéquats comme source d'information pour correspondre à l'objectif qui suscite l'analyse. (Bardin 1977, §III.I.1, p. 128) |
| Cohérence | **Règle** - représentativité d'une entité ayant un ou plusieurs caractères communs (sans trop de singularité) |
| Représentativité | **Règle** - un échantillonnage rigoureux (équilibré/diversité maximale) dont les résultats sont généralisables à tout l'ensemble (recherche de diversité maximale) |
| Régularité | **Règle** - non sélectivité : ne pas permettre d'exceptions pour éviter des écarts d'analyse (manques, excès, éléments étrangers) |
| Complétude | **Règle** - un niveau de détail adapté aux besoins de l'analyse |
| Homogénéité | **Règle** - toutes les grandeurs recensées [variations] sont des quantités de même nature |
| Volume | **Règle** - important pour des analyses statistiques voulues significatives |

# ÉLÉMENTS MÉTHODOLOGIQUES

- Les corpus dans la pratique de la recherche
- Approches méthodologiques : quantitative Vs Qualitative
- Interdisciplinarité SIC/SHS

# Recherche fondamentale et/ou appliquée ?

- Historiquement deux courants rivaux (Monde académique vs monde industriel) ;
- Aujourd'hui, la ligne de démarcation est encore très floue (OCDE, 2003)
- Consensus sur une nouvelle conception de la recherche fondamentale (OCDE, 2003*) ;
- La Recherche fondamentale consiste en « *des travaux expérimentaux ou théoriques entrepris essentiellement en vue d'acquérir de nouvelles connaissances sur les fondements de phénomènes ou de faits observables, sans qu'aucune application ou utilisation pratiques ne soient directement prévues.* » (Journal officiel 2006/C 323/01 du 30/12/2006)

  - *Fondée à la fois sur la curiosité pure, sans aucune application en vue, et la recherche inspirée par des applications éventuelles*

  - *Couvre l'ensemble des types de recherche nécessaire au développement d'un corpus cohérent de savoir pouvant se traduire en avancées socioéconomiques.*


OECD. Gouvernance de la recherche publique : Vers de meilleures pratiques. OECD Publishing; 2003.

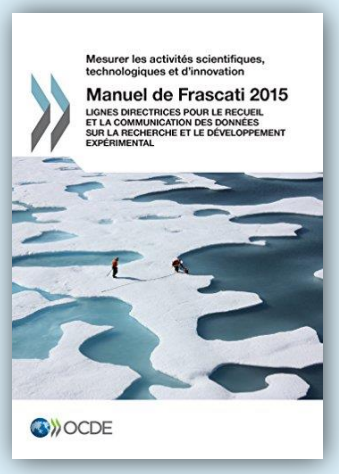


Collectif. Manuel de Frascati 2015: Lignes directrices pour le recueil et la communication des données sur la recherche et le développement expérimental. OECD; 2016

OECD. Gouvernance de la recherche publique Vers de meilleures pratiques: Vers de meilleures pratiques. OECD Publishing; 2003. 181 p.

# Recherche fondamentale et/ou appliquée ?

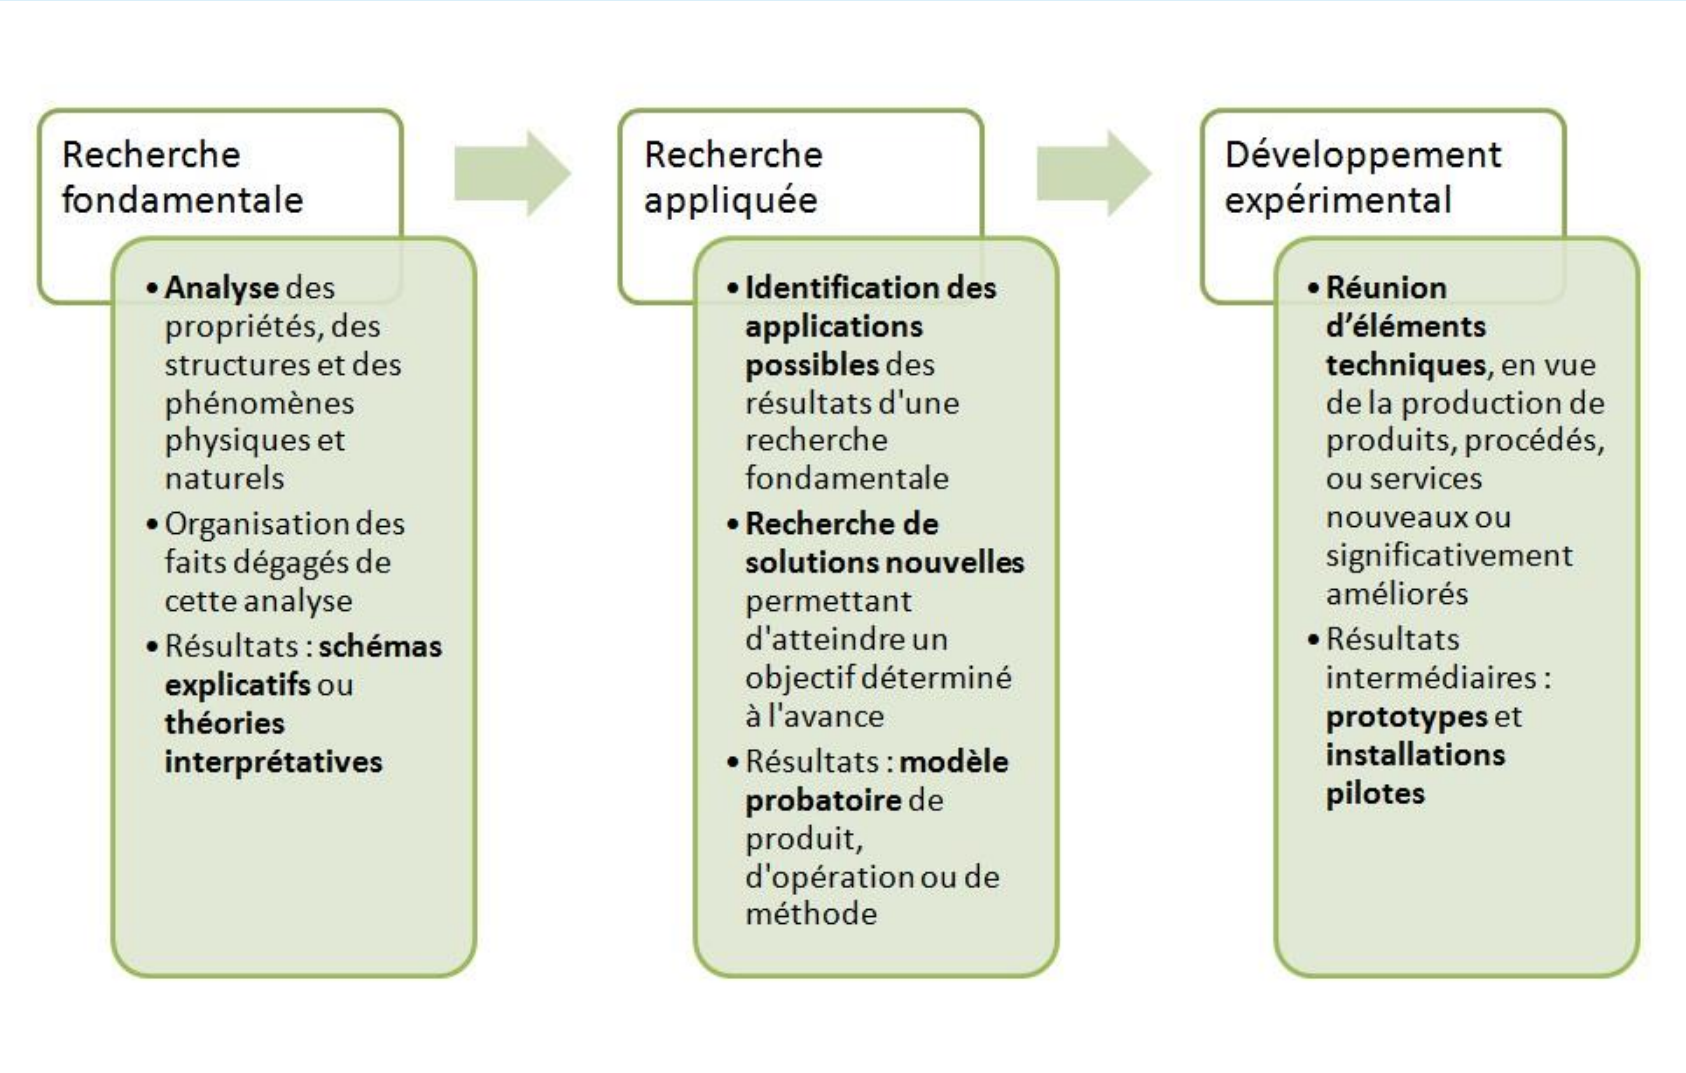

# Corpus dans le processus méthodologiques de la Rech.

- Le choix s'opère au moment de l'élaboration des hypothèses et des questions de recherche
- Approche quantitative ou déductive
  - *Cohérence avec les hypothèses ou théories identifiées en prémisse par le chercheur*
  - *Précise la formulation des hypothèses*
  - *De l'anticipation par rapport aux résultats.*
- Approche qualitative ou inductive (théorie de l'induction):
  - *Phénoménologie : une vision du monde où la réalité est multiple*
  - *Paradigme constructiviste*
  - *Aboutir à une idée par généralisation et non à partir d'hypothèses préétablies.*
- Approche mixte ?

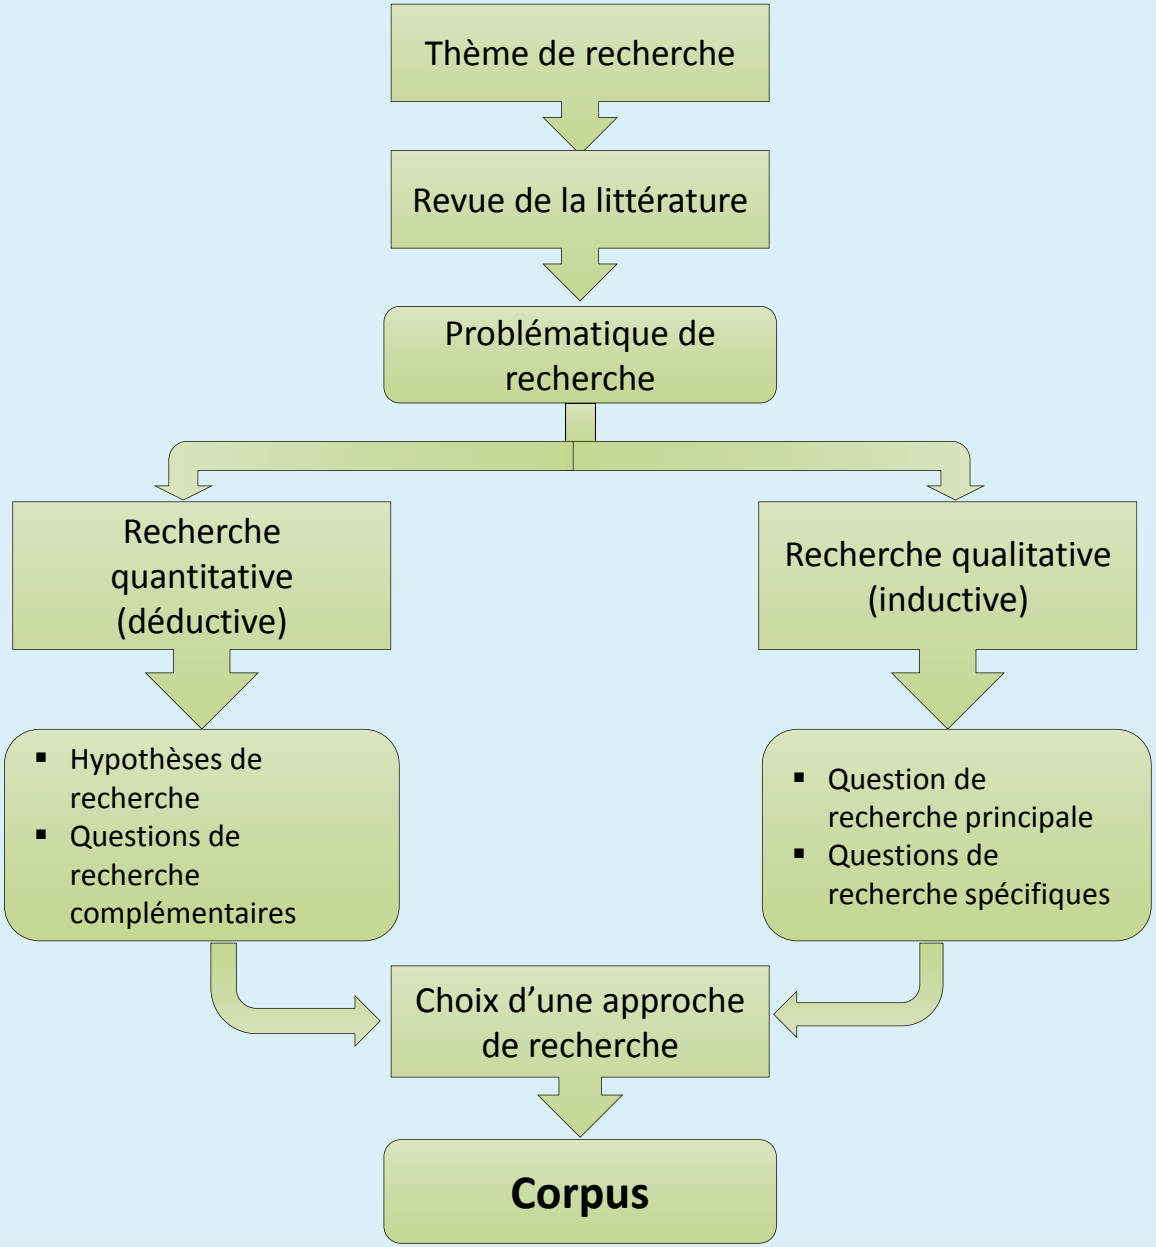

# Facteurs tangibles

- La faisabilité d'une étude se construit en fonction :
  - *des objectifs fixés au départ ;*
  - *des choix méthodologiques ;*
  - *du terrain (périmètre) à étudier ;*
  - *des méthodes d'enquête/analyse ;*
  - *du positionnement du chercheur par rapport à son corpus d'étude ;*
  - *de sa capacité à adapter ses choix aux obstacles,*
- Les choix méthodologiques impactent :
  - *Le recueil des données ;*
  - *L'échantillonnage et la représentativité ;*
  - *L'analyse des données ;*
  - *L'exploitation des résultats.*

# Grandes questions pour le chercheur

**La nature du corpus**

- Sa sélection, sa construction, son organisation, sa hiérarchisation

**Le conditionnement des pratiques méthodologiques**

- Les choix effectués quant à la constitution du corpus et réciproquement, cadre théorique et/ou pratique préalable et adaptabilité à la réalité du terrain

**Le positionnement épistémologique du chercheur**

- L'implication du sujet-chercheur dans son corpus : distanciation par rapport à l'objet, explicitation des choix méthodologiques

**La finalité sociale et scientifique de la recherche**

- L'articulation de cette méthode avec le rôle social de la recherche

# Risque majeur pour le chercheur

« Les dangers liés à une mauvaise gestion des finalités d'une recherche consisteraient par exemple à ne développer à partir de son corpus que les caractéristiques, les tendances corroborant la/les hypothèses que l'on s'est forgées, à n'y « trouver » que ce que l'on souhaite par avance, laissant de côté les résultats des analyses des cas non conformes aux hypothèses, ceux que le chercheur ne comprend pas et/ou qui contredisent ses thèses »

(Le gal, 2011)

Le Gal, D. Méthodes qualitatives et corpus : quelle mise en œuvre ? In : Patrascu, M., Brusq, J., Canivenc, S., Le Gal, D. (dir.). Corpus et méthodes : épistémologies critiques et appropriations multidisciplinaires. Paris : L'Harmattan, 2011, p.35

# Approche quantitative (déductive)

- S'effectue sur des données recueillies (les variables) mesurables :
  - *Données d'enquête (sondages, questionnaires, données statistiques préexistantes) ;*
  - *Données produites par encodage numérique (documents d'archives, dossiers administratifs, sources sonores ou visuelles) ;*

- A pour finalité :
  - *D'étayer une théorie/hypothèse ;*
  - *D'accompagner un raisonnement de recherche dans sa démarche empirique ;*
  - *Déterminer la relation générale entre un énoncé (variable) et une autre variable indépendante dans un corpus donné ;*
  - *Obtenir des informations qui peuvent être déduites d'un échantillon puis généralisées à de larges populations d'unités (corpus existant).*

# Approche qualitative (inductive)

- Utilise des techniques variées :
  - *entretiens individuels semi-directifs approfondis ;*
  - *discussions de groupe (« focus groups ») ;*
  - *analyse de contenu ;*
  - *observation participative ;*
  - *histoires ;*
  - *récits de vie…*
- Se ressource dans le courant constructiviste :
  - *Le constructivisme brise la conception ontologique (métaphysique) de la réalité qui existerait en elle-même, indépendamment de nous ;*
  - *Le constructivisme **radical** : la réalité n'existe pas en dehors de notre imagination. Elle raisonne plutôt en termes d'interactions complexes entre les usagers entre eux et avec l'environnement socialement et historiquement construit (y compris les dispositifs sociotechniques).*

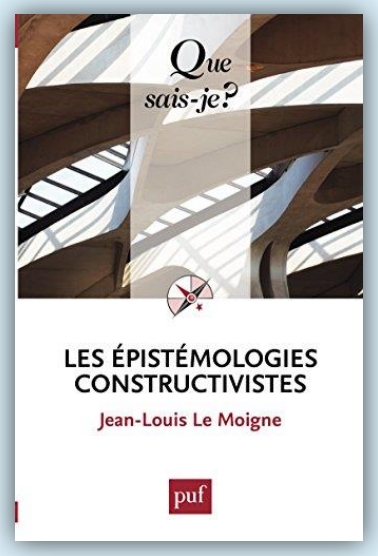


Moigne J-LL. Les épistémologies constructivistes: « Que sais-je ? » n° 2969. Presses Universitaires de France; 2012.

# Approche qualitative (inductive)

- Les dix conditions d'une analyse qualitative (Paillé, 2011*)

| | |
|---|---|
| **Approche terrain** | éviter les hypothèses théoriques ➔ alternance collecte/analyse et ancrage dans les données empiriques du contexte |
| **Logique de proximité** | avec les phénomènes observés, les acteurs, le contexte et le chercheur |
| **Travail de l'esprit** | seul l'esprit humain peut extraire le plus de sens d'une donnée brute |
| **Quête de sens** | un mot n'a pas de valeur absolue, son sens est de l'ordre d'une transaction issue d'une interprétation |
| **Pratique artisanale** | « artiste », « artisan » et « technocrate » |
| **Orientation clinique** | centrée sur le cas comme phénomène singulier |
| **Visée pragmatiste** | obéir plus aux règles d'une pratique qu'aux règles d'une science |
| **Optique interprétative** | fixation sur les objets au détriment des méthodes |
| **Finalité narrative** | nature dialogique : « une chaine de paroles, par laquelle se constitue une communauté de culture et par laquelle cette communauté s'interprète elle-même par voie narrative » (Ricoeur, 1986) |
| **Démarche explicite** | Mais pas trop formaliste, avec des opérations repérables et des règles de décision manifestes et constamment soumises à révision |

Pierre Paillé, « Les conditions de l'analyse qualitative », SociologieS [En ligne], La recherche en actes, Champs de recherche et enjeux de terrain, mis en ligne le 06 juillet 2011. consulté le 29 janvier 2018. URL : http://journals.openedition.org/sociologies/3557

# Un dilemme méthodologique !

- Approche empirico-inductive ou hypothético-déductive ?
- **Inductive** ? priorité aux pratiques réelles, au contexte social :
  - *Ce n'est qu'une fois les faits observés, les données recueillies, que les concepts théoriques sont introduits pour expliquer et interpréter les phénomènes examinés ;*
  - *« les chercheurs tentent de développer une compréhension des phénomènes à partir d'un tissu de données, plutôt que de recueillir des données pour évaluer un modèle théorique préconçu ou des hypothèses à priori » (Blanchet, 2000 : 30)**
  - *La réalité n'existe pas en soi, elle est socialement construite par un ensemble d'opérations (praxéologie), des processus sociaux et d'informations sociales dont nous n'avons pas nécessairement conscience ;*
  - *La qualité de la recherche, selon une conception constructiviste, dépend de la capacité du chercheur à adapter son analyse au vu des résultats, et de prendre conscience de cette dépendance entre méthode et résultats. Ce dernier principe correspond à celui de la « récursivité de la connaissance » (Mucchielli, 2006)*

* BLANCHET P., 2000, La linguistique de terrain, méthodes et théories une approche ethno sociolinguistique, Presses universitaire de Rennes, 145 pages

# Un dilemme méthodologique !

- *Les objets techniques sont ce que Bruno Latour (1991) appelle « hybride socio-technique »,*
- *C'est ce que Michel Foucault appelle « dispositifs » : « un ensemble résolument hétérogène, comportant des discours, des institutions, des aménagements architecturaux, des décisions réglementaires, des lois, des mesures administratives, des énoncés scientifiques, des propositions philanthropiques, bref : du dit aussi bien que du non-dit » (Foucault, 1977 : 299)*
- *« La connaissance (…) ne peut être le résultat de la réception passive, mais constitue au contraire le produit de l'activité d'un sujet » (Von Glasersfeld, 1988)*
- *« La conception constructiviste du monde est potentiellement libératrice, au sens où elle permet à ceux qui l'adoptent d'exploiter leur potentiel créatif » (Segal, 1990).*

# Un dilemme méthodologique !

- **Déductive ?** accorder sa priorité aux expériences :
  - *L'observateur ne peut qu'introduire des « biais », ou au minimum une distorsion, dans la réalité observée :*

    ➔ danger pour une observation « pure » (paradoxe de l'observateur neutre)
  - *Les connaissances découlent directement et exclusivement de l'observation de l'expérience ;*
  - *Très pratiqué dans les sciences de la nature, en médecine, physique ou chimie :*
    - La médecine est l'adepte principal de la pratique fondée sur les évidences, son influence se traduit par un soutien prépondérant de la méthode quantitative de recherche ;
    - « considérée habituellement comme synonyme du positivisme, engagée envers la découverte de lois universelles, utilisant une théorie neutre d'observation basée sur la mesure » (Hunt, 2011*)

Hunt, Elena, et Anne-Marise Lavoie. « Les méthodes de recherche quantitatives et qualitatives peuvent-elles déjà coexister ? », Recherche en soins infirmiers, vol. 105, no. 2, 2011, pp. 25-30

# Regard sur la pratique qualitative en SHS

> « l'analyse qualitative comme théorie et comme pratique est pratiquement invisible au sein de la sociologie française et même, ce qui est pire, au sein des comptes rendus d'enquête et, pire encore, au sein des ouvrages méthodologiques sur la conduite de l'enquête » (Paillé, 2011)

- Le paradoxe : on ne peut s'imprégner d'un corpus de recherche au point que l'interprétation se donne d'elle-même (solidité, justesse et validité) ;
- Ce serait adopter une optique positiviste (objectivation/certitude) que de penser que les opérations d'analyse sont productrices en soi du sens ?
- Des recommandations ?

  - *Dissiper le flou méthodologique autour des opérations d'analyse et d'interprétation des matériaux étudiés ;*
  - *Prolonger les opérations d'analyse vers la mise à jour du sens ;*
  - *Optimiser l'usage des logiciels dans les méthodes d'analyse ;*
  - *S'aligner sur des normes de travail validées (acceptions sociale et technique)*

Pierre Paillé, « Les conditions de l'analyse qualitative », SociologieS [En ligne], La recherche en actes, Champs de recherche et enjeux de terrain, mis en ligne le 06 juillet 2011. consulté le 29 janvier 2018. URL : http://journals.openedition.org/sociologies/3557

# La solution mixte : la voie du compromis !

- Toute vision hiérarchique ou exclusive de ces deux approches est litigieuse (Lafflame, 2007*)

- « Une procédure mixte est justifiable … dans un travail interprétatif raisonné et hautement réflexif » (Franceschini, dans Mahmoudian ; Mondanda, 1998).

- Les deux approches sont essentielles aux SHS :

  - *La quantification peut conduire à la vérité, l'observation rigoureuse en est aussi capable ;*
  - *Elles ont les mêmes impératifs de la rigueur scientifique (triangulation) ;*
  - *Elles questionnent la représentativité de leurs résultats ;*
  - *Elles peuvent être complémentaires en :*
    - Vérifiant différemment une hypothèse comparable ;
    - Ouvrant à la recherche des univers dissemblables ;
    - Vérifiant ce qui a été découvert avec l'approche opposée, ex. :

Simon Laflamme. Nouvelles perspectives en sciences sociales : revue internationale de systémique complexe et d'études relationnelles, vol. 3, n° 1, 2007, p. 141-149

# Le quantitatif en SHS (Brest)

- « Depuis les années 1990 les chercheurs en sciences humaines et sociales ont multiplié de nouvelles façons de produire et de traiter les données allant de paire avec l'émergence, la généralisation d'outils informatiques puis d'internet.
- Les corpus de sciences humaines et sociales ont la particularité d'une certaine **hétérogénéité** et une des difficultés réside dans le fait de les mettre en lien entre elles.
- Il s'agit de croiser nos expérimentations en décloisonnant les préoccupations disciplinaires pour prendre au sérieux d'emblée dans nos protocoles de recherche le triptyque corpus/outils d'analyse/traitements qui déterminent les conditions de production des données ».

http://outiquanti.hypotheses.org/

# Méthode François Rastier

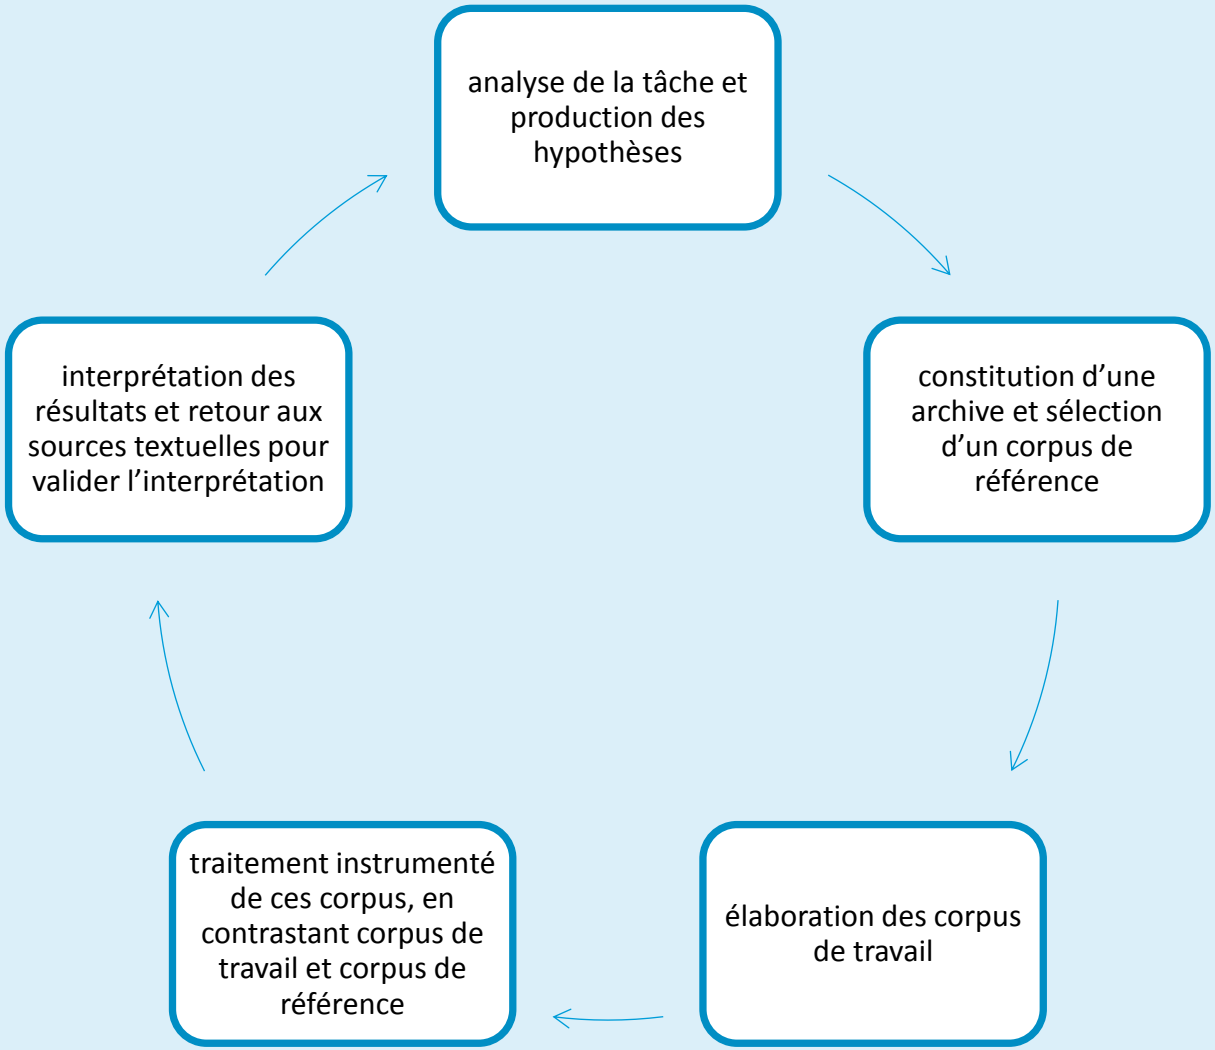


François Rastier. La Mesure et le Grain. Sémantique de corpus, Paris: Editions Honoré Champion, coll. "Lettres numériques" n12, 2011.

# Consignes méthodologiques en SHS

- Prendre du recul et revoir sa méthodologie au fur et à mesure des résultats (pertinence)
- Retenir qu'une science n'est pas figée et qu'elle s'enrichit dans la confrontation aux autres sciences (mutualité)
- Tenir compte de l'approche interdisciplinaire pour adopter les différents points de vue des autres champs du savoir
- Respecte les méthodes propres à sa propre discipline de façon à valider ses résultats
- Cultiver sa spécificités tout en gardant l'esprit ouvert. (Mucchielli, 2006)

# La trans-multi-interdisciplinarité en SHS

- Quelques citations :

  - *Claude Lévi-Strauss (1958 ; 1962) invitait, au nom de la méthode du bricolage, à établir des connexions entre l'anthropologie, la linguistique, la littérature, l'art, la psychologie, le droit, la religion, etc.*

  - *Edgar Morin incite, au-delà même de la transdisciplinarité, à « écologiser les disciplines » en tenant compte de « tout ce qui est contextuel y compris des conditions culturelles et sociales » et en adoptant parfois un point de vue « métadisciplinaire » ;*

  - *« Le renoncement à la complétude et à l'exhaustivité est une condition de la connaissance de la connaissance » (Morin, 1986) ;*

  - *« Toute certitude fondamentale et toute croyance en un achèvement de la connaissance doivent être éliminées à jamais » (Morin, 1991) ;*

  - *« Il est possible de construire une transversalité entre plusieurs disciplines, à condition de le faire d'un lieu géométrique, d'un lieu disciplinaire, faute de quoi il n'y aurait plus de validation possible du savoir » (Charaudeau, 1997, P. 12 - 13) ;*

# Les SIC : le 'tourment' épistémologique

- Les SIC s'inscrivent très tôt dans une double voie :

- L'interdisciplinarité :
  - *Norbert Wiener (Cybernétique), Shanon et Weaver (Science de la transmission et du traitement du signal, Herbert Simon (Processus de décision opérationnelle) reconnus parmi les fondateurs des SIC ;*
  - *En 1993, le Conseil National des Universités (CNU) définit les Sciences de l'Information et de la Communication (SIC) comme une science interdisciplinaire ;*
  - *« une science d'adjonction, c'est-à-dire une science inter, trans et pluridisciplinaire » (Miège, 2004)*

- L'épistémologie constructiviste :
  - *« Nous construisons la réalité, nous l'inventons plus que nous la découvrons : « avec le constructivisme (…) toute prétendue réalité est (…) la construction de ceux qui croient l'avoir découverte » (Watzlawick, 1988) ;*
  - *Ces « nouvelles sciences » vont ainsi être à l'origine du renouvellement du constructivisme et du qualificatif « radical » qui lui est désormais accolé. Elles vont en effet impulser une véritable « entreprise de reconstruction épistémologique, adaptant la science contemporaine à la production de connaissances-processus plutôt qu'à la découverte de savoirs stables » (Le Moigne, 2001).*

Franck Cormerais, Olivier Le Deuff, Amar Lakel et David Pucheu, « Les SIC à l'épreuve du digital et des Humanités : des origines, des concepts, des méthodes et des outils », Revue française des sciences de l'information et de la communication [En ligne], 8 | 2016, mis en ligne le 23 mars 2016, consulté le 31 janvier 2018. URL : http://journals.openedition.org/rfsic/1820

# Éléments techniques

- TIC et corpus numériques
- Les corpus dans l'histoire des Humanités numériques
- Normes de balisage de corpus
- La TEI, une solution au cœur des corpus numériques
- Démo d'exemples pratiques

# Corpus : éléments techniques

- Internet : notion de « Web as Corpus » [La Toile en tant que Corpus] ;
- *WebBootCaT* : un exemple d'outil de siphonage permettant la création de corpus ;
- Toute récolte numérique nécessite beaucoup de travail avant de pouvoir prétendre au nom de corpus.


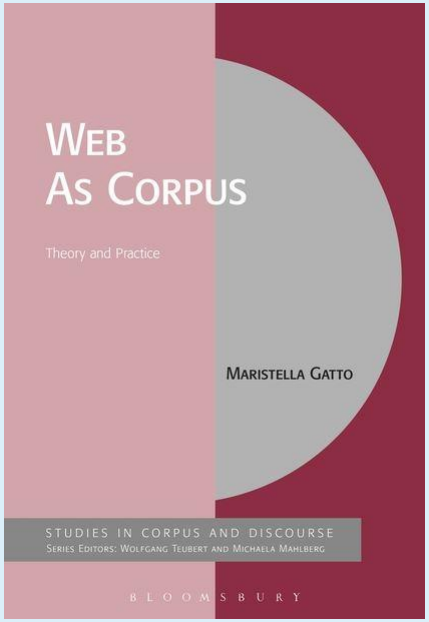


Gatto M. Web As Corpus: Theory and Practice. A&C Black; 2014. 255 p.

# Nouveautés : sources, Processus, techniques

- Le numérique des données :
  - *Plus de données observables ;*
  - *Plus d'alternatives de constitution de corpus ;*
  - *Au cœur des Humanités numériques*

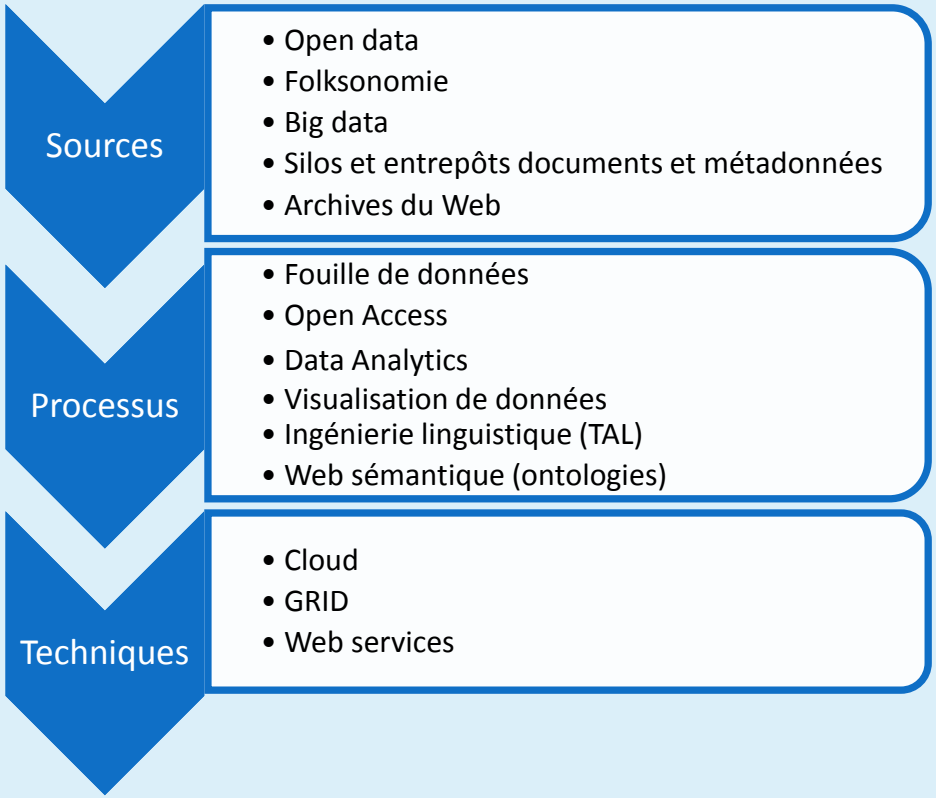


« Les humanités numériques désignent un dialogue interdisciplinaire sur la dimension numérique des recherches en sciences humaines et sociales, au niveau des outils, des méthodes, des objets d'études et des modes de communication » (Marin Dacos et Pierre Mounier, 2014)

# Nouveaux enjeux, nouveaux défis

- Tenir compte des dangers de la « technologisation » liés aux corpus :
  - *Des peurs épistémologiques :*
    - Peur de non représentativité (mythe de l'universalité des phénomènes) ;
    - Peur de non exhaustivité (mythe de l'exhaustivité de l'analyse),
  - *Nouveaux supports de données :*
    - Le papier connecté (nouvelle frontière entre numérique et papier) ;
    - Réalité virtuelle / réalité augmentée (données de synthèse) ;
  - *Complexité des ressources scientifiques :*
    - Nouveaux styles artistiques (eg. NetArt) ;
    - Nouveaux genres littéraires (eg. Dark Romance, SteamPunk) ;

# Nouveaux enjeux, nouveaux défis

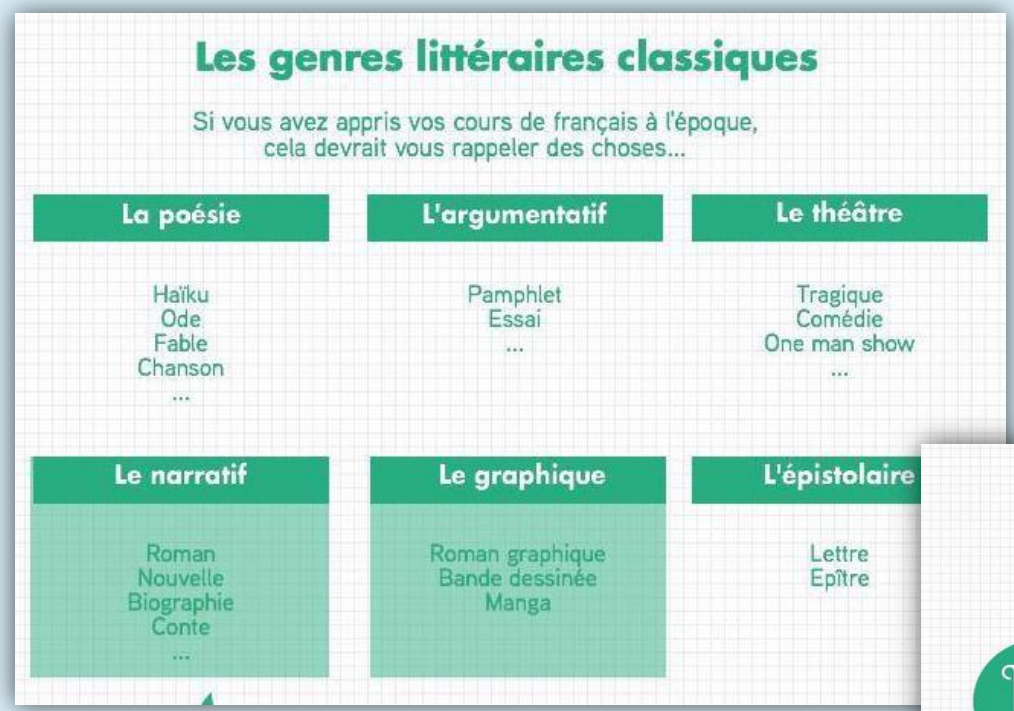


# Nouveaux défis, nouvelles mesures

- Trouver des nouvelles mesures de gestion de corpus numériques conformes aux spécifications RAID :
  - *Réutilisables ;*
  - *Adaptables ;*
  - *Interopérables ;*
  - *Durables.*
- Produire des formes de normalisation et de standardisation (des référentiels normatifs communs) :
  - *qui rendent les données de la recherche intelligibles, compatibles et exploitables entre elles (linked data)*
  - *qui permettent de préserver, exploiter, produire et diffuser de données constitutives d'un patrimoine culturel (corpus, archives, bases de données, systèmes documentaires, etc.)*

# Référentiel normatifs pour corpus HN

- **ADeX** – Archaeological Data eXchange: Standard for the exchange of archaeological subject data
- **CEI** – Charters Encoding Initiative: Standard for encoding historical charters
- **TEI** – Text Encoding Initiative: Standard for encoding textual data
- **EpiDoc** – Epigraphic Documents: Standard for encoding epigraphic inscriptions in TEI XML
- **CIDOC-CRM** – CIDOC Conceptual Reference Model: Ontology for cultural heritage data
- **MEI** – Music Encoding Initiative: Standard for encoding music scores

# La TEI, au cœur des HN

- Les promoteurs des HD proposent de vulgariser certaines approches et règles de bonnes pratiques existantes ;
- L'une des premières « bonnes pratiques » est l'application informatique d'un schéma d'encodage normalisé à des textes numériques en SHS ;
- La TEI (Text Encoding Initiative) est ainsi née ;
- Définies en 1987, les premières directives de la TEI (TEI Guidelines) ont été publiées en Mai 1994 par Lu Burnard
  - *« Nous travaillons sur le texte, qui représente un discours, raconte une histoire, et tâchons d'expliquer ces histoires, ces contes, ces représentations » (Burnard, 2012)*
  - *« Nous sommes des experts de la maïeutique du texte, et c'est précisément ce qui définit la contribution des sciences humaines et sociales à l'élaboration du Web sémantique » (Burnard, 2012).*

Lou Burnard, « Du literary and linguistic computing aux digital humanities : retour sur 40 ans de relations entre sciences humaines et informatique », in Pierre Mounier (dir.), Read/Write Book 2, Marseille, OpenEdition Press (« Collection « Read/Write Book » »), 2012, p. 45-58

# La TEI, rencontre historique avec les HN

- 1960-1980 : *literacy and linguistic computing*
  - *La **statistique des textes** (Occurrences, concordances, fréquences des mots dans les textes (Index Thomisticum / Brown Corpus) ;*
- 1980-1994 : *text encoding (langages de balisage) ;*
  - *Représentation numérique des ressources du monde réel (livres, objets d'art…)*
  - *Émergence des langages de documents structurés (GML, ODA, SGML, TEI)*
- 1994- : *Les Humanités digitales ;*
  - *Bibliothèques numériques, GRID, Cloud, Folksnomie ;*

Les « humanités délivrées » Cultures parlées, visuelles et écrites, réinventées hors du livre 1-2 octobre 2013, Amphimax 414, Université de Lausanne

# TEI : heuristique de construction du sens

- La TEI est une recension aussi large que possible des pratiques d'encodages et d'annotation de textes, et propose une normalisation des balises pour tous ces besoins et une formalisation de leur définition ;
- Méthode :
  - *on commence par se mettre d'accord sur la nature des faits à représenter, puis on définit les solutions d'exprimer ce consensus ;*
  - *Introduire dans le texte, au moyen d'un ensemble conventionnel d'étiquettes lisibles, des indicateurs de caractéristiques textuelles (annotation) ;*
- L'annotation :
  - *Tout corpus est intrinsèquement annoté ;*
  - *Un acte linguistique, interprétatif ;*
  - *Une structuration très simple peut supporter plusieurs niveaux d'annotation complexe*

# TEI : structuration générale de corpus

- Marquage des caractéristiques structurelles sous-jacentes d'un texte (phrases, paragraphes, sections, notes de bas de page, etc.).

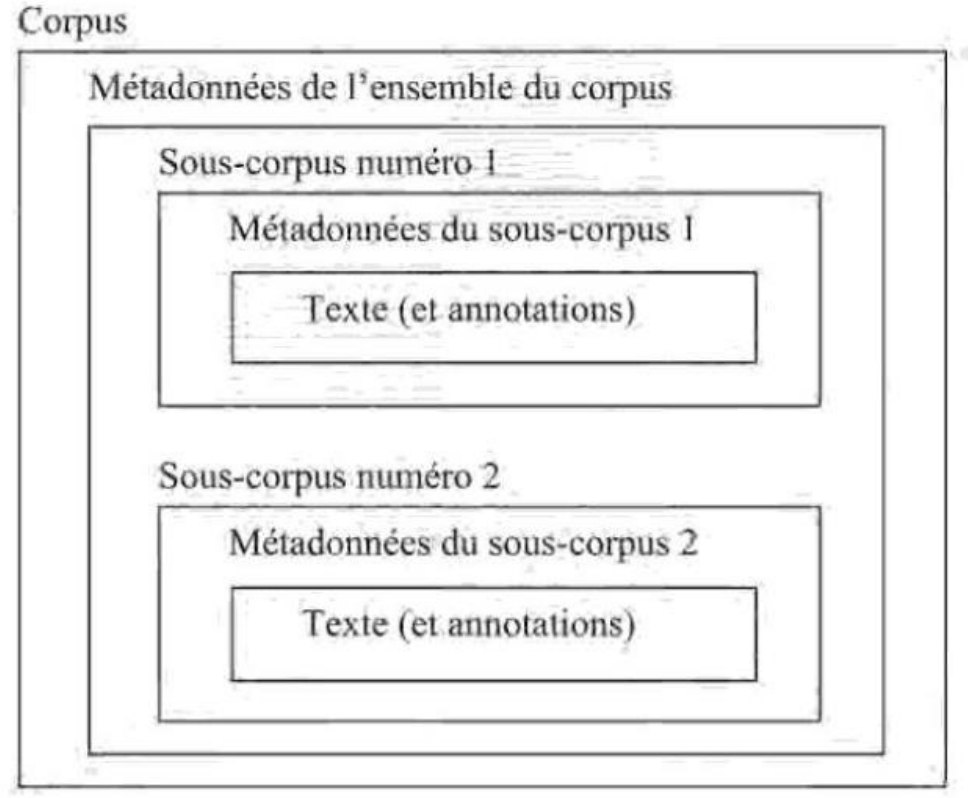


Poudat C, Landragin F. Explorer un corpus textuel: Méthodes - pratiques - outils. Paris: De Boeck Superieur; 2017. 243 p.

# TEI : logique hiérarchique

- Trois niveaux de représentation
  - *Niveau 1 : Tous les corpus de référence disposent d'un minimum de structure commune (Core TAG SET)*
  - *Niveau 2 : Les corpus de référence peuvent avoir des sous-corpus d'étude par genres ou types disposant d'un minimum de points communs (Base TAG SET)*
  - *Niveau 3 : Chaque sous-corpus d'étude peut avoir de corpus spécifiques*

# TEI: logique structurelle

- Structure minimaliste (inspiration livresque)

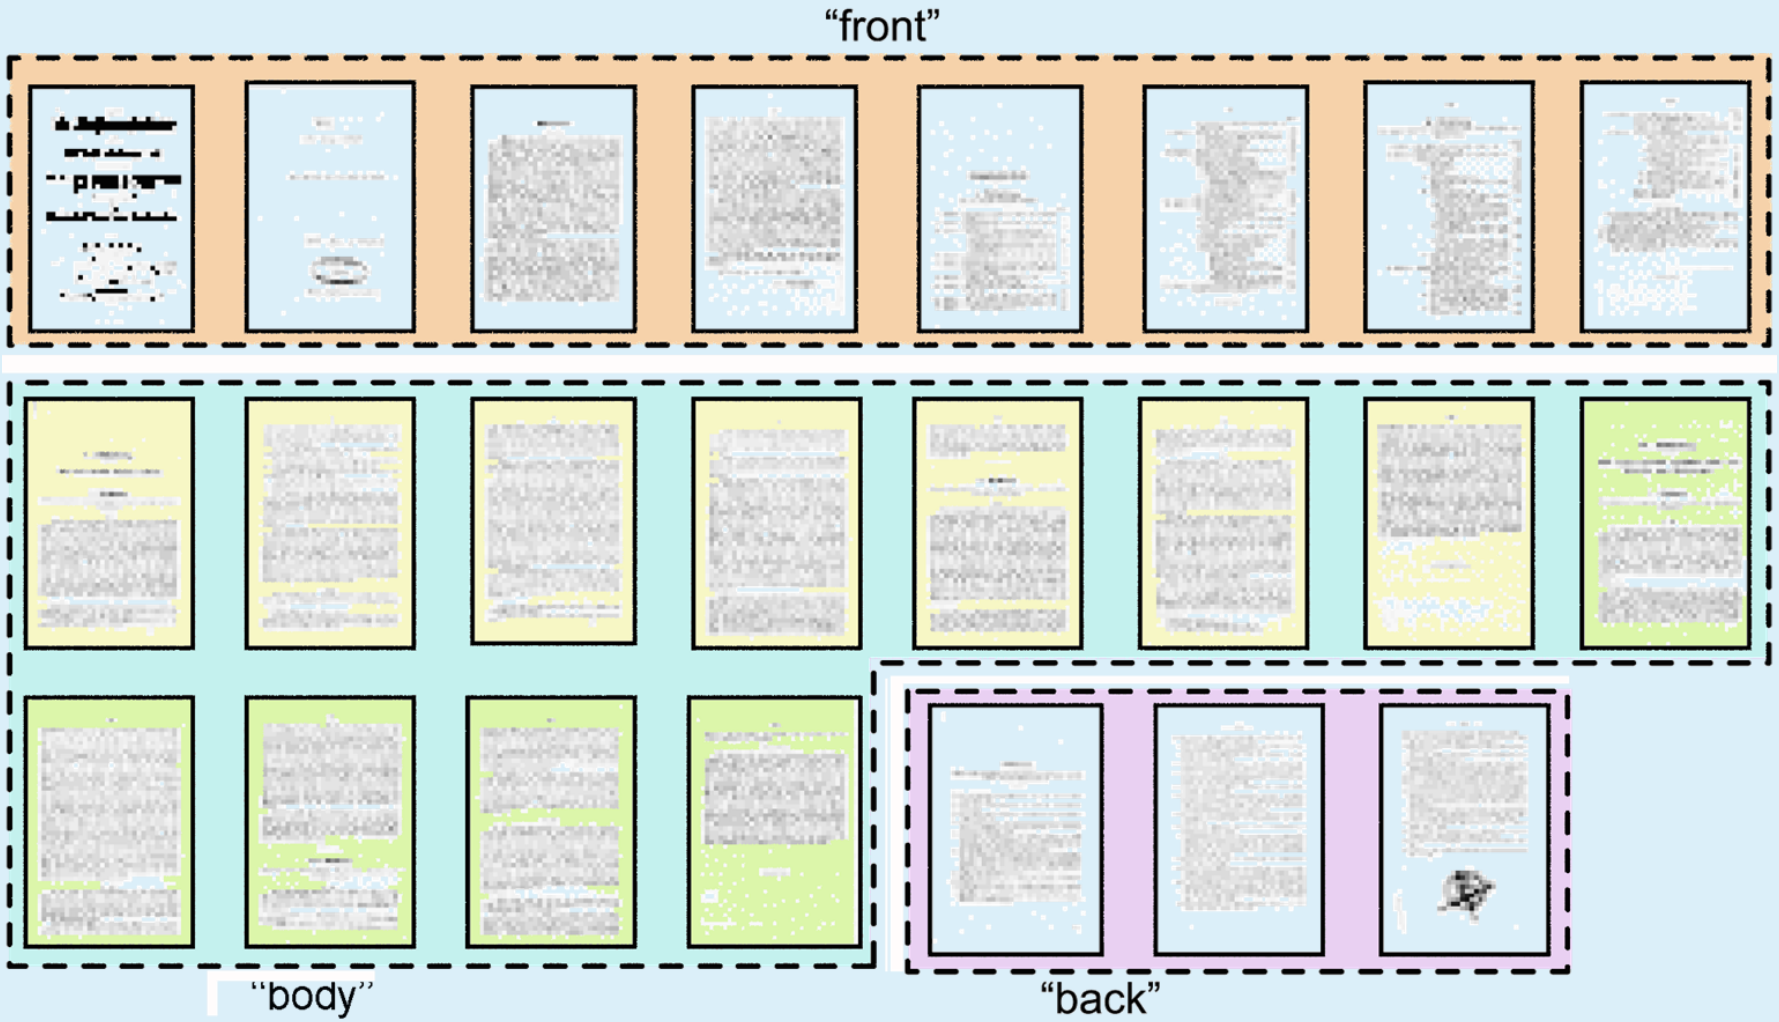

# TEI : anatomie textuelle

Zone en-tête (métadonnées) : Données bibliographqiues, Techniques, administratives, métadonnées sur la ressources numériques ou analogique,

Le corps du document (texte, image, son, vidéo). Subdivisé en:

Liminaires : page de titre, table des matières, préface, dédicace etc

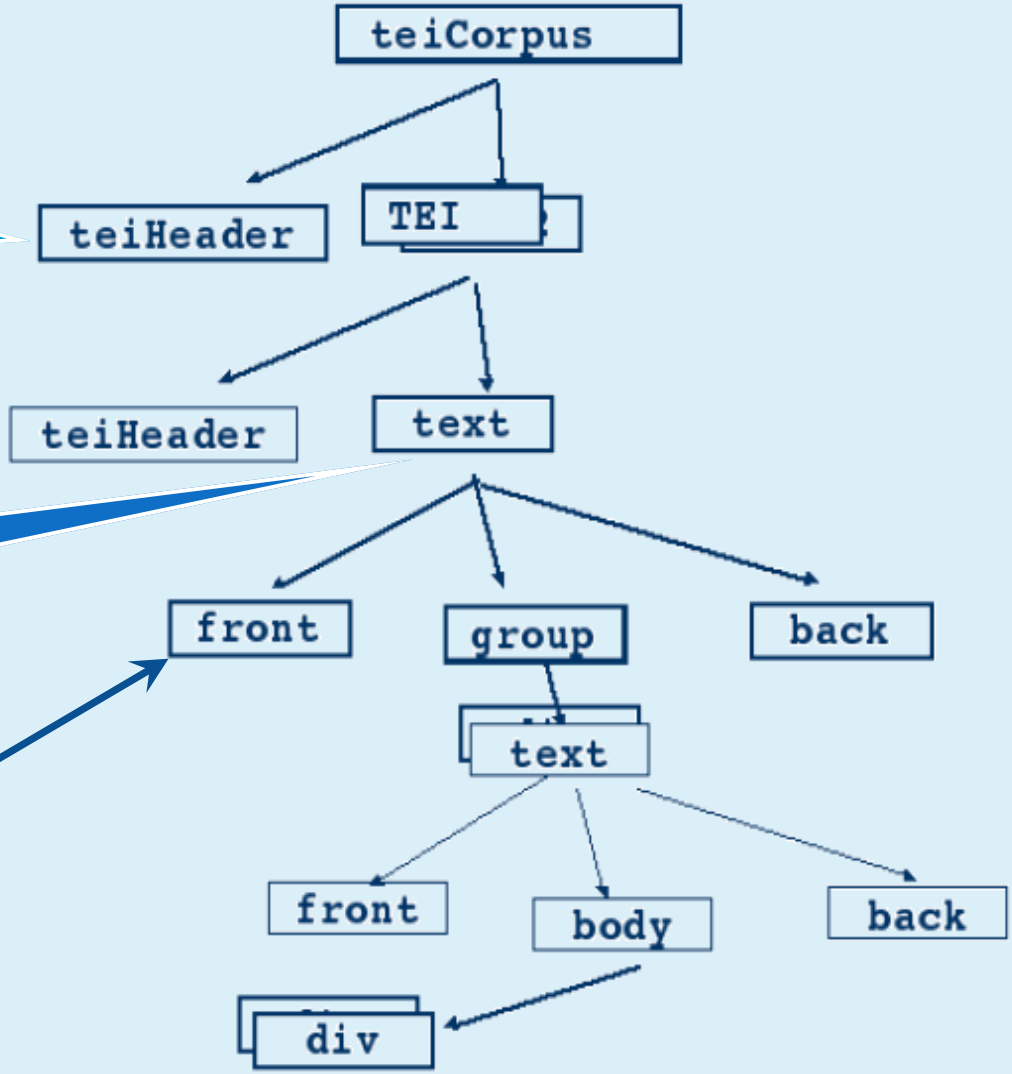

# Annotation d'un poème (TEIVerse)

- Identifier dans un poème
  - *La mesure des vers*
  - *Les différents types de vers*
  - *Les groupes de verts (couplets, quatrains)*
  - *La strophe*
  - *La forme de la strophe*
  - *La rime*
  - *L'enjambement*
  - *Le rejet et le contre-rejet*
  - *…*

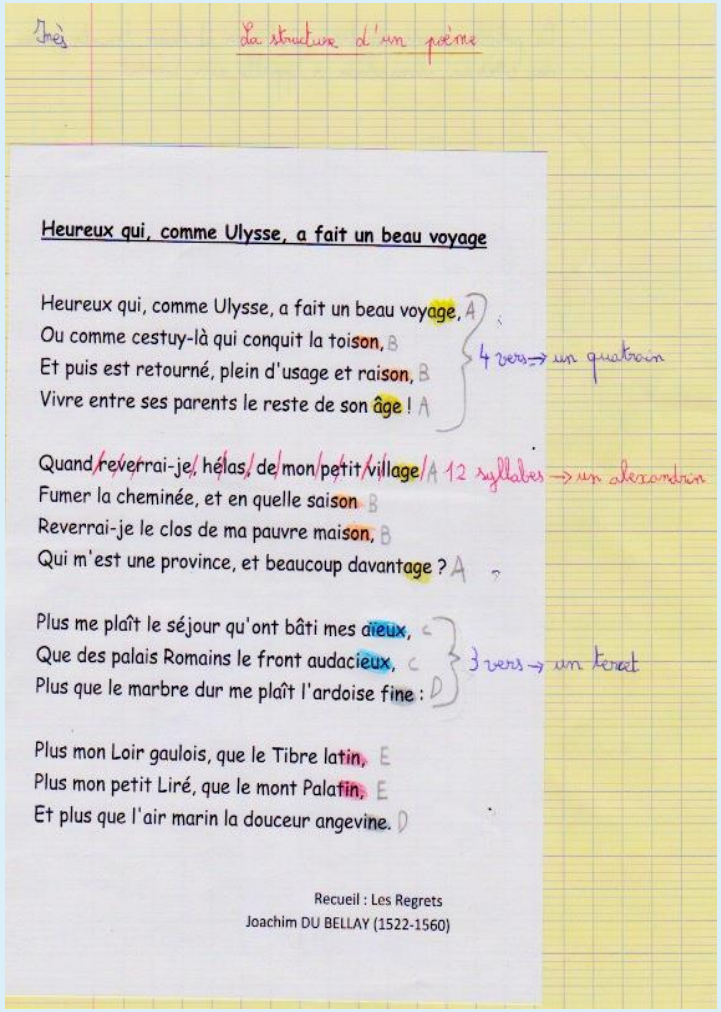


Le choix du niveau de granularité peut varier entre grands segments et éléments plus petits

# Annotation d'une pièce de théâtre (TEIDrama)

- Identifier dans une pièce de théâtre :
  - *L'interprétation et la mise en scène*

<acte 1>**ACTE PREMIER**

<Trait>————</trait>

<scène 1>**SCENE I**

<didascali>
<groupe de lignes n°1>
<ligne><lieu>Elseneur</lieu> — Une plate-forme devant le château</ligne>
<ligne>FRANCISCO montant la garde, BERNARDO vient à lui</ligne>
</fin de groupe de lignes>
</didascali>.
<groupe de lignes n°2>
<Acteur 1>BERNARDO . — Qui va là?</acteur>
<Acteur 2>FRANCISCO . — Non, répondez vous-même. Arrêtez-vous et faites-vous reconnaître. </acteur>
<Acteur 1>BERNARDO . — Vive le roi ¡ </acteur>
<Acteur 2>FRANCISCO . —Bernardo ? </acteur>
<Acteur 1>BERNARDO . — En personne. </acteur>
<Acteur 2>FRANCISCO . — Vous venez très soigneusement à votre heure. </acteur>
<Acteur 1>BERNARDO . — Minuit vient de sonner : va regagner ton lit, Francisco. </acteur>
<Acteur 2>FRANCISCO . — Pour cette délivrance, mille grâces. Le froid est aigre, et j'ai le cœur aussi</acteur>
</fin de groupe de lignes>
…
</fin de scène I>
…
</ fin de l'acte 1>

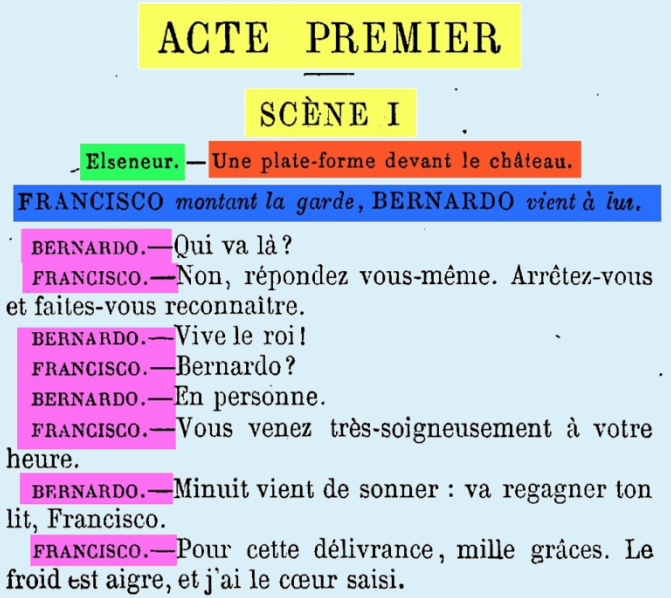

ACTE PREMIER

SCÈNE I

Elseneur. — Une plate-forme devant le château.

FRANCISCO *montant la garde*, BERNARDO *vient à lui.*

BERNARDO.—Qui va là?
FRANCISCO.—Non, répondez vous-même. Arrêtez-vous et faites-vous reconnaître.
BERNARDO.—Vive le roi!
FRANCISCO.—Bernardo?
BERNARDO.—En personne.
FRANCISCO.—Vous venez très-soigneusement à votre heure.
BERNARDO.—Minuit vient de sonner : va regagner ton lit, Francisco.
FRANCISCO.—Pour cette délivrance, mille grâces. Le froid est aigre, et j'ai le cœur saisi.

# Annotation d'un manuscrit (TEIManuscript)

- <surface> : une page, une stèle, tout objet avec une inscription
  - *La surface contient des zones et des lignes*
  - *Elle a des coordonnées*

- <zone>: Une aire de la superficie définie de façon arbitraire à des fins éditoriaux. Les zones peuvent se superposer : la superposition est définie selon des coordonnées spatiaux
  - *Peut contenir des <line>*
  - *Dispose de coordonnées*

- <line> : une suite de texte identifiée de façon claire par l'éditeur
  - *Peu contenir du texte et des <zone>*
  - *Ne dispose pas de coordonnées*

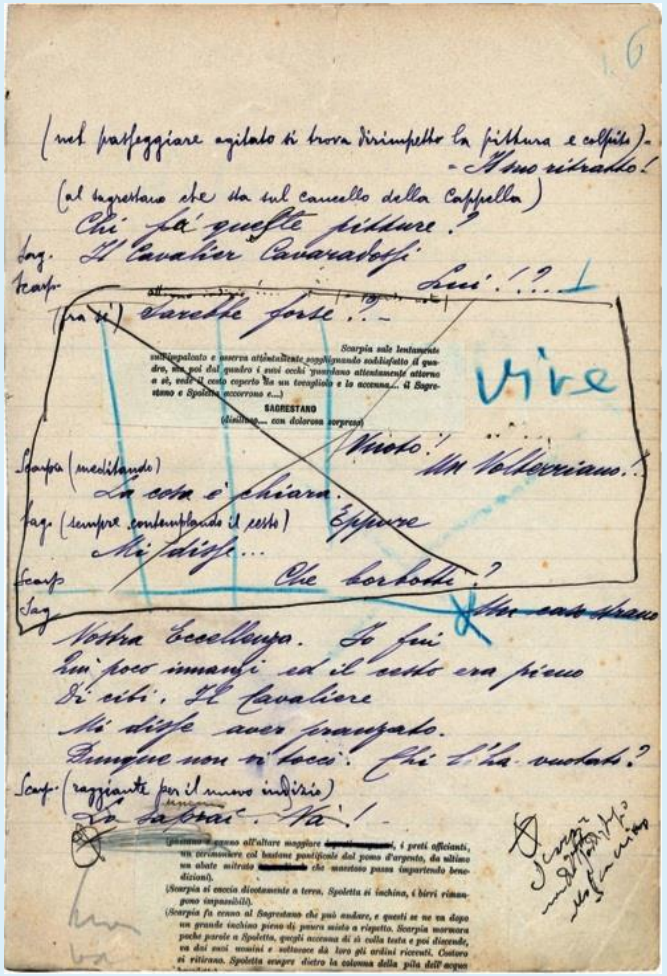

# Annotation d'un manuscrit (TEIManuscript)

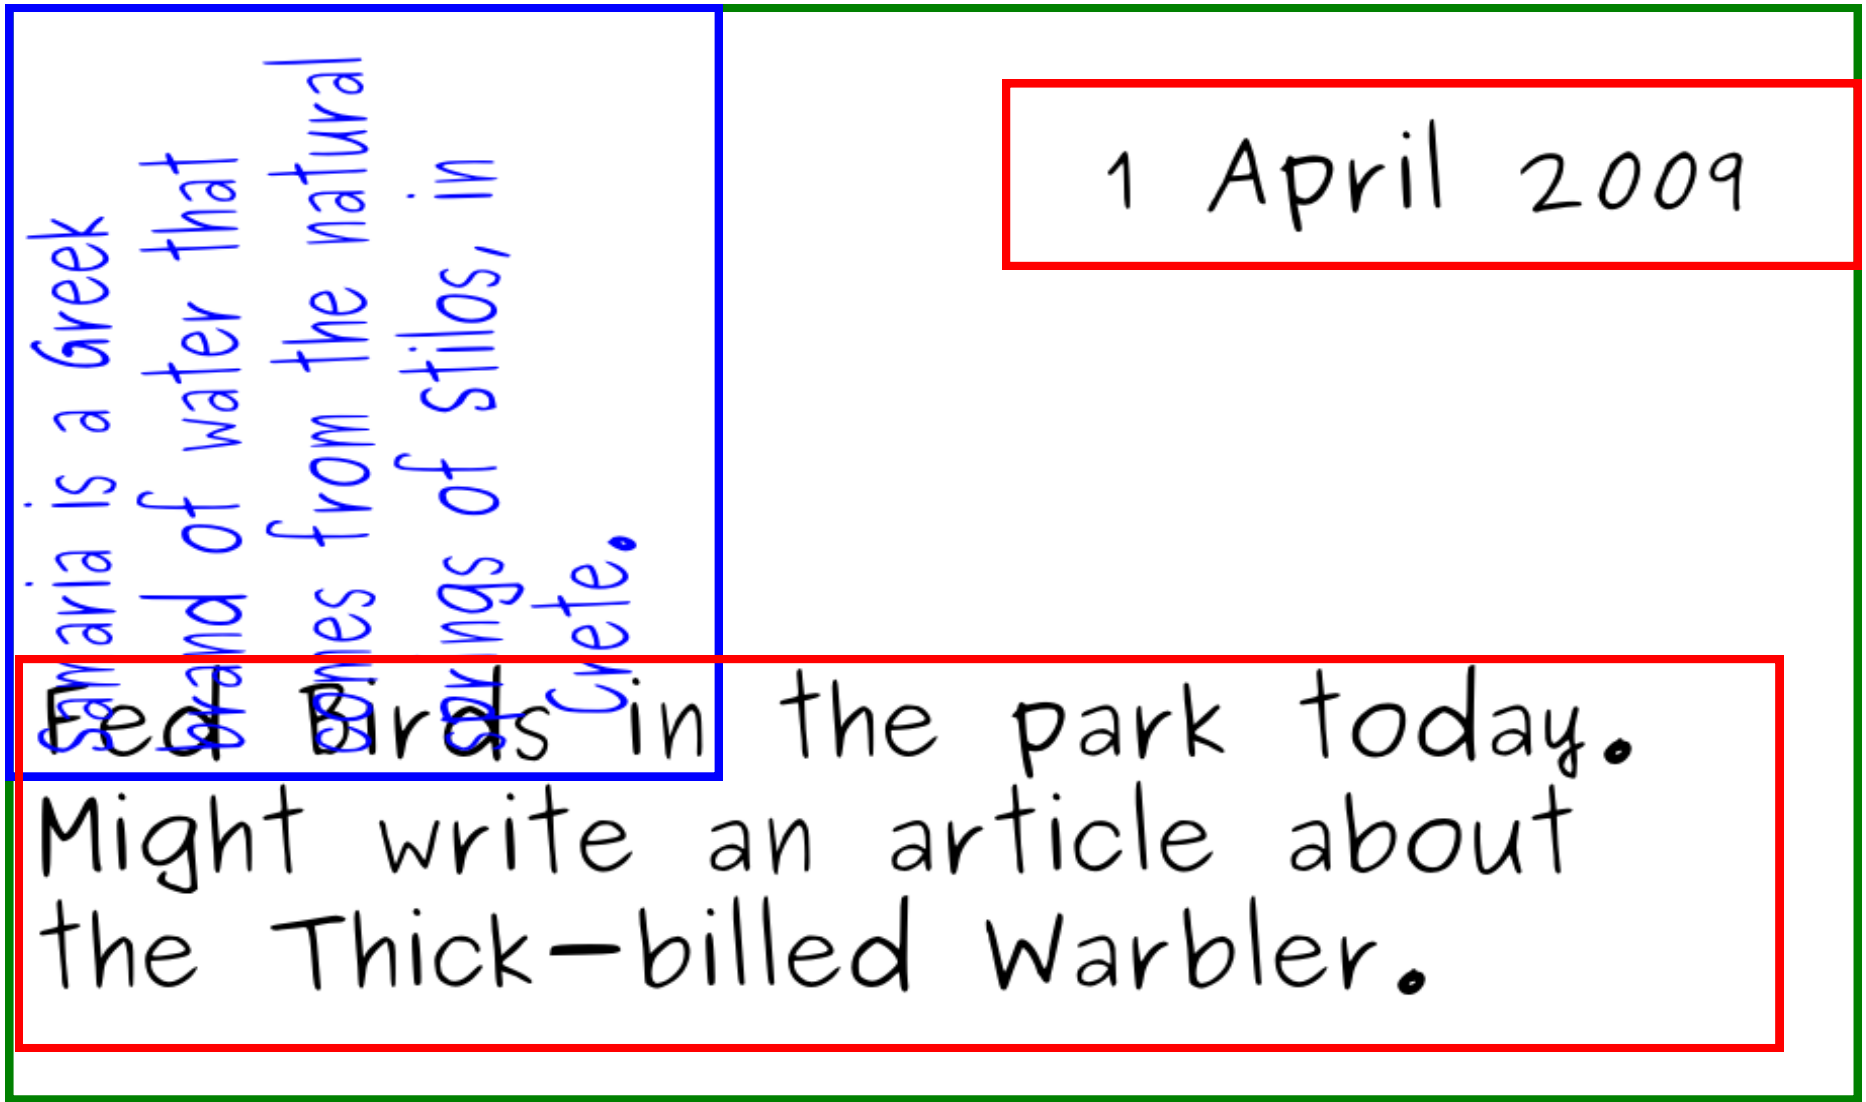

# Annotation d’un manuscrit (TEIManuscript)

```
<surface
      ulx="0"
      uly="0"
      lrx="700"
      lry="1000">
      <!-- ... -->
</surface>
```

```
 <zone
      ulx="93"
      uly="681"
      lrx="967"
      lry="1568">
      <graphic url=« gb.jpg"/>
 </zone>
```

```
<sourceDoc>
 <surface ulx="0" uly="0" lrx="200" lry="300">
 <zone ulx="10" uly="43" lrx="185" lry="84"
 rotate="0”>
<zone>
        <line rend="right"> 1 April 2009</line>
</zone>
<line>Fed Birds in the park today.</line>
<line>Might write an articleabout</line>
<line>the Thick-billed Warbler.</line>
 </zone>
 <zone ulx="9" uly="20" lrx="70" lry="60" rotate="90”>
<line>Samaria is a Greek</line>
<line>brand of water that</line>
<line>comes from the natural</line>
<line>springs of Stilos, in</line>
<line>Crete</line>
</zone>
</surface>
 </sourceDoc>
```

# Annotation d'un manuscrit (TEIManuscript)

```
<surface xml:id="s1" ulx="0" uly="0" lrx="50" lry="50">
 <zone xml:id="s1-z1" ulx="1" uly="1" lrx="10" lry="10">
 <line>Poem</line>
 <!-- ... -->
 <line>the head</line>
 </zone>
 <zone xml:id="s1-z2" ulx="4" uly="4" lrx="20" lry="20">
 <surface xml:id="s2" ulx="0" uly="0" lrx="100" lry="100">
 <zone xml:id="s2-z1" ulx="10" uly="10" lrx="90" lry="95"> Spring has just set in here, and the weather […] a steamer </zone>
 </surface>
 </zone>
</surface>
```

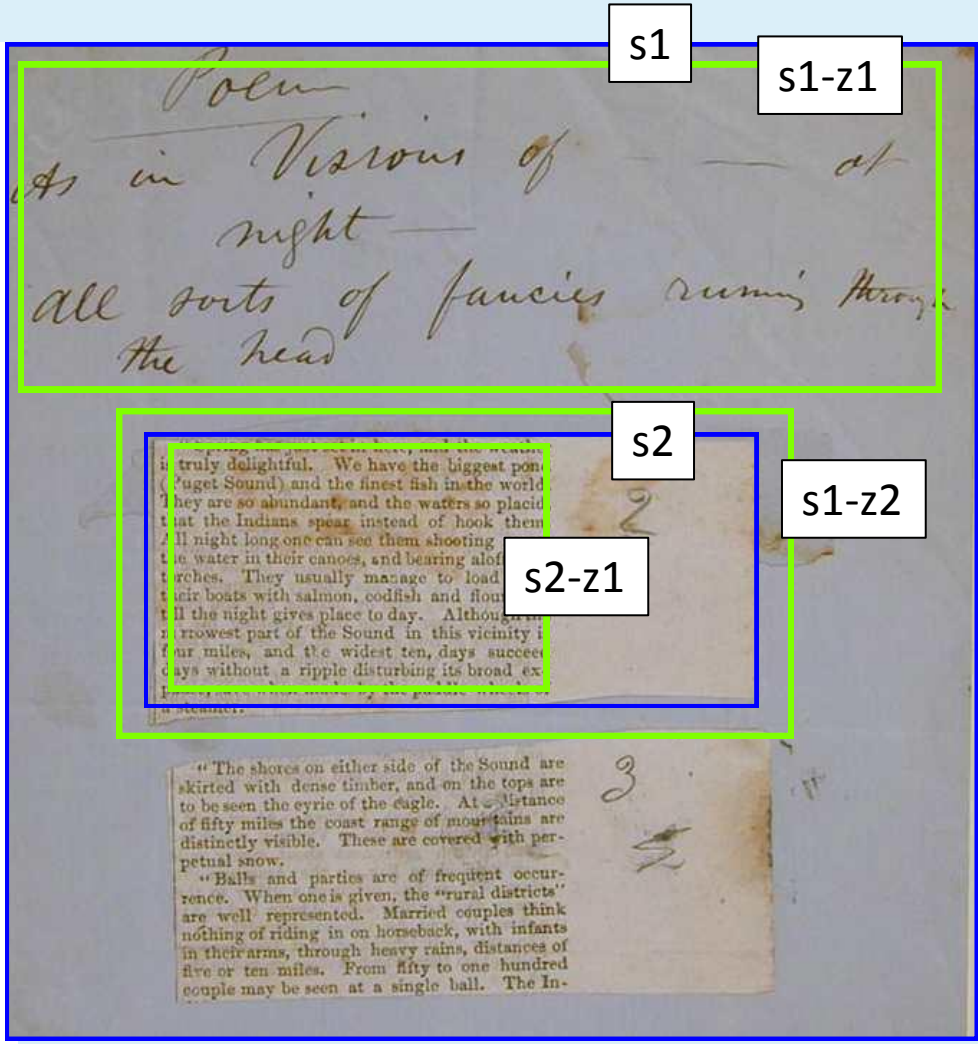

# Annotation d’un graphique (Graph)

- Image Markup Tool

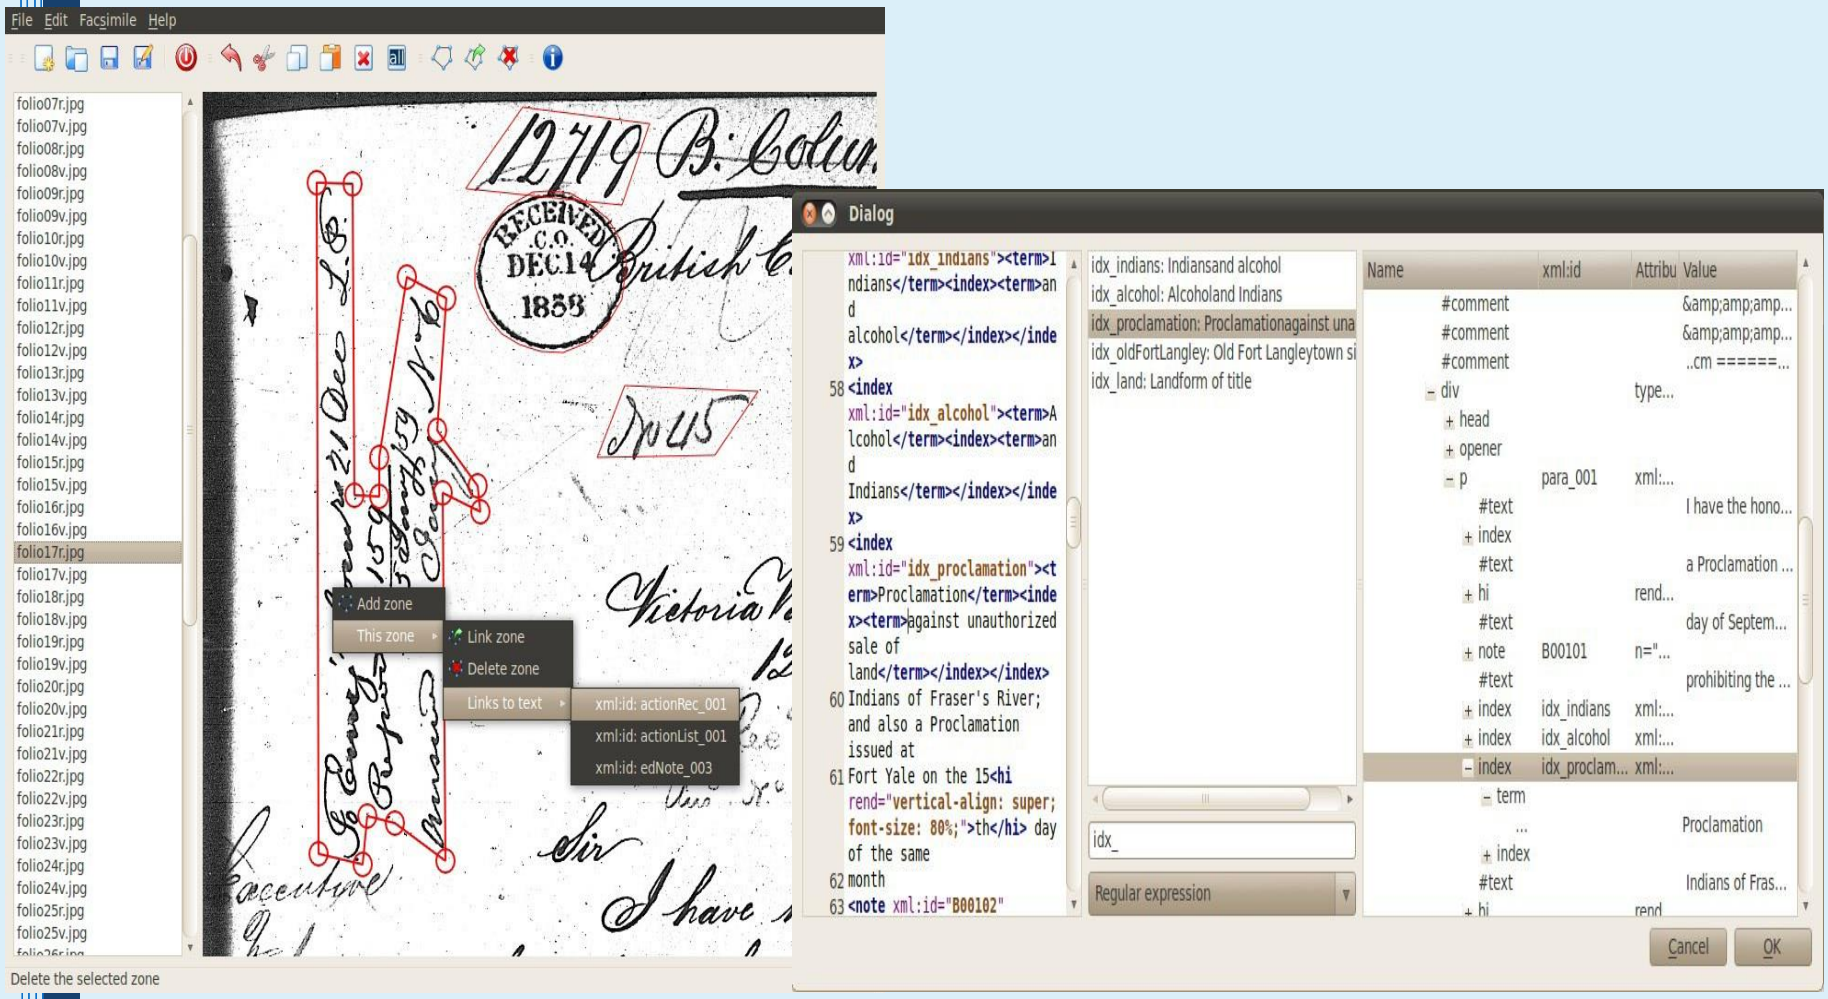

# Annotation d’un graphique (Graph)

- Image Markup Tool

```
<teiHeader>
  <fileDesc>
    <titleStmt>
      <title>The Image Markup Logo</title>
    </titleStmt>
    <publicationStmt>
      <p></p>
    </publicationStmt>
    <sourceDesc>
      <p>377 x 259</p>
    </sourceDesc>
  </fileDesc>
  <encodingDesc>
  </encodingDesc>
</teiHeader>
```

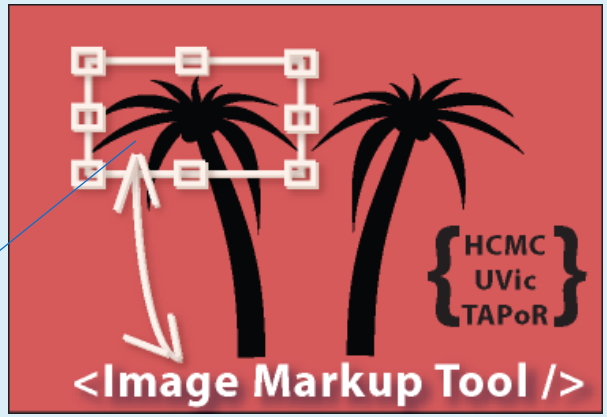

# Annotation MEI de notes de musique

```
<tuplet xml:id="t1" num="3" numbase="2">
  <beam xml:id="b1">
    <note xml:id="n1" pname="d" oct="5" dur="8" />
    <note xml:id="n2" pname="e" oct="5" dur="16" dots="1"/>
    <note xml:id="n3" pname="d" oct="5" dur="32" />
    <note xml:id="n4" pname="c" oct="5" dur="8" accid="s"/>
  </beam>
</tuplet>
<beam xml:id="b2">
  <tuplet xml:id="t2" num="3" numbase="2">
    <note xml:id="n5" pname="d" oct="5" dur="8" />
    <note xml:id="n6" pname="e" oct="5" dur="16" dots="1"/>
    <note xml:id="n7" pname="f" oct="5" dur="32" accid="s"/>
    <note xml:id="n8" pname="e" oct="5" dur="8"/>
  </tuplet>
</beam>
```

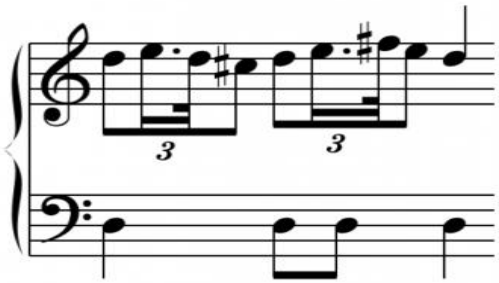


```
<g class="tuplet" id="t1" >
  <g class="beam" id="b1" >
    <g class="note" id="n1" >...</g>
    <g class="note" id="n2" >...</g>
    <g class="note" id="n3" >...</g>
    <g class="note" id="n4" >...</g>
  </g>
</g>
<g class="beam" id="b2" >
  <g class="tuplet" id="t2" >
    <g class="note" id="n5" >...</g>
    <g class="note" id="n6" >...</g>
    <g class="note" id="n7" >...</g>
    <g class="note" id="n8" >...</g>
  </g>
</g>
```

# Application de la MEI au corpus

## Intégration de la MEI à la TEI ?

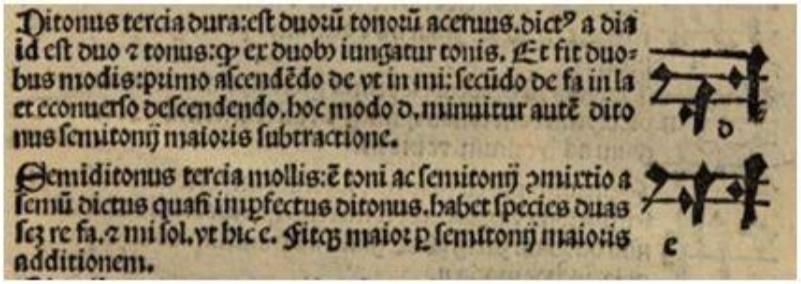


Cochlaeus (1507), f. B1 r., facsimile.

```
<p>
<notatedMusic>
<mei:score>
    <mei:scoreDef key.sig="0">
        <mei:staffGrp>
            <mei:staffDef
                n="1" xml:id="P1"
                lines="3"
                clef.shape="F"/>
        </mei:staffGrp>
    </mei:scoreDef>
    <mei:section>
        <mei:staff n="1">
            <mei:layer n="1">
                <mei:note xml:id="d1e130" pname="c" oct="3"/>
                <mei:note xml:id="d1e142" pname="e" oct="3"/>
                <mei:note xml:id="d1e154" pname="f" oct="3"/>
                <mei:note xml:id="d1e166" pname="a" oct="3"/>
            </mei:layer>
        </mei:staff>
    </mei:section>
</mei:score>
</notatedMusic>
Ditonus tercia dura [...]
</p>
```

Ditonus tercia dura, est duorum tonorum acervus, dictus a dia id est duo et tonus, que ex duobus jungatur tonis. Et fit duo bus modis, primo ascendendo de ut in mi, secundo de fa in la et econverso descendendo, hoc modo d. Minuitur autem ditonus semitonii majoris subtractione.


Cochlaeus (1507), f. B1 r., édition TMG (2015).

Alternative II : Protéger vers le document MEI ou TEI.

# Annotation MEI de notes/texte de musique

Déclaration

Métadonnées (TEI Header)

```
1  <?xml version="1.0" encoding="UTF-8"?>
2  <?xml-model href="http://www.tei-c.org/release/xml/tei/custom/sc
3  <?xml-stylesheet type="text/css" href="7-Taht-El-Yasmina.css"?>
4  <TEI xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance"
5   xmlns="http://www.tei-c.org/ns/1.0"
6   xmlns:math="http://www.w3.org/1998/Math/MathML"
7   xmlns:xi="http://www.w3.org/2001/XInclude"
8   xmlns:svg="http://www.w3.org/2000/svg">
9    <teiHeader>
10     <fileDesc>
11       <titleStmt>
12         <title>تحت الياسمينة في الليل</title>
13         <author role="chanteur">الهادي الجويني</author>
14         <author role="compositeur">الهادي الجويني</author>
15         <author role="parolier">السيدة عزة</author>
16       </titleStmt>
17       <publicationStmt>
18         <p></p>
19       </publicationStmt>
20       <sourceDesc>
21         <p></p>
22       </sourceDesc>
23     </fileDesc>
24   </teiHeader>
```

# Annotation MEI de texte de chanson

تحت الياسمينة في الليل
نسمة والورد محاذيني
الأغصان عليا تـــميل
تمسحلي في دمعة عيني

تحت الياسمينة اتكيت
عدلت الـــعود وغنيت
وتناطر دمعي وبكيت
تفكرتك كيف كنت تجيني

جنينة مزينها النوار
فاحت من ريحت الأزهار
تفكرتك شعـــلت النار
عملت لهلية في قليبي

متوحش وحدي محتار
لا قمرة و لا حس أطيار
كان النسمة ع الأشجار
توانس فيا وتواسيني

Stanza (Quatrin)

```
25  <text>
26    <body>
27      <head>تحت الياسمينة </head>
28    <lg type="stanza">
29      <l>تحت الياسمينة في الليل</l>
30      <l>نسمة والورد محاذيني</l>
31      <l> الأغصان عليا تـــــميل</l>
32      <l> تمسحلي في دمعة عيني</l>
33    </lg>
34    <lg type="stanza">
35      <l> تحت الياسمينة اتكيت </l>
36      <l>عدلت الـــــعود وغنيت</l>
37      <l>وتناطر دمعي وبكيت</l>
38      <l>تفكرتك كيف كنت تجيني</l>
39    </lg>
40   <lg  type="stanza">
41     <l> جنينة مزينها النوار</l>
42     <l> فاحت من ريحت الأزهار</l>
43     <l>تفكرتك شعـــــلت النار</l>
44     <l>عملت لهلية في كنيني</l>
45   </lg>
46   <lg type="stanza">
47     <l>متوحش وحدي محتار</l>
48     <l> لاقمرة ولا حس أطيار</l>
49     <l>كان النسمة ع الأشجار</l>
50     <l>توانس فيا وتواسيني</l>
51    </lg>
52  </body>
```

# Annotation d'un fichier son (TEISpeech)

Un cas extrème -- il n y a pas de texte à annoter; on le crée en annotant.

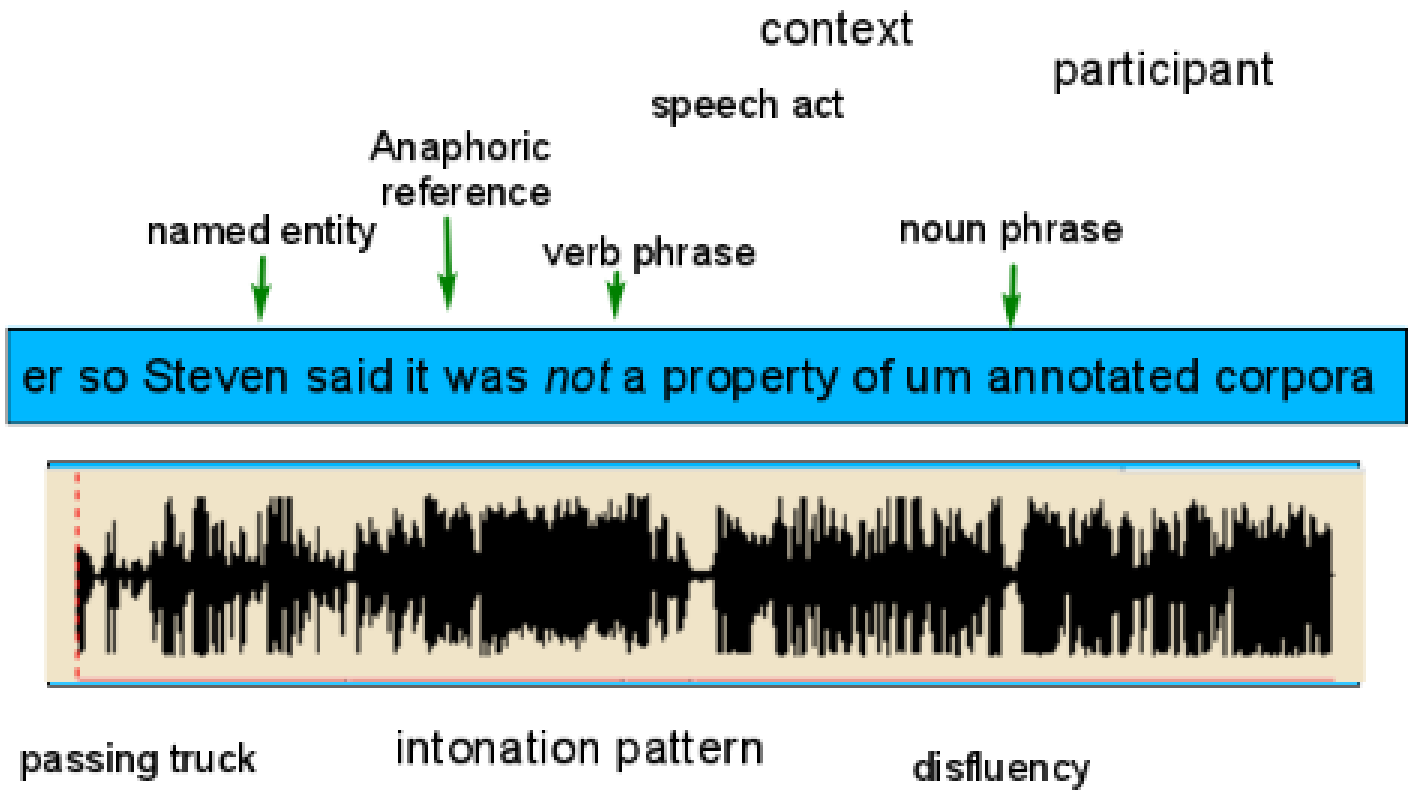

# Annotation d'un fichier son (TEISpeech)

- Un énoncé se définit comme une « séquence attribuée à un locuteur à un instant » : flux temporel « Timeline »

- Description très fine des différents phénomènes de communication oraux et non-oraux qui font partie du discours :
  - *pauses, chevauchements de paroles, changements d'intonation, de voix ou de langue, expressions vocalisées (tousser, rire, se moucher, grogner…), gestes, etc.*

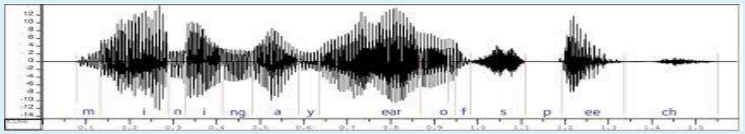

```
<u who="#locuteur" sync="#T234">
  <seg type="interrupted">
    <kinesic>
      <desc>coughs</desc>
    </kinesic>
    <w>you</w>
    <w>must</w>
  </seg>
  <seg type="declarative">
    <w>you</w>
    <w>should</w>
    <w>let</w>
    <pause dur="short"/>
    <w>it</w>
    <w>be</w>
  </seg>
  <seg type="emphatic">
    <vocal>
      <desc>laughs</desc>
    </vocal>
    <w>please</w>
  </seg>
</u>
```

# Annotation d'un fichier son (TEISpeech)

## EXMARaLDA, par exemple

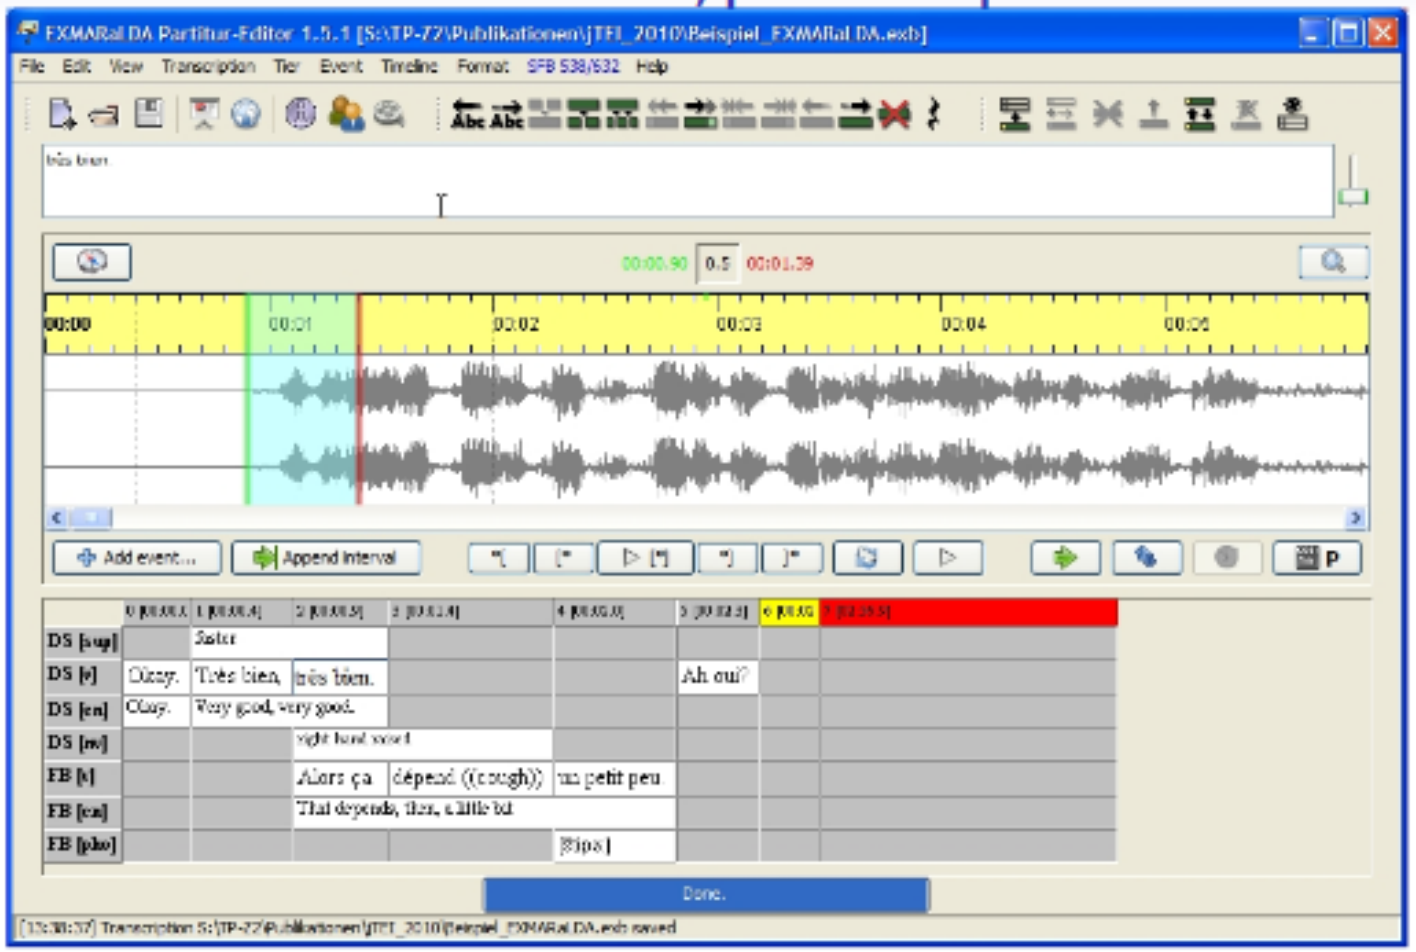


EXMARaLDA: "Extensible Markup Language for Discourse Annotation" http://www.exmaralda.org/

# TEI & travail interdisciplinaire

- Un corpus TEI est une « entreprise » interdisciplinaire par excellence :
  - *Permet une grande liberté intellectuelle dans les choix d'encodage des corpus ;*
  - *Permet le travail collaboratif entre acteurs de plusieurs domaines ;*
  - *Permet l'élaboration de schémas de structuration transversaux à l'étude de plusieurs corpus.*

# Modèle de collaboration interdisciplinaire

- Des schémas TEI par catégorie de ressource (eg. genres littéraires)

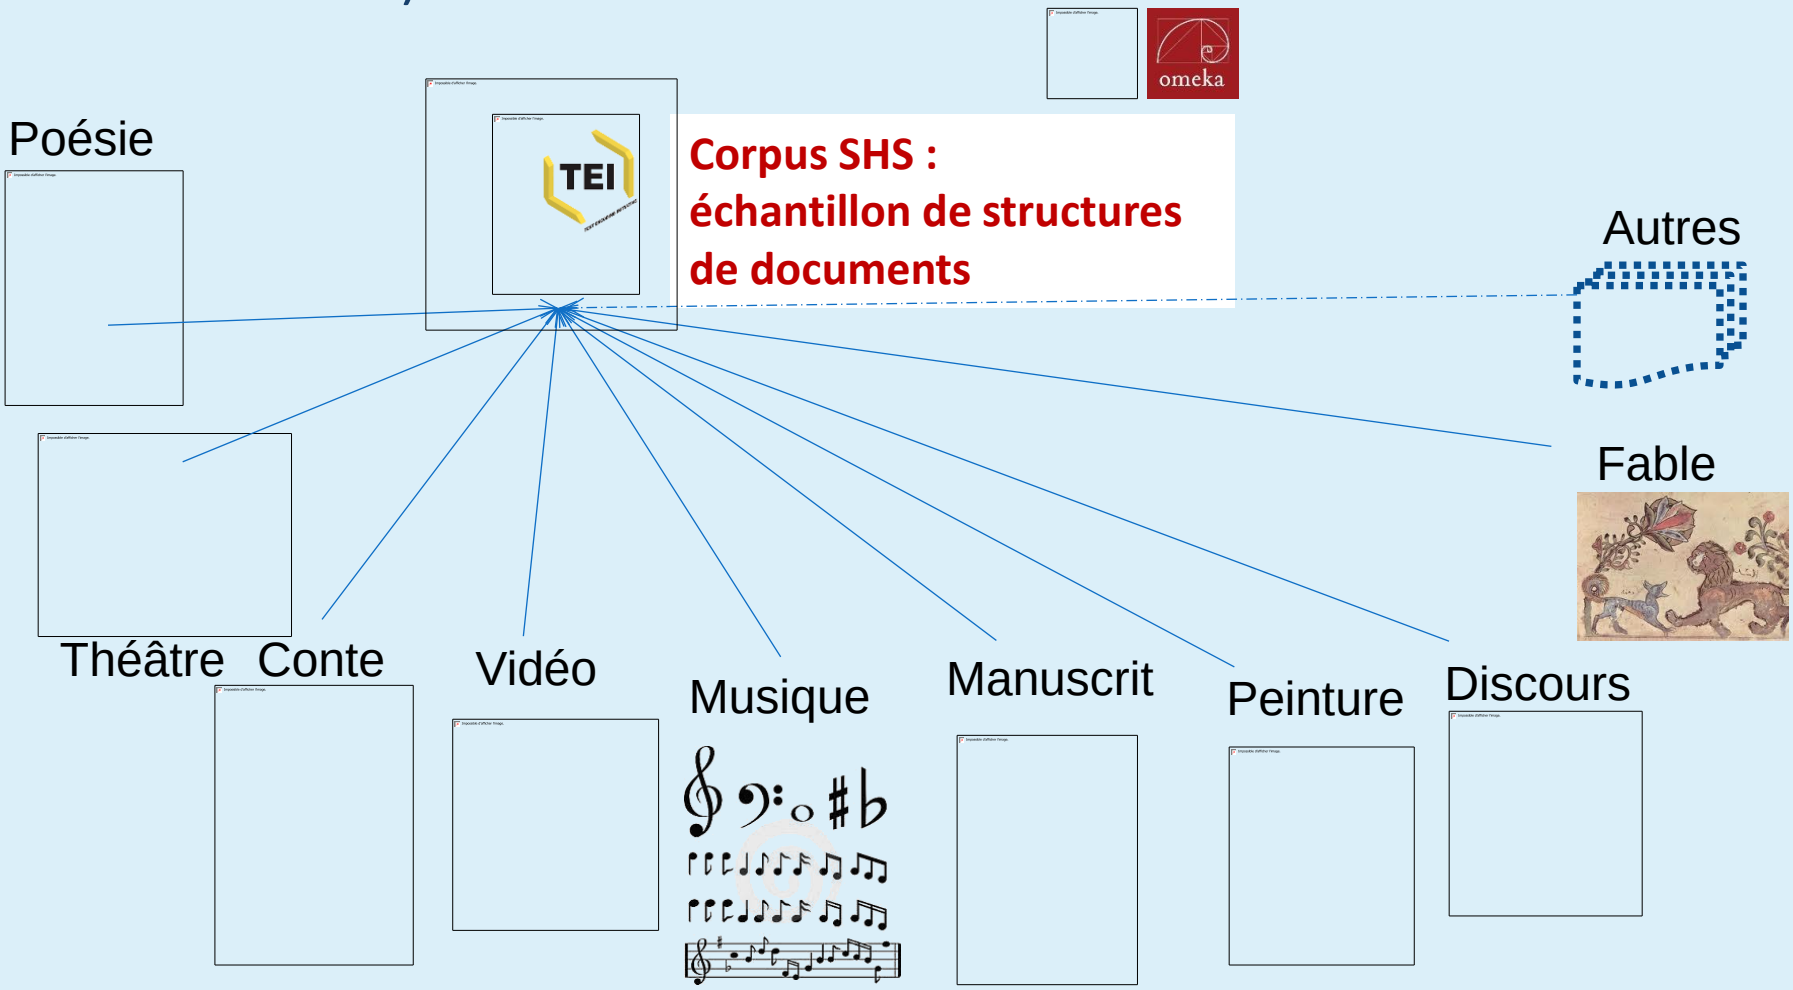

# Modèle de collaboration interdisciplinaire

**Spécialiste Arts & SHS**


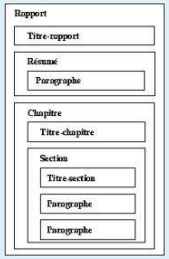


**Technicien XML/TEI**

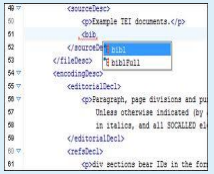

**Corpus Arts & SHS**

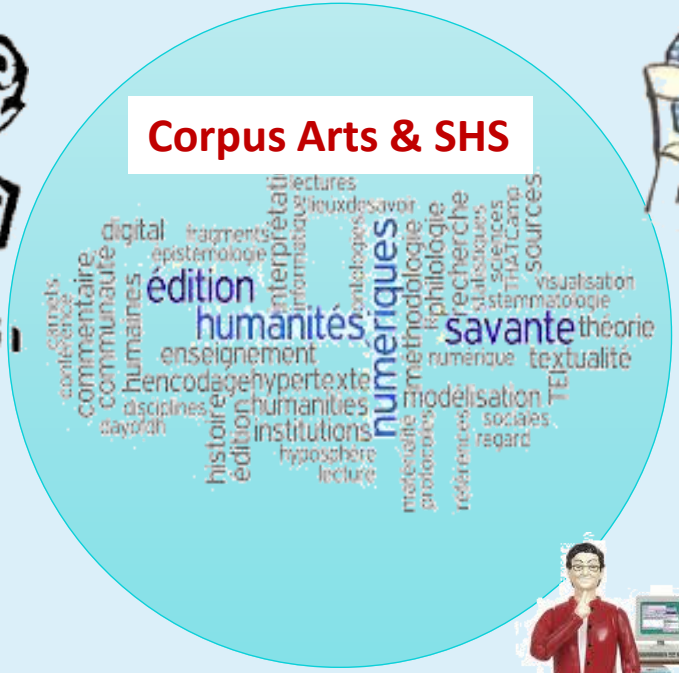


**Spécialiste de l'Info-Com.**

## 1

**Définition/usage d'un schéma XML/TEI conforme a chaque type de corpus**

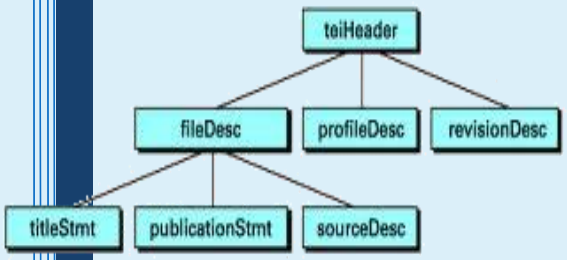


Schéma XML/TEI

## 2

**Production d'une interface graphique conforme au schéma XML/TEI**


Briques sémantiques

**INTERFACE GRAPHIQUE**

## 3

**Saisie des données des différents segments linguistique / sémantique du corpus**

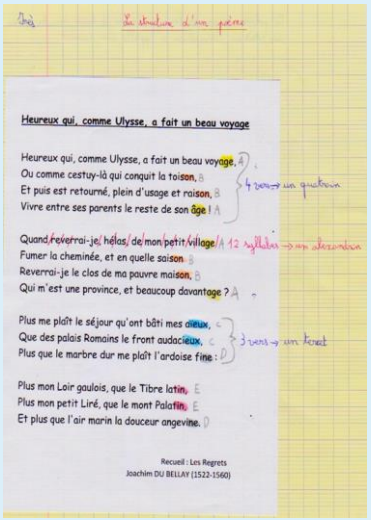



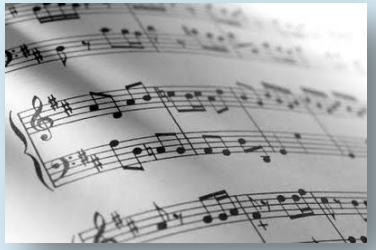

## 4

**Génération du code XML/TEI des éléments du corpus**

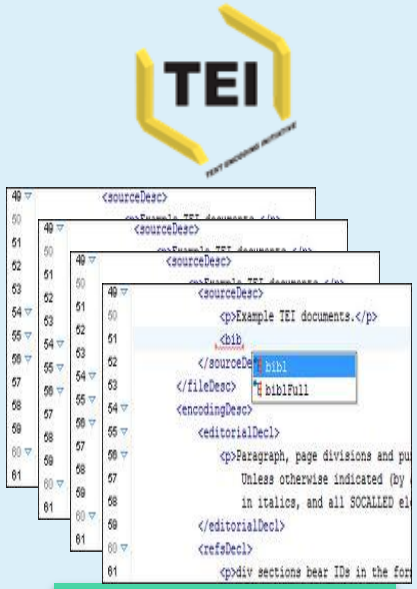


Encodage XML/TEI

**Usages multifonctions**

- Réédition
- Corpus patrimoniaux
- Recherche

# Des outils adaptés

- Dispositif CMS autour d'Oxygen : logiciel de production de corpus numérique en TEI ;

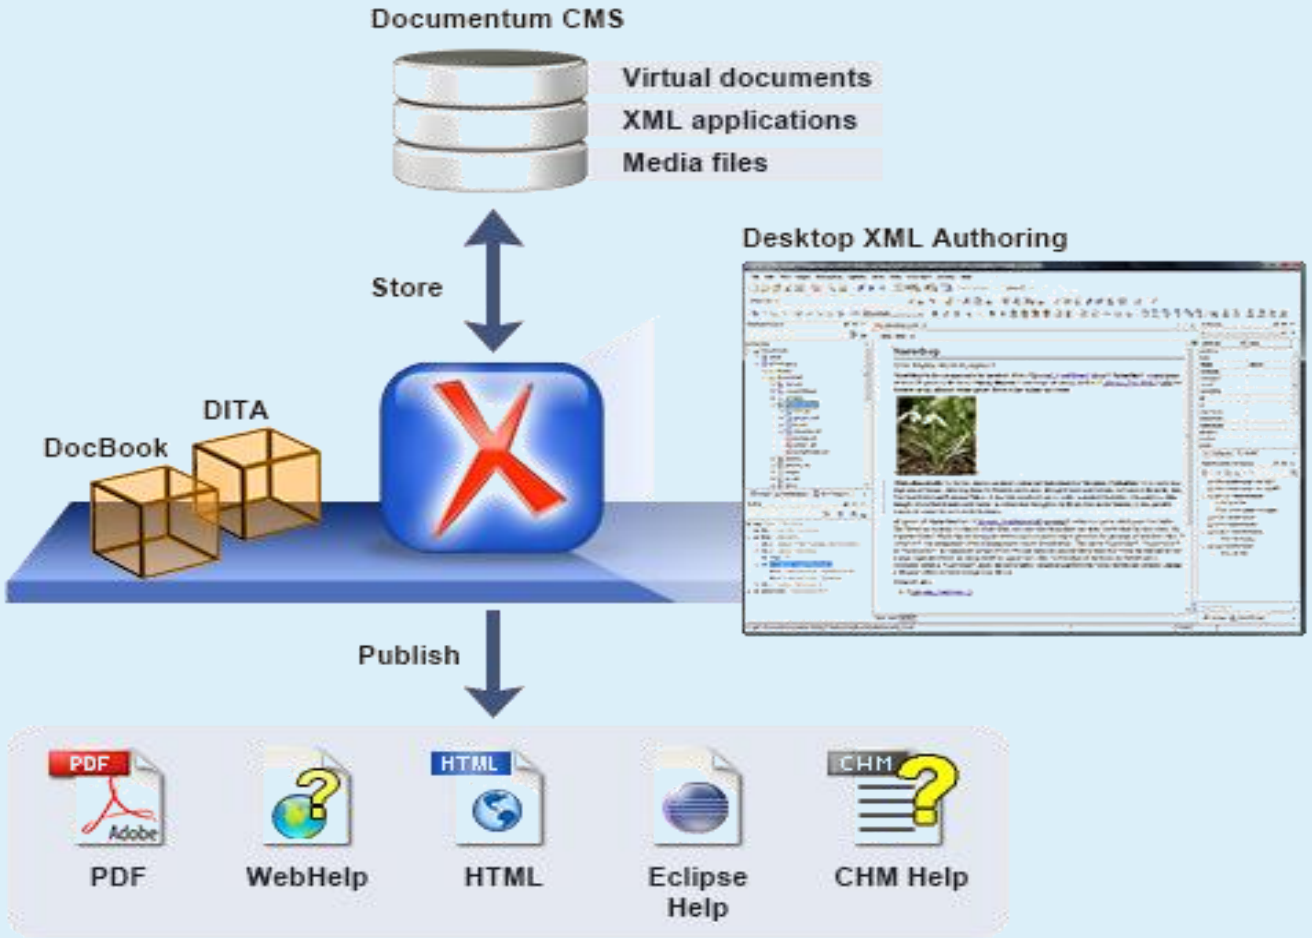

# Des outils adaptés

- OXGARAGE : pour créer des schémas de documents TEI adaptés, interopérables et valides ;

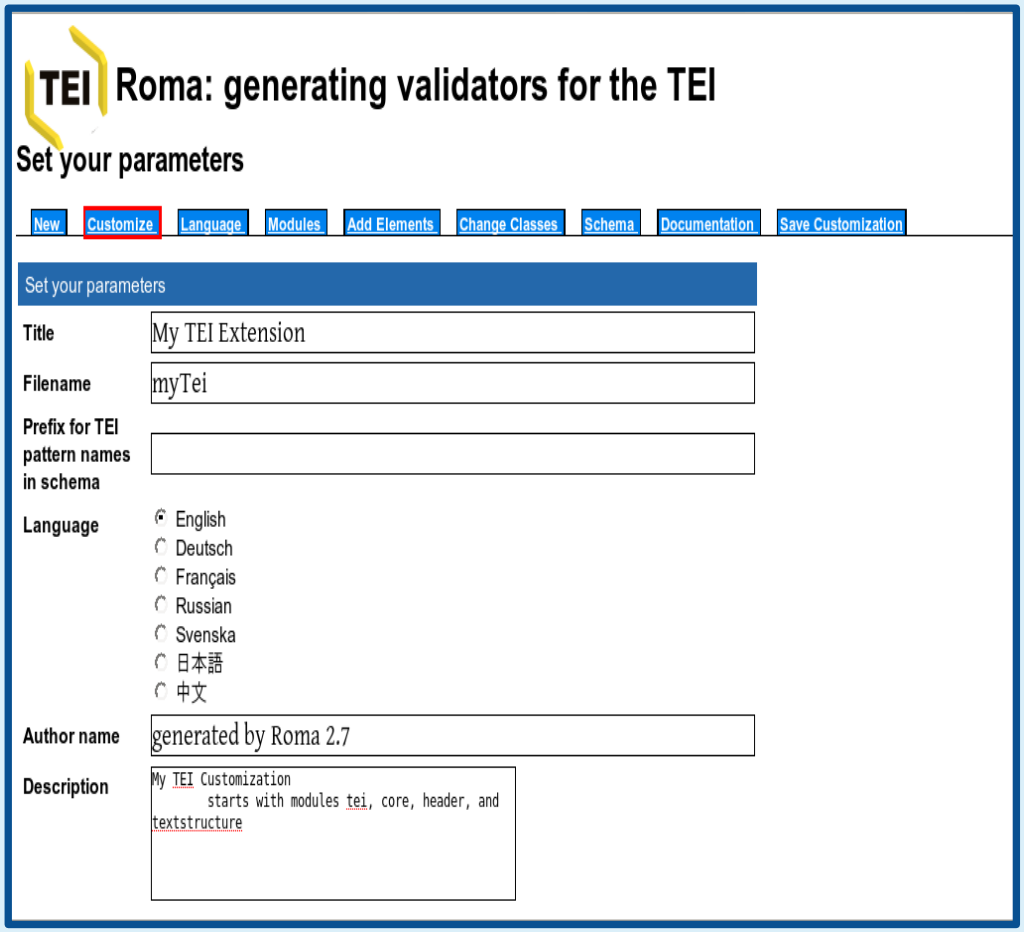

# Des outils adaptés

- OxGarage : pour convertir des formats de documents numériques de et vers la TEI ;

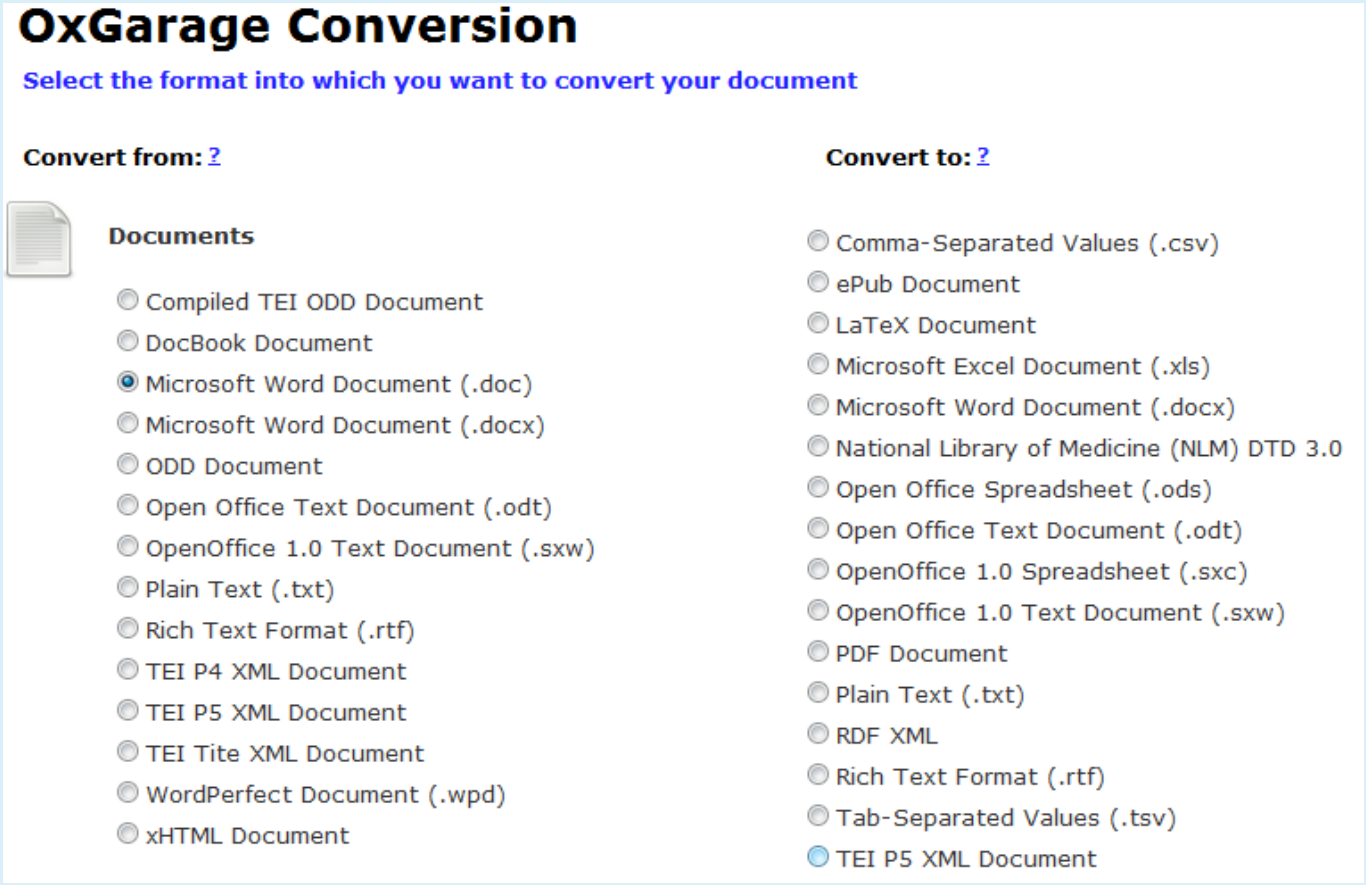

# CES (Corpus Encoding Standard)

- Un sous-ensemble de la TEI (DTD : Data Table Description) pour l'encodage des corpus :
  - *Un niveau d'encodage minimal que les corpus doivent atteindre pour être considérés comme standardisés ;*
  - *Des conventions pour un encodage plus étendu pour l'annotation linguistique ;*
  - *Une architecture générale pour représenter les corpus avec des annotations linguistiques*

- La DTD CES (schema) complète la TEI pour :
  - *l'étiquetage grammatical (CESAna) :*
  - *l'alignement de corpus (CESAlign) :*

# ISO 24624:2016

- ISO 24624:2016 - Gestion des ressources linguistiques -- Transcription du langage parlé :
  - *énonce des règles de représentation des transcriptions d'enregistrements audio et vidéo d'interactions parlées ;*
    - transcription pour des études sociolinguistiques, l'analyse de conversation, la dialectologie, la linguistique de corpus, la lexicographie de corpus, les technologies langagières, les études qualitatives en sciences sociales, et aux autres données de transcription d'enregistrements du langage parlé ;
  - *rattache les données transcrites à des normes de corpus annotés ;*
  - *ne s'applique pas aux autres formes de transcription et surtout pas aux transcriptions de manuscrits ;*

# Un exemple d'initiative

- Exemple de l'Initiative de la COMUE de Lyon (projet préparé l'USR 3439 MOM, l'UMR 5189 HiSoMA et l'UMR 5648 CIHAM)
  - *Programme d'acculturation digitale :*
    - Mettre en synergie des différents métiers dans le HN ;
    - Faire évoluer les cloisonnements disciplinaires et faciliter la construction des dimensions transdisciplinaires et innovantes des projets en HN,
    - Concevoir des outils en phase avec les exigences épistémologiques des recherches en HN ;
    - Rendre transparents les présupposés théoriques sous-jacents à ces outils, qui ne sont jamais purement techniques mais intègrent nécessairement des choix intellectuels que leurs utilisateurs doivent pouvoir maîtriser ;
  - *Construire un écosystème compétitif en HN :*
    - Produire des données partageables et réutilisables (algorithmes [API]) ;
    - Permettre la réutilisabilité numérique grâce aux normes internationales (TEI, OAIS)

DH-COMUE, Lyon. « Projet Humanités numériques dans la COMUE, Sources et données pour la recherche : patrimoine, édition, humanités numériques » , http://dh-lyon.mom.fr/sites/dh-lyon.mom.fr/files/Projet%20Humanit%C3%A9s%20num%C3%A9riques%20Comue_0.pdf

# Un exemple d'initiative

- Exemple de l'Initiative de la COMUE de Lyon (projet préparé l'USR 3439 MOM, l'UMR 5189 HiSoMA et l'UMR 5648 CIHAM)
  - *Un incubateur de recherche pour les humanités numériques*
    - personnels spécialisés, aide à la gestion de projets numériques ;
    - formation aux bonnes pratiques et aux standards de description ;
    - mise en œuvre des procédés d'encodage (TEI) ;
    - anticipation des formats et procédures d'archivage des données ;
    - labellisation par les réseaux et infrastructures françaises et européennes (portails Isidore, Europeana, Dariah) ;
    - Alignement sur les grandes infrastructures de recherche européenne (Dariah) et française (TGIRHuma-num) fondées sur les meilleures technologies et standards ;
    - développement avéré de compétences reconnues à un niveau international dans le domaine du web sémantique et de l'open data.

DH-COMUE, Lyon. « Projet Humanités numériques dans la COMUE, Sources et données pour la recherche : patrimoine, édition, humanités numériques » , http://dh-lyon.mom.fr/sites/dh-lyon.mom.fr/files/Projet%20Humanit%C3%A9s%20num%C3%A9riques%20Comue_0.pdf

# Quelques références


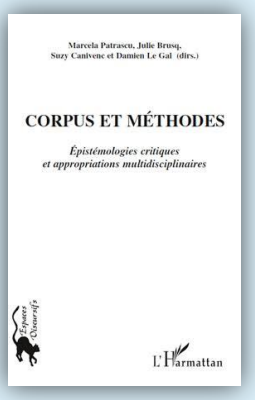



- La revue CORPUS (openedition.org)
- Poudat C, Landragin F. Explorer un corpus textuel: Méthodes - pratiques - outils. Paris: De Boeck Superieur; 2017. 243 p.
- Wigham CR, Ledegen G. Corpus de communication médiée par les réseaux: Construction, structuration, analyse. Editions L'Harmattan; 2017. 260 p.
- Comby É. Corpus de textes : composer, mesurer, interpréter. ENS Éditions; 2016. 194 p. x
- Patrascu M, Brusq J. Corpus et méthodes: épistémologies critiques et appropriations multidisciplinaires. Harmattan; 2011. 210 p.