



HAL
open science

Description et modélisation des chaînes de référence. Le projet ANR Democrat (2016-2020) et ses avancées à mi-parcours

Frédéric Landragin, Marine Delaborde, Yoann Dupont, Loïc Grobol

► To cite this version:

Frédéric Landragin, Marine Delaborde, Yoann Dupont, Loïc Grobol. Description et modélisation des chaînes de référence. Le projet ANR Democrat (2016-2020) et ses avancées à mi-parcours. Cinquième édition du Salon de l'Innovation en TAL (Traitement Automatique des Langues) et RI (Recherche d'Informations), May 2018, Rennes, France. 2018. hal-01797982

HAL Id: hal-01797982

<https://hal.science/hal-01797982>

Submitted on 23 May 2018

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Comme tout avait brûlé – **le feu**, les meubles et les photographies de **Lucien** –, pour **Fabre** et **le fils Paul** c'était tout de suite beaucoup d'ouvrage : toute cette cendre et ce deuil, **l'émotion**, **son** **le** **réfère** dans les grandes surfaces. **Fabre** trouva trop vite quelque chose de moins vaste, deux pièces aux fonctions perméables sous une cheminée de briques dont l'ombre domait l'heure, et qui avaient ceci de bien d'être assez proches du quai de Valmy.

Le soir après le dîner, **Fabre** parlait à **Paul** de **la** **meur**, **l'émotion** **Paul**, parfois dès le dîner. Comme **ce** ne possédait plus de représentation de **l'objet**, **il** s'épuisait à vouloir **le** **descri**re toujours plus exactement : au milieu de la cuisine naquirent des hologrammes que dégonflait la moindre imprécision. Ça ne se rend pas, soupirait **Fabre** en **posant** une main sur **sa** tête, sur **ses** yeux, et le découragement l'endormait. Souvent ce fut **à** **Paul** de **l'appli**quer le canapé convertible, **l'émotion** les choses en chambre à coucher.

Description et modélisation des chaînes de références

Le projet ANR Democrat (2016-2020) et ses avancées à mi-parcours

Frédéric Landragin, Marine Delaborde, Yoann Dupont, Loïc Grobol et le consortium *Democrat*

Le projet ANR Democrat vise à développer les recherches sur la langue et la structuration textuelle du français via l'analyse détaillée et contrastive des **chaînes de références** (instanciations successives d'une même entité) dans un corpus diachronique de textes écrits entre le 9^{ème} et le 21^{ème} siècle, avec des genres textuels variés. Il réunit des chercheurs issus des laboratoires **Lattice**, **LiLPa**, **ICAR** et **IHRIM**. Il a été lancé en mars 2016 et l'essentiel des efforts porte actuellement sur **l'annotation (manuelle) d'un corpus**. Plusieurs expérimentations d'annotation ont eu lieu, de manière à tester différentes procédures. La procédure retenue alterne des phases manuelles et des phases automatiques pour compléter les annotations, via le lancement de scripts.

Objectifs et livrables du projet

Proposer un modèle de la référence et de la composition des chaînes de références

- modèle orienté sur le discours et pas seulement la phrase
- modèle qui s'enrichit de comparaisons inter-langues et d'études diachroniques
- perspectives : étude des transitions référentielles et de la saillance référentielle

Fournir un corpus annoté qui serve de corpus de référence et d'apprentissage

- taille visée : 500.000 mots ; 200 à 300.000 maillons de chaîne annotés
- proposer un pendant au seul corpus similaire existant pour le français : ANCOR

Développer un outil d'annotation adapté aux chaînes de références

- prototype de départ : ANALEC
- intégration des fonctionnalités d'annotation et de gestion de schémas d'annotation dans TXM

Développer un système de résolution automatique de la coréférence

- techniques d'apprentissage artificiel appliquées sur le corpus annoté manuellement
- participation envisagée à une campagne d'évaluation internationale

Publications à mi-parcours

Modèle :

- une dizaine de publications, dont n° de *Langue Française*
- conférences LPTS, GLAD...

Corpus :

- articles de méthodologie
- format XML TEI

Outil d'annotation :

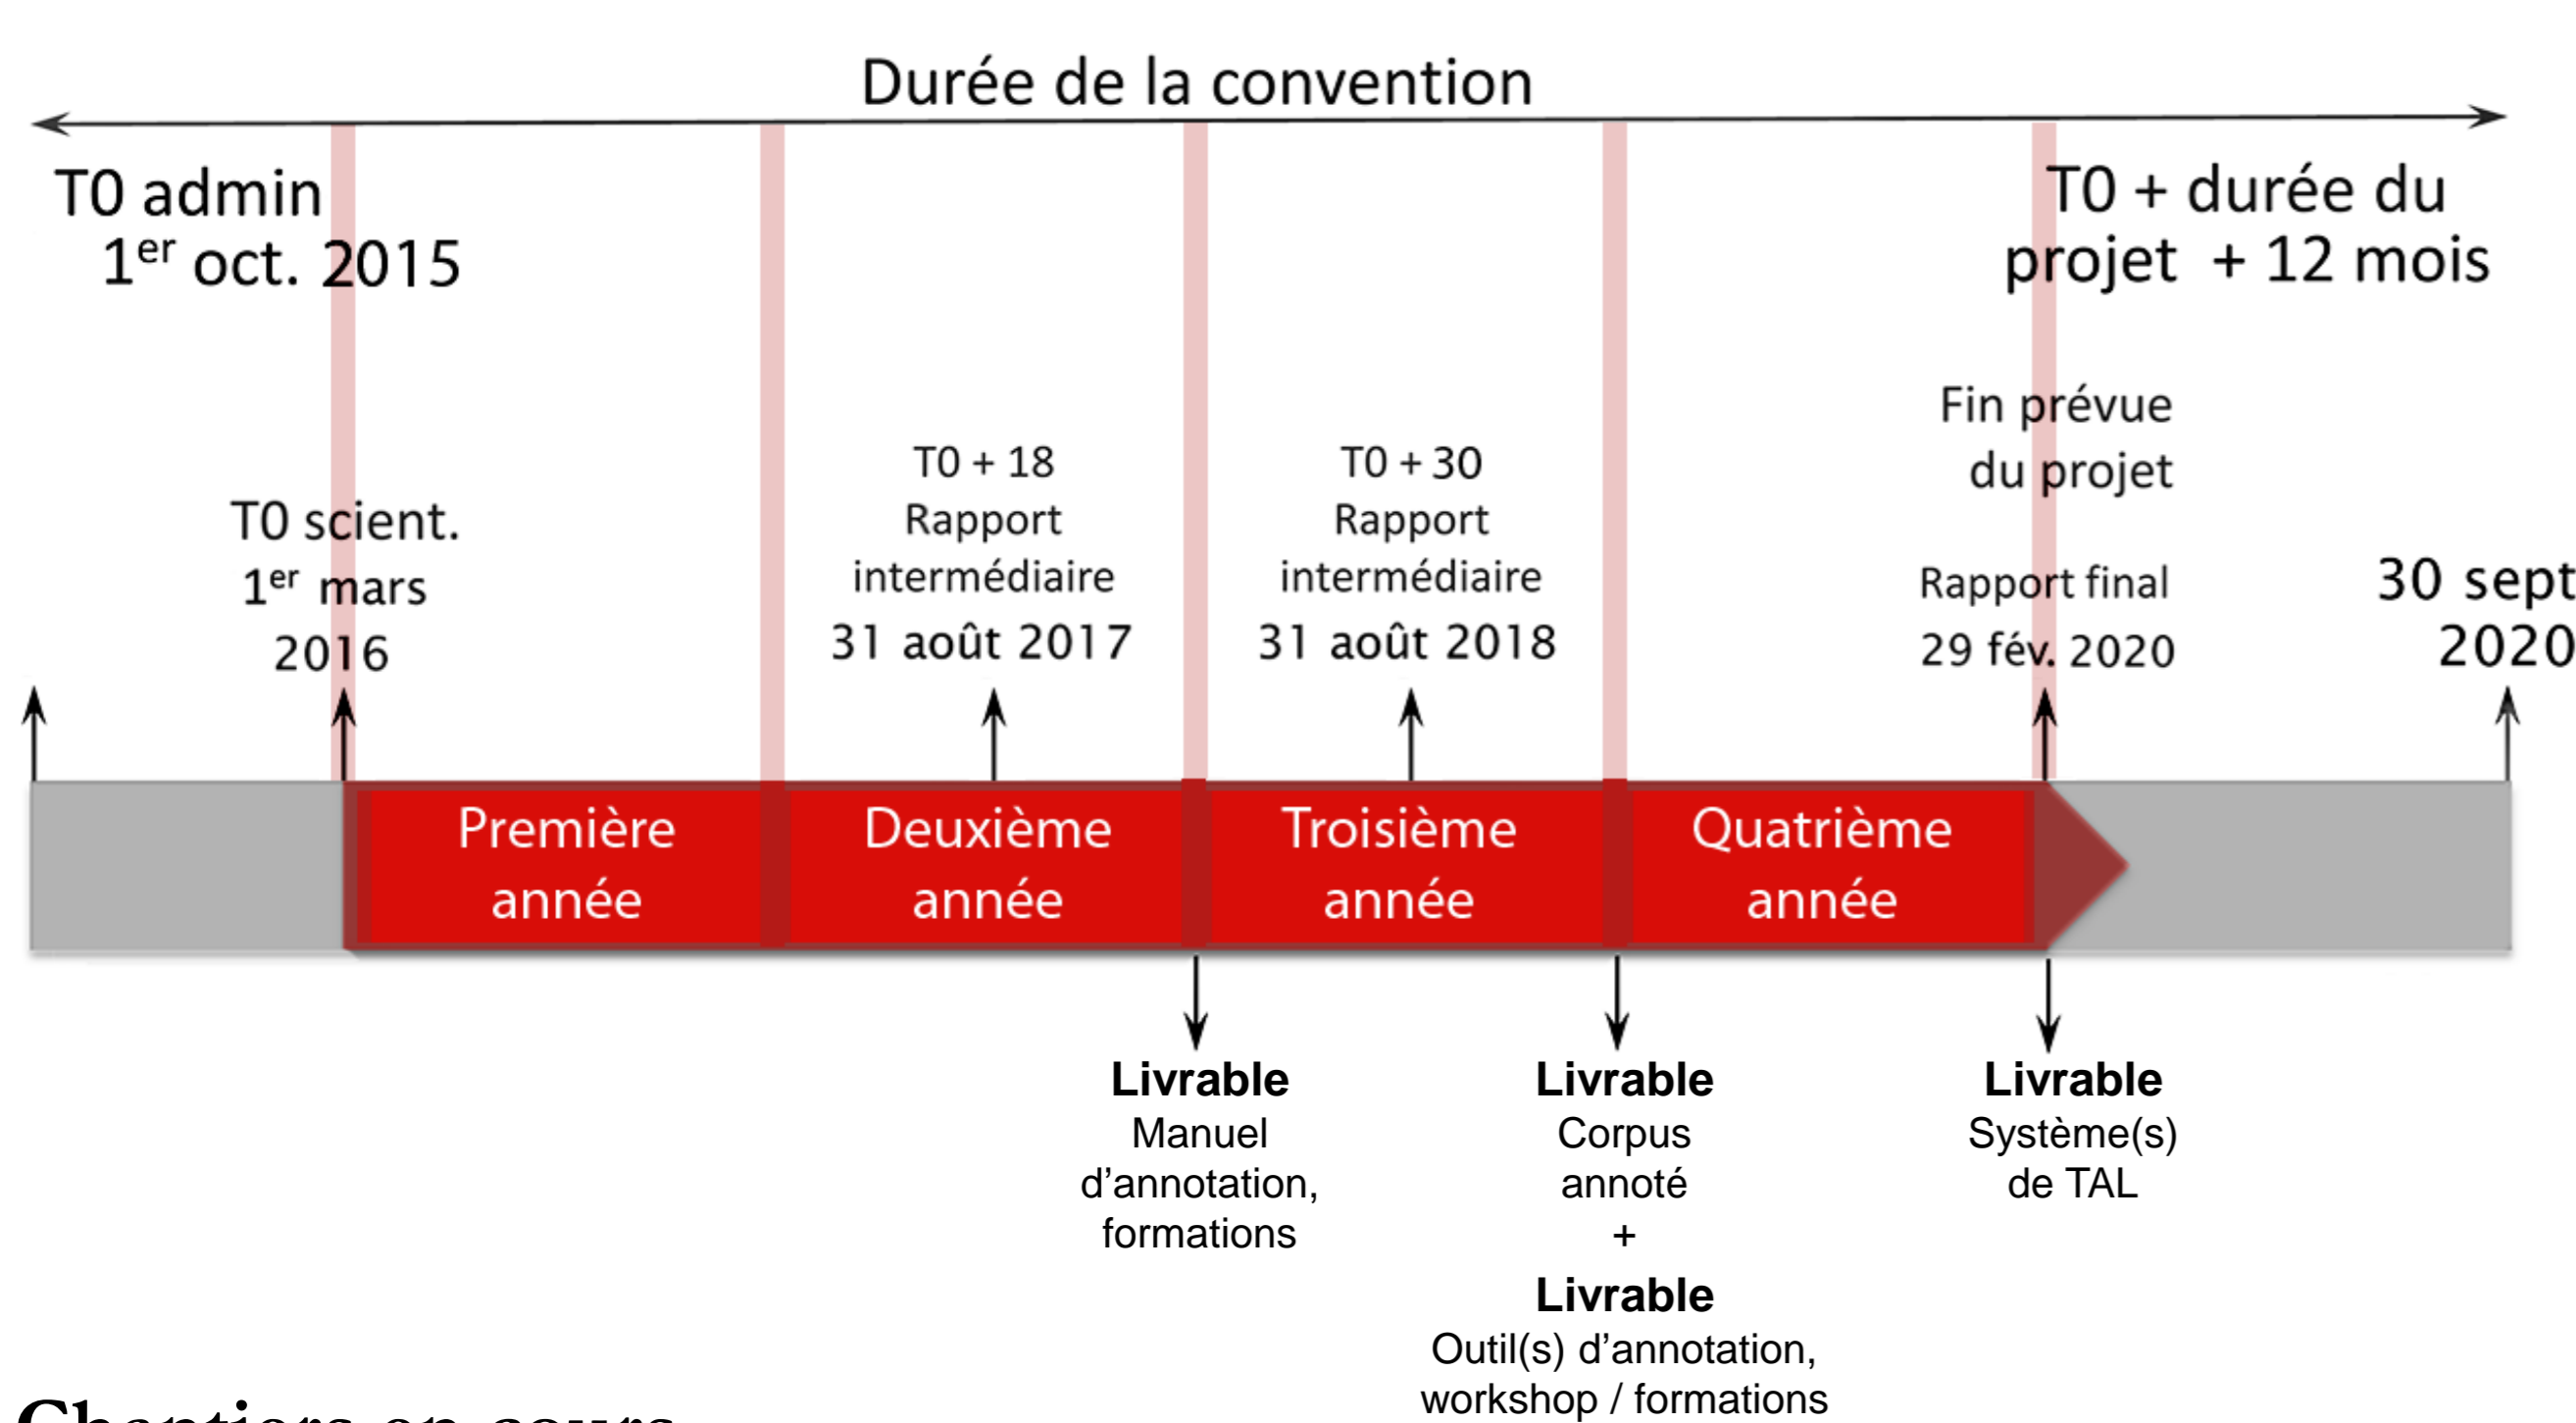
- TXM, ANALEC, SACR
- nouvelles métaphores IHM

Système de TAL :

- apprentissage artificiel, avec plusieurs techniques testées en parallèle (*deep learning*...)
- une dizaine de publications : TALN, TAL, CICLING, LREC...



Echéances et enjeux à mi-parcours



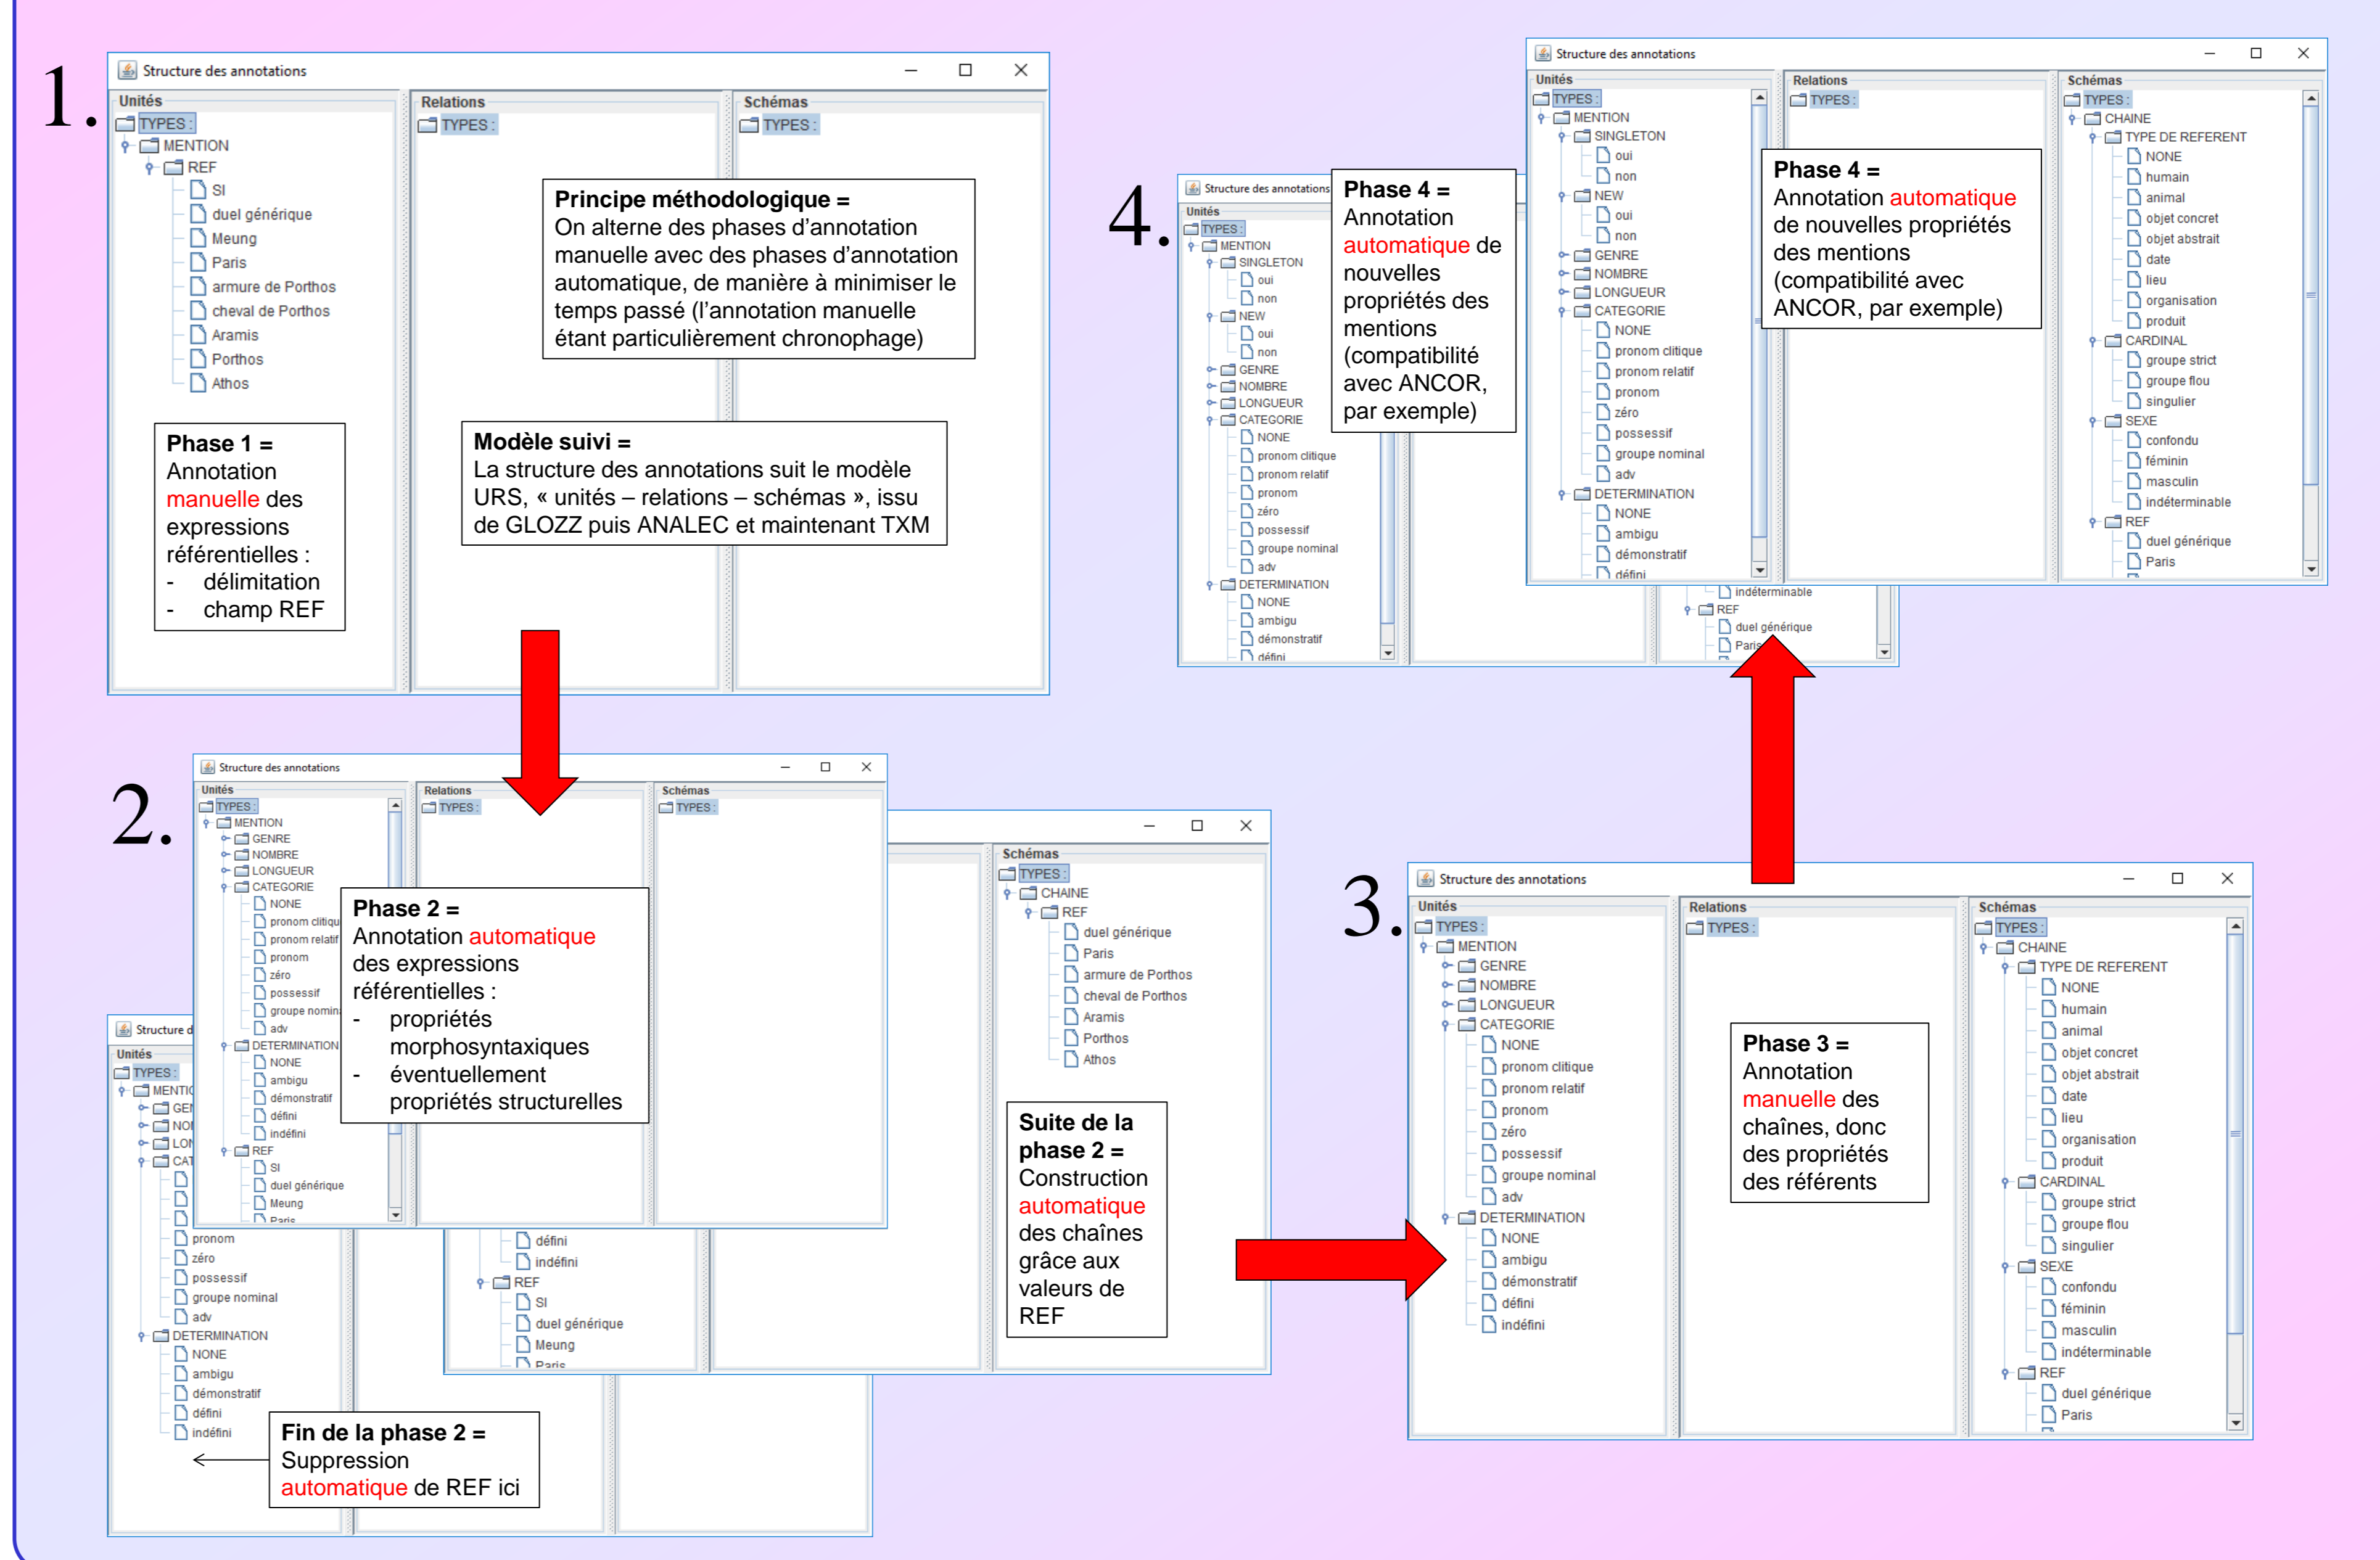
Chantiers en cours

- liens entre chaînes de référence et structures textuelles
- approches contrastives pour l'étude cross-linguistique des chaînes de référence
- méthodologie de l'annotation manuelle pour les objets que sont les chaînes de référence
- ergonomie de l'IHM d'annotation pour la gestion d'unités, de relations et de schémas
- identification de mesures pour quantifier les analyses de chaînes et adapter au projet les possibilités d'interrogation de corpus

Enjeux pour 2018-2019

- finaliser l'annotation du corpus Democrat
- définir une procédure consensuelle d'analyse des chaînes de référence, qui serve à tous les participants et puisse faire office de procédure standard facilitant les comparaisons
- adapter les développements réalisés sur le corpus ANCOR pour le corpus Democrat

Procédure d'annotation



Références

- Désoyer, A., Landragin, F., Tellier, I., Lefeuve, A., Antoine, J.-Y. (2014) « Les coréférences à l'oral : une expérience d'apprentissage automatique sur le corpus ANCOR », *TAL*, 55(2), pp. 97-121.
- Landragin F. (2016) « Conception d'un outil de visualisation et d'exploration de chaînes de coréférences », *Thirteen International Conference on Statistical Analysis of Textual Data (JADT 2016)*, Nice.
- Landragin F., Poibeau T., Victorri B. (2012) "ANALEC: a New Tool for the Dynamic Annotation of Textual Data", *LREC 2012*, Istanbul, Turkey.
- <http://www.agence-nationale-recherche.fr/?Projet=ANR-15-CE38-0008>
- <http://www.lattice.cnrs.fr/democrat/>