

# Opération LR-1

Axe 6 : ressources linguistiques

Vendredi 1<sup>er</sup> juin 2012

1. Rappel des objectifs de l'opération LR-1 (C. Plancq)
  
1. Présentation du travail d'inventaire (S. El Ayari)
  - Grille de description des ressources
  - Présentation de la plateforme
  
- Discussion sur les travaux à venir
  
1. Appels à intervention de l'ingénieur (S. El Ayari et C. Plancq)
  - Critères de sélection et processus de décision
  - Exemples de demandes d'intervention

# Opération LR-1



## LR-1 : A joint approach to language resource development

- Opération transversale : concerne toutes les équipes, tous les axes
- Objectifs principaux : visibilité et accessibilité des ressources, interopérabilité, utilisation des standards
- Moyens : ingénieure de recherche à plein temps (CDD 3 ans)
- Actions : développement logiciel, support/conseil, formation

# Inventaire des ressources



- Visites des laboratoires partenaires du projet
- Elaboration d'une grille de description compatible avec les standards de métadonnées
- Développement d'une plateforme web pour l'enregistrement et l'accès aux ressources

<http://ressources.labex-efl.org>

# Problématique générale



## Types de ressources :

- corpus
- dictionnaires
- lexiques
- outils

## Modalités :

- écrit
- oral

## Trouver un équilibre entre :

- la génération de métadonnées complètes
- des formulaires pas trop longs à saisir (2min/ressource)
- une utilité réelle pour les participants

# Métadonnées



## Standards

- Dublin Core (DC) : 15 descripteurs
- TEI Header
- OLAC : extension du Dublin Core pour les ressources linguistiques
- CLARIN (CMDI) : modules de métadonnées compatibles avec DC, TEI Header, OLAC

## Catalogues

- France : Isidore (TGE Adonis)
- Europe : LRE Map, CLARIN
- International : OLAC

## Initiatives (France)

- TGIR-Corpus (IRCOM, corpus écrits)
- ORTOLANG (ATILF, LPL, MoDyCo, LLL, LORIA, INIST)
- Centre de ressources numériques : CRDO, SLDR, CNRTL

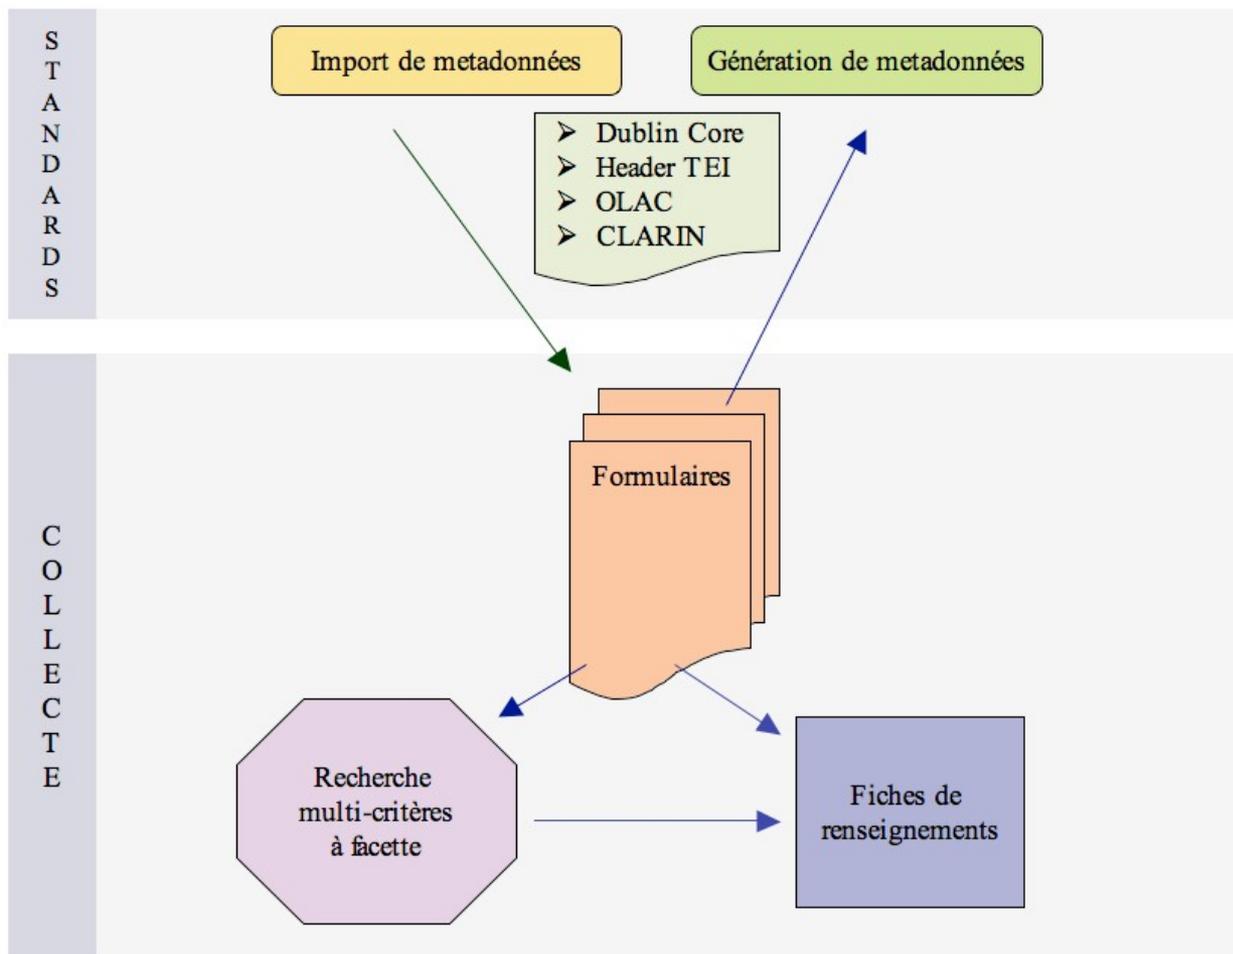
# Grille de description



Description générale	Description particulière
<ul style="list-style-type: none"><li>• Nom</li><li>• Description</li><li>• URL</li><li>• Accès</li><li>• Metadonnées</li><li>• Licence</li><li>• Documentation</li><li>• Publication</li><li>• Projet associé</li><li>• Objectifs scientifiques</li><li>• Lien avec autre ressource</li></ul>	<p><b>Données</b></p> <ul style="list-style-type: none"><li>• Modalité</li><li>• Type de données</li><li>• Source des données</li><li>• Format</li><li>• Taille</li><li>• Langue</li><li>• Annotations</li><li>• Codage des caractères</li><li>• Etat d'avancement</li></ul>
<p><b>Référents</b></p> <ul style="list-style-type: none"><li>• Producteur</li><li>• Référent interne au Labex</li></ul>	<p><b>Outils</b></p> <ul style="list-style-type: none"><li>• Type d'outil</li><li>• Environnement</li><li>• Langage</li><li>• Interface</li><li>• Format d'entrée</li><li>• Format de sortie</li></ul>

# Inventaire des ressources

## Schéma des fonctionnalités

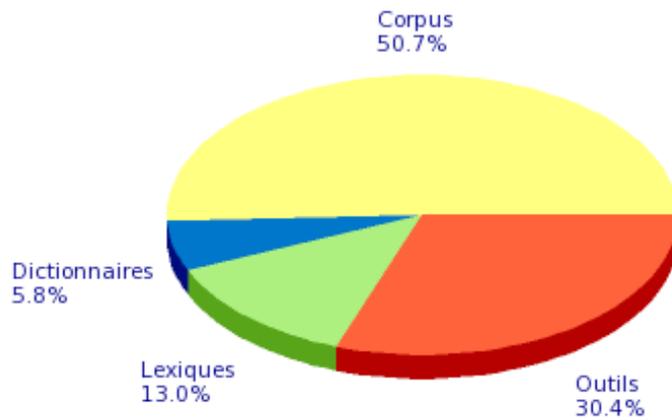


# La plateforme en ligne

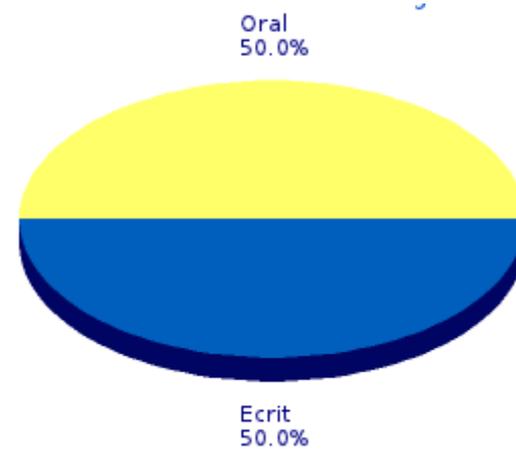


- Enregistrement des ressources >>
- Module de recherche à facettes >>
- Fiches descriptives avec URL stables >>
- Génération de metadonnées aux formats standards : *Dublin Core*, *TEI Header*, *OLAC*, *CLARIN* >>
- Boîte à outils >>  
conversions de metadonnées et conversions de formats de fichiers
- Liens vers des ressources externes au LabEx >>

# Répartition des ressources



Par type de ressources



Par modalité

# Synthèse des données



- 72 ressources, dont :
  - 21 outils
  - 51 données
- Langues représentées
  - Français, Anglais, Latin, Tamoul, Allemand, Perse, Bulgare, Croate, Tchèque, Estonien, Persan, Ouldémé, Ihanzu, Langi, Mahorais, Mankon, Mbugwe, Nagazidja, Nyilamba, Yucuna, Bahing, Hayu, Koyi, Lazé, Limbu, Mizo, Na, Naxi, Nepali, Prinmi, Tamang, Thulung, Espagnol, Galicien, Kurmanji, Polonais, Slovène, Japonais, Danois, Grec, Finnois, Macédonien, etc.
- Objectifs renseignés
  - Apprentissage d'analyseurs statistiques en dépendances, analyse syntaxique, TAL, linguistique expérimentale, observation des SP en tête de phrase, aide à la recherche en linguistique, enquêtes linguistiques, traduction automatique, machine learning.

# Discussion



Qui se charge de diffuser  
les métadonnées ?

# Appels à intervention



- Critères de sélection
  - Ressource cataloguée dans l'inventaire
  - Opération financée ou soutenue par le labex
  - Plusieurs laboratoires concernés
  - Durée de l'intervention précisée
- Processus de sélection
  - Réception des demandes au fil de l'eau
  - Sélection par un comité *ad hoc* de l'opération
  - Validation par comité scientifique restreint tous les trimestres ?