



Imports et modifications en masse dans HAL

Exemple des thèses de l'UL en
partenariat avec l'INIST

Jean-François Lutz – Université de Lorraine

Alain Zasadzinski – INIST-CNRS

2^{es} journées CasuHAL – Dijon – 01/06/2018

Pourquoi transférer des thèses vers HAL ?

- Dépôt numérique des thèses de doctorat adopté tôt dans les universités lorraines (2006 -2007).
Extension aux thèses d'exercice en 2009-2010.
- Choix d'ORI-OAI en 2009 pour le signalement et la diffusion.
- Mise en production à l'automne 2010 (Pétale),

► Bienvenue sur PETALE

Pétale est la plateforme de diffusion en ligne des thèses et mémoires numériques de l'Université de Lorraine.

[\[En savoir plus\]](#)

Rechercher



Pourquoi transférer des thèses vers HAL ?

- En parallèle, politique de numérisation rétrospective des thèses au format papier :
 - 1990-2007 pour les thèses de doctorat
 - 2000-2009 pour les thèses d'exercice
- Signalement dans ORI-OAI également.
- Gestion des accès intranet / internet.

Pourquoi transférer des thèses vers HAL ?

- 2014 : le dossier « archive ouverte » est relancé.
- Analyse fonctionnelle et tests de 3 solutions locales... HAL rattrapé *in extremis* avec la v3.
- Choix de HAL au printemps 2015

Maintenir deux outils en parallèle ?

Préparer le basculement vers HAL

- Volumétrie relativement importante.
- Formats distincts mais mapping ABES TEF -> TEI.
- Deux problématiques :
 - l'import des thèses présentes dans ORI-OAI
 - le traitement des thèses courantes.

Préparer le basculement vers HAL

- Recours au service informatique interne pour l'import des thèses de doctorat et à l'INIST pour celui des thèses d'exercice
- Mise en place d'imports semestriels Sudoc -> HAL par l'INIST pour les thèses d'exercice courantes.

Work Flow dépôt initial

1. Mapping TEF vers TEI-HAL
2. Transformation via scripts shell + perl + librairie XML interne (INIST)
3. Insertion des éléments spécifiques au portail
 - Type de document (MEM pour les thèses d'exercice)
 - idStruct (AuréHAL) de l'établissement
 - Type d'accès (internet ou intranet)
 - Domaines (thèses d'exercice médecine, pharmacie, dentaire)
4. Parsing XML (xmllint)
5. Création des [zip](#) pour dépôt SWORD (TEI-XML avec ou sans pdf selon type d'accès)
6. Exécution du script d'import SWORD

Work Flow correction en masse de métadonnées

1. Correction des métadonnées dans la TEI-HAL avec suppression du champ « editionStmt »
2. Parsing XML (xmllint)
3. Récupération via les API de HAL des métadonnées correspondant aux références à corriger
4. Mapping entre les références initiales et celles récupérées dans HAL afin de récupérer l'identifiant HAL (docid) correspondant :
 - alignement titre+auteur (avec appauvrissement casse, suppression diacritiques et ponctuation)
5. Création des répertoires paper.zip pour dépôt SWORD (avec la TEI corrigée et un fichier [txt](#) contenant le docid de la notice)
6. Exécution du script de correction SWORD

Scripts de dépôt et de correction SWORD

```
#!/bin/bash
```

```
export PATH=$PATH:/usr/local/bin/
```

```
#-- smtp mail
```

```
SMTP="smtp://smtpout.intra.inist.fr:25"
```

```
#-- le user et mot de passe de connexion
```

```
user_pwd="*****:*****"
```

```
#-- le mail pour reception cptr
```

```
#~ mail=florence.join@inist.fr
```

```
#~ mail=alain.zasadzinski@inist.fr
```

```
mail=colette.orange@inist.fr
```

```
#-- pour generer un dépôt avec pdf paper.zip et l'envoyer mettre zip="true"
```

```
#-- pour generer une correction de dépôt :
```

```
    #~ zip="false"
```

```
    #~ maj="true"
```

```
    #-- l'url du dépôt
```

```
    #~ url=https://api-preprod.archives-ouvertes.fr/sword/hal/
```

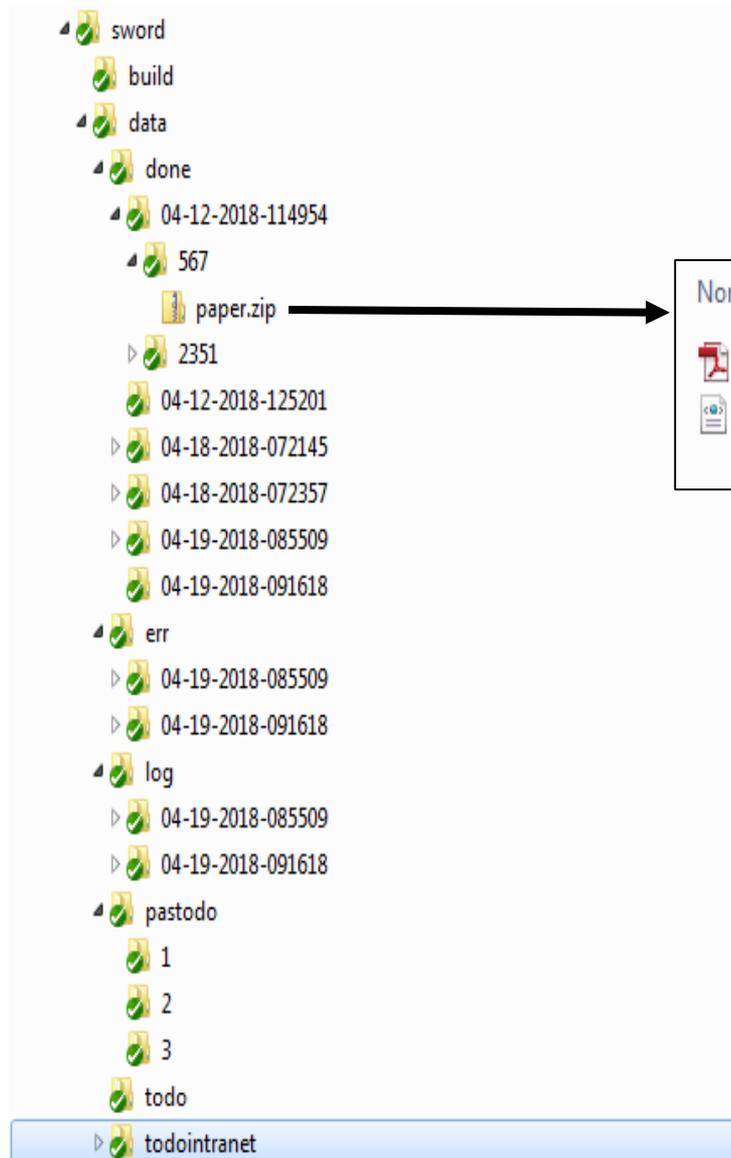
```
url=https://api.archives-ouvertes.fr/sword/univ-lorraine/
```

```
    #~ url=https://api.archives-ouvertes.fr/sword/hal/
```

```
"# -- commande qui traite les données sous $HOME/sword/data/todo/
```

```
docker-compose run --rm --user=$UID sword -u $user_pwd -m $mail -p $url -l $zip -v $maj -j $SMTP
```

Organisation des répertoires de dépôt



Nom	Type	Taille compressée
BUMED_T_2015_GIFFA_MAXIM.pdf	Adobe Acrobat Document	2 371 Ko
BUMED_T_2015_GIFFA_MAXIM.xml	Document XML	2 Ko

Exemples de fichiers TEF et TEI-XML

[Fichier TEF avec pdf](#)

[Fichier TEI-XML avec pdf](#)

[Fichier TEF sans pdf](#) (accès intranet)

[Fichier TEI-XML sans pdf](#)

[Notice WoS en TEI-XML pour dépôt avec PDF](#)

[Fichier TEI XML pour correction HAL](#)

[Fichier associé avec idHAL](#)

Cas de dépôt en masse depuis le WoS : notices + PDF (1)

Principale difficulté :

Résolution de toutes les affiliations françaises par un id_struct

Déclaration des affiliations étrangères dans l'élément « back » de la TEI-HAL

Création d'un dictionnaire de « formes de noms de labos » vers auréHAL-structure

- Utilisation de **auréHal-structure**, **Labintel** et **RNSR** pour création d'une table combinant un maximum de forme de noms
 - **Mapping** entre RNSR, Labintel et auréHal-structure
- Récupération des id_struct via API auréHAL (valid / old / incoming)*

Résolution des affiliations :

- Appauvrissement des affiliations : casse, ponctuation et diacritiques
- Table à 3 ou 4 colonnes de toutes les formes de noms de labos possibles
- Double/triple alignements de chaque affiliation avec la table (script perl) :
 - forme du nom du labo / ville(s) ou tutelle(s)
 - type de labo / numéro /ville(s) ou tutelle(s)
 - Génération de l'id_struct (ou du RNSR ou Labintel ...) et des chaînes de caractères reconnues dans la table pour validation/vérification
 - **Détection des ambiguïtés (ex : id-struct multiples pour même affiliation)**
 - **gestion par dates de publication en relation avec évolution du labo**
 - **validation manuelle des ambiguïtés sous excel par documentaliste**

Cas de dépôt en masse depuis le WoS : notices + PDF (2)

A fournir :

Cle ut avec pour chacune :

- pdf
- id_struct des auteurs des labos concernés pour chaque affiliation concernée
- type de documents
- domaines scientifiques HAL

Pour le dépôt en masse via sword :

- Téléchargement du corpus à partir du WoS et transformation en TEI-HAL
- Ajout des éléments ci-dessus dans la TEI-HAL

Attention doublons potentiels :

- Hal détecte les doublons sur la base du DOI
- Si besoin d'en faire plus, nous contacter (ex : dédoublonnage de documents sans DOI avant dépôt en masse dans HAL)