

OSUG-DOI (public)

Source code: <https://gricad-gitlab.univ-grenoble-alpes.fr/OSUG/DC/osug-doi>

Roadmap:

- tests: metadata + soumission DOI de test: OK
- génération landing pages simples: OK
- génération metadata et landing pages pour amma-catch (pipeline iso 19-115 + templates csv): OK
- TODO List:
 - TEST:
 1. publication DOI avec relatedIdentifier en test (lien invalide): fait = datacite ne vérifie pas la validité des relations
 - DOC:
 1. faire un template CSV (with all possible key/values + comments)
 2. procédure à écrire pour un projet (templates, config...)
 - DEV:
 1. création dépôt DOI sur forge (sourcesup ?): OK
 2. packaging scripts, pipeline + configuration (templates), landing pages: OK
 3. améliorer landing page (html header / footer, about page): OK
 4. générer index.html pour lister les DOIs (staging / public): en cours
 5. gestion BDD:
 1. design des tables: projet et DOI: dates (génération, publication), état(staging/public), URL data access, URL landing page externe, URL landing page active: en cours
 6. améliorer scripts de publication pour gérer des dossiers staging et production (par projet) et modifier l'état en BDD: en cours
 7. accès landing pages: gestion des redirections si landing page personnalisée (générer .htaccess)
 8. supervision pour détecter / signaler les URLs invalides (URL 404)
 - PROD:
 1. création vm doi.osug.fr pour héberger toute la gestion (backoffice simple) et les landing pages
 1. demande: faite
 2. installation paquets (httpd + conf)
 3. installation pipeline + scripts
 4. installation BDD
- backoffice web de gestion/soumission DOI (futur)

Principe



Roles:

- Datacite: assure la résolution du DOI et possède les informations pour chaque DOI: méta données (xml) + URL associée vers doi.osug.fr (landing page ou ressource)

- OSUG-DC: le serveur doi.osug.fr héberge les landing pages (en local) ou réalise une redirection vers un autre serveur (spip...) dans le périmètre de l'OSUG
- les landing pages doivent être pérennes et contenir les instructions pour accéder aux données / services

Développement

OSUG DOI: <http://doi.osug.fr/>

Génération Landing Pages (datacite XML to HTML)

A partir d'un document XML correspondant aux métadonnées du DOI (datamodel datacite), une transformation XSLT génère une page HTML statique (bootstrap + CSS) qui affiche simplement les méta données.

Cependant, il manque les informations pour l'accès aux service / données dans le document XML (datacite).

TODO:

- trier les meta données selon le document AMMA-CATCH: OK
- ajouter un page footer (date + lien vers OSUG-DOI): OK
- rajouter les instructions d'accès aux données via un fragment HTML (fichier dans config); si manquant, prévoir une phrase par défaut
- rajouter l'URL de destination pour accéder aux données
- revoir le page header (optionnel)
- générer l'index pour staging / public

Proposition: fournir ces paramètres à la transformation XSLT récupérés depuis la configuration (projet ou du jeu de données pour URL) depuis les templates CSV (data_access:URL et data_access:information) ou la BDD ?

Outil de génération des métadonnées DOI (datacite XML) à partir des méta données ISO-19139 (CSW)

Cas d'utilisation = AMMA-CATCH (voir <http://bd.amma-catch.org/amma-catch2>)

Principe

Certaines infos nécessaires au schéma datacite sont déjà renseignées pour chaque jeu sur le portail Web d'accès aux données AMMA-CATCH et sont récupérables par http en utilisant le webservice CSW méthode getRecords (format XML ISO 19139):

<http://bd.amma-catch.org/amma-catchWS2/WS/csw/default?service=CSW&request=GetRecords&version=2.0.2&typenames=csw:Record&resulttype=results&maxrecords=100&elementsetname=summar>

[y&outputschema=http://www.isotc211.org/2005/gmd](http://www.isotc211.org/2005/gmd)

Il faut ensuite les compléter pour produire un fichier XML DataCite pour chaque jeu de données.

Chaine de fusion des informations (CSW + templates)

Pour compléter les metadonnées, des templates (global, pays et jeu) au format CSV sont utilisés.



Séquence de traitement:

1. GetRecords → renvoie autant d'éléments `<gmd:MD_Metadata></gmd:MD_Metadata>` qu'il y a de jeux de données à condition d'indiquer le paramètre maxrecords dans l'URL
2. Conversion au format CSV
3. Pour chaque jeu de données, fusionner avec les templates:
 1. template global: `template_all.csv`
 2. template pays: correspondant au pays indiqué par `geoLocationPlace` (`geoLocationPlace;Benin`)
 3. template spécifique au jeu de données: correspondant à l'identifiant indiqué par `identifier` (`identifier:DOI;10.5072/AMMA-CATCH.CL.Run_O`)
 4. sauvegarder et convertir au format XML datacite
4. validation des fichiers XML avec le schéma
5. vérifier les related identifiers (existe en BDD ?) pour tester des références invalides ?
6. générer les landing pages associées
7. tester publication du DOI (metadata + URL) avec le préfixe de test: STAGING
8. sauvegarder les informations du DOI en BDD (statut des étapes de traitement, URL ...)

Note: les identifiants DOI doivent contenir que le préfixe de test (publication ultérieure) et les méta-données en doublons sont ignorées (même clé / valeur) mais attention si les informations ne sont pas disjointes (clés présentes dans plusieurs templates)

Attention à l'encodage des fichiers CSV (utf-8 sous linux et iso-8859-1 sous windows) !

TODO:

- généraliser à d'autres services CSW en externalisant toute la configuration du pipeline dans un fichier (clé=valeur) par projet: en cours
- validation: vérifier la présence de méta-données (en plus, de la validation xml assez laxiste) comme `dataAccess:URL ...`
- comment gérer la mise à jour des templates CSV ? manuel dans un premier temps; plus tard: via `owncloud.osug.fr` ou via interface d'administration

Gestion multi-projet dans le file system:

- config
 - AMMA-CATCH
 - projetX
- staging
 - AMMA-CATCH
 - projetX

- public
 - AMMA-CATCH



Publication DOI (datacite)

objectif: automatiser la publication des DOIs et alimenter la BDD (statut)

TODO:

1. copier la landing page (URL publiée chez datacite): PUBLIC
2. réécrire les identifiants DOI (identifier et relatedIdentifier) pour remplacer le préfixe de test en préfixe OSUG à l'aide de la base de données
3. publier ce DOI avec le préfixe OSUG et mettre à jour la BDD
4. gérer les redirections ie une URL alternative pour la landing page

note: garder les documents XML + URL dans le file system et BDD

From:
<https://wiki-uar.osug.fr/> - Wiki de l'UAR OSUG

Permanent link:
https://wiki-uar.osug.fr/doku.php?id=osug-dc:2-suivi_projets:doi:osug-doi&rev=1531744848

Last update: 2018/07/16 12:40

