

Le circuit des métadonnées à travers les plateformes de mathématiques

Thierry Bouche



*Dynamiques de l'édition scientifique,
de l'industrie de l'information,
de la documentation*

Meudon, mardi 4 novembre 2014

Sommaire

- 1 Le CEDRAM
- 2 Le circuit idéal d'un article
- 3 L'environnement de production du CEDRAM
- 4 EuDML

Le CEDRAM

Introduction

- Un projet CNRS (INSMI) et UJF de soutien aux revues académiques de recherche en mathématiques (principalement)
- Réalisation : cellule Mathdoc (Grenoble)
- « Académiques » : indépendants (labos. . .) ou sociétés savantes
- Un ensemble d'outils de production
- Un portail de diffusion www.cedram.org
- En projet : élargir le périmètre et le nombre de services

Le CEDRAM

Principes

- Les articles sont des travaux de recherche originaux validés scientifiquement sous la responsabilité d'un comité éditorial
- Les actes de séminaires ou conférences suivent une politique plus légère (un responsable scientifique)
- Une fois publiés, les textes ne sont jamais modifiés
- La navigation des collections est libre, les métadonnées sont ouvertes largement, elles peuvent être révisées périodiquement, au fil des enrichissements (liens...)
- L'accès aux articles est libre à l'issue d'une barrière mobile (BM) raisonnable (À ce jour : 4 revues et 5 séries d'actes en accès libre, 1 revue BM = 2 ans, 2 revues BM = 5 ans)
- Les articles sont versés dans une bibliothèque numérique de référence (libre accès à terme, voie « orange »)

Le CEDRAM

Interopérabilité

- Les sources des articles sont archivées (pour leur préservation)
- Les articles sont versés dans NUMDAM 1-2 ans après parution (pour l'accès sur le long terme)
- NUMDAM est partenaire de EuDML et bientôt GDML (pour une plus grande visibilité et la construction d'une bibliothèque de référence couvrant toute la discipline)
- Plus généralement : OAI-PMH (oai_dc, mini-dml, NLM/EuDML)

Le circuit idéal d'un article

Eurêka \LaTeX auteur

Prépublication arXiv/HAL

Soumission Choix de la revue, rapport de referee

Production Corrections, mise aux normes

Publication Texte et métadonnées définitifs

Indexation MathScinet, zbMath, Crossref

Archivage indépendant, pérenne & distribué
Projet : Private CLOCKSS européen

DML Bibliothèque de référence en libre accès à terme
Partagée, mondiale, pérenne, sans but lucratif
Enrichissements globaux : consolidation des métadonnées, liens, similarité, *math mining*, etc.

L'environnement de production du CEDRAM

Objectifs

- Un chaîne de production *maîtrisable* par de petites structures
 - Uniquement des formats habituels en entrée : \LaTeX , Bib \TeX . . .
- Produisant une édition de *qualité*
 - Une structure assez universelle pour permettre des maquettes Web et papier très variables mais des fonctions de base constantes
 - Éditions papier & électronique identiques
 - Métadonnées exactes (déduites des articles)
 - (Méta)données précises et universelles (Unicode, PDF, XML, MathML. . .)
 - Métadonnées compatibles avec NUMDAM, OAI-PMH, faciles à transformer et exporter (dégrader. . .)

L'environnement de production du CEDRAM

Principes

- 1 Les articles et leurs métadonnées sont produits à partir des mêmes sources \LaTeX
- 2 Une métadonnée est déclarée *une fois* au plus, dans un fichier source *ad hoc*
- 3 Toute métadonnée qui n'est pas pertinente dans un fichier source ne doit pas s'y trouver (exemple : tomain ou pagination dans un article)
- 4 Tout ce qui peut être calculé *doit* l'être
Pas de duplication de métadonnées pas d'heuristiques ou de copier-coller (*un processus*) \implies pas d'erreurs de dernière minute !
- 5 L'environnement doit être d'appropriation facile

L'environnement de production du CEDRAM

Les niveaux

Revue

- Les constantes de la revue : titre, ISSN, maquette. . .
- Les quasi-constantes : pages de titre, ours, comité de rédaction, instructions aux auteurs. . .

Volume

- Données bibliographiques (année, mois, tome, fascicule, lieu. . .)
- Le folio du premier article
- La liste ordonnée des articles
- Variables globales et extras (éditorial, pubs. . .)

Article

- Langue, titre, DOI, auteurs, résumés, texte, biblio, etc.

Pages

- Tous les numéros de pages sont calculés à la volée

Diversité graphique

Même source, présentation variable (1).



Annales de l'institut Fourier



Annales de la faculté des sciences de Toulouse (mathématiques)

Diversité graphique

Même source, présentation variable (2).



*Annales mathématiques
Blaise-Pascal*



*Journal de théorie des nombres
de Bordeaux*

Les enrichissements

- Les métadonnées comportent les biblios
- $\text{T}_E\text{X} \mapsto \text{XML/MathML}$ (Tralics)
- Outils de *matching* (articles et biblios) : MathSciNet, Crossref (services); Jahrbuch, zbMATH, mini-DML, EuDML (outils maison)
- Export NLM + plein texte vers EuDML

La vision EuDML



La bibliothèque numérique de mathématiques devrait s'efforcer de réunir un corpus mathématique **aussi vaste que possible** pour

- le rendre **disponible en ligne**
 - en accès **libre à terme**,
 - sous la forme d'une collection **de référence**,
 - **alimentée** en continu par les nouveautés des éditeurs,
 - **valorisée** par des outils de recherche et référencement sophistiqués,
 - développée et entretenue par un réseau d'**institutions**
- + et le **préserver** à très long terme

EuDML

Enrichissements après import

- Intégration de métadonnées (notamment en anglais) en provenance du zbMath
- Conversion des formules en MathML (OCR Infty, Maxtract → recherche de formules)
- Calcul de similitude des articles utilisant le texte intégral, les formules, les métadonnées
- Expérimental : textes accessibles

GDML

Projet en cours de définition

- Corpus mondial interoperable
 - Infrastructure basse rendant possible la construction de services « sémantiques » et « computationnels »
 - Format de description des structures mathématiques (objets, énoncés, preuves, définitions. . .)
 - Outils de traitement automatisé de cette langue surnaturelle
- ⇒ Activités à Washington et Séoul organisées par le CEIC
- ⇒ Rapport du Conseil national de la recherche (NRC, Nat. Sc. Acad. USA)
Developing a 21st Century Global Library for Mathematics Research, The National Academies Press, 2014
- ⇒ Groupe de travail de l'union mathématique internationale

Merci !

Thierry Bouche

Directeur cellule Mathdoc (UMS 5638 UJF/CNRS)

Président EuDML initiative

Membre CEIC (IMU)

Membre GDML-WG (IMU)