



HAL
open science

Exigences des métadonnées

Jacques Millet, Gaëlle Rivérieux

► **To cite this version:**

Jacques Millet, Gaëlle Rivérieux. Exigences des métadonnées. Arabesques, 2012, 67, pp.4-6. hal-00765541

HAL Id: hal-00765541

<https://inria.hal.science/hal-00765541>

Submitted on 21 Dec 2012

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.

Exigences des métadonnées

Le fil rouge de la science

Qu'une donnée puisse en représenter un jeu entier, qu'à son tour ce dernier puisse constituer un corpus cohérent de connaissances, ordonné et exploitable – cela identifie assez, depuis Alexandrie, la nécessité classificatoire des objets de pensée, leur invention¹ et leur mémoire.

Les métadonnées, puisqu'il s'agit bien de ces données *indexantes* du discours, ont connu une fortune invariable de renouvellement, que leur pouvoir d'orientation puis d'interprétation n'a cessé d'affirmer. Elles imposent encore aujourd'hui un maillage des contenus de la science – dans la mesure extensive de leur exposition numérique.

C'est justement sous le couvert empirique d'un univers insensé – le web de données – que la production des métadonnées trouve sa justification tant heuristique qu'économique.

Métadonnées de propriété

Tout objet de discours (de science), toute collection de données, en définitive toute unité de sens peut recevoir une annotation minimale, une cote, un identifiant qui renvoie à un système partagé – un référentiel qui a valeur de norme et contre lequel ils sont rapportés, puis reconnus. C'est à ce premier niveau de propriété qu'une métadonnée distribue les objets comme autant d'objets *uniques*.

Historiquement, de tels identifiants normés ont été attribués et maintenus par des communautés d'intérêts (intellectuelles ou commerciales) exerçant un droit de propriété sur les contenus visés. Une autorité auteur par exemple, au sens bibliothéconomique du terme, peut étendre sa représentation dans une définition stricte, portée par un identifiant numérique unique. L'initiative *Orcid*² constitue à ce titre l'effort sans doute le plus significatif à l'établissement d'un registre mondial de contributeurs scientifiques, y compris d'œuvres orphelines ou posthumes. L'enjeu que représente l'établissement d'une telle métadonnée intéresse directement la propriété intellectuelle et les ayants droit d'une œuvre de l'esprit – tout en permettant de lier les objets qu'ils ordonnent à l'échelle d'une *e-science* dont les contributions connaissent un développement exponentiel.

Autant l'ISSN constitue une métadonnée de propriété captive – et de même le DOI qui demeure une attribution éditoriale – autant la nécessité de métadonnées de propriété d'un autre ordre, visant tous les objets de la recherche scientifique, apparaît comme un enjeu aux nombreuses ramifications. Une extension aux données brutes de la science de ces identifiants

¹*Inventio* – au sens latin de découverte.

² Open Researcher and Contributor ID – proposé comme identifiant unique et ouvert pour les contributeurs d'œuvres de l'esprit, similaire à ce que pourrait être un DOI [Digital Object Identifier] d'auteur. Cf. www.orcid.org Voir également, sur un périmètre élargi des œuvres de création, l'ISNI [International Standard Name Identifier] qui ambitionne l'interopérabilité de systèmes d'identification propriétaires.

spécifiques est notamment portée par le consortium *DataCite*³, dès lors accessibles à la citation comme aux liaisons sémantiques.

Métadonnées descriptives

C'est une société d'informatique dans les domaines de la santé et de la médecine qui dépose la marque « Metadata », en 1986. La NASA l'utilise pour la première fois en 1988 dans une édition du *NASA's Directory Interchange Format Manual*⁴. Dans les années 1990, le vocable entre peu à peu dans le domaine public et s'impose comme définissant la description des données. En 1995, après qu'une première spécification ait été réalisée pour les données géographiques, le terme apparaît dans le monde bibliothéconomique avec la création du *Dublin Core Metadata Set Element*. Les professionnels de l'information prennent alors conscience qu'ils sont créateurs, depuis des décennies, de nombreuses métadonnées et que celles-ci peuvent tout autant décrire des documents papier que des ressources électroniques.

C'est ainsi que les données catalographiques, depuis leur socle descriptif MARC⁵, n'ont cessé de décliner de nouveaux modèles de représentation. Aujourd'hui, le modèle conceptuel FRBR⁶ entend formaliser les relations sémantiques entre une œuvre et ses différents types d'expressions, en s'affranchissant de la notion de « document » comme première unité signifiante. Les enjeux de ce modèle verront se démultiplier de nouveaux points d'accès à l'information et permettre de nouvelles liaisons sémantiques entre des sources de données hétérogènes.

Ces nouveaux principes, organisés autour d'entités et de relations, permettront d'offrir un cadre de données structurées, appuyé sur de nombreux schémas de métadonnées XML – formats créés en fonction de l'usage des ressources⁷. Nous voici à l'aube de la construction du web de données, où il ne s'agit plus seulement d'assurer des liens entre des objets ou des documents, mais d'offrir un accès logique et pérenne entre les données elles-mêmes. L'accès à la connaissance suppose d'ores et déjà l'appropriation de ces nouvelles cartes du savoir, affranchi de ses limites propres.

Métadonnées d'enrichissement

Pour porter le paradigme documentaire au sens, le seul signalement des ressources, fut-il normé et extensif, ne saurait servir qu'à un seul effet d'accumulation de données. C'est la structuration des métadonnées dans de véritables systèmes d'information, puis leurs liaisons avec d'autres univers de données, leur interopérabilité, qui permettront leur ouverture tant aux moteurs de recherche qu'aux routines des bases de connaissances. Toutes opérations qui requièrent un apport d'intelligence : le coût du facteur humain dans l'analyse et l'enrichissement des données oblige à des contournements ou à la mise en œuvre de relais

³ Datacite.org – et son Metadata Store : <https://mds.datacite.org/>

⁴ Caplan, P. : *Metadata for all librarians*, Chicago, American Library Association, 2003, p. 1.

⁵ Machine Readable Cataloguing.

⁶ Functional Requirements for Bibliographic Record.

⁷ Dublin Core, EAD, MODS, METS...

sémantiques qui aient quelque valeur probante dans les différents champs de l'économie numérique.

Une première approche tient dans l'imposition de règles de production des médias d'information eux-mêmes, à des fins d'extraction automatique et contrôlée de métadonnées utiles : une telle disposition éditoriale augmente la performance des systèmes de fouille de données et des logiciels d'appariement lexicaux associés. Courante dans la chaîne éditoriale du document, de l'image ou du son (œuvre ou fragment), elle reste à généraliser aux objets complexes de la culture et de la connaissance (objets de la recherche scientifique, flux de données primaires, bruits des différents fonds de données archivées). Des ontologies y répondent, mais la méthode semble introuvable⁸, tant l'expression du sens d'un objet (textuel, multimédia, sériel...) semble hors de la portée des outils qui le manipulent (quand ceux-ci seraient fondés sur des recommandations du web sémantique). En clair, un jeu de métadonnées ontologiques, qui expose un contenu à l'interprétation d'agents logiciels, ne saurait épuiser le sens qu'il porte, sauf à le rapporter à un segment de science (une discipline captée par son lexique) ou de culture (une œuvre représentée par ses codes) – c'est-à-dire à des référentiels fermés, sans prétention herméneutique (interprétative)⁹.

Mais à défaut de sens, ces métadonnées référentielles peuvent-elles opérer une aire de correspondances entre différents univers de données ; des objets liés à des référentiels hétérogènes peuvent entrer en résonance, sans corrompre leurs lexiques propres. Des initiatives comme SKOS cherchent les conditions d'interopérabilité de ces différents référentiels auxquelles de grands prescripteurs institutionnels apportent leur soutien¹⁰.

Une exposition au plus grand nombre

Un des enjeux d'exploitation de la variété des gisements informationnels repose sur leur facilité d'exposition (*Open Data*¹¹) et d'intégration dans des systèmes tiers, au-delà de leurs éventuelles incompatibilités natives pouvant résulter de leur structuration physique ou sémantique.

A titre d'exemple, la complexité de la description de l'objet muséal ou archéologique, dans toute la variété de ses formes, a conduit à la création de modèles, tel CRM-CIDOC¹² devenu norme ISO en 2006, et à plusieurs standards pour les décrire tels CDWA¹³ et LIDO¹⁴.

CRM-CIDOC, ontologie de domaine orientée objet, entend modéliser et formaliser la nature et les relations existant entre divers éléments descriptifs des objets de musée, qu'ils soient

⁸ C'est cependant l'horizon que se donne RDF (Resource Description Framework), avec l'établissement de représentations sémantiques des métadonnées descriptives des objets de recherche et de culture – sans le filtre d'une lecture humaine.

⁹ Cf. Zacklad, M. : « Evaluation des systèmes d'organisation des connaissances », *Les Cahiers du numérique*, 2010, vol. 6, n° 3, pp. 133-166.

¹⁰ Bibliothèques nationales, ministères de la culture, registres de publications officielles. Voir www.w3.org/2001/sw/wiki/SKOS/Datasets

¹¹ <http://www.data.gouv.fr/>

¹² <http://www.cidoc-crm.org/>

¹³ CDWA : Categories for Description of Work of Art, développé au début des années 1990 :

http://www.getty.edu/research/publications/electronic_publications/cdwa/index.html

¹⁴ <http://www.lido-schema.org/documents/LIDO-Handout.pdf> (2010).

unitaires ou partie d'un tout, réels ou virtuels. Ce modèle s'accorde à donner le sens précis des métadonnées ainsi que des événements entrant en relation avec l'objet décrit. Ces descriptions fortement contextualisées permettent de préciser l'unicité de l'item (en restituant ses identifiants, ses marques, ses mesures...) tout en offrant des liens d'adjacence avec des ressources externes qui qualifient son environnement (géographique, historique, manifestations en rapport, intervenants...).

Appliqué à divers corpus documentaires, tels qu'images, textes, vidéos, CRM-CIDOC peut offrir de nouveaux espaces de médiation fédérant des ressources variées et favorisant ainsi la découverte, au-delà des frontières disciplinaires ou institutionnelles. L'initiative CLAROS¹⁵, programme soutenu par l'UNESCO, réunit plus de 20 millions de notices d'objets de l'antiquité gréco-romaine issus des musées du monde entier, grâce à l'utilisation du CRM-CIDOC et de RDF, le tout interrogeable via le langage de requête SPARQL.

La création de ces nouveaux points d'accès permet une plus vaste exposition des métadonnées, véritable enjeu de diversité culturelle et d'aide à la recherche scientifique, rendus possible grâce aux langages et vocabulaires sémantiques tels que RDF, SKOS...

Dans un contexte plus commercial, les métadonnées d'identification, telles ISAN¹⁶, ISRC¹⁷ et ISMN¹⁸, prennent tout leur sens dans un contexte de reproductibilité des supports, de quantité de transactions et d'échanges dans le cadre mondial du e-commerce. En tant qu'identifiants uniques, ces formats répondent à une attente très forte de la part des ayants droit, des gestionnaires de collections, des diffuseurs ou revendeurs de contenus. En général, ils sont attribués par une autorité fédérative gérant un répertoire central.

Et demain ?

Ces métadonnées, embarquées dans de nouveaux médias, utilisées via des dispositifs ubiquitaires (extensifs et mobiles), se proposeront demain spontanément aux utilisateurs que nous sommes, en fonction de nos usages passés – appréciations, prescriptions et consommations. Alors qu'à ce jour, l'utilisateur numérique se devait d'être actif pour accéder à l'information, celle-ci pourrait être dotée d'une forme d'intelligence afin d'anticiper les besoins informationnels, préparant ainsi le web de demain : l'Internet des objets¹⁹.

*Jacques Millet, délégué à l'information scientifique, Inria
Gaëlle Rivérieux, responsable IST du Centre Inria Grenoble Rhône-Alpes*

¹⁵Classical Art Research Online Service : www.clarosnet.org

¹⁶International Standard Audiovisual Number (ISO standard 15706:2002 & ISO 15706-2).

¹⁷International Standard Recording Code (ISO 3901).

¹⁸International Standard Music Number (ISO 10957).

¹⁹<http://hal.archives-ouvertes.fr/hal-00598395>