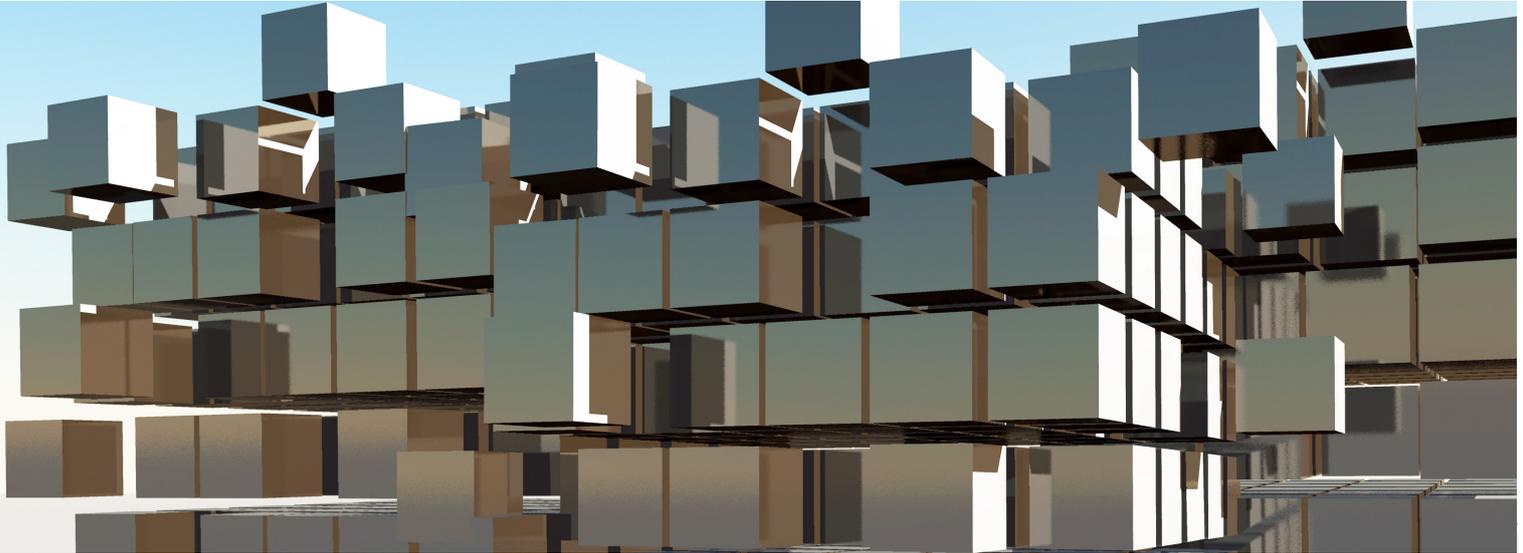




**Huma-Num**  
la TGIR des humanités numériques

# Les guides de bonnes pratiques



#2

## Le guide des bonnes pratiques numériques

Le passage au numérique est devenu une priorité et parfois même une nécessité dans le paysage actuel de la recherche et de sa patrimonialisation. Il n'est cependant pas toujours simple d'opérer le bon choix technologique pour numériser, sauvegarder ou exploiter des données souvent hétérogènes. En s'intéressant de manière détaillée aux formats, standards et pratiques les plus stables aujourd'hui en matière de numérique, ce guide souhaite répondre aux besoins de ceux qui souhaitent se lancer dans un projet numérique ou mettre à niveau leurs corpus numériques existants.

En savoir plus



Il peut être téléchargé sur :

<http://www.huma-num.fr/ressources/guides>

TGIR Huma-Num  
Pôle communication  
190, avenue de France  
75013 PARIS

[huma-num.fr](http://huma-num.fr)

INFORMER

PARTAGER

DIFFUSER

HN

---

*Ce guide de bonnes pratiques est une version remaniée du guide initialement publié en septembre 2011.*

## INTRODUCTION

Le passage au numérique est devenu une priorité et souvent même une nécessité dans le paysage actuel de la recherche et de sa patrimonialisation. Numériser comme procédé de communication et d'exploitation de l'information, numériser comme procédé de conservation de l'information. Numériser afin de traiter et d'analyser autrement et plus en profondeur les données, et de créer un patrimoine scientifique pour les générations à venir, afin d'être en phase avec les pratiques qui se généralisent ailleurs, afin de valoriser la production scientifique, afin de pouvoir travailler à distance et en collaboration sur des corpus ; voici, parmi bien d'autres, les objectifs qui motivent les laboratoires, chercheurs et enseignants-chercheurs à effectuer ce passage. S'ajoute aux opérations de numérisation le fait qu'aujourd'hui de plus en plus de données sont numériques dès leur création.

Malgré les opportunités incontestables qu'offre le numérique, il est aussi parfois synonyme de confusion et de propagation de pratiques, formats et supports les plus divers et les moins transparents. Nombreux sont ceux qui se retrouvent, après des efforts humains et financiers parfois considérables, avec un corpus numérique inexploitable quelques années plus tard seulement, parce que les formats ont changé ou que les outils de lecture et d'exploitation n'existent plus. Souvent aussi des corpus numérisés se révèlent inexploitable sur des plateformes ou avec des logiciels couramment utilisés dans le monde de la recherche et de l'archivage numérique.

Le passage aux pratiques numériques n'est ainsi pas automatiquement synonyme de potentiel d'exploitation, ni d'archivage à long terme. Encore faut-il que les pratiques numériques soient en phase avec celles qui sont adoptées par les acteurs du paysage. D'où l'importance de choisir des formats interopérables, c'est-à-dire des formats qui permettent l'échange des données et des informations : « l'objet » devient partageable et diffusable, car sa description sur le plan informatique respecte des formats standards ou bien des normes, soit encore des références internationalement reconnues.

Ce guide de bonnes pratiques constitue une première étape dans l'accompagnement des chercheurs qui se lancent dans le numérique. En s'intéressant de manière détaillée aux formats et en faisant le point sur les pratiques les plus récentes, ce guide peut aussi répondre aux besoins de ceux qui souhaitent harmoniser ou mettre à niveau leurs corpus numériques existants. Le guide est une réalisation de la TGIR Huma-Num, à laquelle ont collaboré différents acteurs de la communauté des humanités numériques. Il a été rédigé sous l'impulsion de l'Institut des Sciences Humaines et Sociales du CNRS et du Ministère de l'Enseignement Supérieur et de la Recherche.

Janvier 2015.

# SOMMAIRE

Introduction .....	3
Le projet numérique.....	7
1. Décider .....	7
2. Organiser .....	7
3. Numériser .....	8
4. Structurer.....	9
5. Exploiter .....	9
6. Diffuser.....	10
7. Pérenniser .....	10
8. Liste des recommandations .....	11
Métadonnées, HTML, RDF, protocole OAI-PMH .....	13
1. Métadonnées : généralités .....	13
2. Métadonnées et schémas génériques.....	14
2.1 Le Dublin Core.....	14
2.2 Le schéma METS.....	14
3. HTML.....	16
4. Le RDF.....	16
5. Le protocole OAI-PMH .....	17
6. Les ressources .....	17
Les bases de données.....	19
1. Généralités .....	19
2. Les métadonnées .....	19
5. Les ressources .....	20
3. L'entrepôt.....	20
4. Liste des recommandations .....	20
Les données textuelles .....	21
1. Les données .....	21
2. La numérisation.....	21
3. Les métadonnées .....	22
4. La TEI (text encoding initiative).....	22
5. Liste des recommandations .....	23
6. Les ressources .....	23

<b>Les données iconographiques - I. les images fixes .....</b>	<b>25</b>
1. Les données .....	25
2. La numérisation.....	25
2.1 Le format de fichier.....	25
2.2 Paramètres de qualité.....	26
3. Les métadonnées .....	27
3.1 Métadonnées techniques .....	27
3.2 Les métadonnées techniques : les EXIF.....	27
3.3 Métadonnées descriptives .....	28
3.4 Les métadonnées descriptives : les XMP et les IPTC .....	28
4. Liste des recommandations .....	29
5. Les ressources .....	29
<b>Les données iconographiques - II. Les images animées et les films .....</b>	<b>31</b>
1. Les données .....	31
2. Les conteneurs et les codecs .....	31
2.1 Les principaux formats conteneurs vidéo .....	31
2.1 Les principaux codecs vidéo.....	33
3. La numérisation.....	34
4. Les métadonnées .....	34
5. Liste des recommandations .....	35
6. Les ressources .....	35
<b>Les données sonores.....</b>	<b>36</b>
1. Les données .....	36
2. La numérisation.....	36
3. Les métadonnées .....	37
4. Liste des recommandations .....	38
5. Les ressources .....	38
<b>Glossaire .....</b>	<b>39</b>



# LE PROJET NUMÉRIQUE

Un projet numérique est toujours un projet collectif, car il requiert des compétences variées (problématique de recherche, informatique, documentation, communication, etc.).

Tout projet numérique demande d'adopter une méthodologie de projet.

Les différentes étapes d'un projet numérique peuvent être structurées à travers les verbes suivants :

- Décider
- Organiser
- Numériser
- Structurer
- Exploiter
- Diffuser

Il faut y ajouter le verbe « Pérenniser », qui rassemble un ensemble de questions **qu'il importe de se poser dès le début du projet**, et qui implique des décisions et des actions, pratiquement à chaque étape du projet.

## 1. Décider

Il s'agit ici de collecter les idées, de définir l'objectif et de préciser tous les aspects et tous les enjeux du projet. On recommande l'application de la méthode *QQOQCCP*: « Qui fait Quoi, Où, Quand, Comment, Combien, Pourquoi », qui permet de poser l'ensemble des questions nécessaires. Il importe de répondre à chacune de ces questions avec le plus de précisions possibles.

À cette étape du projet, trois questions importantes sont à traiter : la question des droits juridiques (qui touchent les données du projet, notamment en matière de diffusion), la question du stockage et la question de l'archivage.

D'autres méthodes que la méthode *QQOQCCP* existent. On peut citer la méthode Agile, la méthode en V, la méthode itérative. Nous les recommandons non au début du projet, mais plutôt pour les étapes de réalisation des différentes phases du projet.

Le document final résultant de cette étape est une note d'intention qui reprend les différentes questions de la méthode *QQOQCCP* dans le but de convaincre ses interlocuteurs (financeurs, partenaires, ...).

## 2. Organiser

On prépare ici le pilotage du projet. Celui-ci passe par la préparation d'une note de cadrage, qui établit l'organisation précise du projet. Elle en permet la validation. Par la suite, il faut construire le cahier des charges fonctionnel. Idéalement, celui-ci doit suivre la norme AFNOR NF X50-151. Enfin, il importe d'établir le planning prévisionnel du projet et en particulier de ses livrables.

### 3. Numériser

Numériser des données revient à :

- Établir les spécifications techniques
- Numériser ou faire numériser
- Contrôler la qualité des résultats

Plus précisément, il s'agit de :

Sélectionner les documents à traiter (corpus de fait ou créé). Points importants : cohérence du regroupement, respect du contenu et des droits.

- Établir un cahier des charges adapté aux spécificités de l'objet : il permet de préciser la demande à la personne en charge de la numérisation mais aussi de servir de document « tiers » lors du contrôle de la qualité.
- Définir les modes opératoires (recopie brute, corrections ; utilisation de logiciels avec entraînement ou non, etc.).
- Choisir des formats d'enregistrement non propriétaires, respectant des normes internationales ou bien étant des standards de fait.
- Définir un plan de nommage des fichiers ; voir ci-après.
- Toujours contrôler la qualité des résultats obtenus (relecture, observation attentive, etc.).

Le cahier des charges devra, au besoin, préciser les conditions de livraison des originaux ainsi que des copies numérisées, les conditions d'assurance sur les originaux et les conditions de réutilisation des données numérisées par le prestataire. Il pourra aussi parfois être utile de préciser le degré de confidentialité à respecter.

#### **Le plan de nommage des fichiers numériques**

Une identification claire des fichiers numériques doit être préparée, à la fois en prévision du traitement et pour en réaliser l'inventaire. Il y a toujours nécessité de fournir un inventaire des fichiers.

Il faut utiliser pour chaque fichier un nom unique. Cela permet d'éviter une confusion :

- entre les fichiers et leurs différentes versions ;
- entre les fichiers numérisés et les fichiers de métadonnées (cf. § 2.1.).

Prenons l'exemple des données sonores. Voici ce que recommande la BNF, dans son document *Écrire un cahier des charges de numérisation de collections sonores, audiovisuelles et filmiques* :

- Un nom unique devra être attribué à chaque document à numériser. Par exemple : XX\_000001
- Les différentes parties (volumes, bobines, cassettes, numéro de la face (cassette), nom de la piste (CD), etc.) doivent être identifiées en utilisant une subdivision du nom unique. Par exemple : XX\_000001\_V1\_1 ou XX\_000001\_V1\_n, si n parties.
- Le nom unique doit toujours être reporté sur le boîtier (s'il y en a un) et sur le support lui-même.
- Pour des volumes importants et pour la gestion ultérieure des supports, l'usage de codes barres est souhaitable.

Quelle que soit la hiérarchie choisie de dossiers et sous-dossiers (pour les fichiers numérisés ou pour les fichiers de métadonnées), chaque fichier doit avoir un nom unique. Pour écrire le nom unique, tous les caractères ne sont pas admis :

- Il faut utiliser uniquement les lettres a...z et les chiffres 0...9, et ne jamais utiliser l'espace ni de caractères accentués.
- Le signe \_ (underscore) est autorisé et recommandé pour distinguer des entités au sein du nom du fichier (mais en cas d'utilisation sur le web l'underscore peut être confondu avec le soulignement propre au lien hypertexte).

## 4. Structurer

Structurer les données signifie :

- Analyser et modéliser
- Choisir des formats
- Les enrichir

Ce qui est déterminant dans les choix de structuration des données, c'est l'exploitation qui est visée. En d'autres termes, ce qui doit être explicité, circonscrit, discrétisé est déterminé en partie par les objectifs du projet. Eventuellement, il y aura un compromis à établir entre ce que l'on souhaite et le temps/les moyens/les outils dont on dispose.

Beaucoup de projets numériques sont fondés sur l'utilisation de métadonnées. Pour celles-ci, il faut choisir des formats interopérables, ouverts, fondés sur des standards internationaux. Il importe donc de connaître les initiatives et de choisir celle(s) qui est(sont) adoptées aux objets numériques traités.

Comme toute information textuelle, les métadonnées doivent être encodées en Unicode UTF-8<sup>1</sup>. Ce format garantit l'affichage de tous les caractères, quels qu'ils soient. L'encodage en Unicode/UTF-8 ne couvre que l'aspect encodage des caractères, c'est-à-dire principalement du contenu textuel des métadonnées.

Sauf cas particuliers, les métadonnées seront inscrites dans un fichier différent de celui qui contient la donnée numérisée. On conservera le lien entre le fichier de la donnée numérisée et le fichier des métadonnées qui lui ont été associées, en gardant le même nom de fichier à l'extension près (seuls les trois derniers caractères seront différents). Enfin, on documentera les catégories utilisées et les ressources produites.

Il faut distinguer le codage des catégories de métadonnées (standards : dublin-core, PREMIS, OLAC, MARC, EAD, etc.), le codage de leur organisation (standard METS), du format utilisé pour les écrire (fichiers XML).

## 5. Exploiter

L'exploitation des données s'inscrit toujours dans la problématique de recherche ou la problématique documentaire. Elle s'appuie uniquement sur ce qui aura été structuré.

Exploiter ses données revient à les outiller, puis à les utiliser et les interpréter. On indique ci-dessous différentes pistes d'exploitations possibles. Elles ne sont pas exclusives les unes des autres :

a) Ouverture des données ou mise à la disposition de la communauté. Par exemple :

- Mise en place d'entrepôts respectant le protocole OAI-PMH (cf. § 2.5.)
- Mise en place de descriptions archivistiques de fonds (« instruments de recherche ») respectant le standard EAD.
- Documentation sémantique du système de balisage utilisé dans les fonds textuels, en format ODD pour la TEI.

<sup>1</sup> Unicode est un standard développé par le Consortium Unicode et synchronisé depuis 1993 sur la norme ISO/IEC 10646. Unicode vise à donner à tout caractère de n'importe quel système d'écriture un nom et un identifiant numérique, et ce de manière unifiée, quelle que soit la plateforme informatique ou le logiciel. Cette norme concerne l'encodage des caractères et non leur visualisation, qui elle a besoin d'une police adaptée. Le choix d'UTF-8 n'a pas ainsi de répercussion sur la police que l'on utilise pour visualiser les données à l'écran. Il ne faut pas confondre les encodages de l'Unicode (UTF-8, 16, 32, etc.) avec les encodages d'autres codes comme ceux de l'ASCII et l'ISO-88591.

- Représentation des données sous la forme d'un graphe RDF (cf. § 2.4.) et leur exposition suivant les principes du « web de données ».
- b) Traitement en ingénierie linguistique :
- Mise à disposition des résultats d'analyses linguistiques (analyse des formes, statistiques, etc.)
- c) Construction de réseaux sociaux  
d) Géolocalisation  
Etc.

## 6. Diffuser

Il importe d'envisager à travers une stratégie éditoriale la forme ou bien les différentes formes que vont revêtir la publication et la valorisation des données. Site web spécifique, espace partagé pour une communauté particulière, ouverture à l'ensemble de la communauté scientifique, autant de possibilités, parfois non exclusives, qu'il faut préciser.

### Barrière mobile

Les éditeurs de données numériques ont mis au point la notion de barrière mobile : l'accès aux données peut être différé dans le temps (une ou plusieurs années). Quel que soit le moment auquel on donnera accès aux données, le respect des standards et des normes reconnus internationalement demeure un impératif.

## 7. Pérenniser

Il importe tout d'abord de déterminer quelle est la durée d'utilité des données pour l'organisme qui les a produites (courte, moyenne ou longue). Au delà de cette durée où l'organisme qui a produit la donnée l'utilise (exploitation scientifique par exemple) ou la garde par devers lui pour des raisons juridiques, fiscales, etc. il convient de déterminer si les données ont un intérêt historique qui justifie leur conservation définitive par une institution dont c'est la mission.

Pendant la période d'utilisation courante de la donnée, il faut penser à son stockage.

Une sauvegarde des données « hors de ses murs », pour laquelle on veillera à ce que les données soient enregistrées de manière régulière (x fois par y heures / jours / semaines), de même qu'à une sauvegarde sur plusieurs supports stockés sur des sites différents représentent de bonnes pratiques permettant de lutter contre les pertes accidentelles. « Moins » de contraintes pèsent sur le choix des formats et sur le codage des données si l'on s'en tient strictement à du stockage sur du court terme.

Par contre, si l'on souhaite garantir l'accès à ses données sur le « long » terme, le simple stockage ne suffit pas. Il faut alors passer à l'archivage numérique à long terme<sup>2</sup>, ce qui nécessite de la gestion, de la surveillance et le renouvellement des supports d'enregistrement, mais aussi l'absence de formats propriétaires et un bon codage initial des données.

Pour archiver ses données à long terme, il faut là encore se conformer aux standards internationaux. On recommande le modèle OAIS (Open Archival Information System) pour la gestion et l'archivage à long terme.

<sup>2</sup> L'archivage à long terme doit garantir que les données, bien évidemment à la condition que celles-ci respectent un certain nombre de formats, seront encore accessibles dans 10, 20, 30 ans et plus. Lire à ce propos le dossier consacré à la conservation des données, <http://www.huma-num.fr/sites/default/files/ressourcesdoc/dossier-thematique-mai2014.pdf>

## 8. Liste des recommandations

R1 : Appliquer en début de projet la méthode QQQCCP pour définir, de la manière la plus détaillée qui soit, tous les aspects du projet numérique.

R2 : Organiser son projet demande de construire un cahier des charges fonctionnel et d'établir un planning prévisionnel.

R3 : Pour numériser des données, établir des spécifications techniques, choisir éventuellement un prestataire, contrôler la qualité des résultats.

R4 : Préparer un plan de nommage. Attribuer un nom unique à chaque document à numériser. Utiliser uniquement les lettres a...z, les chiffres 0...9, éventuellement le signe \_ (underscore). Ne jamais utiliser l'espace ni de caractères accentués.

R5 : Pour l'écriture des métadonnées :

- a) se conformer à une initiative existante, adaptée aux spécificités de l'objet.
- b) écrire les métadonnées en utilisant l'Unicode UTF-8.
- c) Sauf cas particuliers, inscrire les métadonnées dans un fichier différent de celui qui contient la donnée numérisée.
- d) Toujours conserver le lien entre le fichier de la donnée numérisée et le fichier des métadonnées qui lui ont été associées (même nom à l'extension près).
- e) Toujours documenter les catégories utilisées et les ressources produites.

R6 : Exploiter ses données en respectant les protocoles d'échanges interopérables, reconnus comme standards sur le plan international.

R7 : Construire une stratégie éditoriale qui offre au moins deux points de vue sur les données.

R8 : Même si les données vont être soumises à une barrière mobile, les traiter en respectant les standards et les normes reconnus internationalement.

R9 : Pour archiver de manière pérenne des données, se conformer au modèle OAIS.



# MÉTADONNÉES, HTML, RDF, PROTOCOLE OAI-PMH

## 1. Métadonnées : généralités

Les métadonnées sont des données qui décrivent d'autres données. La notion de métadonnée renvoie, dans les faits, à des éléments et à des notions de nature différente.

Avant l'ère du numérique, les documents des bibliothèques étaient décrits à l'aide de notices bibliographiques dans lesquelles on identifiait les auteurs, les éditeurs, les titres, les dates de parution, etc. Ces notices étaient utiles tant aux bibliothécaires pour la gestion de leur fonds, qu'aux usagers pour retrouver un ouvrage. À ces notices étaient accolés des « descripteurs », soit des mots-clés chargés de spécifier le contenu des documents.

Avec l'ère du numérique, les notices se sont informatisées et normalisées. Dans le domaine de l'informatique documentaire, les métadonnées correspondent maintenant aussi bien aux éléments des notices bibliographiques (auteur, titre, éditeur, etc.) qu'aux descripteurs (mots-clés). Les documents identifiés par les notices sont désormais appelés « ressources ».

En parallèle, depuis plusieurs années s'est développé, sous l'impulsion du Web, un langage de structuration de l'information utilisant des balises : le XML<sup>1</sup>. Ce langage permet de décrire un document, de spécifier, d'ajouter, de catégoriser des informations à celui-ci. On utilise alors une suite de caractères délimitée par des chevrons, par exemple <Exemple\_balise>, qui encadre une « information ».

Avec le RDF (Resource description framework), soutenu par le W3C (organisme international gérant les évolutions du web), le mode de représentation change. Il ne s'agit plus ici d'annoter, d'ajouter des informations, puis de les interpréter, mais plutôt de structurer cette description – qui est toujours une annotation interprétative – dans un langage qui ne connaît qu'une structure simple : le triplet « sujet-objet-prédicat », cette structure pouvant être représenté par un graphe. La représentation contient en elle-même son propre système d'interprétation (qui est ici fondé sur une adaptation de la logique des prédicats du 1<sup>er</sup> ordre).

Par la suite, on distinguera :

- les métadonnées techniques qui sont des métadonnées liées à la technicité associée à la numérisation de la donnée (par exemple, le temps d'exposition d'une photo) ;
- les métadonnées descriptives ou documentaires qui sont des métadonnées qui renvoient à la problématique de recherche ou documentaire, à l'utilisation des données, à leur administration, etc. ;
- les métadonnées génériques qui sont des métadonnées qui s'appliquent à n'importe quel type d'objet numérisé ;
- le schéma qui est un ensemble de balises (rubriques) prédéfinies ;

Dans le cas de XML (Extensible Markup Language), la définition d'un schéma est assez similaire à la définition des champs dans une table de base de données. XML peut être considéré comme l'une des façons de mettre en forme la structuration de l'information dans les champs.

En § 2.2, on décrit des métadonnées ou des schémas de métadonnées génériques. Les métadonnées dont l'utilisation est spécifique à un type d'objet numérique seront introduites dans la section qui lui est consacrée.

<sup>1</sup> « eXtensible Markup Language » (XML) est une recommandation du W3C qui prend sa source dans la norme SGML (ISO 8879:1986).

## 2. Métadonnées et schémas génériques

### 2.1 Le Dublin Core

En 1995, à Dublin (Ohio), des représentants issus du monde des bibliothèques, de l'informatique et du web, se sont réunis pour définir un noyau commun de métadonnées : le Dublin Core Metadata Initiative (DCMI), abrégé souvent en Dublin Core ou encore DC.

Le Dublin Core est un ensemble de 15 descripteurs de portée très large et de sens très générique. Certains ont trait au contenu, d'autres à la propriété intellectuelle, d'autres enfin à l'instanciation. Cet ensemble de descripteurs a été normalisé au sein de l'ISO en 2003 sous le nom d'ISO Standard 15836-2003.

Les 15 descripteurs sont les suivants :

- Contributor (diffuseur de la ressource)
- Coverage (couverture géographique ou temporelle de la ressource)
- Creator (auteur de la ressource)
- Date (événement dans la vie de la ressource)
- Description
- Format (format mime ; dimension physique ; durée de la ressource) ;
- Identifiant (identifiant unique de la données : URL, DOI, n° ID, etc.)
- Language (normalisé selon l'ISO 639 par exemple)
- Publisher (éditeur)
- Relation (lien vers d'autres ressources)
- Rights
- Source
- Subject
- Title
- Type (nature descriptive de la données : événement, corpus, fonds de chercheurs, film, image, photo, etc., cf. <http://dublincore.org/documents/dcmi-typevocabulary/>)

Ces éléments de base peuvent dans certains cas être insuffisamment précis. Il est alors possible d'en utiliser d'autres. Ce sont les qualifieurs (*qualifiers*), qui précisent l'acceptation. Deux ensembles de qualifieurs ont été proposés :

1. Les raffineurs (refinements) qui précisent le sens d'un élément. Par exemple, à la place de l'élément « Date », il est possible d'utiliser un de ces raffineurs : Created, Valid, Available, Issued, Modified, DateAccepted, DateCopyrighted, DateSubmitted.

2. Les schémas d'encodage et les vocabulaires contrôlés. Par exemple le schéma « Point » qui permet de définir les propriétés d'un point géographique (coordonnées : longitude, latitude, altitude, référentiel, nom).

Le Dublin Core peut servir de base au Dublin Core dit qualifié dans lequel il est possible de typer les métadonnées, en utilisant les types de données proposés par le DCMI ou ses propres types de données définis dans un schéma XML.

### 2.2 Le schéma METS

Développé à l'initiative de la Digital Library Federation et maintenu par la Library of Congress, METS (*Metadata Encoding and Transmission Standard*) est destiné à faciliter la gestion, la préservation et l'échange d'objets numériques entre plusieurs institutions. Le schéma METS peut être utilisé dans le

modèle OAIS (Open Archival Information System).

C'est un schéma de structuration pour l'encodage et la transmission de métadonnées liées à des objets numériques textuels ou graphiques. Il permet leur caractérisation physique et logique. Exprimé sous la forme d'un schéma XML, il encapsule dans un même fichier toutes les données liées à cet objet :

- a) Une description de la structure hiérarchique de l'objet ;
- b) Les noms et la localisation des fichiers qui le composent ;
- c) L'ensemble des métadonnées associées aux fichiers (descriptives, techniques, administratives et structurelles) ;
- d) Un jeu de pointeurs permettant de faire un lien entre les différents fichiers et éléments de métadonnées.

Un fichier qui respecte le schéma XML METS est structuré en sept sections :

1. *En-tête METS* (METS header <metsHdr>) : informations sur le document METS lui-même (statut du document, date de création et de dernière modification, etc.).

2. *Métadonnées descriptives* (Description Metadata Section <dmdSec>) : cette section contient les métadonnées descriptives de l'objet principal et éventuellement celles des ressources qui le constituent.

Exemple : un fichier METS décrit un fonds d'estampes. On peut à la fois décrire le fonds dans une section de métadonnées descriptives et avoir autant de sections qu'il y a d'estampes.

Ces métadonnées descriptives peuvent être internes ou externes au document.

Les métadonnées internes sont encapsulées grâce à l'élément conteneur <mdWrap>. Pour les métadonnées externes, on utilise l'élément <dmdSec>, qui fournit une URI permettant de récupérer ces métadonnées externes.

3. *Métadonnées administratives* (Administrative Metadata Section <amdSec>) : cette section regroupe les métadonnées techniques, les métadonnées de gestion des droits, les métadonnées concernant l'objet original (source analogique dont l'objet numérique est dérivé), ainsi que les métadonnées décrivant les relations entre l'objet original et l'objet numérique et le processus de transformation. Elles peuvent être externes au document ou y être encapsulées.

4. *Section des fichiers* (File Section <fileSec>) : cette section permet d'indiquer le nom et la localisation de chaque fichier. Elle comprend un ou plusieurs éléments <fileGrp> qui permettent de rassembler des fichiers par groupe de même nature et subdiviser les fichiers par version de l'objet.

5. *Carte de structure* (Structural Map <structMap>) : la carte de structure indique la hiérarchie physique ou logique des objets et permet de naviguer dans le document. Grâce au système de pointeurs, elle permet de relier chaque élément de cette structure aux fichiers et aux métadonnées qui s'y rapportent.

6. *Liens structurels* (Structural Map Linking <structLink>) : cette section permet d'indiquer l'existence d'hyperliens entre différents éléments de la carte de structure.

7. *Comportement* (Behaviour section <behaviourSec>) : cette section associe les exécutables destinés au traitement et à l'exécution de l'objet.

METS sépare les différents types de métadonnées, ce qui permet d'organiser et de relier les objets décrits dans différentes sections, indépendamment de la structure globale retenue. Les différentes sections qui correspondent à un même objet sont reliées par un système d'identifiants et de références aux identifiants.

Par ailleurs, il propose un système d'enveloppes (mdWrap) qui permettent de renseigner les métadonnées descriptives ou administratives dans le format XML le plus adapté : il est possible de décrire l'objet principal et les objets qui le constituent dans différents formats de métadonnées existants. Ce système offre ainsi une grande souplesse pour utiliser les formats de métadonnées les mieux adaptés à ses besoins.

### 3. HTML

Pour afficher des contenus sur un site Web, HTML (*Hypertext Markup Language*) peut constituer une solution minimale tout à fait utile. C'est un format standard interopérable, dérivé de SGML (*Standard Generalized Markup Language*). Il est constitué d'un ensemble de balises, qui rendent compte d'un certain nombre d'aspects formels du texte (titre, paragraphe, attributs de police de caractères, etc.).

Un fichier HTML est constitué d'un en-tête et d'un corps. L'en-tête rassemble les informations liées au document, notamment son titre et les différentes métadonnées que l'on aura entrées. Le corps représente ce qui est affiché. Le W3C développe actuellement le HTML 5, cinquième évolution du langage incluant des fonctions multimédia directement disponibles dans le code (streaming audio et vidéo par exemple), mais la compatibilité avec l'ensemble des navigateurs n'est pas complète.

### 4. Le RDF

Mis au point au W3C dans le cadre des activités du Web sémantique, le modèle RDF est un modèle de représentation des données. Ce n'est pas un schéma de métadonnées. Il permet de décrire de manière formelle tout type de données afin d'en faciliter l'exploitation et le traitement automatique.

Le modèle de représentation de données RDF repose sur trois concepts :

1. *ressource* : tout objet (livre, personne, billet de blog, etc.) décrit en RDF est une ressource identifiée et nommée par une URI (Uniform Resource Identifier).
2. *propriété* : qualité, particularité, relation spécifique pouvant être appliquée à la ressource pour la décrire
3. *objet* : valeur de la propriété, cela peut être une autre ressource exprimée par une URI ou un littéral (un littéral est une chaîne de caractères, dont on peut spécifier éventuellement la langue).

Toute donnée est ainsi décrite par ce type de déclaration simple, composée d'un sujet (ressource), d'un prédicat (propriété), et d'un objet, Le sujet, le prédicat et l'objet forment ce qu'on appelle un triplet RDF.

On indique ci-dessous quelle est la représentation en RDF de la phrase suivante : *le site web de la TGIR Huma-Num a pour mot-clé « digital humanities »*.

- Sujet (ressource) : le site web de la TGIR Huma-Num = <http://www.huma-num.fr/>
- Prédicat (propriété) : mot-clé = <http://purl.org/dc/terms/subject>
- Objet : « digital humanities » = « digital humanities »

Un ensemble de triplets reliés entre eux constitue un graphe RDF ; il est composé de différents noeuds correspondant aux sujets et aux objets des triplets.

Différents vocabulaires peuvent être utilisés pour qualifier des données en RDF :

- RDFS (RDF Schema)
- OWL (Web Ontology Language)
- Dublin Core
- etc.

Plusieurs syntaxes sont également possibles pour formaliser du RDF :

- XML
- N3
- N-triples
- Turtle
- RDFa (syntaxe utilisée pour la description des données d'une page web)

De nombreux langages de requêtes permettant d'interroger des graphes RDF sont également disponibles, mais le langage d'interrogation SPARQL (qui est recommandé par le W3C) devient prédominant.

## 5. Le protocole OAI-PMH

L'OAI-PMH (*Open Archive Initiative - Protocol for Metadata Harvesting*) est un protocole standard interopérable qui permet d'avoir accès aux métadonnées d'un entrepôt numérique. Il a été mis au point en 1999 par l'Open Archives Initiative pour faciliter l'échange et la visibilité des données stockées dans les archives ouvertes (des entrepôts d'articles scientifiques mis à disposition par les chercheurs eux-mêmes). Il s'est peu à peu diffusé dans d'autres domaines du fait de sa simplicité et de la disponibilité de nombreux outils.

Ce protocole est particulièrement utile dans le cas des bases de données. Si d'un côté, les données contenues dans ces bases peuvent être affichées dynamiquement dans des pages web, faire l'objet de requêtes particulières, etc., il est toujours souhaitable de les dupliquer et de les rassembler dans un entrepôt. Quand cet entrepôt est muni de métadonnées respectant le protocole OAI-PMH, on assure l'interopérabilité et par suite le moissonnage par des moteurs de recherche.

Le protocole OAI-PMH implique ainsi deux acteurs :

- *Le fournisseur de données* (data provider) qui expose, grâce à une interface Web spécifique, les métadonnées des différents enregistrements contenus dans son entrepôt.
- *Le fournisseur de services* (service provider) qui moissonne un ou plusieurs entrepôts, en utilisant les interfaces exposées par le fournisseur de données, afin d'offrir aux utilisateurs des interfaces de recherche ou de navigation.

La plateforme ISIDORE (<http://rechercheisidore.fr>), initiée par Huma-Num, comme d'autres moteurs de recherche<sup>1</sup> pourront ainsi moissonner les métadonnées exposées selon le standard OAI-PMH.

Dans un entrepôt OAI-PMH, chaque ressource stockée correspond à une notice ou encore « enregistrement » (ou « record »). Chaque notice ou enregistrement est obligatoirement décrit à l'aide de métadonnées respectant a minima le Dublin Core simple. Il est possible de décrire les métadonnées, en plus du Dublin Core simple, à l'aide de vocabulaires plus riches : DC Terms, MODS, OLAC, etc.

Ces enregistrements peuvent être rassemblés en différents ensembles (« set ») et un enregistrement peut appartenir à plusieurs ensembles. Les différents ensembles peuvent être organisés hiérarchiquement.

Par exemple, on peut avoir des objets particuliers (des descriptions de photographies), qui sont regroupés dans un ensemble/set (toutes les photographies d'un photographe particulier).

Les différents formats de métadonnées utilisés par l'entrepôt, celles publiées en Dublin Core simple comme les autres, sont accessibles au moissonneur grâce à une requête spécifique.

## 6. Les ressources

Dublin Core : <http://dublincore.org>

Dublin Core - Informations sur les 15 descripteurs : <http://dublincore.org/documents/dces/>

METS : <http://www.loc.gov/standards/mets>

METS - Schémas : <http://www.loc.gov/standards/mets/mets-schemadocs.html>

METS - Liste d'outils dédiés : <http://www.loc.gov/standards/mets/mets-tools.html>

<sup>1</sup> OAIster, (<http://www.oclc.org/oaister/>), Driver-Community (<http://www.drivercommunity.eu/>), etc.

MODS : <http://www.loc.gov/standards/mods>

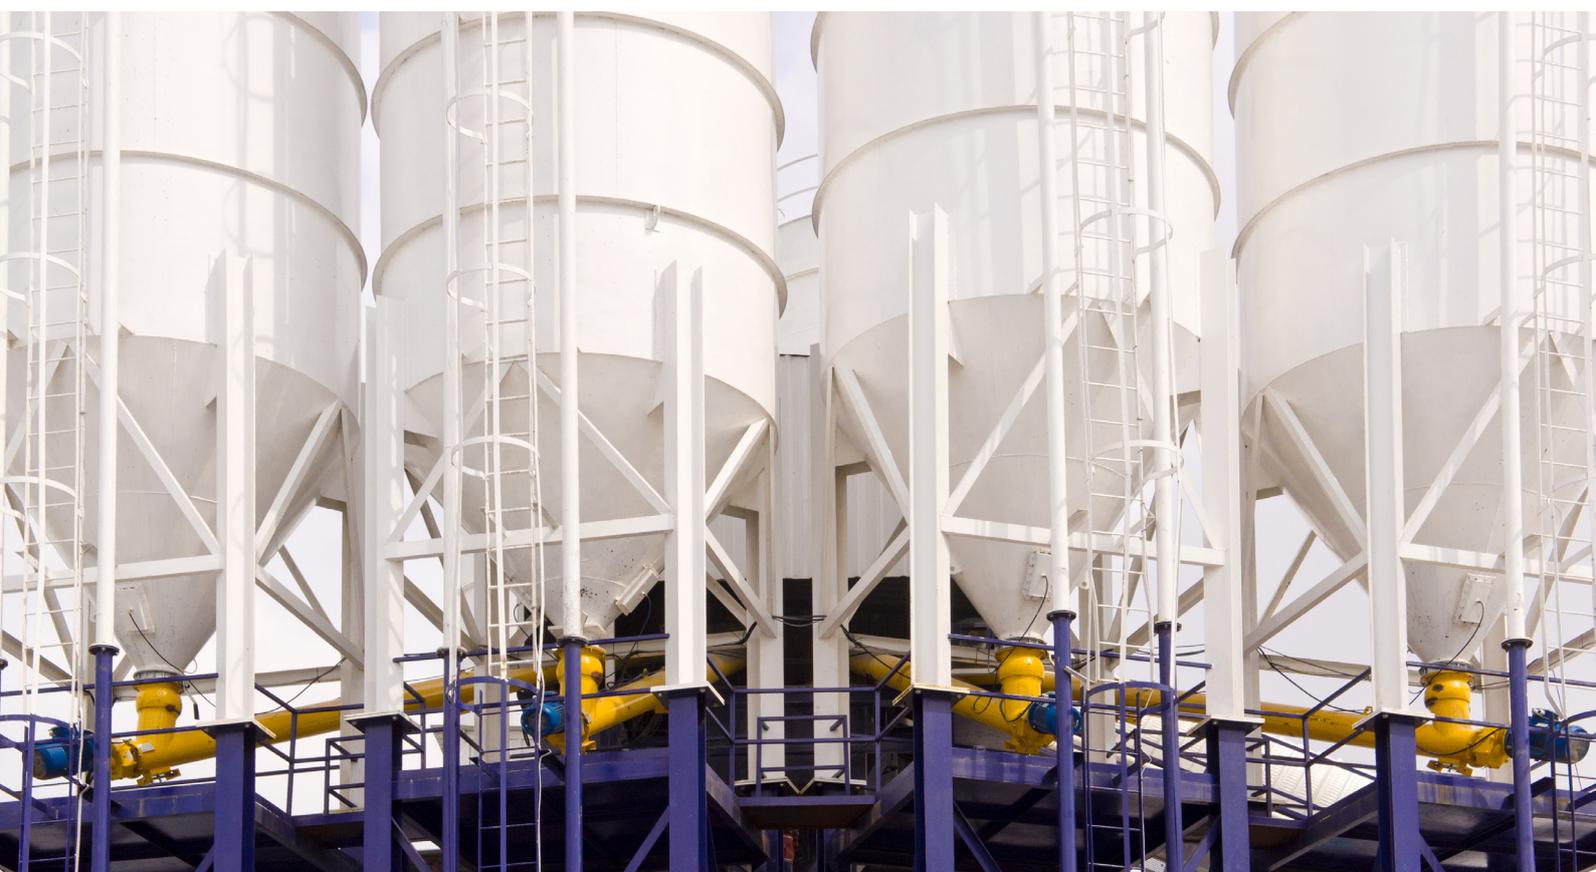
OAI-PMH : <http://www.openarchives.org/OAI/openarchivesprotocol.html>

Open Archives Initiative : <http://www.openarchives.org>

RDF : <http://www.w3.org/RDF>

RDF - Liste d'outils dédiés et classés par catégories : <http://www.w3.org/2001/sw/wiki/Category:Tool>

Unicode : <http://www.unicode.org>



# LES BASES DE DONNÉES

## 1. Généralités

Une base de données, du point de vue des humanités numériques, doit être considérée comme un réservoir organisé de données, dont on affiche une ou plusieurs « vues » à un instant T.

Les « vues » peuvent être constituées par les données « brutes » et/ou par les métadonnées qui y ont été associées. Les vues sont affichées par différents moyens :

- via une édition électronique statique : par exemple un fichier en format pdf ;
- via une édition en flux d'information ;
- via une interface web de recherche.

Dans les deux derniers cas, on parle d'édition dynamique des données.

Avec le numérique et l'obsolescence des formats, la durée plus courte des projets de recherche, une réflexion approfondie doit être conduite, dès lors qu'on souhaite mettre à disposition dans un avenir plus ou moins proche ses données à l'ensemble de la communauté.

La réflexion doit donc inclure AU TOUT DEBUT DU PROJET un travail permettant d'avoir une idée claire sur la pérennisation des données que l'on traite. Dans un tel cadre, l'édition d'une base de données ne peut se limiter à l'édition d'un formulaire de recherche et à l'élaboration d'une maquette graphique.

L'application d'une méthodologie de projets liée aux objets numériques est ici aussi nécessaire, et il faudra veiller particulièrement :

- à l'utilisation de standards internationaux pour le codage des données ;
- à l'utilisation de formats « ouverts ».

Il existe bien évidemment d'autres bases de données qui n'ont pas vocation à être éditées : des bases de données « personnelles », pour organiser la recherche en train de se faire. Cependant, il importe de noter que bon nombre de ces projets évoluent très souvent vers des projets d'édition et de mise à disposition des données à l'ensemble de la communauté.

Dans ce cas, quand on a choisi au départ un format propriétaire (qui se justifiait donc dans le cadre du projet de départ), très souvent, le chercheur doit refaire dans un autre format ce qui a déjà été fait. Cet investissement, considéré sous un angle strictement technique, est souvent jugé trop onéreux et inintéressant. La conséquence en est que des données seront effectivement mises à disposition de la communauté mais... pour un temps a priori très limité. Et la pérennisation des données ne sera en aucun cas assurée.

Aussi on recommande de choisir des formats ouverts (non propriétaires), respectant des standards internationaux, y compris pour les bases de données « personnelles ».

## 2. Les métadonnées

Une base de données ayant vocation à stocker et à organiser des données de différentes natures (taille, format, etc.), on se reportera aux chapitres consacrés aux différents types de données.

### 3. L'entrepôt

Des données numérisées peuvent être manipulées à travers une base de données, compatible par exemple avec le langage de requêtes SQL. Cependant, pour que cette base de données puisse être moissonnable par des moteurs de recherche, on recommande de transformer ces bases de données en entrepôt de données.

Cela entraîne de nouvelles tâches : définir les objets que l'on va considérer comme des « ressources » de l'entrepôt (cf. § 2.5), établir une correspondance entre des champs de la base et des rubriques du Dublin Core et éventuellement d'autres schémas de métadonnées, implémentation des fonctions utiles au protocole OAI-PMH, etc.).

L'entrepôt de données doit être construit en respectant le protocole OAI-PMH (cf. § 2.5.). À chaque élément de la base de données, il faudra associer des métadonnées, qui seront exprimées en Dublin Core simple, soit un jeu de 15 métadonnées supplémentaires.

### 4. Liste des recommandations

R10 : Pour les bases de données, y compris les bases de données « personnelles », choisir des formats ouverts reconnus internationalement.

R11 : Transformer sa base de données en entrepôt de données.

R12 : Pour un entrepôt de données, utiliser le protocole OAI-PMH et entrer les métadonnées en utilisant le Dublin Core simple.

### 5. Les ressources

OAI-PMH : <http://www.openarchives.org/OAI/openarchivesprotocol.html>

Open Archives Initiative : <http://www.openarchives.org>

# LES DONNÉES TEXTUELLES

## 1. Les données

Les données textuelles recouvrent aussi bien des textes « bruts » que des textes structurés, et ce, quelle que soit leur structure formelle, narrative, etc. : romans, poèmes en vers, pièces de théâtre, interviews, transcriptions de conversations, lettres, listes de mots, dictionnaires, etc. Ces textes peuvent être intéressants aussi bien du point de vue de leur contenu que du point de vue des aspects linguistiques qu'ils comportent.

## 2. La numérisation

### *Mise en place d'une chaîne de traitement*

On met en place une chaîne de traitement qui doit être adaptée à chaque format. En effet, on ne numérise pas de la même manière un manuscrit médiéval, une collection d'ouvrages reliés, etc.

### *Captation*

On effectue la captation du texte via une « image fixe ». En d'autres termes, on numérise en format image la page d'un ouvrage, la feuille d'un manuscrit, etc. Pour plus d'informations, on se reportera à la section 5.

### *Application d'un logiciel de reconnaissance optique de caractères : logiciel OCR / océrisation*

Selon les besoins, on peut utiliser un logiciel de reconnaissance automatique de caractères. Ce programme permet de transformer le contenu de l'image en un texte éditable.

L'« océrisation » est pertinente :

- quand on a de gros volumes de données à traiter ;
- si la qualité de l'original le permet ;
- si la langue des données textuelles est reconnue par le logiciel OCR ;
- dans le cas d'une écriture manuscrite, si celle-ci est « facilement » déchiffable.

Il existe des programmes OCR comportant des modules d'entraînement. On peut alors tester et entraîner le logiciel sur une petite partie du corpus, puis décider, en fonction des résultats, de l'utiliser sur l'ensemble du corpus.

### Attention !

Dans tous les cas, c'est-à-dire, quels que soient les volumes traités, le logiciel OCR retenu (avec ou sans entraînement), relire attentivement le résultat de l'« océrisation ».

### *Le format « texte seul » avec l'encodage UTF-8*

Pour du texte sans mise en page, il est recommandé d'utiliser le format « texte-seul » avec l'encodage UTF-8.

### 3. Les métadonnées

Il existe de nombreuses manières d'exploiter et d'afficher des données textuelles : simple exposition dans un environnement de site web ; qualification sophistiquée des différents éléments des « textes » ; analyse automatique du corpus, extraction de données, etc. De plus, les mêmes données textuelles peuvent être exploitées de différentes façons. Tout dépend de la problématique de recherche, des résultats auxquels on souhaite arriver, des résultats que l'on souhaite exposer, etc.

Si l'exploitation des données recourt à des métadonnées, il faut impérativement :

- Choisir pour les métadonnées un format structuré et construit.
- Accoler à ce format un modèle de données et/ou une documentation sur les différentes catégories créées.

Le modèle de données et/ou la documentation des différentes catégories sont essentiels, car ils garantissent le fait que les données pourront encore être exploitées, éventuellement par d'autres, dans les années qui viennent.

Le modèle de données le plus couramment utilisé est le format XML, qui est un standard international. Les métadonnées exprimées dans ce format suivent un schéma prédéfini, qui définit les règles concernant l'usage des balises.

Parmi les modèles de données respectant le format XML, on trouve :

- Metadata Encoding and Transmission Standard (METS)
- Hypertext Markup Language (HTML)
- Text Encoding Initiative (TEI)

Pour METS et HTML, on se reportera au § 2.2 et au § 3. On présente ci-dessous la TEI, modèle que l'on recommande quand on souhaite structurer (et par la suite, analyser, exploiter, exposer, etc.) des données textuelles.

### 4. La TEI (text encoding initiative)

La TEI a été lancée sur le plan international comme projet de recherche en 1987. Depuis 2000, sa gestion et son évolution sont supportées par un consortium à but non lucratif. Un Conseil Technique TEI est chargé de l'amélioration du modèle et de ses aspects techniques.

La TEI fournit un modèle très riche de composants pour tous les types de textes. On peut ainsi choisir ceux qui seront pertinents dans le cadre du projet scientifique. Ces composants devront être articulés dans un schéma.

Plus souples qu'un schéma XML classique, les « TEI Guidelines », qui en sont à leur cinquième version (P5)<sup>1</sup>, proposent un ensemble de recommandations particulières, rassemblées dans des modules distincts. Elles comprennent essentiellement des indications sur la structure sémantique du contenu textuel, et une documentation formelle des balisages employés. Ces recommandations peuvent être adaptées en fonction de besoins particuliers.

Le système est largement utilisé en sciences humaines et sociales, où une communauté très large et active se charge de son évolution et de son exploitation pour l'édition des sources primaires (manuscrits, documents historiques, etc.), les ressources lexicales et linguistiques (dictionnaires, corpus, etc.), les textes littéraires et politiques, etc.

<sup>1</sup> Voir : <http://www.tei-c.org/Guidelines/>

## 5. Liste des recommandations

R13 : Pour garantir le bon codage de tous les caractères, choisir le codage UTF-8.

R14 : Pour la structuration des données textuelles, utiliser la TEI. Suivre les « TEI Guidelines », les adapter à son corpus et documenter ses choix.

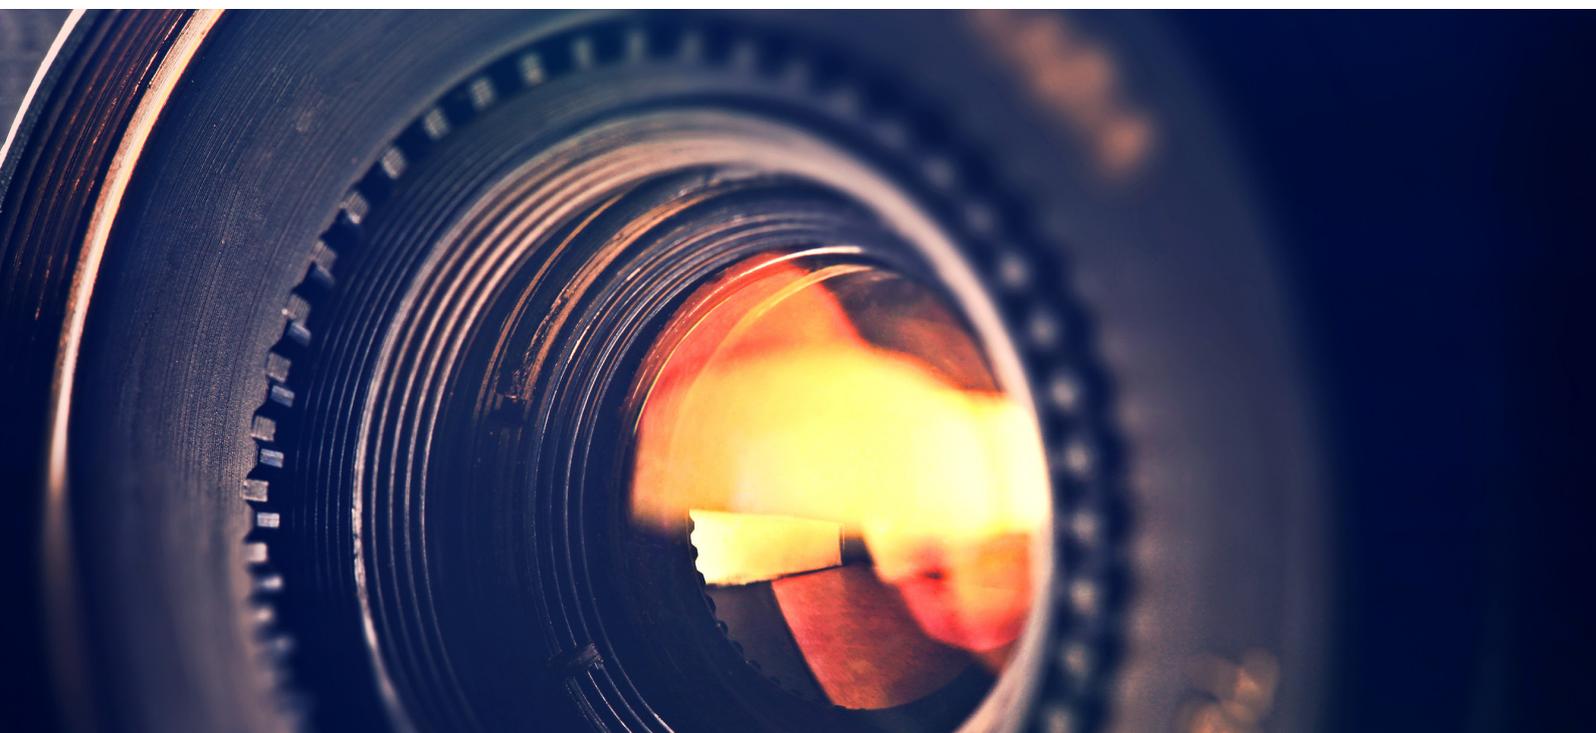
## 6. Les ressources

Centre de ressources numériques CNTRL (Centre national de ressources textuelles et lexicales) : <http://www.cnrtl.fr>

Centre de ressources numériques TELMA (Traitement électronique des manuscrits et des archives) : <http://www.cn-telma.fr>

METS : <http://www.loc.gov/standards/mets/>

TEI : <http://www.tei-c.org>



# LES DONNÉES ICONOGRAPHIQUES

## I - LES IMAGES FIXES

### 1. Les données

Les données iconographiques - images fixes recouvrent aussi bien :

- des photographies : diapositives, négatifs, tirages positifs, photos numériques ;
- des documents visuels fixes : documents 2D numérisés, illustrations, plans, croquis, dessins, cartes anciennes ou plus récentes (à l'exclusion des cartes construites automatiquement à partir de coordonnées et données géographiques).

Elles rassemblent donc des données nativement numériques et des données non numériques au départ et que l'on aura numérisées.

*Images matricielles et images vectorielles*

Sur un plan technique, on distingue :

- les images matricielles ou « bitmap » ou « raster »
- les images vectorielles « images orientées objet ».

Les images matricielles prennent la forme d'une grille - ou matrice - où chaque « élément d'image » (pixel) a un emplacement unique dans la matrice et une valeur de couleur indépendante ; chacune de ces valeurs peut être modifiée indépendamment.

Les images vectorielles fournissent un ensemble d'instructions mathématiques utilisées par un programme de dessin pour construire une image.

Des logiciels tel que Photoshop ou Gimp créent et lisent en règle générale des images matricielles, alors qu'Illustrator crée et lit des images dites vectorielles. Les images vectorielles peuvent être converties en images matricielles. L'inverse n'est que difficilement possible et implique le plus souvent la reprise du dessin, à la main, dans un éditeur.

### 2. La numérisation

En général, le processus de numérisation génère une image matricielle, les images vectorielles étant le plus souvent le produit d'un logiciel de dessin.

Les différents choix qui doivent s'opérer lors de la numérisation sont fonction du document, de son format, du rendu tout comme de l'usage ultérieur que l'on souhaite faire ensuite du fichier.

Pour les images matricielles, deux éléments doivent être pris en considération : le format de fichier et les paramètres de qualité. De manière générale, les images doivent être créées à la meilleure résolution possible et à la profondeur de bits la plus élevée possible, mais en veillant à ce que les fichiers obtenus soient pratiques et maniables en fonction des utilisations envisagées.

#### 2.1 Le format de fichier

Les images matricielles peuvent être créées et enregistrées sous l'un des formats suivants : Tagged Image File Format (TIFF), Portable Network Graphics (PNG), Graphical Interchange Format (GIF) ou JPEG Still Picture Interchange File Format (JPEG/SPIFF).

Il importe par ailleurs de créer toujours deux jeux de données, l'un sera utilisé pour la conservation

et l'archivage ; l'autre sera exploité dans le cadre du web. Dans le premier cas, la numérisation devra être effectuée sans compression, donc sans perte. On recommande alors le format TIFF. Dans le second cas, il pourra y avoir compression, à la condition cependant que la qualité reste maximale. On recommande alors le format JPEG.

Il est possible de créer le premier jeu au format TIFF puis d'utiliser un logiciel comme mogrify (<http://www.imagemagick.org>) pour créer un second jeu d'images.

## 2.2 Paramètres de qualité

La sélection des paramètres de qualité lors de la numérisation d'une ressource est déterminée par la taille de l'original, la quantité de détails présents dans l'original et les utilisations prévues de l'image numérique. Doivent être prises en compte :

### a) La résolution spatiale

La résolution spatiale établit la fréquence avec laquelle des échantillons de l'original sont capturés par le dispositif de numérisation. Elle est exprimée sous la forme d'un nombre d'échantillons par pouce (spi) ou plus communément sous la forme de pixels par pouce (ppp dans l'image numérique qui en résulte). Il s'agit là de la densité d'information enregistrée par unité de surface. Plus cette densité est haute, plus l'image numérisée sera de bonne qualité. La densité pour les pages web est normalement de 72 ppp. L'impression se sert normalement de densité oscillant entre 300 et 600 ppp.

### b) La résolution des couleurs ou profondeur de bits

Le nombre de couleurs (ou de niveaux de luminosité/gris) disponibles pour représenter différentes couleurs (ou tons de gris) dans l'original, est exprimé en nombre de bits. Par exemple, une résolution de couleurs de 8 bits signifie que 256 couleurs différentes sont disponibles.

Le choix de la profondeur de bits dépend du support de départ : numériser une diapositive de 35mm exige une résolution plus élevée que celle d'une lithographie de 6x4, car la diapositive est plus petite et plus détaillée. Si l'une des utilisations de l'image d'une aquarelle requiert de pouvoir analyser d'infimes détails de coups de pinceaux, la résolution doit être plus élevée que pour le seul affichage de l'image à l'écran.

### Attention !

Plus la qualité de l'image numérisée est grande, plus le fichier sera lourd à manipuler. Cependant, plus la qualité de l'image numérisée est grande, plus l'image pourra être agrandie sans que l'on perde en qualité visuelle.

À titre d'exemple, une résolution de 600 points par pouce (ppp) et une profondeur de bits de 24 bits couleur ou de 8 bits à échelle de niveaux de gris, devraient être envisagées pour les impressions photographiques. Une résolution de 2400 ppp devrait être appliquée pour des diapositives de 35 mm afin de capturer la plus grande densité d'informations.

Dans certains cas, par exemple lors de l'utilisation d'appareils photo numériques de moindre qualité, les images peuvent être stockées sous un format JPEG/SPIFF, comme alternative au format TIFF. Les images seront alors plus petites et de plus basse qualité. De telles images peuvent être utiles pour la présentation de photographies d'événements pour un site internet. Mais l'utilisation de tels appareils photos n'est pas recommandée pour une numérisation à grande échelle.

## 3. Les métadonnées

Sans métadonnées une image numérique est vierge de toute information. Il est impossible de déterminer quel en a été le contexte de production (auteur, lieu, date, etc.) et de ce fait l'image reste inexploitable. Il est donc nécessaire d'intégrer dans le document un certain nombre d'informations – des métadonnées – qui pourront ensuite être exploitées dans la chaîne de production en aval (récupérées lors de la création de bases de données, moissonnées par des moteurs de recherche, etc.).

### 3.1 Métadonnées techniques

Pour les photos numériques, un certain nombre de métadonnées sont automatiquement générées par les appareils photographiques eux-mêmes et contenues dans le fichier image lui-même. Ce sont ce qu'on appelle des métadonnées techniques. Elles concernent les paramètres de prise de vue, et les réglages des appareils photographiques numériques. Ces métadonnées peuvent être affichées, éditées ou extraites grâce à des logiciels libres.

Ces métadonnées n'ont pas vocation à être transformées, certains éléments pouvant même être endommagés en cas de modification. C'est pourquoi on recommande d'établir un autre jeu de métadonnées. Ce seront des métadonnées descriptives.

### 3.2 Les métadonnées techniques : les EXIF

EXIF est une spécification de format de fichier pour les images utilisées par les appareils photographiques numériques. Elle a été établie par le Japan Electronic Industry Development Association (JEIDA). La dernière version 2.3. a été publiée en avril 2010.

Le format EXIF, bien que n'étant pas établi par une organisation internationale de standardisation, reste un format incontournable puisque la majorité des constructeurs d'appareils photographiques numériques l'utilise. Il peut être également exprimé selon le standard MIX en XML.

Il permet le stockage d'un large éventail d'informations techniques concernant les paramètres de prise de vue et les réglages des appareils photographiques numériques lors de la capture numérique :

- date et heure de la prise de vue ;
- réglage de l'appareil (marque, modèle de l'appareil mais aussi d'autres informations comme la vitesse d'obturation, la longueur focale, la sensibilité, etc.) ;
- informations géographiques provenant d'un éventuel système GPC connecté à l'appareil.

Ces données sont fournies automatiquement par l'appareil photographique numérique et sont contenues dans le fichier image lui-même.

Liste des principaux champs EXIF :

- Tag name : description
- MakerNote : données constructeur
- File Size : taille du fichier
- Mime Type : type MIME du fichier (ex : image/jpeg)
- ExposureTime : temps d'exposition en secondes
- FocalLength : distance focale en millimètres
- ExifImageWidth : dimensions de l'image
- ExifImageLength
- X-Resolution : résolution de l'image
- Y-Resolution
- Date and Time (Original) : date et heure de l'original
- DateTimeDigitized : date et heure de numérisation
- Tags Relating to GPS : toutes les données relatives aux coordonnées GPS.

Plusieurs logiciels permettent d'afficher, d'éditer et d'extraire les métadonnées EXIF : Exifer, Exif Reader, ExifTool, ExifPro Image Viewer, Exiv2, IrfanView, Photo Studio, XnView, etc.

### 3.3 Métadonnées descriptives

Dans tous les cas (images numérisées, images nativement numériques), il importe d'indiquer des métadonnées descriptives. Sous le terme de métadonnées descriptives, on rassemble des métadonnées de type technique (cf. ci-dessus), mais aussi des métadonnées de type documentaire, ciblant le contenu du document.

De manière générale, les métadonnées descriptives sont indiquées dans un autre fichier que celui du fichier de l'image, qui a le même nom que celui du fichier de l'image, à l'extension près.

### 3.4 Les métadonnées descriptives : les XMP et les IPTC

- *XMP (Extensible Metadata Platform)*

Le format de métadonnées XMP a été lancé par la société Adobe en 2001. Adobe possède donc cette marque et en contrôle les spécifications.

Ce format structure de l'information et permet de l'enregistrer sous la forme d'un fichier XML, qui peut être inclus dans l'image (ce n'est pas ce que nous recommandons) ou bien stocké à part. Il utilise une expression en RDF simplifiée de champs totalement paramétrables et adaptables à des besoins particuliers. Le format XMP est compatible avec le format IPTC via le format d'IPTC-Core (voir ci-dessous).

- *IPTC/IIM*

Élaboré par le monde de la presse et des agences photographiques dans les années 1990, via l'International Press Telecommunications Council (IPTC)<sup>1</sup> pour leurs besoins spécifiques d'échange d'images et d'informations, le format IPTC/IIM (IIM pour Information Interchange Model) permet d'encapsuler les informations à propos du document. Les métadonnées souvent utilisées sont le nom de l'auteur ou du photographe, des informations sur le copyright et les descriptions. S'il est principalement utilisé pour les images de presse, il peut aussi être appliqué à d'autres types de documents, tels que le texte ou d'autres médias.

- *IPTC-Core*

Dans sa dernière version, l'IPTC a adopté le format XMP. Le format de métadonnées IPTC-Core redéfinit ainsi en XMP les métadonnées IPTC/IIM et offre la possibilité d'ajouter aux champs IPTC standards de nouveaux champs. IPTC-Core n'est pas une norme ouverte, mais un standard de fait.

Il existe plusieurs logiciels qui permettent d'afficher, d'éditer et d'extraire les métadonnées XMP, IPTC/IIM et IPTC-Core : Exifer, ExifTool, Exiv2, IrfanView, PhotoThumb IPTCExt, Rodeo Info (Mac OS), XnView, etc.

En parallèle, on recommande de compléter la description du document en utilisant le Dublin Core (cf. § 2.2.1.). Les métadonnées seront stockées dans un fichier séparé de format XML, dont le nom sera identique à celui du fichier de l'image à l'extension près : NomDuFichierDeLImage.xml

<sup>1</sup> L'International Press Telecommunications Council (IPTC) est une organisation internationale créée par les agences de presse en 1965. Sa mission est d'établir et de maintenir un standard normalisé de stockage des métadonnées relatives aux images de presse pour en faciliter l'échange.

## 4. Liste des recommandations

R15 : Réaliser au moins deux jeux de données :

- pour la conservation et l'archivage, le jeu de données sera numérisé sous une forme non comprimée, sans traitement supplémentaire : en haute résolution au format TIFF ;
- pour une exploitation sur le Web, le jeu de données sera numérisé au format JPEG en qualité maximale.

R16 : Toujours réaliser plusieurs jeux de métadonnées. Pour les métadonnées techniques, utiliser EXIF ; pour les métadonnées descriptives, utiliser IPTC-Core.

R17 : Utiliser le Dublin Core pour compléter la description du document iconographique.

R18 : Stocker les métadonnées descriptives dans un fichier portant le même nom que le fichier de l'image à l'extension près.

## 5. Les ressources

Dublin Core : <http://dublincore.org/> ; <http://dublincore.org/documents/dcmi-terms>

Didacticiel d'imagerie numérique de Cornell University : <http://www.library.cornell.edu/preservation/tutorialfrench/contents.html>

EXIF : <http://www.exif.org>

IPTC : <http://www.iptc.org>

IPTC - Métadonnées : <http://www.iptc.org/cms/site/index.html;jsessionid=a6fFGI6cnmYe?channel=CH0089>

Recommandations MINERVA : <http://www.minervaeurope.org/interoperability/digitisationguidelines.htm>



# LES DONNÉES ICONOGRAPHIQUES

## II - LES IMAGES ANIMÉES ET LES FILMS

### 1. Les données

Les données considérées ici sont des supports vidéos ou bien des films argentiques. Pour les supports vidéos, il s'agit de :

- Bande 2 Pouce Quadruplex
- Bande ½ Pouce
- Vidéo Casette ¾ Pouce
- Vidéo Casette ½ Pouce « substandard »
- Vidéo Casette ½ Pouce professionnelle
- Vidéo Casette 8 mm
- Vidéo Casette ¼ Pouce
- Vidéodisque

Pour les films argentiques, il s'agit de :

- 8 mm, Super 8 mm, 9,5 mm
- 16 mm
- 35 mm

### 2. Les conteneurs et les codecs

Les données multimédias (audiovisuelles/sonores) numériques font appel à deux notions techniques :

- *Codec* (codeur/décodeur) : programme permettant d'encoder à la capture puis de décoder à la lecture les données. Il permet également de compresser et/ou décompresser ce signal. Il ne doit pas cependant être confondu avec le procédé de compression/décompression, même s'il permet de réaliser à la fois l'encodage et la compression. Il est le plus souvent utilisé comme algorithme de compression pour réduire la taille d'un flux (vidéo/audio).
- *Conteneur* : fichier « enveloppe » contenant des données destinées à être archivées et les informations relatives à l'interprétation de ces données. Il peut contenir divers types de formats, ce qui permet de gérer les différents flux audio et/ou vidéo codés à l'aide de codecs, ainsi que d'autres types de données : chapitrage, sous-titres, métadonnées, description des flux contenus, etc.

#### 2.1 Les principaux formats conteneurs vidéo

- *AVI* (Audio Video Interleave)

Conteneur multimédia de Microsoft pour le système Windows. Il supporte divers algorithmes de compression et de décompression et tous les codecs associés.

- *ASF* (Advanced Streaming Format)

Conteneur multimédia Microsoft, utilisé dans la suite logicielle Windows Media. Il permet la diffusion

en continu (streaming), il supporte la haute définition et fournit un module de gestion des droits (DRM).

- *3GP*

Conteneur multimedia défini par 3GPP. Il a été conçu pour diminuer le stockage des fichiers, en facilitant la lecture de contenu multimédia sur les réseaux sans fil pour les téléphones mobiles de troisième génération (3G).

- *FLV (Flash Video)*

Conteneur multimedia développé par Adobe Systems. C'est le format de référence pour diffuser des vidéos sur le web via le lecteur Adobe Flash Player.

- *MKV (Matroska Video)*

Conteneur multimédia libre. Le format MKV permet de regrouper dans un même fichier plusieurs pistes vidéo (DivX, H.264, realVideo, Theora, VP8, XviD, etc.) et audio (AAC, AC3, DTS, FLAC, MP2, MP3, Vorbis, etc.), ainsi que des sous-titres et chapitres (SRT, ASS, SSA, USF, etc.). Il supporte pratiquement tous les flux multimédias existants et permet de réaliser des fonctions de chapitrage, de créer des menus, de faire des recherches dans le fichier, de sélectionner une source sonore ou bien encore d'ajouter une pièce jointe.

- *MPEG-2 (Moving Pictures Experts Group)*

Norme désignant le système de codage vidéo et audio, la combinaison et la méthode de compression pour la transmission sur les réseaux de télévision numérique. Cette norme spécifie le format de films distribués sous format DVD ou SVCD. Elle intègre également deux formats conteneurs : le MPEG-TS et le MPEG-PS.

- MPEG-TS (Transport Stream) : format conteneur permettant la transmission de flux multiplexé, utilisé notamment pour diffuser la télévision numérique.

- MPEG-PS (Program Stream) : format conteneur supportant le multiplexage vidéo / audio et utilisé pour le stockage sur DVD

- *MP4 (ISO/IEC 14496-14)*

Conteneur multimédia issu de la norme MPEG-4 : MPEG-4 ASP, MPEG-4 AVC (vidéo) et AAC (audio). Il supporte tous les types de contenus multimédia (plusieurs pistes son, vidéo, sous-titres, etc.) et des contenus avancés (« Rich Media » ou BIFS (Binary Format for Scenes) : menus de type DVD, graphisme 2D/3D, etc.). Il est également distribuable en streaming.

- *M4V*

Format conteneur développé par Apple pour les contenus iTunes et les périphériques vidéo de la marque (iPod, iPad et PlayStation). Ce format est basé sur la norme MPEG-4 avec le codec vidéo AVC.

- *OGG Média*

Conteneur multimédia libre et ouvert de la fondation Xiph.org. Il permet au sein d'un même fichier de gérer un flux vidéo et plusieurs pistes audio. Il intègre les sous-titres et le chapitrage. Flux vidéos supportés : Theora, Xvid ou DivX ; et audio : OGG Vorbis, MP3, WAV, ACC, FLAC, WAV.

- *QuickTime*

Environnement de développement multimédia développé par Apple, désignant à la fois un codec vidéo, un codec audio et un conteneur. Le conteneur permet de gérer plusieurs pistes vidéo (animation, graphique, 3D, etc.) audio et texte (sous-titres). Chaque piste contient une piste média (stream) permettant la diffusion en temps réel via Internet. Quicktime supporte de nombreux formats audio, et vidéo : formats audio (WAV, AAC, MIDI, etc.) et vidéo (DV, H.261, H.263, H.264, MPEG-2, MPEG-4).

- *WebM*

Format multimédia, sous licence libre, développé par Google. Il est composé d'un conteneur dérivé de Matroska Video (MKV), d'un codec vidéo VP8 et du codec audio libre OGG Vorbis. Il est destiné à faire fonctionner de manière native les contenus multimédias sur le Web, notamment avec HTML5

qui permet grâce aux balises <video> et <audio> de gérer les vidéos sans recourir à un autre lecteur. Il est supporté par Google Chrome, Mozilla Firefox 4.0 et Opéra. Il existe désormais un plug-in WebM pour Internet Explorer 9. La société Adobe a par ailleurs indiqué que Flash supportera le format WebM.

## 2.1 Les principaux codecs vidéo

- *DivX*

Codec vidéo propriétaire et fermé de DivX Inc. Il a été conçu à partir de MPEG-4 part2 (MPEG-4 a été modifié pour pouvoir compresser le son au format MP3). Il permet ainsi d'obtenir des vidéos compressées très peu volumineuses stockées dans les fichiers AVI.

La septième édition de sa suite logicielle comprend un nouveau codec de compression et de décompression, un convertisseur de formats et un lecteur. Il s'appuie désormais sur la norme de codage vidéo H.264 (MPEG-4 Part 10) et le codec audio AAC lui aussi défini dans la norme MPEG-4. L'intégration des normes de codage MPEG-4 permet au codec DivX d'être compatible avec les vidéos HD, cette dernière étant utilisée pour le stockage Blu-ray, HD DVD etc. Il reconnaît aussi le conteneur Matroska (MKV) permettant la gestion de plusieurs flux vidéo et audio.

- H.264 (MPEG-4 AVC : Advanced Video Coding)

Codec développé par le groupe MPEG et édité par l'UIT-T (Union Internationale des Télécommunications). Il offre de multiples techniques permettant d'améliorer le taux de compression par rapport au MPEG-2 et une meilleure qualité d'affichage. Il est également adapté à une très grande variété de réseaux et de systèmes : TNT, VOD, Blu-ray, téléphonie mobile (iPhone, iPad, etc.) et streaming.

- MJ2 Codec - Motion JPEG 2000

Codec vidéo compressant chaque image au format JPEG 2000. Il permet d'effectuer un codage sans perte notamment pour la compression spatiale. Il peut donc être utilisé comme format de conservation.

- Theora

Codec vidéo libre et ouvert de la fondation Xiph.org. C'est l'un des composants du format conteneur OGG. Il est fondé sur le codec VP3 développé par On2 technologies (société rachetée par Google) et open-source depuis 2002.

- VP8

Codec vidéo libre de Google (développé initialement par On2 Technologies, société rachetée par Google) utilisé dans le format WebM. Ce codec est largement utilisé dans HTML5 et supporté par de nombreux navigateurs.

- WMV (Windows Media Video)

Codecs vidéos propriétaires développés par Microsoft. Le dernier codec, WMV 9-VC1, s'appuie sur le codec VC-1 normalisé par la SMPTE (Society of Motion Picture and Television Engineer) et développé par Microsoft. Concurrent du codec H264 de MPEG-4, il est destiné à être employé pour la haute définition (HD) : HD Blu-ray et HD-DVD.

- XviD

Le format XviD est une implémentation OpenSource du codec Divx. Il repose également sur la norme de codage MPEG-4.

- X264

Codec libre, sous licence publique, permettant de coder des flux vidéo en H264.

## 3. La numérisation

Quand on prépare le corpus, il importe de déterminer :

- La datation des données
- La nature des données :
  - Extraits de films, émissions
  - Films complets
  - Rushes

Il s'agit de points importants qui vont entraîner des structurations différentes du corpus.

Faire attention à la dangerosité de certains matériaux.

Il faut connaître la composition des films argentiques. En effet, les films nitrate de cellulose, qui peuvent s'auto-enflammer, sont à identifier avec la plus grande précaution. Voici ce que préconise la BNF, dans son document *Écrire un cahier des charges de numérisation de collections sonores, audiovisuelles et filmiques*:

« Une analyse visuelle et olfactive (syndrome du vinaigre) de la boîte et de son contenu permettent de se faire une idée de l'état de conservation du document : poussière, moisissures, état des étiquettes et de leur colle, ratures synonymes d'une réutilisation d'un support enregistrable sont autant d'indices de problèmes éventuels et de la nécessité d'un dépoussiérage ou d'un nettoyage, voire plus, avant lecture. On prendra garde également aux dangers inhérents à certains supports, comme les films nitrate de cellulose, susceptibles de s'auto-enflammer. En cas de doutes, et afin d'éviter tout risque de contamination croisée, il devra être fait appel à un spécialiste pour un diagnostic précis. »

Lors de la numérisation, il convient de produire une version de conservation ET une version de diffusion. Pour plus de détails, on se reportera aux guides de la BNF et de la TGIR Huma-Num cités plus bas.

## 4. Les métadonnées

Pour les métadonnées, on peut utiliser la norme MPEG-7. C'est une norme ISO élaborée par le MPEG (Moving Picture Experts Group - Groupe d'experts sur les images animées). Elle permet de décrire les caractéristiques de contenu audio et vidéo de telle sorte que les utilisateurs puissent rechercher, parcourir et extraire ce contenu de manière effective et efficace. Elle combine :

- des métadonnées techniques sur le fichier ;
- des métadonnées documentaires (titre, créateur, droits, renseignements sur les personnes, les objets et les événements représentés dans le fichier multimédia, etc.).

Cette norme reste cependant difficile à implémenter. C'est pourquoi, tout comme pour les images fixes, on recommande la structuration des métadonnées à l'aide du Dublin Core (cf. § 2.2.1.). Les métadonnées seront enregistrées dans un fichier XML séparé, portant le même nom que le fichier du document audiovisuel, à l'extension près.

## 5. Liste des recommandations

R18 : Réaliser au moins deux versions numérisées, l'une pour la conservation l'autre pour la diffusion.

R20 : Pour les métadonnées, utiliser le Dublin Core. Les métadonnées sont enregistrées dans un fichier XML séparé, portant le même nom que le fichier du document audiovisuel à l'extension près.

## 6. Les ressources

Écrire un cahier des charges de numérisation de collections sonores, audiovisuelles et filmiques, BNF : [http://www.culture.gouv.fr/culture/mrt/numerisation/fr/technique/documents/cahier\\_charges\\_numerisation.pdf](http://www.culture.gouv.fr/culture/mrt/numerisation/fr/technique/documents/cahier_charges_numerisation.pdf)

Guide méthodologique pour le choix de formats numériques pérennes dans un contexte de données orales et visuelles : <http://www.huma-num.fr/ressources/guides>

Institut national de l'audiovisuel (INA) : <http://www.ina.fr>

Logiciel d'annotation de films, Ligne de Temps de l'IRI : <http://www.iri.centrepompidou.fr/fr/atelier.html>



# LES DONNÉES SONORES

## 1. Les données

Par données sonores, on entend l'ensemble des données audio : enregistrement de parole, de conversations ou de musique. Elles peuvent être considérées du point de vue aussi bien de leur contenu que du traitement linguistique dont elles peuvent faire l'objet.

Parmi les supports les plus couramment rencontrés dans les fonds d'archives, les bibliothèques, les musées ou les autres services culturels, on trouve <sup>1</sup> :

- le cylindre
- le disque « 78 tours »
- le disque à gravure directe
- le disque microsillon
- la bande magnétique
- la cassette
- la micro cassette
- le DAT (Digital Audio Tape)
- le miniDisc
- le CD audio (Compact Disc)

La nature du contenu et la typologie des supports sont en étroite relation avec le contexte de leur production. L'usage de tel ou tel support ne présage cependant en rien du caractère unique et de l'importance du contenu.

### Attention !

L'évaluation de la qualité des supports (de leur boîte et de leur contenu) est primordiale avant d'entreprendre leur lecture et de s'engager dans un projet de numérisation.

## 2. La numérisation

Il convient de distinguer les données sonores analogiques et les données sonores nativement numériques.

Pour un document analogique, afin de permettre une exploitation la plus riche possible en termes d'information, il sera important de rechercher les niveaux les plus élevés en matière de quantification et de fréquence d'échantillonnage.

Pour un document nativement numérique, il n'est pas nécessaire de le copier dans un format de qualité supérieure à celui d'origine.

<sup>1</sup> La liste est issue du guide de numérisation édité par la BNF.

Quelle que soit l'origine du document (analogique ou nativement numérique), qu'il s'agisse de conservation, diffusion, ou de restauration, il importe de suivre les recommandations techniques associées à chaque type d'opération.

Pour la conservation :

- Numérisation sans compression
- Format de fichier: WAV ou BWF
- Quantification : 16, 24 bits ou plus
- Fréquence d'échantillonnage : 44.1, 48, 96, 192 kHz ou plus
- Copie « droite » : absence de traitement

Pour choisir le convertisseur analogique / numérique, faire préalablement des tests.

Pour la diffusion sur le web :

- Conversion sous forme compressée (au format MP3, OGG, ou autre) à partir de la version pour archive, ou de la version « restaurée », si elle existe.
- Débit à ajuster en fonction du mode de diffusion envisagé.

Pour la restauration :

- À partir de la copie « droite » non compressée, application de divers traitements pour une restauration la plus linéaire possible (réduction des bruits de surface, réduction de souffle, de bruit, de sifflement, filtrages divers...). En outre, des interventions ponctuelles (rayures, « trou de son »...) peuvent être nécessaires.
- Format de fichier « normalisé » : WAV ou BWF
- Quantification : 16, 24 bits ou plus
- Fréquence d'échantillonnage : 44.1, 48, 96, 192 kHz ou plus

Il faut distinguer la restauration du support (bandes collantes, cassures, etc.) de la restauration du contenu.

Pour la conservation et la diffusion, il importe de faire plusieurs jeux de numérisation.

### 3. Les métadonnées

Les métadonnées associées aux documents sonores peuvent être récupérées de manière automatique (lors de la numérisation) ; elles sont sinon indiquées manuellement.

Comme pour les autres types de données traitées dans ce guide, il est essentiel que les métadonnées soient renseignées selon des normes et des standards reconnus. C'est la problématique de recherche et les objectifs du projet qui conduisent à se déterminer par rapport aux différents formats possibles.

Plusieurs schémas sont disponibles pour exposer les métadonnées. On peut utiliser des schémas génériques (cf. § 2.2.).

Pour une exploitation linguistique, on suivra les recommandations de l'*Open Language Archive Community* (OLAC), qui est une organisation internationale dont l'objectif est le partage et la diffusion de ressources de nature linguistique. Celle-ci recommande l'utilisation du Dublin Core qualifié, auquel ont été ajoutés 5 attributs dont les valeurs sont liées à des vocabulaires contrôlés. Il s'agit de :

1. l'attribut « language » ajouté aux éléments DC « subject » et « language » et dont la valeur doit être prise dans le catalogue Ethnologue (<http://www.ethnologue.com/>) devenu depuis la nouvelle norme ISO-639 d'abréviation des langues sur 3 caractères ;
2. l'attribut « linguistic-field » ajouté à l'élément DC « subject ». Il doit prendre sa valeur dans une liste fermée (phonetics, phonology, pragmatics, psycholinguistics...);

3. l'attribut « discourse-type » ajouté aux éléments DC « type » et « subject », à choisir dans une liste fermée (drama, formulaic\_discourse, interactive\_discourse, language\_play, oratory, narrative, procedural\_discourse, report, singing, unintelligible\_speech) ;

4. l'attribut « linguistic-data-type » ajouté à l'élément DC « type », à choisir dans une liste fermée (lexicon, primary\_text, language\_description) ;

5. l'attribut « role » peut être ajouté aux éléments « contributor » et « creator ». Il doit prendre sa valeur dans une liste fermée (recorder, researcher, singer, speaker, transcriber, translator...). Le fichier rassemblant les métadonnées doit être stocké de manière séparée. C'est un fichier de format XML, dont le nom sera identique à celui du fichier sonore à l'extension près.

Le fichier rassemblant les métadonnées doit être stocké de manière séparée. C'est un fichier de format XML, dont le nom sera identique à celui du fichier sonore à l'extension près.

## 4. Liste des recommandations

R19 : Numériser un document analogique au niveau le plus élevé en matière de quantification et de fréquence d'échantillonnage.

R20 : Formater un document nativement numérique en choisissant un format de qualité égal à celui d'origine.

R21 : Pour la conservation et la diffusion, prévoir plusieurs jeux de numérisation.

R22 : Pour une exploitation linguistique, renseigner les métadonnées dans le format OLAC.

R23 : Les métadonnées sont enregistrées dans un fichier XML séparé, portant le même nom que le fichier sonore, à l'extension près.

## 5. Les ressources

Centre de ressources numériques pour la description de l'oral :

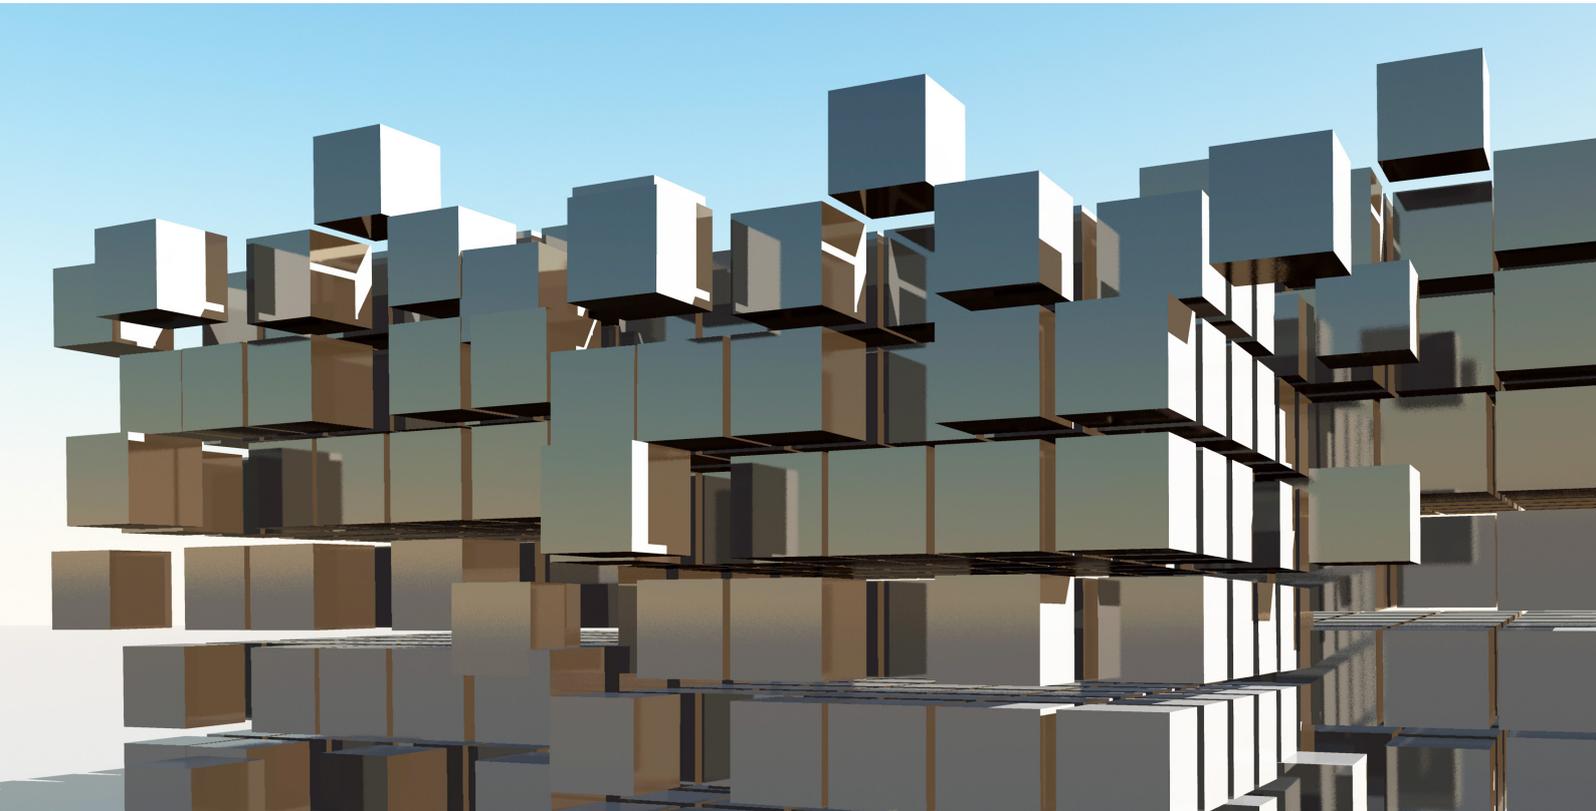
- Aix : <http://crdo.fr>
- Paris : <http://crdo.risc.cnrs.fr/exist/crdo/>

Corpus Oraux, Guide des bonnes pratiques, O. Baude (dir.), PUO, 2006  
[http://www.dglf.culture.gouv.fr/recherche/corpus\\_parole/Corpus\\_Oraux\\_GBP%202006\\_version\\_imprimee.pdf?CV=5584&type1=Ouvrage](http://www.dglf.culture.gouv.fr/recherche/corpus_parole/Corpus_Oraux_GBP%202006_version_imprimee.pdf?CV=5584&type1=Ouvrage)

Écrire un cahier des charges de numérisation de collections sonores, audiovisuelles et filmiques, BNF, août 2009 :  
[http://www.culture.gouv.fr/culture/mrt/numerisation/fr/technique/documents/cahier\\_charges\\_numerisation.pdf](http://www.culture.gouv.fr/culture/mrt/numerisation/fr/technique/documents/cahier_charges_numerisation.pdf)

OLAC : <http://www.language-archives.org/>

Projet TELEMETA : <http://telemeta.org>



## GLOSSAIRE

### Attribut

En langage XML, un attribut apporte des informations sur l'élément qui le contient. Le nom des attributs, les éléments qui les contiennent et le type de valeurs que les attributs peuvent contenir, peuvent être précisés dans des schémas (schémas XML, DTD, relaxng, etc.).

Ex. <element type= "exemple">. Ici l'attribut « type » est renseigné par la valeur « exemple », qui précise le nom de la balise <element>.

### Balise

Une balise est un élément fondamental des langages d'encodage. Elle fonctionne comme un marqueur syntaxique. Une balise permet d'identifier et de qualifier des contenus. Par exemple une balise <title> désigne un titre. Le nom d'une balise est formellement écrit entre deux chevrons. Les balises fonctionnent par paire : une balise ouvrante et une balise fermante.

Ex :<title>La géographie du notaire languedocien</title>

### Compression

Compresser une information numérique permet d'en réduire la taille d'où :

- un gain d'espace ;
- une réduction de l'infrastructure inhérente (volume d'une baie de stockage, d'archivage, ou de consommation électrique, etc.) ;
- une réduction du temps de transfert lors de téléchargements.

En ce qui concerne les sources orales ou visuelles, la compression pourra cependant entraîner l'augmentation du temps de traitement pour la lecture, qui est en général compensée par de plus faibles volumes à traiter.

Les compressions peuvent être :

- a) sans perte : l'opération est dite « réversible ». Le document produit après compression puis décompression est identique au document original ;
- b) avec pertes : dans ce cas la fidélité de l'écoute et de la visualisation d'une séquence audiovisuelle peut être plus ou moins altérée selon le « codec » choisi.

La compression sans perte est idéale pour l'archivage à long terme : au gain de place s'ajoute la fidélité de la restitution.

Pour les images numériques, chaque pixel est défini par une série d'informations digitales : plus il y a d'informations, plus l'image est de bonne qualité mais plus le fichier est lourd. Le « codec » généralement utilisé pour compresser les images et en réduire le poids est le JPEG.

### Dublin Core

C'est une norme internationale très souvent employée pour la description et l'échange de métadonnées. Son langage simplifié (15 balises ou « descripteurs ») permet de faciliter l'échange de métadonnées génériques et l'interopérabilité entre différents projets.

### EXIF (Exchangeable Image File)

Format de métadonnées images. Les métadonnées EXIF sont générées automatiquement par les appareils de prise de vue numériques. Selon les fabricants, on retrouve à peu près les mêmes types d'informations concernant la prise de vue (date, heure, diaphragme, vitesse, focal, avec ou sans flash).

### Format informatique

Un format informatique est une convention pour représenter une donnée sous forme numérique. Il peut être spécifié, ouvert, normalisé, standardisé ou propriétaire.

### Format normalisé ou standardisé

Un format est normalisé ou standardisé quand sa description est adoptée par un organisme de

normalisation ou de standardisation. Parmi ces organismes dans le domaine des technologies de l'information, on citera :

- AFNOR – Association française de normalisation – <http://www.afnor.org/>
- ISO – Organisation Internationale de normalisation – <http://www.iso.org/>
- OASIS – Organization for the Advancement of Structured Information Standards – <http://www.oasis-open.org/>
- W3C – World Wide Web Consortium – <http://www.w3.org/>

### **Format ouvert**

L'article 4 de la loi française n°2004-575 du 21 juin 2004 pour la confiance dans l'économie numérique, définit un format ouvert : « on entend par standard ouvert, tout protocole de communication, d'interconnexion ou d'échange et tout format de données interopérable et dont les spécifications techniques sont publiques et sans restriction d'accès ni de mise en oeuvre ».

Un format ouvert est légalement exempté de droits d'utilisation et sa description est publique. Il est alors compréhensible et interopérable. Il est compréhensible car sa description ou spécification est publique : tout le monde peut alors prendre connaissance de la manière dont les informations sont organisées au niveau de ce format. Il est alors possible à partir de cette connaissance de créer une variété de programmes ou d'équipements qui l'exploitent. On dit d'un tel format qu'il est interopérable. Les notions de format ouvert et de format libre sont très proches. Un format sera qualité de libre uniquement si aucune restriction juridique ne lui est applicable. Un format qui n'est pas « ouvert » est naturellement dit « fermé ».

### **Format propriétaire**

Un format est dit propriétaire si son cadre d'utilisation est contrôlable par une personne ou une entité juridique. Ce droit peut s'établir par exemple via le droit d'auteur, le brevet ou le copyright. Cependant, même si l'utilisation du format est contrôlable, cela ne signifie pas qu'elle soit obligatoirement contrôlée. Ainsi le format PDF est ouvert, car ses spécifications sont libres d'accès et que son propriétaire Adobe Systems, société de droit privé, autorise des programmes tiers à réutiliser son format. Ce format est donc ouvert même s'il est propriétaire. Ces deux notions ne sont pas antinomiques. Le terme propriétaire est souvent et abusivement employé pour désigner un format dont l'utilisation est fortement restreinte par les droits que possède son propriétaire. Si tel est le cas – et si la spécification n'est même pas consultable – on parle de format fermé. Un format qui n'est pas « propriétaire » est un format dit « libre ».

### **Format spécifié**

Un format est dit spécifié lorsqu'il est suffisamment décrit pour en développer une implémentation complète. La spécification est souvent trouvée sous la forme d'un fichier au format PDF ou TEXT, en une ou plusieurs langues. Elle contient des informations qui nécessitent le plus souvent une bonne connaissance en informatique. Il n'y a pas d'adresse particulière regroupant toutes les spécifications. Elles se trouvent, le plus souvent, sur le site internet du propriétaire du format ou sur celui de l'organisme qui a édité une norme à son sujet.

### **HTML (Hyper Text Mark-Up Language)**

Langage de balisage qui permet d'écrire de l'hypertexte et de structurer sémantiquement le contenu de pages web. Il contient un nombre fixe de balises.

### **Interopérabilité**

Des ressources numériques sont dites interopérables quand elles sont décrites et exposées à l'aide de formats standardisés ou normalisés. Elles peuvent alors être recherchées, identifiées, exposées, partagées, réutilisées, etc.

### **IPTC (International Press Telecommunications Council)**

Consortium réunissant les principales agences de presses et photographiques dont la principale activité consiste à développer et à maintenir des standards permettant l'échanges des données. Il a notamment mis au point le format **IPTC/IIM** (pour *Information Interchange Model*). Ce format de métadonnées documentaires est spécifique aux images.

### **JPEG (Joint Photographic Experts Groups)**

Né de la fusion en 1986 de plusieurs groupes de professionnels de l'industrie de l'image, ce groupe à

donné son nom à une norme ouverte de compression d'images numériques, le JPEG. C'est un format de compression à perte (il élimine donc des informations) mais son taux de compression est réglable, ce qui permet un bon compromis entre le taux de compression et la qualité de l'image compressée.

### **Métadonnée**

Une métadonnée est une donnée servant à définir ou à décrire une autre donnée, qui représente le document numérique résultant de la transformation de la source première. Les métadonnées sont à la base des techniques du web sémantique. Elles doivent donc être rédigées en tenant compte des standards, car ce sont elles qui permettent l'accès aux données et qui garantissent l'interopérabilité.

### **METS (Metadata Encoding and Transmission Standard)**

Schéma XML permettant la description d'objets numériques. Il est particulièrement destiné aux échanges entre institutions patrimoniales et est conforme aux recommandations de l'OAIS (Open Archival Information System). Ce schéma est maintenu actuellement par la Bibliothèque du Congrès.

### **Numérisation**

Au sens le plus répandu, la numérisation est la conversion d'un signal (vidéo, image, audio, caractère d'imprimerie, impulsion, etc.) en une suite de nombres permettant de représenter cet objet en informatique ou en électronique numérique.

### **OAIS (Open Archival Information System)**

Modèle conceptuel destiné à la gestion, à l'archivage et à la préservation à long terme des documents numériques. C'est une norme ISO (référence 14721). Il permet de décrire les fonctions, les responsabilités et l'organisation d'un système qui souhaite préserver de l'information.

### **OAI-PMH (Open Archives Initiative – Protocol for Metadata Harvesting)**

Protocole standard interopérable qui permet d'avoir accès aux métadonnées d'un entrepôt de données numériques.

### **RDF (Resource Description Framework)**

C'est un modèle de représentation de données, qui relie des triplets (sujet-prédicat-objet) dans un graphe. Il permet de décrire de façon formelle des ressources web et leurs métadonnées et des traiter informatiquement. Développé par le W3C, RDF est le langage de base du web sémantique.

### **TEI (Text Encoding Initiative)**

Il s'agit d'un langage XML permettant de structurer des données et des métadonnées textuelles. C'est un système de modélisation textuelle, permettant la construction des schémas XML pour la structuration des données et des métadonnées textuelles, très répandu dans le domaine scientifique.

### **Unicode**

Norme visant à donner de manière unifiée à tout caractère de n'importe quel système d'écriture, un nom et un identifiant numérique.

### **W3C (World Wide Web Consortium)**

Organisme de standardisation fondé en octobre 1994, par Tim Berners-Lee (principal inventeur du web). Le consortium est chargé de promouvoir la compatibilité des technologies du web. Il a été fondé au MIT/LCS (Massachusetts Institute of Technology/Laboratory for Computer Science) avec le soutien de l'organisme de défense américain DARPA et la Commission européenne.

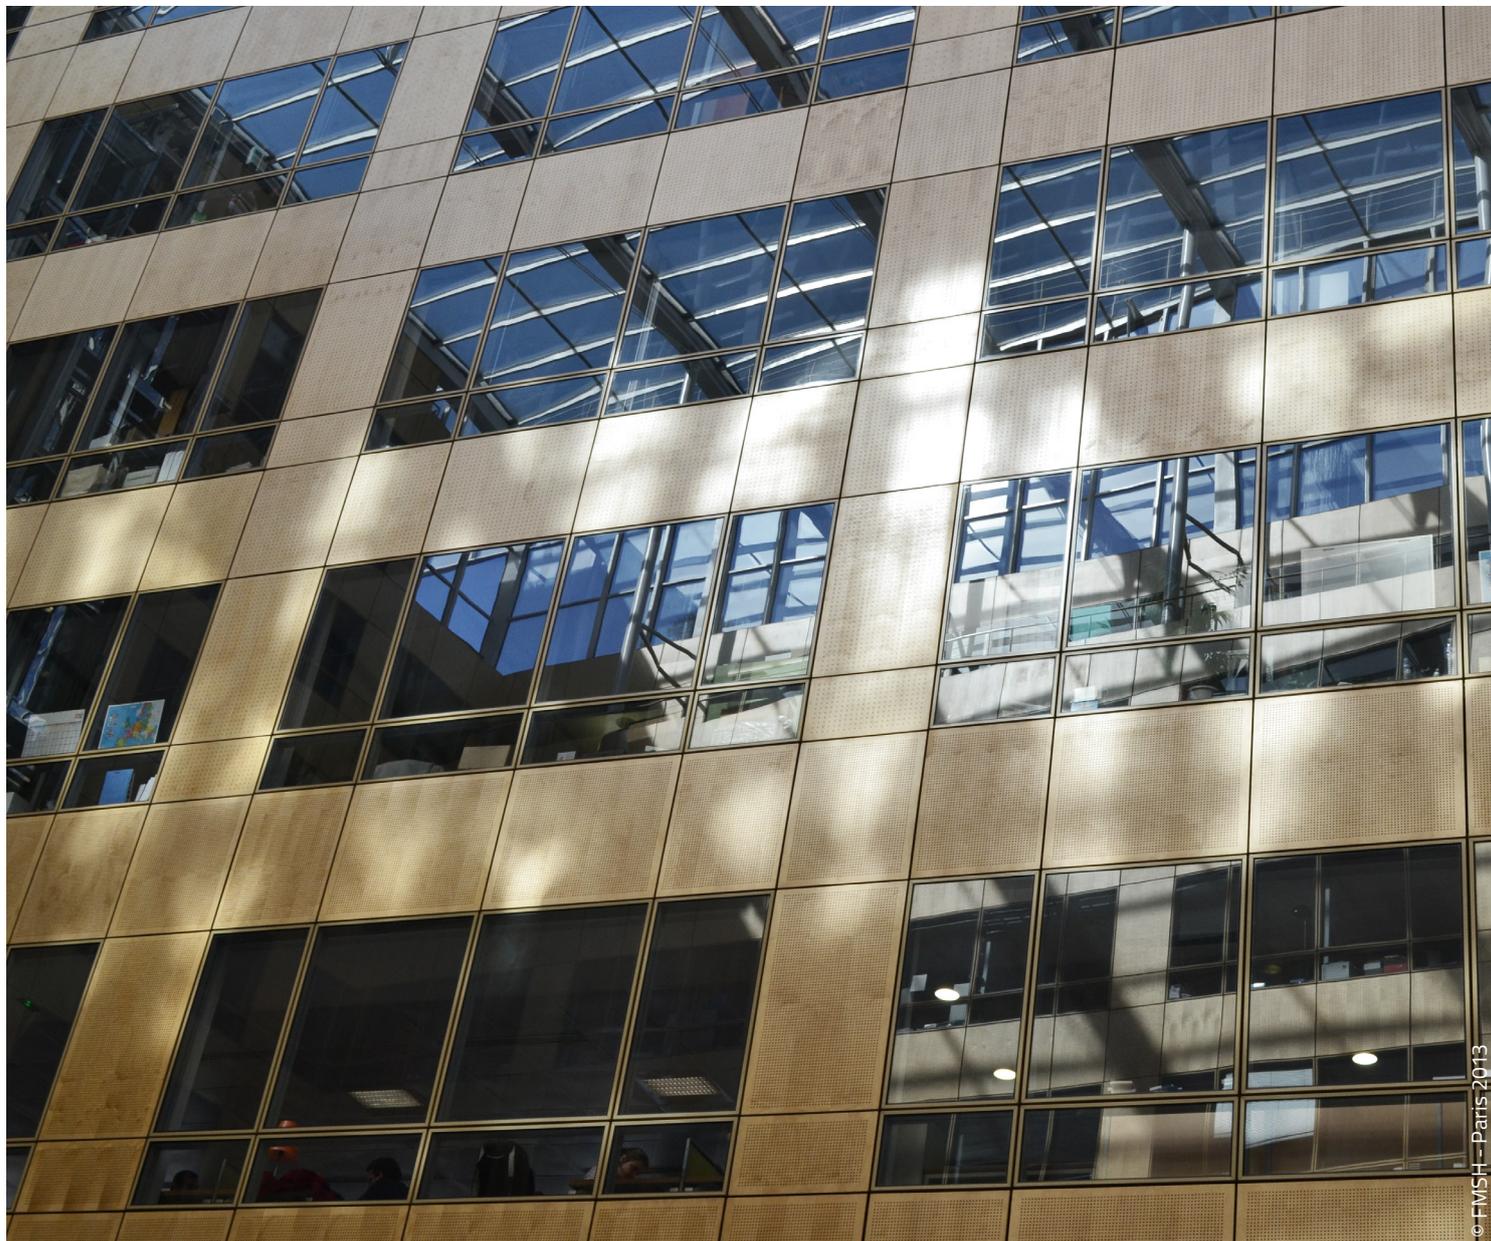
### **XML (Extensible Markup Language)**

Langage de balisage extensible. C'est un langage qui permet de structurer sous forme d'arborescence les données. À la différence du langage HTML dont le nombre de balises est fixe, le langage XML peut accueillir autant de nouvelles balises que nécessaire.

### **XMP (eXtensible Metadata Platform)**

Format de métadonnées documentaires particulièrement utilisé pour les images.





Les guides de bonnes pratiques sont réalisés  
par le pôle communication de la TGIR Huma-Num.

Retrouvez toute l'actualité d'Huma-Num sur :  
<http://www.huma-num.fr>  
<http://humanum.hypotheses.org>

