LA PRESERVATION DU DOCUMENT NUMERIQUE

JAMES M TURNER
École de bibliothéconomie et des sciences de l'information
Université de Montréal
james.turner@umontreal.ca

INTRODUCTION

Pour discuter la question de la préservation du document numérique, il faut d'abord la distinguer d'avec la préservation des objets physiques tels que papier, film, verre, bois, pierre, ou encore film ou ruban magnétique. La préservation d'objects physiques a rapport surtout à la stabilisation chimique de l'objet en vue de prévenir la détérioration.

La question de la préservation de documents sur papier n'est devenue urgente que depuis la découverte, dans les années 1950, de l'acidité du papier produit depuis 1860 environ (Barrow & Sproull 1959, Barrow Research Laboratory 1963). Concernant le développement de la préservation en tant que science et profession, on peut noter que l'International Institute for Conservation of Historic and Artistic Works date d'environ 1950 (International Institute 2003) et qu'on assiste à l'essor des activités dans ce domaine durant la deuxième moitié du vingtième siècle. Il s'agit donc d'une discipline encore jeune.

Le problème de la préservation du document numérique était reconnu beaucoup plus rapidement par les professionels de l'information, du fait que par sa nature le document numérique a des besoins d'intervention quasi immédiats, sinon il devient rapidement inutilisable. À titre d'exemples bien documentés, la découverte aux États-Unis en 1975 qu'il n'y avait que deux ordinateurs sur terre encore capables de lire le recensement de 1960 ainsi que la perte de données provenant de l'espace enregistrées depuis 1958 par la National Aeronautics and Space Administration (NASA) aux États-Unis. Les gouvernements de beaucoup d'autres pays ont maintenant constaté des faits semblables. Bien qu'il n'y ait à ce jour pas de solutions définitives, on déploie des efforts considérables pour étudier la question et pour expérimenter diverses approches.

Cet article se veut un survol de la problématique servant à initier l'archiviste qui souhaite prendre connaissance de cette question. C'est une problématique entièrement nouvelle, qui est caractérisée par l'aspect expérimental et aléatoire des méthodes, par la difficulté de surmonter le problème de l'instabilité des supports physiques et par l'urgence de trouver des solutions assez rapidement. On dit qu'un document sur papier a de meilleures chances de survivre pendant un siècle qu'un document électronique pendant une décennie. On note aussi la robustesse d'autres supports comme les tablettes d'argile, le parchemin et la pierre. Mais en ce qui

concerne les documents numériques, c'est le fichier qu'on souhaite préserver et non pas le support. C'est une problématique sans analogue dans toute l'histoire et qu'on peut réduire à ceci: on passe de la préservation d'objets physiques par des moyens de stabilisation chimique à la préservation d'objets numériques, sans forme physique, par la stabilisation du fichier informatique.

Bien que les termes «document numérique» et «document électronique» sont généralement considérés comme des synonymes, nous préférons le terme «document numérique» à cause d'une ambiguïté causé par le fait que certains documents sont électroniques tout en étant analogiques. Par exemple, des cassettes vidéo ou des cassettes audio sont des documents électroniques parce qu'elles nécessitent de l'équipement électronique pour la consultation. Toutefois, le signal est encodé sur le ruban magnétique en format analogique. De la sorte, ces documents sont électroniques, mais ils ne sont pas numériques. Le terme «document numérique» implique que le contenu du document est nécessairement encodé en format numérique. Une définition donnée par Thibodeau (*State of digital preservation* 2002, 6) identifie des caractéristiques de documents pertinentes pour la préservation, appartenant à trois classes: l'objet physique, l'objet logique et l'objet conceptuel. Cependant, aux fins du présent exposé, nous pouvons nous contenter de sa définition de base, à savoir que c'est l'encodage qui définit l'objet comme étant numérique («*an information object expressed in digital form*»).

DOCUMENTS CONVERTIS AU FORMAT NUMERIQUE ET DOCUMENTS «NES NUMERIQUES»

Dans une perspective archivistique, il convient de distinguer les documents «nés numériques» des documents dont l'original est analogique, mais qui sont numérisés pour l'utilisation en ligne. L'objet «né numérique» s'avère plus vulnérable parce que l'original est sujet à tous les aléas qui peuvent survenir au cours de sa vie tandis qu'on peut dire qu'un document dont l'original est analogique tombe plutôt sous le régime de préservation d'objets physiques.

Par ailleurs, la numérisation peut aussi être considérée comme une stratégie de préservation. Imaginons un document papier que l'on souhaite numériser parce que son degré de détérioration en rend la manipulation risquée. En numérisant, on

créera une copie de consultation, ce qui évitera de manipuler l'original. De plus, si jamais le papier périt, on aura ainsi assuré la survie du contenu informationnel.

Dans le cas de documents électroniques mais qui ne sont pas numériques, par exemple des enregistrements de films, de vidéos ou de musique ou autres informations sonores sur film, sur ruban magnétique ou sur vidéodisque analogique, un problème sérieux se pose. Faut-il préserver le film, le ruban ou le disque ou faut-il plutôt numériser le contenu? En dépit des problèmes importants de préservation d'images sur film, on peut assurer une certaine stabilité lorsque les conditions de stockage sont adéquates. On peut aussi ralentir la détérioration des rubans magnétiques et de vidéodisques en les emmagasinant dans de bonnes conditions, mais pour les archives de nombreux pays, notamment ceux de la zone tropicale, de telles conditions sont difficilement réalisables.

Même si on peut conserver ces matériaux dans des conditions idéales, il faut reconnaître que dans la durabilité qu'il faut viser pour les archives (c'est-à-dire la vie illimitée) la vie du support est relativement courte. Il est pensable de viser une centaine d'années pour le film, mais seulement dix ou vingt ans pour le ruban magnétique (Lindner 1996) ou le vidéodisque (sans parler de la technologie nécessaire à la consultation de ces documents). Avant la fin de la vie du support il faut repiquer le document, sinon on le perd.

Or, on perd un peu de qualité de l'image ou du son chaque fois qu'on copie le document d'un support sur un autre. En quelques générations à peine (environ cinq), la qualité est tellement détériorée que le document n'est plus consultable. On peut donc projeter qu'à long terme il faudrait numériser tous les documents audiovisuels qui sont électroniques, mais dont l'encodage sur le support est analogique, à défaut de quoi on risque une déperdition totale, même an ayant recours au repiquage périodique. Il en ressort que la numérisation de documents audiovisuels est probablement inévitable parce que nécessaire pour assurer la préservation de l'image et du son. Les techniques ne sont pas encore très stables, mais elles le deviendront avec le temps.

OBSTACLES TECHNOLOGIQUES

De nombreux et sérieux problèmes doivent être solutionnés pour que l'on puisse assurer la préservation à long terme des documents numériques. Dans cette section, nous présentons quatre obstacles majeurs à la longévité des documents numériques : les supports instables, la compression, les technologies de stockage et l'évolution des technologies d'enregistrement et de lecture.

Les supports instables. L'obstacle le plus important est probablement le fait qu'aucun support pour l'information numérique n'est stable. Il ne s'agit donc pas de numériser les documents une fois pour toutes. Le ré-encodage du signal du mode analogique au mode numérique est certainement salutaire parce que cela met fin à la détérioration dûe à la perte de qualité d'une génération analogique à une autre. Mais cela ne suffit pas, étant donné que le nouveau support ne va pas vivre très longtemps et alors il faut prévoir de recopier le document encore une fois, dans quelques années, sur un support neuf. Lors de cette opération-là, au moins n'y aura-t-il pas déperdition de la qualité du signal, parce que la copie se fera d'encodage numérique à encodage numérique. Ainsi, nous sommes entraînés dans un cycle vicieux de repiquage à toutes les quelques années, à seule fin de gagner du temps en attendant une ou des solutions à l'obstacle de l'instabilité des supports. L'ironie est de constater que le bon vieux papier reste le support le plus stable pour l'information.

La compression. À cause de l'énormité des fichiers informatiques qu'exigent les documents audiovisuels, en particulier l'image en mouvement numérique et ensuite les fichiers sonores numériques, on fait appel à des techniques de compression. Mais, encore ici, il y a perte de qualité parce qu'une fois compressé, le document ne peut être restitué entièrement, c'est à dire décompressé. Théoriquement, l'archiviste ne peut pas approuver l'idée que la compression soit acceptable parce que cela équivaudrait à considérer la perte de qualité comme acceptable. La réalité est que l'archiviste, du moins pour le moment, se trouve devant le dilemme suivant : numériser ses documents audiovisuels afin de les préserver et de pallier au problème de la perte de qualité d'une génération analogique à l'autre, mais, ce faisant, être obligé de compresser le fichier numérique et donc accepter une autre sorte de détérioration de qualité, quoique moins grave, le document se trouvant en bout de ligne toujours sur un support instable. Ce problème est donc lié au problème des technologies de stockage. Il faut attendre

une découverte importante qui nous offrira la possibilité de stocker des fichiers non compressés sur un support stable ; même un support toujours instable mais qui peut accueillir de grandes quantités de données serait une amélioration. Dans ce contexte, on peut noter que le prix des disques durs baisse continuellement—mais est-ce raisonnable d'élaborer une stratégie d'accumulation de disques durs pour le stockage de produits audiovisuels, au rythme d'un document numérique par disque dur?

Les technologies de stockage. Peut-on espérer voir le jour où une ou plusieurs technologies de stockage puissent être considérées comme stables, c'est-à-dire pouvant durer des siècles plutôt que quelques années seulement avant de devenir inutilisables? L'idée n'est pas nouvelle chez les archivistes, mais le fait est que cette communauté ne représente pas une très grande part du marché pour les fabricants. La motivation manque chez ces derniers pour travailler à l'élaboration d'un tel support. De plus, c'est évidemment à leur avantage que les clients rachètent souvent leurs produits pour remplacer ceux qui sont usés. À petite échelle, c'est relativement facile de repiquer un ruban magnétique tous les dix ans, par exemple, mais pour une archive qui consiste en de grandes voûtes pleines de documents le problème est beaucoup plus sérieux. Il faut dans ce cas prévoir des coûts importants et un programme de gestion de l'activité de repiquage, laquelle devrait s'effectuer d'une manière continue et selon un système de rotation.

Toutefois, non seulement il n'existe pas de support pour l'information numérique qui durera très longtemps, il y a aussi la longévité des formats à gérer. C'est vrai pour les médias magnétiques autant que pour les médias optiques. Certains formats sont éphémères, n'étant disponibles que durant quelques années avant que le fabricant cesse la production parce que le marché est devenu trop peu intéressant. L'archiviste peut faire face à cette situation en ne choisissant que des formats dont la fabrication est assurée, mais ce n'est pas suffisant. C'est qu'une archive va nécessairement acquérir des documents sur formats éphémères et, en conséquence, il faudra transférer les documents hébergés dans ces formats vers d'autres formats de plus longue durée.

L'évolution des technologies d'enregistrement et de lecture. Comme l'a déjà fait valoir Mallinson (1986), même si on réussit à assurer la longévité des médias, le problème de la préservation de documents électroniques ne sera pas résolu pour autant. C'est que ces médias nécessitent des appareils pour permettre la

consultation des documents qu'ils hébergent. Mallinson observe que le problème se situe principalement au niveau de l'entretien de l'équipement. Les appareils électroniques ont une durée d'utilisation d'environ 2000 heures. Par surcroît, avec le temps, les fabricants cessent de produire les modèles proposés parce qu'ils en mettent de nouveaux sur le marché ; ils cessent aussi d'offrir un soutien technique pour les dits modèles et ne produisent plus de morceaux de rechange. Il incombe alors à l'archiviste d'entretenir les appareils nécessaires pour la consultation, ce qui exige de lui des compétences d'ordre technique. Les archivistes qui ont ce genre de responsabilité achètent souvent sur le marché d'occasion des appareils usagés afin d'y dénicher des morceaux de rechange, mais il est évident qu'une telle stratégie de prolongation de la vie utile de documents ne peut pas durer indéfiniment.

STRATEGIES DE PRESERVATION

D'après Thibodeau, il est impossible de préserver un document numérique en tant qu'objet physique. Ce que l'on préserve, c'est la capacité de reproduire le document (*State of digital preservation* 2002, 13). Thibodeau offre une réflexion très intéressante sur les enjeux et les approches de la préservation numérique, cependant nous nous en tiendrons ici à trois stratégies qui font l'objet d'un vif débat actuellement dans le milieu professionnel : le repiquage, la migration et l'émulation.

Le repiquage. Afin de pallier au problème de la détérioration des supports physiques sur lesquels sont hébergés des documents numériques, on copie périodiquement le fichier informatique sur un support neuf. Comme nous l'avons noté, il y a une perte de la qualité lorsqu'il s'agit d'un signal encodé analogiquement, mais lorsque le signal est numérique, la copie est identique au fichier source. À l'aide d'algorithmes de vérification et de correction, l'exactitude du fichier de destination est assurée. Le repiquage est donc une stratégie rassurante quoique imparfaite, puisqu'elle apporte une solution temporaire au problème dans l'attente d'une meilleure. En vue du problème de la trop courte vie des supports physiques pour les documents numériques, il convient de conceptualiser ces derniers comme étant sans domicile fixe et le problème lui-même comme étant relatif à un logement plus permanent.

Si le document repiqué est hébergé sur un autre type de support, par exemple d'un disque dur sur une disquette ou un CD-R ou encore sur un ruban magnétique, il s'agit toujours de repiquage. Ce qui caractérise cette stratégie, c'est la copie pour fins de prolongation de la vie utile du document parce que le support qui l'héberge actuellement risque de se détériorer bientôt.

La migration. La migration, quant à elle, vise à assurer l'actualité du format de fichier. Au fur et à mesure que de nouvelles versions de logiciels voient le jour, des documents créés avec d'anciennes versions deviennent graduellement obsolètes. Normalement, un logiciel devrait être capable de lire des fichiers créés avec ses versions antérieures, mais périodiquement, il y a une refonte majeure de la façon d'encoder les données, de la manière dont le système d'exploitation interagit avec le logiciel, ou encore du traitement des données par le matériel informatique. La migration vise à recoder un document sous une forme plus actuelle d'un logiciel afin de maintenir aisément consultable ce document. Par exemple, la conversion d'un document Word 4 à Word 6 puis à Word 98.

Certains formats deviennent obsolètes indépendamment des logiciels utilisés pour les créer. Sauvegarder un document créé avec un de ces formats dans un format plus courant ou plus stable, c'est aussi de la migration—par exemple, la conversion d'une image de format MacPaint au format TIFF. La notion de migration consiste donc en la conversion d'un document numérique dans un autre format de fichier afin d'assurer l'accessibilité continue de l'information contenue dans le document.

Cette stratégie n'est pas exempte de problèmes. La traduction de documents d'un format à un autre se fait selon les possibilités du logiciel cible. Il n'est pas toujours possible de traduire exactement certains aspects, ni même de les traduire minimalement. Une intervention humaine peut être nécessaire pour corriger les faiblesses du logiciel cible aini que pour permettre d'assurer la préservation du contenu sémantique d'un document. Certains aspects du formatage peuvent être tout simplement perdus.

Malgré tout, il ne suffit pas de repiquer périodiquement des documents numériques, car cela ne sera à rien si les logiciels ne sont plus capables de les interpréter pour permettre la consulation. Une stratégie alternative, l'émulation, est proposée.

L'émulation. Cette stratégie se fonde sur l'approche suivante: on laisse les documents dans leur forme originale et au lieu de les migrer constamment vers des versions plus récentes de logiciels permettant de les consulter, on crée des logiciels émulateurs capables de reproduire sur des ordinateurs modernes les comportements d'anciens ordinateurs, systèmes d'exploitation ou logiciels. De la sorte les fichiers restent intacts. C'est une solution attirante parce qu'elle élimine les problèmes inhérents à la migration. Cependant, l'émulation non plus n'est pas sans problèmes.

Il y a trois couches d'intervention à émuler. Au niveau de base, l'ancien ordinateur peut être très différent de l'ordinateur d'aujourd'hui, non seulement quant à sa capacité de traitement des données en mémoire vive et en mémoire morte mais aussi en ce qui concerne la façon dont les données sont traitées à même le processeur. Il n'est pas évident que l'on puisse maintenir les structures, les comportements et l'affichage d'anciens documents numériques sans altération aucune. Le système d'exploitation, qui constitue la seconde couche, est construit en fonction du matériel informatique et, en créant un émulateur pour cette fonction, il faut l'harmoniser avec l'émulateur de la première couche, ce qui n'est pas évident. La troisième couche, qui est la couche logicielle, vient s'ajouter à cette problématique, parce qu'elle aussi est construite en fonction des deux premières couches.

Afin de rentabiliser tout le travail nécessaire à la création et à la publication d'émulateurs il faudrait créer un genre d'«émulathèque» capable d'héberger tous les émulateurs des trois couches pour tous les ordinateurs jamais créés. Cependant, les émulateurs eux-mêmes pourraient être sujets à la migration, parce que de nouvelles architectures d'ordinateurs seront créés avec le temps et il faudra alors migrer les anciens émulateurs pour qu'ils fonctionnent sur les nouvelles machines.

Le débat actuel. Les auteurs qui écrivent sur la question se répartissent en deux groupes : ceux qui prônent la migration et ceux qui prônent l'émulation. À titre d'exemples de cette discussion, citons Granger (2000), Eiteljorg (1999), Rothenberg (1999) et Mermet (1996-97). Il y en a beaucoup d'autres. Besser (2001) souligne que dans les deux cas (la migration et l'émulation), la stratégie est employée conjointement avec le repiquage. Ce jumelage des stratégies demeurera nécessaire jusqu'au développement d'un support physique pouvant survivre longtemps avant de se détériorer.

TRAVAUX EN COURS

Actuellement rien n'est définitif en ce qui concerne les stratégies à adopter pour la préservation de documents numériques. Heureusement, il y a beaucoup de travaux d'expérimentation et d'essais en cours. Le Web demeure l'environnement de choix pour lire sur le sujet. Notre initiative à l'Université de Montréal, le MétroMéta (2003) tente de réunir en un seul endroit toutes les informations sur les initiatives les plus importantes ainsi que sur des normes et ensembles de métadonnées. Le plus important projet international de recherche sur la question de la préservation de l'information numérique est InterPARES (2003). Il contribue de façon notable à la base de connaissances disponibles dans le domaine de la préservation numérique et offrira des solutions à cette problématique.

CONCLUSIONS

Le problème de la préservation des documents numériques s'est manifesté avec une relative soudaineté conjointement à la venue des ordinateurs sur la scène mondiale et, plus particulièrement, depuis l'introduction de micro-ordinateurs dans les années 1980. Aujourd'hui la grande majorité des documents, surtout les documents officiels de type archives, sont produits par des ordinateurs. Il s'agit donc de documents numériques. Témoin des changements technologiques rapides et parfois radicaux, la communauté professionnelle s'est conscientisée à cette problématique, et ce, dès le début de l'histoire des documents numériques. Elle a réagi en initiant un nombre important de réflexions, de discussions, de projets expérimentaux, de même qu'en formant des groupes de travail. La communauté de chercheurs universitaires étudie également cette problématique tout en transmettant des informations à ce sujet aux étudiants inscrits dans les programmes pertinents. Les problèmes identifiés dans cet article assez sommaire sont traités en profondeur par de nombreux auteurs dans des publications spécialisées. Nous espérons toutefois que notre article permettra aux professionnels de la gestion de l'information, qui souhaitent s'informer sur le sujet, de mieux comprendre quels sont les principaux enjeux de la problématique.

REFERENCES ET BIBLIOGRAPHIE/WEBOGRAPHIE

BARROW, William James and REAVIS C. Sproull. «Permanence in book papers». *Science*, 129 (24 April, 1959): 1075-1084.

BARROW, William James. «Permanence/durability of the book — A two year research program». *W. J. Barrow Research Laboratory Publications*, 1 (1963). Richmond, Virginia (USA).

BESSER, Howard. «Digital preservation of moving image material?», *The Moving Image: the Journal of the Association of Moving Image Archivists* 1, n. 2 (fall, 2001). Disponible au http://www.gseis.ucla.edu/~howard/Papers/amia-longevity.html (document consulté le 2003.10.31).

DIGITAL Preservation Coalition. 2002. Disponible au http://www.dpconline.org/ (document consulté le 2003.10.24).

EITELJORG, Harrison, «Preservation for the Future -- with emulation or migration?», *CSA Newsletter* XII, nº. 1 (spring, 1999). Document disponible le 2003.10.31 au http://www.csanet.org/newsletter/spring99/nls9906.html.

GRANGER, Stewart. «Emulation as a digital preservation strategy». *D-Lib Magazine* 6, nº. 10 (October, 2000). Disponible au http://www.dlib.org/dlib/october00/granger/10granger.html (document consulté le 2003.10.31).

INTERNATIONAL Institute for Conservation of Historic and Artistic Works. *Articles of association.* Disponible au http://www.iiconservation.org/docs/art_assoc.pdf (document consulté le 2003.10.24).

InterPARES. 2003. Disponible au http://www.interpares.org (site consulté le 2003.10.31).

LINDNER, Jim. *Magnetic tape deterioration: tidal wave at our shores*, 1996. Disponible au http://www.vidipax.com/articles/tidal.html (document consulté le 2003.10.29).

MALLINSON, John C. «Preserving machine-readable archival records for the millennia». *Archivaria* 22 (summer, 1986), pp. 147-152.

MERMET, Jean-Michel. *Le rôle des bibliothèques dans l'archivage des périodiques électroniques scientifiques.* Lyon : INSA, 1996-97. Document disponible le 2003.10.31 au http://www.insa-lyon.fr/Insa/Departements/DocInsa/jmm/rrbfinal_complet.html.

Le METROMETA. 2003. Disponible au http://mapageweb.umontreal.ca/turner/ (site consulté le 2003.10.31).

ROTHENBERG, Jeff. *Avoiding technological quicksand: finding a viable technical foundation for digital preservation.* CLIR Publications and Resources, 1999. Disponible au http://www.clir.org/pubs/reports/reports.html (page consultée le 2003.10.31).

The STATE of digital preservation: an international perspective: conference proceedings. Washington: Institutes for Information Science, 2002. Disponible au www.clir.org/pubs/reports/pub107/pub107.pdf (document consulté le 2003.10.31).