



**HAL**  
open science

# A study of users documents memory for the design of personal information systems

Tristan Blanc-Brude, Dominique Scapin

► **To cite this version:**

Tristan Blanc-Brude, Dominique Scapin. A study of users documents memory for the design of personal information systems. [Research Report] RR-5785, INRIA. 2005. inria-00070236

**HAL Id: inria-00070236**

**<https://inria.hal.science/inria-00070236>**

Submitted on 19 May 2006

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



INSTITUT NATIONAL DE RECHERCHE EN INFORMATIQUE ET EN AUTOMATIQUE

**Etude de la mémoire des documents pour la conception de  
systèmes d'aide à leur récupération**

Tristan Blanc-Brude  
Dominique L. Scapin

N° 5785

Décembre 2005

————— Thème COG —————

A large, stylized grey 'R' with a white swoosh, followed by the words 'Rapport de recherche' in a grey, serif font. A horizontal grey bar is positioned below the text.

*Rapport  
de recherche*





## **Etude de la mémoire des documents pour la conception de systèmes d'aide à leur récupération**

Tristan Blanc-Brude et Dominique L. Scapin

Thème cog C – **Interaction homme-machine**  
Projet MErLIn

Rapport de recherche n°5785– Décembre 2005 - 23 pages

**Résumé :** Cette étude a pour but de déterminer quels sont les attributs (e.g., nom, localisation etc.) dont les utilisateurs se rappellent à propos de leurs propres documents (papier et électronique) et comment ils se les rappellent, dans le but de fournir des recommandations sur la manière de concevoir des systèmes qui permettent aux utilisateurs de retrouver leurs fichiers électroniques plus efficacement et plus facilement. Une quasi-expérience a été conduite avec quatorze participants dans leur propre environnement de travail. On leur demandait tout d'abord de se rappeler des caractéristiques d'un (ou plusieurs) de leurs documents de travail et deuxièmement de les retrouver. Tout d'abord, lorsqu'on demandait aux participants de retrouver leurs documents, ils n'ont utilisé qu'un sous-ensemble réduit des attributs dont ils étaient capables de se rappeler et ils ont souvent eu des difficultés à retrouver leurs documents, avec leurs outils actuels. Ceci va dans le sens d'un besoin pour des outils de récupération plus performant. Les résultats indiquent quels attributs des documents sont plus souvent rappelés (e.g., mots-clefs) mais aussi quels sont ceux qui sont le mieux rappelés, c'est-à-dire avec le moins d'erreurs (e.g., type). Ainsi, les résultats indiquent quels sont les attributs qui sont de bons candidats pour faciliter la récupération. Les résultats fournissent également des recommandations potentielles sur: comment le système de recherche devrait autoriser les utilisateurs à exprimer les attributs; la tolérance à inclure dans les résultats pour pallier à la nature peu fiable de la mémoire; et quelles sont les informations précises relatives à l'utilisation des documents dont le système devrait garder une trace. Enfin les résultats suggèrent que la conception d'outils de recherche pourrait exploiter le fait que le rappel des attributs de document dépend du type d'utilisateur et de la fréquence d'utilisation des fichiers.

**Mots-clés :** Personal information management, moteur de recherche sur le bureau, recherche d'information, mémoire, conception centrée utilisateur.



## A study of users' documents memory for the design of personal information systems

**Abstract:** This study aims at finding out which attributes (e.g., names, location etc.) people actually recall about their own documents (electronic and paper), and how they recall them, in order to provide recommendations on how to design tools that allow users to retrieve their electronic files more effectively and more easily. A quasi-experiment was conducted with fourteen participants at their workplace. They were asked first to recall features about one (or several) of their own work document(s), and secondly to find these documents. First of all, when participants were asked to find their document(s), they only used a small subset of the attributes they were able to recall, and often they had difficulties in finding their document(s), with current available tools. This correlates with the need for better tools for retrieval. In addition, the results indicate which document attributes are more often recalled (e.g., keywords) but also which ones are best recalled, that is with less errors (e.g. type). Thus, results indicate which attributes are candidate for facilitating file retrieval. Results also provide potential recommendations on: how the retrieval system should allow users to express these attributes; how the retrieval system should include a tolerance in the results to overcome the unreliable nature of memory; and what particular information in relation to the use of files should be tracked by the system. Finally, results suggest that the design of search tools could exploit the fact that the recall of document attributes depend on the type of user and the frequency of use of the files.

**Keywords:** Personal information management, desktop search engine, information retrieval, memory, user centered design.



# SOMMAIRE

<b>1. INTRODUCTION</b> .....	<b>3</b>
<b>2. LE ROLE DES ATTRIBUTS DE DOCUMENTS DANS LEUR RECUPERATION</b> .....	<b>3</b>
<b>3. METHODES POUR LA CONCEPTION DES OUTILS D'AIDE A LA RECUPERATION DES DOCUMENTS</b> .....	<b>4</b>
<b>4. METHODOLOGIE</b> .....	<b>6</b>
4.1. PARTICIPANTS : .....	6
4.2. PROCEDURE : .....	6
4.3. MATERIEL : .....	7
<b>5. RESULTATS</b> .....	<b>7</b>
5.1. PHASE DE "RAPPEL LIBRE" .....	8
5.2. PHASE DE "RAPPEL INDICE" .....	8
5.2.1. Localisation.....	10
5.2.2. Type ou Format.....	10
5.2.3. Nom.....	10
5.2.4. Titre.....	11
5.2.5. Taille .....	11
5.2.6. Moment.....	12
5.2.7. Mots-clefs.....	13
5.2.8. Éléments visuels .....	13
5.2.9. Événements associés .....	13
5.2.10. Liens .....	14
5.2.11. Opérations.....	14
5.3. PHASE DE RECUPERATION DES DOCUMENTS .....	15
<b>6. DISCUSSION ET IMPLICATIONS POUR LA CONCEPTION</b> .....	<b>15</b>

<b>7.</b>	<b>CONCLUSION .....</b>	<b>21</b>
<b>8.</b>	<b>BIBLIOGRAPHIE .....</b>	<b>23</b>



## **1. Introduction**

La quantité de données numériques que nous acquérons et stockons dans nos ordinateurs durant nos activités de travail ou dans notre vie privée est devenue considérable. Par conséquent, un problème important auquel faire face est la gestion de ces informations. Les outils informatiques classiques s'appuyant sur la métaphore du bureau physique et imposant une organisation de type hiérarchique des fichiers électroniques ont montré leurs limites (Jones et Dumais, 1986; Marsden et Cairns, 2003). Le besoin de nouveaux outils permettant aux utilisateurs de gérer plus facilement leurs données apparaît donc comme une nécessité. Le terme *Personal Information Management (PIM)* désigne le domaine de recherche qui étudie la manière dont les utilisateurs gèrent leurs documents physiques (livre, cahier, feuille etc.) ou numériques (fichier, email, page web, etc.) dans le but de concevoir des outils informatiques d'aide à la gestion de ces documents (*PIM tools*). Selon Boardman (2004), l'activité même de gestion des documents (ou items) peut être décomposée en 4 sous-activités : l'acquisition, l'organisation, la maintenance et la récupération des documents. Nous nous intéressons plus particulièrement à la sous-activité dite de récupération car nous pensons qu'elle constitue l'un des problèmes majeurs liés à la gestion des documents. En effet, compte tenu de leur nombre croissant, nos documents sont souvent difficiles à retrouver "dans la masse". De plus, certains auteurs (Lansdale, 1988; Barreau et Nardi, 1995; Jones, Dumais et Bruce, 2002; Bellotti, Ducheneaut, Howard, Smith et Neuwirth, 2002) mettent l'accent sur le fait que le but principal de l'activité de gestion des documents est précisément de permettre leur récupération ultérieure. Les résultats obtenus par Dumais, Cutrell, Cadiz, Jancke, Sarin et Robbins (2003) vont également dans ce sens puisqu'ils observent que des utilisateurs ressentent moins le besoin de maintenir une hiérarchie complexe de leurs documents lorsqu'ils disposent d'un outil de recherche performant leur permettant de retrouver plus facilement leurs documents.

Ce rapport présente tout d'abord la problématique de l'étude, puis décrit la méthodologie employée, ainsi que les résultats obtenus selon les phases de la quasi-expérience. Enfin, la discussion se focalise sur les implications des résultats pour la conception ; la conclusion évoquant les limites de l'étude et les perspectives ouvertes.

## **2. Le rôle des attributs de documents dans leur récupération**

Les outils d'aide à la gestion des documents personnels (*PIM tools*), qu'ils soient des prototypes de recherche ou des systèmes commercialisés, exploitent différents types d'*attributs* des documents pour permettre, entre autres, leur récupération par l'utilisateur. Par *attributs* nous entendons les différentes dimensions pouvant caractériser un document comme sa taille, son titre, sa couleur etc. Par exemple, les outils classiques des systèmes d'exploitation conçus selon la métaphore du bureau physique et imposant une organisation hiérarchique des fichiers font reposer la récupération des documents principalement sur deux attributs : la localisation spatiale des documents et le nom des documents. D'autres *PIM tools* issus de la recherche et conçus comme des alternatives aux outils classiques ont choisi d'exploiter en priorité d'autres types d'attributs comme le temps lié à l'utilisation des documents (*Lifestreams*, Freeman et Gelernter, 1996) ou le projet d'appartenance des documents (*UMEA*, Kaptelinin, 2003). Enfin certains *PIM tools* (*Presto*, Dourish, Edwards, LaMarca et Salisbury, 1999; *Haystack*, Adar, Kargar et Stein, 1999) ainsi que les outils de recherche des systèmes d'exploitation de nos ordinateurs (e.g., Spotlight dans Mac OS X Tiger, fonction "rechercher" dans MS Windows Vista Beta 1) tentent d'exploiter le maximum

d'attributs pouvant être utilisés par l'utilisateur lors de sa recherche (e.g., nom, contenu, date, taille etc.).

Boardman (2004) souligne toutefois le manque d'évaluation et de fondement empirique ou théorique dans le processus de conception de la plupart des prototypes de recherche dans le domaine *PIM*. Quant aux outils de recherche des systèmes d'exploitation, des études montrent que les utilisateurs ne s'en servent qu'en dernier recours, préférant parcourir les répertoires (Barreau et Nardi, 1995, Ravasio et al. 2004). Or, nous pensons que l'une des principales raisons pour laquelle ils ne sont pas utilisés est qu'ils ne sont pas suffisamment utiles et utilisables (l'autre principale raison étant qu'ils sont trop lents, mais les outils de recherche de nouvelle génération comme Mac OS Spotlight se sont largement améliorés sur ce point).

La raison pour laquelle certains attributs sont choisis plutôt que d'autres et la manière dont ils sont exploités par ces différents types d'outils ne sont pas justifiées par des données empiriques. Or, dans certains cas, les attributs utilisés par ces outils correspondent à des caractéristiques techniques des fichiers électroniques que les systèmes peuvent extraire facilement mais qui n'ont pas de sens du point de vue de l'utilisateur non expert. Par exemple, l'attribut de taille exprimé en nombre d'octets est souvent utilisé par les outils de recherche. Si cet attribut est facile à obtenir et à exploiter d'un point de vue technologique, il ne fait pas partie des informations relatives aux documents auquel un utilisateur lambda prête le plus d'attention. Dès lors, on ne peut guère s'attendre à ce que celui-ci l'ait mémorisé et puisse s'en servir au moment de la tentative de récupération d'un document. Nous rejoignons sur ce point Ravasio, Schär et Krueger (2004) pour qui la raison pour laquelle les outils de recherche des systèmes d'exploitation ne sont pas utilisés pourrait être que "*existing search tools have never been designed for average users but rather for experts*" (p. 173). Nous sommes également d'accord avec leur conclusion selon laquelle "*Technical file metadata is, for the most part, useless to users and should be replaced by more user-friendly attributes*" (p. 176).

### **3. Méthodes pour la conception des outils d'aide à la récupération des documents**

Les travaux dans le domaine *PIM* ont d'abord été conduits dans le contexte d'environnements de bureaux physiques puis virtuels: par exemple, Malone (1983) a conduit une étude visant à comprendre la manière dont les gens gèrent leurs documents dans leur bureau (physique); Barreau et Nardi (1995) ont conduit quant à elles chacune deux études indépendantes pour observer la manière dont les utilisateurs organisent et trouvent leurs documents dans leurs ordinateurs. Dans les deux types d'études les auteurs ont trouvé que les utilisateurs préfèrent la recherche basée sur la localisation spatiale.

Toutefois, selon Fertig, Freeman et Gelernter (1996), les études du type de celles menées par Barreau & Nardi (1995) présentent l'inconvénient de révéler des stratégies *ad hoc* employées par les utilisateurs pour s'accommoder des systèmes basés sur la métaphore du bureau. La prise en compte de ce type d'observations ne pourrait donc servir qu'à améliorer les systèmes existants mais ne pourrait pas être extrapolée à des assertions générales sur la manière dont les utilisateurs acquièrent, organisent, maintiennent et récupèrent de l'information.

Une critique analogue avait déjà été adressée par Lansdale (1988) aux travaux de Malone (1983). Il considère que les stratégies d'organisation spatiale observées par Malone ne sont pas représentatives d'un « besoin » de l'utilisateur mais sont en réalité une stratégie

compensatoire aux problèmes de classification, un compromis pour éviter le processus de classification.

Selon Fertig et al. (1996), la solution pour concevoir des nouveaux *PIM tools* consiste davantage à étudier les utilisateurs dans des environnements qui incluent de nouvelles métaphores, qui ne sont pas celles du bureau, ce qui implique la conception de prototypes de recherche radicalement différents des outils existants.

On peut penser qu'effectivement des telles études révéleront des préférences différentes chez les utilisateurs mais on peut aussi craindre qu'elles ne conduisent à des comportements qui sont trop spécifiques à l'environnement étudié pour pouvoir être généralisés, des comportements qui resteront donc des artefacts des systèmes en jeu.

Whittaker, Terveen et Nardi (2000) soulignent également les problèmes liés à l'"invention radical", notamment dans le domaine *PIM*, consistant à créer des outils entièrement nouveaux comme alternatives aux outils existants, car cela empêche la construction d'objets de recherche communs au domaine.

Il y a donc un besoin de créer un savoir de base sur le comportement et les besoins de l'utilisateur sur lequel de nouveaux systèmes pourront être construits. Cette idée rejoint le point de vue de Lansdale (1988) qui prône l'investigation des mécanismes cognitifs sous-jacents à l'activité de *PIM*. Dans cette tentative, il met l'accent sur les processus psychologiques liés à la mémoire étant donné que la mémoire est utilisée dans la récupération des documents personnels puisqu'on tente de se souvenir par exemple des noms de fichier, de la date à laquelle on a reçu l'information, de l'apparence du document, etc. L'idée de Lansdale est que si l'on arrive à déterminer ce dont les individus sont susceptibles de se souvenir et ce dont ils ne sont pas susceptibles de se souvenir, alors on peut d'une part, examiner comment les systèmes existants exploitent ou n'exploitent pas la mémoire et d'autre part, on peut voir comment concevoir les systèmes les plus utilisables possibles.

Des études expérimentales sont allées dans ce sens en testant la capacité des utilisateurs à mémoriser et à rappeler certains attributs (e.g. localisation, apparence, noms etc.) dans des tâches de récupération de documents (Dumais & Jones, 1985; Jones & Dumais, 1986; Lansdale, 1988; Lansdale, 1991; Lansdale, Simpson & Stroud, 1990; Czerwinski et al. 1999). Si ces études ont permis d'obtenir des résultats très intéressants, elles présentent cependant l'inconvénient du manque de validité écologique du matériel utilisé. En effet, sans doute à cause des contraintes qui s'exercent sur les expérimentations contrôlées, les tâches de récupération ne font pas intervenir les documents propres aux participants, mais des documents collectés par l'expérimentateur avec lesquels l'utilisateur doit se familiariser dans le contexte de l'expérimentation. Ainsi, ces études ne permettent pas de répondre à la question suivante : de quoi les utilisateurs se rappellent-ils à propos de leurs "propres" documents personnels.

Gonçalves et Jorge (2004) ont fait un pas dans cette direction en demandant à des utilisateurs de raconter l'histoire de trois documents qu'ils possédaient pour identifier les types d'attributs les plus souvent rappelés et comment ces attributs s'enchaînent dans la narration. Cependant, leur étude ne nous renseigne ni sur la fiabilité du rappel (i.e. quel est le degré d'exactitude du rappel ?, cela dépend-t-il du type d'attribut ?), ni sur la manière dont les attributs sont rappelés (i.e. de quelles informations précises relatives à un attribut donné les utilisateurs se souviennent-ils ?, avec quel degré de précision s'exprime le rappel ?, quelles sont les expressions utilisées pour exprimer le rappel ?). Nous pensons que ces informations sont nécessaires pour concevoir des outils d'aide à la récupération des documents qui soient adaptés aux capacités de mémorisation et de rappel des utilisateurs et permettent de les exploiter au mieux. L'objectif de l'étude que nous allons présenter maintenant est de tenter de répondre à ces questions.

## 4. Méthodologie

### 4.1. Participants

Quatorze membres du personnel de l'Institut National de Recherche en Informatique et en Automatique ont participé à l'étude. Les participants ont été sélectionnés de manière à former deux groupes de personnes effectuant deux types de travail qualitativement différents dans le but d'obtenir une meilleure représentativité de notre échantillon et de tester les effets éventuels du type des caractéristiques de l'activité sur la mémorisation des caractéristiques des documents de travail. Un groupe comportait sept membres du personnel de recherche de l'institut et un autre comportait sept membres du personnel administratif de l'institut.

### 4.2. Procédure

Des interviews semi-dirigées accompagnées d'une quasi-expérience ont été conduites lors de sessions d'une heure et demie à deux heures dans le bureau des participants.

L'objectif principal était de déterminer dans quelle mesure les participants se rappellent des informations ou des événements liés à leurs documents et de déterminer quelles sont les caractéristiques qui sont utilisées ou non pour la récupération des documents.

Dans un premier temps, des **interviews semi-dirigées** ont été conduites pour interviewer les participants sur leur travail, leur environnement, et sur la manière dont ils gèrent leurs fichiers électroniques et leurs documents papier. Dans le contexte de notre étude, le but visé n'était pas seulement de comprendre comment les individus organisent leurs documents de travail (cela a déjà été fait dans d'autres études avec les limites que nous avons évoquées) mais aussi et surtout de connaître le contexte de travail des participants pour orienter le choix des documents spécifiques sur lesquels portait la quasi-expérience et pour faciliter l'interprétation des résultats. La grande quantité de données recueillie dans cette partie ne sera donc pas présentée ici.

Dans la **quasi-expérience**, on demandait aux participants de faire la description d'un ou plusieurs documents (papier et/ou électronique) que l'expérimentateur avait dégagé à l'issue des informations recueillies lors de la première partie (un à trois documents par participant étaient étudiés en fonction du temps imparti).

Cette quasi-expérience était constituée de deux phases:

- Une phase initiale de « **rappel** » explorant la caractérisation intuitive des documents par les participants, basée sur leur mémorisation. Cette phase comportait deux sessions : une session « **rappel libre** » et une session de « **rappel indicé** ». Dans la session de « **rappel libre** », on demandait aux participants de dire les choses dont ils se rappelaient en premier à propos du document dans le but d'observer quels sont les attributs qui sont le plus facilement évoqués, de manière spontanée par les participants. Dans la session de « **rappel indicé** » on demandait aux participants de se rappeler des caractéristiques de chaque attribut du document, à partir d'une liste préétablie de 11 attributs. Cette liste était constituée à partir des principaux attributs rencontrés dans la littérature du domaine de la *PIM* et de l'ensemble des attributs que nous avons jugé pertinents pour l'utilisateur et donc susceptibles d'être mémorisés par celui-ci. Les attributs proposés étaient : **localisation** (répertoire électronique ou localisation physique), **type de fichier ou format de document**, **nom de fichier** (seulement pour les documents électroniques), **titre** (si approprié), **taille** (e.g., nombre de pages, nombre de lignes, etc.), **moment de dernière utilisation**, **mots-clefs**, **éléments visuels** (e.g., existence de graphiques, tables, couleurs), **événements associés à l'utilisation des documents**(e.g.,

email, appel téléphonique), **liens** (i.e. documents liés, différentes versions du document) et **opérations** (i.e. opérations effectuées sur le document).

- Une phase de “**récupération**” au cours de laquelle il était demandé aux participants de retrouver leurs documents évoqués, dans leur propre environnement, avec leurs propres outils. Cette phase avait pour but d'observer avec quelle facilité et par quels moyens les participants parvenaient à retrouver leurs documents avec leurs propres systèmes. Cette phase avait également pour but de permettre à l'expérimentateur d'étudier le document retrouvé pour vérifier l'exactitude des éléments rappelés par les participants au cours de la phase précédente.

### **4.3. Matériel**

Les interviews semi-dirigées et la quasi-expérience ont été menées dans l'environnement de travail (bureau et ordinateurs) propre à chaque participant.

Les items utilisés pour la quasi-expérience étaient des documents (électroniques et papiers) propre à chaque participant. Le choix des documents était orienté par l'expérimentateur sur la base des informations recueillies à l'issue de l'interview semi-dirigée lors de laquelle on demandait aux participants quelles étaient les principales tâches qu'ils effectuaient dans leur travail. Chaque document sélectionné correspondait à un document qui avait été utilisé lors d'une occurrence d'une des tâches évoquées (e.g., les diapositives de présentation utilisées par un participant chercheur pour une de ses communications orales à une conférence).

Sur l'ensemble des 30 documents cibles sélectionnés, il y avait 9 documents papiers et 21 documents électroniques. 12 documents sur les 30 étaient créés par l'utilisateur lui-même, 13 documents avaient juste été consultés et 5 avaient été consultés et modifiés. 16 sont des documents anciens (qui ont été créés, consultés ou modifiés il y a + de 6 mois); 5 sont des documents récents (qui ont été créés, consultés ou modifiés il y a - de 6 mois) et 9 sont des documents récurrents (qui sont consultés régulièrement).

Sur les 30 documents, 2 documents sont en fait les versions papier d'un document électronique ce qui explique que le nombre considéré comme total dans les résultats est de 28 et non de 30 (en effet la plupart des attributs sont indépendants de la nature du document).

Les différents types de documents sélectionnés étaient:

- Électroniques : 8 documents texte (2 PDF et 6 documents Word), 5 pages Web (ou ensemble de pages Web), 4 présentations (3 documents PowerPoint, 1 document SVG), 2 mails, 1 tableau (Excel) et un répertoire (Windows).
- Papiers : 4 ensembles de feuilles (agrafées ou non), 3 ouvrages et 1 ensemble de pages dans un cahier.

## **5. Résultats**

L'examen des données a été mené essentiellement à partir d'analyses quantitatives et qualitatives des réponses à la phase de rappel et des comportements observés à la phase de récupération. Les analyses quantitatives portent sur : les fréquences des attributs exprimés spontanément et des réponses aux attributs proposés ; la robustesse des informations rappelées par rapport aux éléments effectivement présents dans les documents concernés; le degré de réussite des tâches de récupération. Les analyses qualitatives portent sur : la nature exacte des informations relatives à un attribut évoquées par les participants; les moyens d'expression utilisés par les participants lors du rappel des attributs; les stratégies utilisées par les participants pour retrouver leurs documents; enfin, des comparaisons ont été

effectuées entre les attributs exprimés lors de la phase de rappel et les attributs ayant conduit à la récupération de documents.

Notons que dans l'ensemble, il n'y a pas eu d'effet significatif du type de participants (chercheur vs administratif) sur les résultats, sauf pour le rappel de l'attribut "date de dernière utilisation" lors de la session de "rappel indicé" (voir détails dans la présentation des résultats de cette session).

Des effets significatifs ou marginalement significatifs du type de document (récent, fréquent ou récurrent) ont été observés uniquement pour les attributs suivants : mots-clefs, taille et éléments visuels.

### 5.1. Phase de “Rappel Libre”

À la question générale de l'expérimentateur demandant aux participants de décrire le document en disant ce dont ils se souvenaient en premier, la plupart des participants ont répondu en rappelant des caractéristiques du contenu du document sous la forme de résumés du contenu (e.g., "il (*le document*) contient le détail de ce qu'il faut faire pour traiter les factures de gasoil"), d'informations sur la structure du contenu (e.g., "la première partie décrit ..., la deuxième partie traite des ..."), et/ou de parties spécifiques du texte (e.g., "sur la première page il y a le titre qui est *Marché passé selon la procédure...* "). 71.4 % de l'ensemble des descriptions de documents comportaient ce type de caractéristique.

Les autres types de rappel ont concerné principalement des éléments visuels du document comme la présence de couleurs ou d'images (e.g., "la couverture est verte ou bleue", "il y a une photo à droite") et le type de document ou format du fichier (e.g., "livre au format A5", "tableau Excel"). 25% des descriptions de documents contenaient des références à des éléments visuels. 21.4% des descriptions comportaient des informations relatives au type ou format.

Les attributs qui ont été rappelés plus marginalement étaient le titre, la taille, le lien et l'auteur.


Le nombre moyen d'attributs différents rappelés par participant n'était que de 1.46 attributs.

### 5.2. Phase de “Rappel Indicé”

A propos du « rappel indicé », les résultats concernent le type d'attributs les plus ou moins fréquemment sélectionnés et exemplifiés par les participants, à partir des attributs de la liste indicée, comme pouvant contribuer à la caractérisation de leurs documents (i.e., les attributs que les participants pouvaient instancier pour un document particulier).

Comme le montre la Figure 1, 5 attributs (parmi les 11 proposés) ont été rappelés dans tous les cas (pour tous les participants et pour tous les documents). Ces attributs sont : localisation, type de fichier ou format de document, moment de dernière utilisation, mots-clefs et événements associés. Les autres attributs n'ont pas été toujours rappelés (bien qu'ils fassent partie des attributs des documents).

Les résultats montrent également que tous les attributs sur lesquels ont été interrogés les participants ont un pourcentage de rappel élevé (ils concernent au minimum 70 % des documents) ce qui suggère que ces attributs sont de bons descripteurs des documents, du point de vue des participants.



**Figure 1. Pourcentages de documents pour lesquels chaque attribut a été rappelé**

Quand cela était possible, on a comparé les attributs exprimés avec les attributs effectivement présents dans les documents. Les attributs de documents à la fois exprimés et présents (dans la plupart des cas) ont été l'attribut "type de fichier ou format de document" et l'attribut "éléments visuels" ; la plupart des autres attributs étant moins ou partiellement robustes.

Le Tableau 1 synthétise les résultats concernant la qualité du rappel pour chaque attribut sauf pour les attributs Evénements associés, Liens et Opérations. Il est très difficile en effet de vérifier l'exactitude de ceux-ci car ils concernent les relations existant entre le document et son environnement (l'utilisateur, les tâches, les autres documents etc.), relations dont le système ne garde souvent aucune trace.

**Tableau 1. Pourcentages des documents pour lesquels le rappel concernant chaque attribut était totalement exact, partiellement exact, ou totalement faux.**

	Rappel totalement exact	Rappel partiellement exact	Rappel totalement faux
Localisation	36%	32%	32%
Type ou format	93,3%	3,3%	3,3%
Nom	25%	66,7%	8,3%
Titre	33,3%	46,7%	20%
Taille	15,4%	30,8%	53,8%
Moment	4,8%	47,6%	47,6%
Mots-clefs	32%	68%	0%
Éléments visuels	76,2%	23,8%	0%

On peut constater qu'un pourcentage très important de rappels d'attributs est en fait partiellement exact (e.g., attributs mots-clefs et nom), c'est-à-dire qu'une partie seulement des informations rappelées par les participants est exacte mais l'autre non ou bien l'information rappelée n'est pas précise.

On observe également que les rappels les moins robustes concernent les attributs taille et moment.

Un certain nombre de résultats qualitatifs ont par ailleurs été obtenus pour chacun des 11 attributs de documents.

Le détail des résultats quantitatifs et l'ensemble des résultats qualitatifs sont maintenant présentés pour chaque attribut.

### **5.2.1. Localisation**

Sur l'ensemble des 30 documents, 5 n'ont pas été retrouvés et n'ont donc pu faire l'objet d'une vérification du rappel. Les participants ont cependant toujours rappelé un emplacement même si celui-ci a pu se révéler incorrect. Pour les documents électroniques, le rappel consistait la plupart du temps à se souvenir du chemin exact dans l'arborescence de dossier jusqu'au dossier contenant le document en question. Pour les mails, les participants ont tenté de se rappeler la boîte contenant le message. Pour les pages web, il s'agissait de trouver le dossier des favoris contenant le pointeur ou de se rappeler des mots-clefs à taper dans un moteur de recherche. Pour les documents papiers, il s'agissait d'une localisation physique qui pouvait être plus ou moins précise (e.g., sur un bureau, dans une pile, dans une chemise, à tel page d'un cahier, etc.).

Sur les 25 documents, 9 ont fait l'objet d'un rappel totalement exact, c'est-à-dire de l'intégralité du chemin pour les documents électroniques et de l'emplacement précis pour les documents papiers. 8 ont fait l'objet d'un rappel partiellement exact c'est-à-dire qu'une partie seulement du chemin ou de la localisation a été correctement rappelée. Pour les documents électroniques, ce sont les cas où le début du chemin (le ou les premiers répertoires) était correct, mais pas la fin (le ou les derniers répertoires), c'est-à-dire que la fin du chemin comportait des erreurs (le nom du ou des dossiers ne correspondait pas exactement à celui ou ceux rappelés) ou bien, elle n'était pas rappelé du tout. Dans un cas seulement le contraire s'est produit : le participant a rappelé correctement le nom du dernier dossier et pas les autres. Ceci concernait par exemple, un répertoire situé sur un serveur dont l'arborescence n'avait pas été créée par l'utilisateur et dont le chemin devait être tapé avec des lignes de commande. Pour les documents papier, les rappels partiellement exacts étaient ceux pour lesquels une localisation était fournie (e.g., un carton, cahier, pile etc.) mais où l'emplacement à l'intérieur même de cette localisation n'était pas précisé. Enfin, il y a eu 8 faux rappels c'est-à-dire, des cas où l'emplacement donné par le participant était erroné, même si dans tous les cas sauf un, le début de la hiérarchie était juste pour les documents électroniques et que le document se trouvait effectivement dans la zone rappelée pour les documents papier (e.g., "dans la chemise rose, en deuxième, sous le CV de x", le document se trouvant effectivement dans la chemise désignée mais pas en 2<sup>e</sup> sous le CV de x).

### **5.2.2. Type ou Format**

Tous les participants ont été capables de désigner le type du document sauf un participant qui hésitait entre les formats PDF et WORD d'un document électronique et un participant qui pensait qu'un document était un article alors qu'il s'agissait en fait d'un livre.

### **5.2.3. Nom**

Sur 30 documents, 1 document n'a pu faire l'objet d'une vérification, car il n'a pas été retrouvé. 13 documents n'étaient pas, par nature, susceptibles d'être explicitement nommés : il s'agissait de tous les documents de type papier et de documents électroniques tels que les



mails et les pages web dont les noms n'apparaissent pas la plupart du temps aux utilisateurs. Parmi les documents ayant un nom explicite, 4 n'ont fait l'objet d'aucun rappel. Un seul document a fait l'objet d'un rappel qui ne correspondait pas du tout au véritable nom du document. Pour 8 documents, les noms ont été rappelés de manière partielle, c'est-à-dire que les participants ont été capables de fournir une sous partie du nom véritable (7 d'entre eux) ou bien que, parmi les mots qu'ils pensaient être inclus dans le nom, il y en avait qui y étaient effectivement (mais d'autres non). Notons enfin qu'il y a eu 3 documents pour lesquels les participants ont fait un rappel exact du nom.

#### **5.2.4. Titre**

Sur les 28<sup>1</sup> documents, 1 document n'a pu faire l'objet d'une vérification et 6 documents ne comportaient pas de titre (pour l'un d'entre eux le participant a cependant rappelé un titre). Sur les 21 restants, 6 n'ont suscité aucun rappel de la part de leur utilisateur. Soit le participant n'en avait aucun souvenir soit le participant pensait, à tort, qu'il n'avait pas de titre. Pour 3 documents, le titre rappelé n'avait aucun mot en commun avec le titre réel. Pour 7 documents, les participants se sont rappelés d'un ou plusieurs mots du titre (pour 4 documents) ou le titre qu'ils ont rappelé contenait un ou plusieurs mots du titre plus d'autres mots erronés (pour 3 documents). 5 titres de documents ont été rappelés parfaitement.

#### **5.2.5. Taille**

La taille des documents devait être exprimée en termes de pages, si possible. Cependant, de par leur nature, la taille de certains documents n'était pas exprimable en nombre de pages. La taille d'une page web a ainsi été évaluée en termes de pages-écrans, ce qui est approximatif puisque cela peut bien sûr dépendre de la résolution et de la taille de l'écran. La taille d'un programme informatique a été évaluée en termes de nombre de fichiers. Un document mail et un document *Excel* ont été évalués en termes de nombre de lignes de texte et de données.

Dans la plupart des cas, les participants étaient capables d'évaluer la taille de leurs documents.

Dans un peu moins de la moitié des cas (11 sur 26) les participants ont en fait répondu à la question en donnant un nombre exact alors que dans un peu plus de la moitié des cas (15 sur 26) ils ont fait une approximation. Les approximations étaient de différents types: le plus souvent les participants donnaient un chiffre rond accompagné d'une forme linguistique marquant l'approximation (e.g., "une 40aine de transparents", "environ 500 pages"), la deuxième approximation la plus utilisée était la spécification d'un intervalle (e.g. "entre 10 et 20 pages-écrans"). Trois autres formes ont été utilisées: l'expression de la limite inférieure (e.g., "au moins 2000 pages-écrans"), l'expression de la limite supérieure (e.g., "moins de 100 lignes") et enfin par un adjectif (e.g., "un mail très court").

Il y a eu à peu près autant de rappels totalement exacts (nombre exact rappelé correct) ou partiellement exacts (approximation rappelée correcte) que de faux rappels (nombre exact ou approximation faux). Pour les faux rappels, la marge d'erreur moyenne entre les estimations et la réalité était de 31,3 %.

Le rappel dépend beaucoup du caractère récurrent ou non du document. En effet, la proportion de rappels totalement exacts est bien plus importante pour les documents récurrents que pour les documents ponctuels. Le calcul du khi-carré prenant en compte les deux variables "type de document (récurrent vs. ponctuel)" et "exactitude du rappel

---

<sup>1</sup> Sur les 30 documents, 2 sont en fait les versions papier des documents électroniques, ce qui explique que le nombre à prendre comme total pour la plupart des attributs est de 28 et non de 30.

(totalement exact vs. pas totalement exact)" indique que ces deux variables sont dépendantes ( $X^2 = 7.94$ ,  $p < .001$ ).

### 5.2.6. Moment

Tous les participants ont tenté un rappel : aucun n'a dit ne pas se souvenir du tout de la date de dernière utilisation des documents sur lesquels il était interrogé. Les participants ont formulé à peu près autant de rappels partiellement exacts (approximation rappelée correcte) que de faux rappels (approximation rappelée fausse) concernant l'estimation du moment de dernière utilisation des documents (concerne uniquement les documents dont on a pu vérifier la date de dernière utilisation). Seul un participant a été capable de rappeler la date exacte au jour près.

Les dates ont été le plus souvent formulées sous forme de périodes exprimées en termes d'année, semestre, saison, mois, semaine, jour, demi-journée ou heure. Les périodes ont été très majoritairement formulées en termes de mois (e.g., "en février 2004"). La deuxième manière de donner une date était une estimation du temps écoulé par rapport au temps présent sous la forme "il y a ..." (e.g., "il y a deux mois", "il y a une quinzaine de jours").

Pour les documents récents et/ou récurrents, les estimations ont été faites davantage en termes de jour ou de semaine. À l'inverse, pour les documents plus anciens, les estimations étaient faites davantage en termes de mois. Il y a donc un rapport entre l'ancienneté du document et la précision du rappel. Plus précisément les documents utilisés il y a moins d'un mois étaient en général estimés en termes de semaine et de jour (e.g., "il y a 15 jours...donc c'était le 10 mars"; "il y a 15 jours trois semaines"). Les documents consultés entre un mois et un an avant étaient quant à eux davantage estimés en termes de mois.

Les erreurs commises l'ont été avec une marge d'erreur allant d'un jour à six mois, mais la plupart étaient inférieures à deux mois. Tous les faux rappels commis lors d'une estimation en termes de jour étaient faux à un jour près. Les écarts entre les estimations en termes de mois et la réalité allaient de deux semaines à deux mois. Une erreur a été commise lors d'une estimation en termes d'année : elle était fautive de 6 mois. L'écart entre le rappel et la réalité est donc proportionnel au degré de précision de l'estimation.

Le nombre de faux rappels n'est pas proportionnel à l'ancienneté de la dernière utilisation car plus le document est récent, plus la tentative de précision des participants augmente et donc moins la marge d'erreur est grande.

Les faux rappels sont plus fréquents chez les administratifs que chez les chercheurs tandis que les vrais rappels sont plus fréquents chez les chercheurs que chez les administratifs. Le calcul du khi-carré prenant en compte les deux variables "type de participant" et "exactitude du rappel" retourne une valeur non significative mais très proche de la valeur correspondant au seuil de significativité de 3.84 ( $X^2 = 3.83$ , NS ou  $p < .10$ ).

Autrement dit, les administratifs ont eu davantage de difficultés que les chercheurs à se rappeler la date ou la période correspondant à la dernière utilisation de leurs documents familiers. Ce résultat pourrait être expliqué par le fait que les documents gérés par les administratifs sont surtout des documents qui sont utilisés lors de procédures récurrentes (propres aux différentes fonctions de chaque administratif). Ces procédures routinières peuvent être plus difficiles à dater que des procédures ponctuelles liées à des événements particuliers qui sont quant à elles plus fréquentes pour les chercheurs (e.g., préparation d'un papier pour une conférence ayant eu lieu à telle date, transparents utilisés pour un cours donné à tel moment de l'année, etc.).

### **5.2.7. Mots-clefs**

3 documents seulement n'ont pas été pris en compte pour le rappel des mots-clefs. L'un d'eux parce qu'il n'a pas été retrouvé et qu'il n'y avait donc aucun moyen de vérifier l'exactitude du rappel des participants. Les deux autres parce qu'il s'agissait de documents dans lesquels il n'y avait pas de texte (un document ne contenant que des graphiques et un dossier contenant des fichiers d'un programme informatique).

Tous les autres documents ont fait l'objet d'un rappel contenant au moins un mot-clef effectivement présent dans le texte du document. La moyenne du nombre de mots-clefs exacts par document est de 3,24 et celle de mots-clefs faux est de 1,2. La moyenne du rapport entre le nombre de mots-clefs faux et le nombre de mots-clefs total est de 24 %. 8 rappels sur les 25 ne comportaient que des mots-clefs exacts.

Notons enfin que la proportion de mots-clefs rappelés faux est plus importante pour les documents anciens que pour les documents récurrents. Toutefois le khi-carré calculant la dépendance entre les deux facteurs n'est pas significatif même si il est très proche du seuil ( $X^2 = 3.68$ , NS ou  $p < .10$ ).

### **5.2.8. Éléments visuels**

Pour la majorité des documents (21 sur 28) les participants ont rappelé au moins un élément visuel effectivement présent dans le document. Sur les 53 éléments rappelés au total (tous documents confondus), seuls 5 n'étaient pas exacts.

Les différentes catégories d'éléments visuels rappelés étaient, du plus fréquent au moins fréquent, la couleur (e.g., "titre vert kaki, puces rouge bordeaux, fond blanc"; "couverture bleu ciel"), le format et la mise en page (e.g., "double colonne", "titre en gros", "table des matières"), la présence d'objets autres que du texte (graphiques, images, tableaux...) et des graphismes qui font partie de la mise en page (en-tête, bandeaux, traits...). D'autres caractéristiques visuelles parfois mentionnées ne concernaient que les documents papiers : les dimensions (e.g., estimation de la longueur des côtés et de l'épaisseur d'un livre), l'aspect (e.g., couverture "glacée et souple" d'un livre) et la présence d'annotations manuscrites. Une dernière manière de caractériser visuellement un objet qui a été observé était le fait de mentionner l'absence d'un élément attendu (e.g., absence de photo sur un CV).

Il est intéressant de noter que les caractéristiques rappelées ne se trouvaient pas forcément sur la première page du document. Parmi les descriptions de documents comportant plusieurs pages, 2 (sur 20) seulement ne comportaient que des éléments concernant la première page. Les autres rappels comportaient aussi des éléments compris dans les pages suivantes ou (dans 2 cas) ne comportaient que des éléments présents dans d'autres pages que la première page. En particulier, les rappels d'objets comportaient davantage d'objets situés dans les autres pages que sur la première page.

Les documents récents et/ou récurrents ont tous fait l'objet d'un rappel, ce qui n'est pas le cas des documents anciens. Le calcul du khi-carré prenant en compte les deux variables "type de document (ancien vs. récent/récurrent)" et "exactitude du rappel" indique que ces deux variables sont dépendantes ( $X^2 = 6.03$ ,  $p < .005$ ).

### **5.2.9. Événements associés**

Pour tous les documents, les participants ont été capables de rappeler au moins un événement concomitant à leur dernière utilisation. Sur l'ensemble de ces événements, 55,5% peut être mise en relation avec une "trace" électronique produite par le ou les événements du contexte. Par contre, 44,5% n'a produit aucune trace. Toutes les traces produites sont en fait des mails

reçus ou envoyés par l'utilisateur et qui sont liés aux buts de l'utilisation du document et correspondent pour la plupart à des échanges de mails avec des collaborateurs.

Un peu plus de la moitié des traces (mails) étaient encore présentes sur la machine des participants tandis qu'un peu moins de la moitié était absente, dans la plupart des cas parce que le participant les avait supprimés. Dans d'autres cas, ils ont été perdus lors du passage d'une machine à l'autre. Une troisième possibilité est que les mails étaient bien présents mais n'ont pas été retrouvés par l'utilisateur. Notons que la suppression des mails correspond à une stratégie de l'utilisateur consistant à effacer les mails correspondant à des affaires réglées pour "faire le ménage".

Les événements du contexte cités par les participants mais n'ayant pas laissé de traces étaient en premier lieu des communications directes (orales) ou téléphoniques entre le participant et des collaborateurs (proches ou non), des éditions ou des consultations de documents, un courrier (postal) et enfin des événements particuliers (e.g., refonte d'un site web, fin d'un projet, etc.)

### 5.2.10. Liens

Les utilisateurs ont, dans la majorité des cas, été capables de rappeler au moins un document lié au document principal. Seuls 3 documents sur 28 n'ont fait l'objet d'aucun rappel (après vérification, il s'est avéré que ces documents étaient en fait également liés à au moins un autre document, présent dans la machine du participant).

Sur l'ensemble des documents liés rappelés (N = 42), la majorité (N = 37) était effectivement présente dans le système pour les documents électroniques ou dans le bureau pour les documents papiers. Les documents rappelés étaient liés au document principal, le plus souvent parce qu'ils participaient à la même tâche ou au même type de tâche. La plupart des documents principaux (20 sur 25) avaient au moins un document lié rappelé dont le lien n'était pas seulement "abstrait" (i.e. de contenu ou de fonction) mais également "concret" (i.e. d'action ou de localisation) et donc potentiellement exploitables par un système.

Un bon nombre de documents liés rappelés partageaient la même localisation : dans le même dossier pour les documents électroniques et dans le même dossier ou pile pour les documents papier. Un autre type de lien assez souvent rencontré est le copier/coller (entrant ou sortant).

Les autres types de liens étaient le lien hypertexte (entrant ou sortant), la filiation (ascendante ou descendante), l'attachement (de type mail pour les documents électroniques ou de type trombone pour les documents papiers), le uploading (pas de cas de downloading observé mais n'est pas à exclure), l'historique de recherche de Google, l'insertion (documents électroniques) et le scanning, ainsi que la photocopie (documents papier).

### 5.2.11. Opérations

Pour la plupart des documents (24 sur 30) les participants ont rappelé au moins une action effectuée sur le document. L'action la plus fréquente était la modification du document. Pour un document créé par l'utilisateur lui-même, cela signifiait qu'il avait subi une modification notable après la création d'une version stable du document (il ne s'agit pas des modifications successives inhérentes à la création de tout document). Pour un document non créé par l'utilisateur, cela signifie que celui-ci a apporté ses propres modifications au document (e.g., le remplissage des champs d'un formulaire électronique, l'écriture d'annotations sur un document papier). Trois autres types d'actions assez fréquentes étaient l'impression (pour un document électronique), l'envoi et le déplacement (changement de l'emplacement du document). Les autres types d'actions rappelées marginalement par les participants étaient, pour les documents papiers, la photocopie, et pour les documents électroniques la mise en

ligne sur un site web, l'upload, la conversion (i.e. d'un document Word en PDF) et l'insertion (du document dans un autre document).

### **5.3.Phase de récupération des documents**

La méthode la plus utilisée par les participants pour retrouver leurs documents était, pour les documents électroniques, le parcours dans la hiérarchie des répertoires jusqu'au répertoire censé contenir le fichier cible puis la recherche visuelle du document cible parmi tous les documents du répertoire. Seul un participant a utilisé la fonction "rechercher" de son OS parce qu'il n'arrivait pas à retrouver le bon dossier.

En ce qui concerne les documents papiers, la méthode la plus classique était la localisation d'un endroit donné du bureau dans lequel le document était censé se trouver, puis la compulsions des différents documents présents à cet endroit pour retrouver le document cible. La recherche des documents comportait donc deux phases : une phase de localisation basée sur le rappel et une phase de compulsions basée sur la reconnaissance. Cette distinction est cohérente avec la proposition de Lansdale (1988) que chaque tentative de récupération d'informations implique deux processus psychologiques distincts : la recherche dirigée par le rappel (*recall-directed search*) suivie du balayage basé sur la reconnaissance (*recognition-based scanning*).

4 participants n'ont pas réussi à retrouver leurs documents (dont 3 documents papiers et 1 document électronique). Trois d'entre eux en ont conclu que le document n'était plus présent sur leur machine ou dans leur bureau. Un seul document (papier) susceptible d'être toujours présent dans le bureau n'a donc pas été retrouvé.

Sur les 26 documents retrouvés, 8 n'ont pas été retrouvés facilement dont 2 papiers et 6 électroniques. Dans la plupart des cas (5 sur 8) c'est la première phase qui posait problème : le participant cherchait dans le mauvais répertoire ou le mauvais emplacement.

Dans un cas, c'est la deuxième phase de recherche qui posait problème : le document cible se trouvait bien à l'endroit recherché, mais il devait être reconnu parmi de nombreux candidats (e.g. retrouver un mail dans un dossier). Dans un autre cas, les deux phases ont posé problème. Enfin dans un dernier cas, le participant ne cherchait ni au bon endroit ni le bon nom de fichier, ce qui a provoqué l'utilisation de la fonction rechercher.

## **6. Discussion et implications pour la conception**

Les résultats de la phase de récupération confirment le fait que les utilisateurs ont souvent des difficultés à retrouver leurs documents dans leur environnement actuel, avec les outils dont ils disposent.

De plus, il apparaît que les stratégies utilisées par les utilisateurs n'ont pas exploité la variété des attributs dont ils sont capables de se rappeler. Pour la première phase de recherche, la stratégie de recherche basée sur la localisation domine largement. Or nous avons vu que c'est cette phase qui semble poser le plus de problème. Cette phase étant basée principalement sur un processus cognitif de rappel, les résultats que nous avons recueilli concernant ce processus et les implications que l'on a pu en tirer sont donc susceptibles d'aider les utilisateurs à mieux retrouver leurs documents. Concernant la phase de reconnaissance, notre méthodologie ne nous a pas permis d'analyser précisément toutes les caractéristiques des documents qui peuvent avoir joué un rôle dans la reconnaissance de ceux-ci. Notons toutefois qu'elle semble principalement basée, pour les documents papier, sur l'apparence et, pour les documents électroniques, sur la reconnaissance du nom. Or si le nom remplace l'apparence pour la

reconnaissance des documents électroniques, nos résultats concernant le rappel de l'attribut "apparence" suggèrent au contraire la pertinence de cet attribut pour la phase de reconnaissance des documents électroniques, y compris les documents plutôt textuels. Nous pensons donc que la prédominance de la stratégie de reconnaissance du nom est davantage le résultat d'une contrainte imposée par les systèmes actuels que le reflet d'une préférence des utilisateurs.

Les résultats à la phase de récupération confirment également le fait que les outils de recherche sont très peu utilisés. Cela va dans le sens d'un besoin pour des outils de recherche plus performants pour la récupération des documents personnels.

Nos résultats aux sessions de rappel des attributs fournissent des recommandations potentielles sur la manière dont les différents attributs, susceptibles d'être mémorisés par les utilisateurs, pourraient être exploités par les systèmes de récupération de documents. La session de "rappel libre" ayant provoqué un taux de rappel faible quant au nombre d'attributs rappelés spontanément, ces recommandations proviennent principalement des implications des résultats à la session de "rappel indicé".

Notons que le fait que les participants aient rappelé peu d'attributs spontanément mais qu'ils soient capables d'en rappeler un grand nombre de manière indicée implique que l'interface des outils de recherche doit jouer un rôle incitatif en suggérant explicitement aux utilisateurs les attributs susceptibles d'aider à la récupération des documents.

Les implications et recommandations sont d'abord détaillées pour chaque attribut, puis nous présentons une synthèse de ces recommandations organisées en recommandations générales.

**Localisation :** Nous avons vu que les utilisateurs récupèrent leurs documents en se servant de leur localisation lorsqu'ils utilisent les systèmes de hiérarchie de répertoires qui sont sur leurs machines. Malgré cela, moins de la moitié des personnes interrogées ont mémorisé l'emplacement exact de leurs documents. Nos résultats rejoignent ainsi ceux de Jones et Dumais (1986), qui ont observé que les utilisateurs ont des difficultés à se souvenir de la localisation spatiale de documents (d'autant plus que le nombre de documents est important). L'ensemble de ces résultats semble impliquer que se souvenir de l'emplacement des documents n'est pas une méthode satisfaisante pour les retrouver.

Toutefois, nous avons vu que si les utilisateurs ont des difficultés à rappeler l'emplacement exact, ils parviennent à rappeler une partie c'est-à-dire le début de la hiérarchie pour les documents électroniques et un emplacement englobant l'emplacement exact pour les documents papiers. Une recommandation pour les systèmes d'aide à la récupération de documents pourrait donc être de permettre aux utilisateurs de définir un "périmètre" dans lequel ils pensent trouver le document, et non pas seulement la plus petite localisation contenant le document. Une application de cette recommandation pour les systèmes qui utilisent une hiérarchie de répertoires serait de permettre aux utilisateurs de visualiser tous les documents d'un dossier, y compris ceux qui sont dans des sous-dossiers.

**Type ou format :** Le type ou format est un attribut dont les utilisateurs se souviennent presque toujours correctement. Pour les documents électroniques, nous pensons que la raison en est que le type est étroitement lié à l'application que les utilisateurs ont utilisée pour créer, consulter ou modifier le document. Cette information est donc pertinente pour les utilisateurs à chaque fois qu'ils utilisent leurs documents. Le type se trouve ainsi être l'attribut le plus fiable au niveau du rappel et donc un des plus importants à prendre en compte pour la recherche de document. Toutefois les utilisateurs ne formulent pas seulement le type de leurs documents du point de vue du système mais également d'un point de vue sémantique de plus haut niveau (e.g., "une présentation PowerPoint", "un tableau Excel", "une image sous Word", "un ensemble de slides" etc.). Un outil de recherche devrait donc permettre de filtrer

et de trier les documents en utilisant ces catégories de plus haut niveau qui ont du sens pour l'utilisateur.

**Nom :** Peu d'utilisateurs parviennent à se souvenir du nom exact de leurs documents électroniques, mais un nombre important se souvient d'une partie du nom ce qui va dans le sens de l'évolution des outils de recherche qui permettent une recherche par mots contenus dans le nom et non pas seulement par le nom complet. Cette méthode semble d'autant plus pertinente que les cas de rappels partiels qui comprennent une séquence qui n'est pas dans le nom réel est rare. Or seul ce cas est réellement préjudiciable puisqu'il implique que le système ne retournera pas le document recherché.

Toutefois le nombre de fois où les utilisateurs ne se souviennent pas du tout du nom n'étant pas négligeable, un système ne permettant de lancer une recherche que par une partie ou l'ensemble du nom du fichier est à éviter et une alternative consistant à pouvoir lancer une recherche par mots du contenu (mots-clefs) paraît donc indispensable.

**Titre :** Il est intéressant de noter que la qualité du rappel est assez proche de celle du nom. Le titre d'un document pourrait donc être utilisé comme attribut de recherche aussi efficacement que le nom ou de manière complémentaire. Les titres des documents se situant sur la première page des documents, on pourrait imaginer que le système permette à l'utilisateur de spécifier des mots du contenu avec la condition qu'ils figurent sur la première page du document.

**Taille :** Le fait que les utilisateurs ont été le plus souvent capables de fournir un rappel sur la taille des documents suggère que l'attribut de taille exprimé en nombre de pages (ou de lignes) est pertinent pour l'utilisateur.

Toutefois, si les utilisateurs sont capables de fournir un rappel à propos de la taille de leurs documents, celui-ci n'est pas toujours précis ni exact. Pour qu'un système soit utile, il doit donc permettre d'afficher les résultats de la requête de l'utilisateur avec une certaine marge d'erreur.

Cela est de plus consistant avec le fait que les utilisateurs fournissent dans la moitié des cas une approximation plutôt qu'un chiffre exact. Les différents types d'approximation exprimées par les utilisateurs indiquent quels sont les différents modes de requête qui devraient être permis par le système (e.g., chiffre rond + marge d'erreur, intervalle, limite supérieure ou inférieure).

Comme l'écart entre le nombre rappelé et le nombre réel est proportionnel à la grandeur du nombre rappelé (la corrélation est positive :  $r(13) = .74$  ;  $p < .004$ ), une manière de tenir compte de la marge d'erreur serait de montrer les documents de la taille spécifiée en tenant compte d'un pourcentage d'erreurs qui peut être fixe. L'erreur moyenne entre le nombre rappelé et le nombre réel était dans notre cas de + ou - 37,8 % (du nombre rappelé), la marge d'erreur prévue par le système pour la présentation des documents pourrait par exemple être fixé à 35 %, ce qui aurait permis dans notre cas de recouvrir plus de la moitié des erreurs et d'inclure ainsi le bon fichier dans les résultats d'une requête des utilisateurs basée sur la taille.

**Moment :** Le fait que tous les utilisateurs aient eu une idée de la date de dernière utilisation de leurs documents suggère qu'ils sont susceptibles d'utiliser cet attribut assez naturellement pour la recherche de leurs documents.

Nous avons vu que très rares sont les cas où l'utilisateur parvient à se rappeler le moment d'utilisation d'un document avec une précision au jour près. Ce résultat indique donc qu'il n'est pas adapté de demander aux utilisateurs de spécifier la date exacte à laquelle il pense avoir utilisé le document. À l'inverse, il semble important de permettre à l'utilisateur de spécifier une période. La spécification d'un mois du calendrier étant la formulation la plus

utilisée, elle devrait être possible et facilement utilisable (e.g., occuper la première place sur la liste des filtres d'un moteur de recherche par exemple). Une autre possibilité devant être fournie à l'utilisateur est celle qui consiste à estimer le temps qui s'est écoulé entre l'utilisation du document et le temps présent. L'utilisateur doit également pouvoir s'exprimer avec différentes unités (mois, semaines, jours...) puisque différentes unités ont été utilisées pour le rappel en fonction du degré d'ancienneté de l'utilisation du document.

Toutefois, nous avons vu que le rappel des utilisateurs n'est pas fiable. Il faut donc permettre à l'utilisateur de visualiser les résultats de sa recherche avec un intervalle de confiance, c'est-à-dire en ne lui montrant pas uniquement les documents utilisés à la date spécifiée mais également ceux qui ont été utilisés un peu avant et un peu après. Comme la marge d'erreur est proportionnelle à la précision du rappel, si le rappel est exprimé en mois, le système devrait aussi présenter (ou rendre facilement visualisable) les documents qui ont été utilisés un mois avant ou un mois après. Si le rappel est exprimé en semaines, le système devrait montrer (ou rendre facilement visualisables) également les documents utilisés une semaine avant ou après.

Enfin il faut noter que cette marge d'erreur paraît d'autant plus nécessaire pour les utilisateurs qui exécutent des tâches routinières, lesquelles ne sont pas associées à des événements marquants et facilement datables mais qui reviennent périodiquement, à des dates variables. On peut ainsi recommander de laisser à l'utilisateur la possibilité ou non d'afficher les résultats de recherche avec ou sans marge d'erreur, en fonction de la confiance qu'il acquiert en ses rappels temporels au fur et à mesure des utilisations du système.

**Mots-clefs :** Les résultats montrent que la génération de mots du contenu par l'utilisateur est un outil très puissant pour la récupération de documents textuels puisque les utilisateurs sont toujours capables de se rappeler les mots qui sont réellement présents dans le document. Toutefois la probabilité qu'un mot-clef non présent dans le texte soit rappelé reste importante et peut ainsi être la source de résultats de requête non pertinents. Des solutions doivent être trouvées pour pallier ce problème. Nous proposons que l'utilisation de plusieurs mots lors d'une requête soit possible mais qu'ils puissent être saisis dans des champs d'entrée séparés pour faciliter l'activation/désactivation des mots isolément les uns des autres afin de permettre de nouvelles requêtes avec de nouvelles combinaisons en entrée si les résultats ne sont pas satisfaisants pour l'utilisateur.

**Éléments visuels :** Les résultats montrent que les utilisateurs se rappellent presque toujours d'éléments visuels présents dans leurs documents et qu'ils se trompent très rarement à ce sujet. Une présentation d'un aperçu de l'aspect du document lui-même, en plus de la simple présentation de l'icône correspondant au type du document apparaît donc pertinente pour faciliter la reconnaissance du document. Toutefois nous pensons que les systèmes ne doivent pas se limiter à la première page car nous avons vu aussi que les éléments visuels rappelés peuvent tout aussi bien concerner les autres pages d'un document. Certains documents de travail peuvent même être difficiles à discriminer les uns des autres par la première page car celle-ci est souvent standard (e.g., la première page d'un article scientifique). En revanche, les objets spécifiques à un document susceptibles de faciliter sa reconnaissance se trouvent souvent dans les autres pages. Les utilisateurs devraient donc avoir facilement accès à la visualisation de toutes les pages d'un document. On peut par exemple imaginer que la vignette d'aperçu d'un document soit accompagnée de boutons de navigation de type page précédente - page suivante (ou que les pages se mettent à défiler à l'approche de la souris) pour que l'utilisateur puisse visualiser l'ensemble du document.

**Évènements associés :** Les résultats relatifs au rappel des événements associés montrent que la possibilité d'exploiter le contexte pour la récupération des documents est limitée par le fait



que beaucoup d'évènements liés à l'utilisation du document ont lieu en dehors du système, ce qui rend leur exploitation quasiment impossible.

Les seules traces d'évènements qui sont présentes dans le système sont les mails. Or dans les systèmes actuels, les mails restent encapsulés dans les applications de messagerie et donc "coupés" des autres documents. Pour que les mails puissent aider à la récupération de documents qui leur sont liés, nous pensons que leur organisation doit être davantage liée à celle des autres documents. De plus le stockage des mails comme évènements liés à d'autres documents devrait être séparé du stockage standard des mails pour ne pas que les traces de ces évènements disparaissent en même temps que la suppression d'un mail par l'utilisateur pour "faire du ménage".

**Liens :** La capacité des utilisateurs à rappeler de manière pertinente la présence dans leur système de documents liés au document recherché encourage leur utilisation pour la récupération de documents. En effet il est possible qu'un utilisateur puisse se rappeler davantage de choses à propos d'un document lié (son emplacement par exemple) que du document recherché lui-même. Si le système permet la restitution automatique des documents liés à un autre document, alors le document cible pourrait être récupéré facilement.

Le fait que les documents liés entre eux participent à la même tâche ou au même type de tâche suggère que l'organisation des documents par rapport aux tâches auxquels ils participent peut être un premier moyen de faciliter leur récupération comme l'ont déjà postulé certains auteurs (e.g., Kaptelinin, 2003).

Mais nos résultats montrent également que les documents sont liés par des actions effectués les uns sur les autres. Ces actions sont effectuées via le système pour les documents électroniques et sont donc potentiellement enregistrables et réutilisables par le système pour restituer les liens existants. Les résultats de notre étude fournissent déjà la liste d'un certain nombre d'actions qui pourrait être exploitées par le système pour la restitution des liens entre documents.

**Opérations :** Les utilisateurs parviennent en majorité à rappeler au moins une action effectuée sur leur document et notre étude fournit une liste des différentes actions qui pourrait être utilisées comme attributs pour retrouver un document. L'action de modification est déjà utilisée en partie par les systèmes actuels avec l'attribut "*date de dernière modification*". Notre étude montre que d'autres attributs seraient utiles. Par exemple, un utilisateur pourrait demander au système de lui montrer tous les documents d'un certain type qu'il a imprimé.

Les différentes recommandations présentées pour chaque attribut peuvent être synthétisées selon quelques dimensions générales :

**- Favoriser les attributs appropriés**

Les attributs qui sont les plus souvent et/ou les mieux rappelés, c'est-à-dire la localisation, le type ou format, le moment de dernière utilisation, les mots-clefs, les évènements associés et les éléments visuels, devraient être utilisés en priorité dans les outils de recherche.

**- Favoriser les expressions appropriées :**

- **Expression du temps :** les moyens d'exprimer le moment de dernière utilisation les plus utilisés sont : la spécification d'une période (un mois dans la plupart des cas, e.g., "en février 2004") et l'information relative au temps écoulé (e.g., "il y a deux mois"). Ces moyens d'expressions doivent donc être permis par les systèmes de recherche.

- **Expression de la taille** : les adverbes d'approximation (e.g., "environ 500 pages") et les intervalles (e.g., "entre 10 et 20 pages") sont les moyens d'expression les plus employés par les utilisateurs et devraient donc être permis par les outils de recherche.
- **Prévoir de la flexibilité dans les requêtes**
  - **Flexibilité des requêtes textuelles** : le fait que les utilisateurs sont capables de rappeler des mots-clefs de leurs documents encourage l'utilisation de moteurs de recherche. Mais les moteurs de recherche devraient prendre en compte le fait que les utilisateurs ne rappellent pas seulement des mots-clefs exacts mais aussi des mots-clefs erronés pour le même document (e.g., permettre l'utilisation de plusieurs champs de requête textuelle avec des options d'activation/désactivation pour chaque champ, fournir des suggestions pour des synonymes et des hyperonymes etc.). De même, les utilisateurs se souvenant souvent de parties des noms et des titres des fichiers, les systèmes devraient autoriser la recherche par parties (du nom, du titre).
  - **Flexibilité pour la taille** : fournir différents types d'unités de taille (e.g., nombre de pages, nombre de lignes etc.) et différents moyens d'exprimer les approximations (e.g., "entre ... et ... pages"; "environ ... pages" etc.) pour s'adapter à la variabilité des expressions des utilisateurs.
  - **Flexibilité pour le temps** : fournir différents types d'unités de temps (e.g., année, mois, semaine etc.) et différents moyens d'exprimer les approximations (e.g., "il y a..."; "durant la période de..." etc.) pour s'adapter à la variabilité des expressions des utilisateurs.
- **Permettre l'extensibilité des résultats** :
  - **Extensibilité de la localisation** : étant donné que les utilisateurs se rappellent plus facilement des dossiers parents que des derniers sous-dossiers contenant effectivement le document recherché, fournir une visualisation pour étendre la vue classique du contenu des répertoires (e.g., fichiers cachés dans les sous-dossiers, etc.).
  - **Extensibilité du temps** : le système devrait fournir des moyens d'étendre les résultats de la première estimation exprimée par les utilisateurs étant donné que leur rappel est souvent approximatif (e.g., si l'utilisateur spécifie une période d'un mois le système devrait permettre de visualiser facilement aussi les fichiers qui ont été utilisés durant les mois adjacents).
  - **Extensibilité de la taille** : étant donné que le rappel des utilisateurs est souvent approximatif, le système devrait donner la possibilité de visualiser aussi les fichiers qui ont plus ou moins la même taille que celle spécifiée (nos résultats suggèrent qu'une tolérance à l'erreur d'environ 35% serait souhaitable).
- **Fournir des visualisations du contenu des documents** :

Autoriser la recherche manuelle ou automatique des éléments qui sont inclus dans le document (pas seulement ceux de la première page), par exemple, fournir des aperçus des documents permettant la recherche de graphiques, images etc. sur toutes les pages.
- **Exploiter les relations explicites entre les documents** :

Étant donné que les utilisateurs sont capables de se rappeler de documents associés au document recherché, les systèmes devraient être capables d'enregistrer ces associations pour que l'utilisateur puisse retrouver un document en partant d'un document associé déjà retrouvé (e.g., permettre la récupération d'un fichier en montrant les relations de copier/coller entre les fichiers; réduire la distance entre les systèmes d'organisation des fichiers et des mails pour faciliter l'exploitation de leurs relations pour la récupération).
- **Fournir les logs de certaines opérations effectuées sur les documents** :

Etant donné que les utilisateurs sont capables de se rappeler des opérations qu'ils ont effectuées sur un document, autres que l'ouverture et la modification, les systèmes devraient être capables d'enregistrer ces opérations et de permettre leur utilisation, combinée à d'autres attributs de fichiers, pour la récupération de fichier (e.g., recherche d'un document imprimé en Février).

**- Permettre la combinaison semi-automatique d'attributs :**

La conception d'outils de récupération de documents pourrait exploiter le fait que le rappel de certains attributs dépend de la récence ou fréquence d'utilisation du document. Le système pourrait encourager certaines associations d'attributs durant la spécification de la recherche et en décourager d'autres. Par exemple, si l'utilisateur spécifie une date de dernière utilisation relativement ancienne (e.g., plus de six mois), le système pourrait suggérer d'enrichir la recherche avec les attributs dont le rappel n'est pas dépendant du temps (e.g., type, nom, localisation etc.) par opposition à ceux dont le rappel se détériore avec le temps écoulé.

## **7. Conclusion**

Nos résultats indiquent que les attributs le plus rappelés, c'est-à-dire ceux qui ont été rappelés pour le plus grand nombre de documents, sont : la localisation, le type de document ou format du fichier, le moment de dernière utilisation, les mots-clefs et les événements associés.

En effet, ces attributs ont fait l'objet d'un rappel par les participants pour tous les documents (mais cela ne signifie pas que le rappel était toujours exact).

Le contenu est le seul attribut qui a toujours donné lieu à un rappel de la part des participants et le rappel contenait toujours au moins un élément (i.e. un mot) effectivement présent dans le document. Cela signifie que les utilisateurs ont les capacités de trouver grâce au rappel du contenu un sous-ensemble de leur document dans lequel se trouvera le document recherché sur lequel il pourra appliquer des filtres pour affiner sa recherche. Ce résultat va dans le sens de l'utilisation de moteur de recherche par le contenu, mais à la condition que l'interface permette à l'utilisateur de combiner plusieurs mots-clefs car nos résultats montrent également que les utilisateurs peuvent rappeler des mots qui ne sont pas dans le document.

D'autre part, les attributs qui sont rappelés avec le moins d'erreurs par les participants sont le type de document ou format du fichier et les éléments visuels ce qui indique qu'ils devraient être utilisés en premier lieu pour filtrer les documents et/ou aider à leur reconnaissance. (e.g., mettre l'attribut Type ou format en premier dans liste des filtres; fournir des aperçus des documents textuels extensibles à toutes les pages).

Ces résultats vont en partie dans le sens de ceux de Dumais et al. (2003) qui observent que les filtres les plus utilisés dans leur outil de recherche (outre l'entrée textuelle) (*SIS*) sont le type de fichier puis la date. Mais nos résultats montrent également que la localisation, les événements associés et les éléments visuels sont également très importants.

Les résultats montre également comment les différents attributs que l'utilisateur est capable de rappeler devraient être exploités pour être utilisables. Le système devrait d'une part, permettre à l'utilisateur de les formuler selon la forme et le degré de précision avec lesquels il se les rappellent. D'autre part, le système devrait tenir compte de la nature peu fiable mais prévisible du rappel dans les résultats qu'il retourne en incluant une marge d'erreur dans les résultats ou en permettant à l'utilisateur de modifier facilement les paramètres de l'attribut.

Les résultats fournissent également des pistes pour exploiter le fait que le rappel de certains attributs peut dépendre d'une part, du type d'utilisateur et d'autre part, de la fréquence d'utilisation des documents.

Enfin, ils encouragent à développer l'enregistrement par le système des attributs qui concernent les interactions entre le document et son environnement comme le contexte, les liens et les traitements et elle montre qu'elles sont les types précis d'interactions qu'il serait pertinent d'enregistrer.

Notre étude comporte cependant un certain nombre de limites : elle ne permet pas vraiment de dégager un ordre strict d'importance des attributs entre eux ; quand on demande aux sujets de dire ce dont ils se souvenaient à propos de leurs documents, peu de choses étaient rappelées spontanément, la plupart des attributs rappelés ont donc été induits par l'expérimentateur ce qui limite nos résultats aux attributs que nous avons jugés importants.

Il serait donc intéressant de proposer une méthodologie permettant d'avoir une proportion plus élevée de rappel spontané. Gonçalves et Jorge (2004) ont par exemple demandé aux utilisateurs de "raconter l'histoire" de leurs documents ce qui a provoqué un rappel spontané de davantage d'attributs (sur l'ensemble des histoires, 17 attributs différents ont été recensés) que notre question ouverte. Notons que l'un des attributs les plus rappelés dans leur étude, le but du document, ne fait pas partie de nos résultats pour des raisons méthodologiques<sup>2</sup>. L'attribut "auteur" du document aurait également pu faire partie de notre liste pour la session de rappel indicé. En effet une information relative à un auteur a été évoquée pour un document lors de la phase de rappel libre et l'auteur des documents (outre les documents créés par l'utilisateur lui-même) était la plupart du temps évoqué par l'utilisateur de manière spontanée lors des autres phases.

Nous pensons que l'application des recommandations que nous avons dégagées à la conception des outils de récupération des documents peut aider les utilisateurs à mieux retrouver leurs fichiers. Toutefois des études sont nécessaires pour tester l'utilisabilité et l'utilité de nouveaux systèmes dont la conception serait basée sur ces recommandations, par rapport aux systèmes actuels. Les outils de recherche basés sur une entrée textuelle, l'application de filtres correspondant à des attributs et le groupement des résultats par attributs, est un exemple d'outils sur lesquels ces recommandations pourraient s'appliquer car ils exploitent une variété d'attributs et de moyens d'interactions rendant leur utilisation complexe. Mais d'autres outils conçus autour de l'exploitation d'un attribut en particulier (e.g., les outils montrant les documents utilisés sur une ligne de temps) pourraient également bénéficier des recommandations spécifiques concernant l'attribut sur lesquels ils reposent (e.g., le temps).

Notons enfin que la manière dont les utilisateurs parviennent à se rappeler des attributs n'est pas la seule dimension à prendre en compte pour déterminer leur utilisation dans les outils de recherche. La capacité relative des attributs à permettre de discriminer les documents entre eux et de formuler des requêtes retournant le moins d'items possible est une dimension aussi importante à étudier et à prendre en compte pour la conception d'outils de recherche performant.

---

<sup>2</sup> La sélection des documents sur lesquels portait notre quasi-expérience se faisait, lors de l'interview semi-dirigée, à partir de l'évocation des tâches de l'utilisateur. Les buts des documents au sein des tâches étant rappelés de manière implicite durant cette phase, ils ne pouvaient faire l'objet d'un rappel ultérieur objectif.

## **8. Bibliographie**

- Adar, E., Kargar, D. and Stein, L. A. (1999). Haystack: per-user information environments. In *Proceedings of the eighth international conference on Information and knowledge management*, 413-422.
- Barreau, D. and Nardi, B. (1995). Finding and Reminding: File Organization from the Desktop. *SIGCHI Bulletin*, 27(3), 39-43.
- Bellotti, V., Ducheneaut, N., Howard, M., Smith, I. and Neuwirth, C. (2002). Innovation in extremis: evolving an application for the critical work of email and information management. In *Proceedings of the conference on Designing interactive systems*, 181-192.
- Boardman, R. (2004). *Improving Tool Support for Personal Information Management*. PhD Dissertation. Imperial College, London.
- Czerwinski, M., van Dantzich, M., Robertson, G. G. and Hoffman, H. (1999). The contribution of thumbnail image, mouse-over text and spatial location memory to web page retrieval in 3D. In *Proceedings of Interact '99*, 163-170.
- Dourish, P., Edwards, W. K., LaMarca, A. and Salisbury M. (1999). Presto: an experimental architecture for fluid interactive document spaces. *ACM Transactions on Computer-Human Interaction (TOCHI)*, 6(2), 133-161.
- Dumais, S. T., Cutrell, E., Cadiz, J. J., Jancke, G., Sarin, R. and Robbins, D. C. (2003). Stuff I've Seen: A system for personal information retrieval and re-use. In *Proceedings of SIGIR' 03*, 72-79.
- Dumais S. T. and Jones W. P. (1985). A comparison of symbolic and spatial filing. In *Proceedings of the SIGCHI conference on Human factors in computing systems*, 127-130.
- Fertig, S., Freeman, E. and Gelernter, D. (1996). "Finding and reminding" reconsidered. *ACM SIGCHI Bulletin*, 28(1), 66-69.
- Freeman E. and Gelernter D. (1996). Lifestreams: a storage model for personal data. *ACM SIGMOD Record*, 25(1), 80-86.
- Gonçalves, D. and Jorge, J. A. (2004). Describing documents: what can users tell us? In *Proceedings of the 9th international conference on Intelligent User Interfaces*, 247-249.
- Jones, W. P. and Dumais, S. T. (1986). The Spatial Metaphor for User Interfaces: Experimental Tests of Reference by Location versus Name. *ACM Transactions on Office Information Systems*, 4(1), 42-63.
- Jones, W. P., Dumais, S. and Bruce H. (2002). Once found, what next?: A study of "keeping" behaviors in the personal use of web information. In *Proceedings of ASIST 2002*, 391-402.
- Kaptelinin, V. (2003). Umea: Translating interaction histories into project contexts. In *Proceedings of the SIGCHI conference on Human factors in computing systems*, 353-360.

- Lansdale, M. W. (1988). The psychology of personal information management. *Applied Ergonomics*, 19(1), 55-66.
- Lansdale, M. W. (1991). Remembering about documents: memory for appearance, format, and location. *Ergonomics*, 34(8), 1161-1178.
- Lansdale, M. W., Simpson, M. and Stroud, T. R. M. (1990). A Comparison of Words and Icons as External Memory Aids in an Information Retrieval Task. In *Behaviour and Information Technology*, 9(2), 111-131.
- Malone, T. W. (1983). How do people organize their desks?: Implications for the design of office information systems. *ACM Transactions on Information Systems (TOIS)*, 1(1), 99–112.
- Marsden, G. and Cairns, D. E. (2003). Improving the Usability of the Hierarchical File System, *Proceedings of SAICSIT 2003*, 122-129.
- Ravasio, P., Schär, S. G., and Krueger, H. (2004). In pursuit of desktop evolution: User problems and practices with modern desktop systems. *ACM Transactions on Computer-Human Interaction*, 11 (2), 156-180.
- Whittaker, S. Terveen, L. and Nardi, B. A. (2000). Let's stop pushing the envelope and start addressing it: a reference task agenda for HCI. *Human Computer Interaction*, 15 (2-3), 75-106.