



Thèse en Cotutelle



Entre :

Université Mentouri de Constantine
Faculté des sciences de l'ingénieur
Laboratoire de Recherche en Informatique Répartie
Département d'Informatique

Université Claude Bernard Lyon1
Laboratoire d'InfoRmatique en Image et Systèmes
Ecole Doctorale Informatique et Mathématiques

Spécialité Informatique

Présentée par
Mme Yahiaoui Leila

Pour obtenir le grade de
Docteur de l'Université Claude Bernard Lyon1
et
Docteur de l'Université Mentouri Constantine

Sujet de la thèse

Redocumentation des traces d'utilisation d'un environnement informatique

Composition du Jury

Président :

- Nacereddine Zarour, Professeur des universités, Université de Constantine.

Directeurs de thèse :

- Zizette Boufaida, Professeur des universités, Université de Constantine.
- Yannick Prié, Maître de conférences HDR, Université Claude Bernard Lyon1.

Rapporteurs :

- Serge Garlatti, Professeur des universités, Telecom Bretagne.
- Mohamed Tarek KHADIR, Professeur des universités, Université de Annaba.

Examineur :

- Manuel Zacklad, Professeur des universités, Conservatoire National des Arts et Métiers (CNAM).

Année 2011-2012

Remerciements

A Djamel et Amira

Je tiens à remercier, tout d'abord, mes directeurs de thèse :

Monsieur **Yannick Prié**, HDR à l'université Lyon1, à qui je dois énormément dans cette thèse, pour ses conseils et ses critiques, pour ses orientations de recherche, pour le temps et la confiance qu'il m'a accordés, pour son soutien durant les moments les plus difficiles, pour sa patience et ses encouragements sans lesquelles je n'aurais jamais pu réaliser ce travail. Sincèrement, je lui dis mille merci d'avoir pu être, à la fois, un ami et un directeur de thèse.

Madame, **Zizette Boufaïda**, professeur à l'université de Constantine, qui m'a fait découvrir le domaine de la recherche scientifique et qui m'a soutenu tout au long de mon parcours, pour son aide, pour ses encouragements et ses conseils, pour la confiance qu'elle m'a toujours accordée, pour son enthousiasme, pour la disponibilité dont elle a su faire preuve malgré ses responsabilités. J'espère qu'elle trouvera dans ce travail de thèse l'expression de ma profonde gratitude.

Merci à tous les membres du jury qui m'ont fait l'honneur de bien vouloir évaluer mon travail : Pr. Nacereddine Zarour de l'université de Constantine, Pr. Serge Garlatti de Telecom Bretagne, Pr. Manuel Zacklad du CNAM et Pr. Mohamed Tarek KHADIR, Professeur des universités, université de Annaba.

Un grand merci à mon laboratoire LIRE et tous les membres de mon équipe de recherche SIBC ainsi qu'au laboratoire LIRIS qui m'a accueilli et tous les membres de l'équipe SILEX qui m'ont aidé à la réalisation de mon travail de thèse, et tout particulièrement à Mille Alain qui a accepté au début d'être mon directeur de thèse officiel et qui m'a souvent aidé, à Pierre-Antoine Champin pour ses orientations et ses critiques qui m'ont permis d'améliorer mes propositions théoriques et pratiques et à Damien Cram pour son soutien moral et son aide précieuse.

Je remercie également Monsieur Manuel Zacklad, directeur du Conservateur National des Arts et Métiers (CNAM), avec qui les discussions m'ont permis de situer et de raffiner mes propositions théoriques.

Du fond du cœur, je remercie tous mes proches pour leur soutien : mes parents, mon mari, mes frères et sœurs ainsi que ma petite fille Amira.

Résumé

Nos activités sont devenues de plus en plus supportées par des systèmes informatiques. La documentation de celles-ci est souvent assurée par l'ensemble des fichiers traces générés automatiquement suite à l'interaction des utilisateurs avec les systèmes informatiques utilisés. Cependant, la qualité de ces documents traces n'est pas suffisante si l'on souhaite décrire l'activité dans toute sa richesse, tout en assurant la lisibilité et la compréhensibilité de cette description pour une personne non forcément qualifiée. Notre objectif est en effet d'utiliser ce produit de la documentation de l'activité pour des échanges avec soi-même (mémoire et réflexivité) ou avec d'autres personnes (analyse de comportement et partage d'expérience). Cette thèse d'ingénierie des connaissances a pour objet la redocumentation de l'activité médiée informatiquement à base de ses traces. Au cours d'un tel processus, un utilisateur interprète et réécrit les traces dans un nouveau document, qui correspond à un genre particulier et décrit l'activité dans toute sa richesse ; il a notamment la possibilité de reformuler le contenu des traces, de l'enrichir avec d'autres informations (justification ou informations sur le contexte), de supprimer des parties, etc. Il s'agit ainsi de renforcer le statut documentaire des traces selon les trois dimensions de la lisibilité, de l'intelligibilité et de l'échange.

Nous proposons une approche générique semi-automatique qui combine le contenu de traces de l'activité et les connaissances des utilisateurs dans des formes narratives, facilement échangeables, décrivant l'activité de façon personnalisée pour les utilisateurs. Celle-ci utilise des modèles formels pour les traces et les documents produits, ainsi que les principes de la théorie de la structure rhétorique (RST). Elle soutient la redocumentation à travers deux phases : une phase automatique pour générer un document initial fragmenté à partir de la trace d'activité comme une première description pour celle-ci et une phase interactive pour personnaliser cette description selon les besoins et les choix d'un utilisateur afin de produire un document. Nous proposons également la spécification de cette approche pour le cas particulier de la redocumentation par le texte et nous présentons ActRedoc, un outil auteur que nous avons développé pour implémenter cette approche spécifique en utilisant différentes technologies du Web Sémantique. Les résultats de notre travail ont été testés dans un environnement réel qui est celui de la redocumentation des traces de navigation dans un site d'archives de journaux du XIX^{ème} développé par la bibliothèque municipale de Lyon. Nous présentons ainsi les résultats d'une première évaluation de l'approche de redocumentation en texte et de l'outil ActRedoc auprès d'un groupe d'utilisateurs.

Mots-clés : *trace d'activité informatique, document numérique, modèle de trace, modèle de document, processus de redocumentation, RST, outil auteur.*

Abstract

Our activities are becoming more and more computer-mediated ; whereas the documentation of these activities is usually insured by the set of traces files generated automatically from the interaction of users with the used computer systems. However, the quality of these traces is not sufficient if we wish to describe the computer-mediated activity with all its details and insuring the legibility and the comprehensibility of this description for a person not necessarily qualified. Indeed, we wish to use this product of the activity documentation for exchanges with itself (for memory or reflexivity) or with other persons (for behavior analysis or experience sharing). This thesis is situated within the framework of knowledge engineering ; it is particularly interested in the redocumentation of the computer-mediated activity from its traces. We suppose that during such a process, a user interprets and rewrites traces in a new document that corresponds to a particular genre and describes the traced activity in détails ; all this via the possibility to rewrite traces content, to enrich this content with other information (justifications or information on the context), to delete parts from it, etc. Therefore, we strengthen the documentary status of traces according to the three dimensions of legibility, comprehensibility and exchange.

For implementing such a process, we propose a generic semi-automatic approach which combines the content of activity traces with users knowledge in narrative forms, easily exchangeable, to describe the traced activity in a personalized way for users. This Approach uses formal models for traces and documents (produced), as well as principles of the rhetorical structure theory (RST). It supports the redocumentation process through two phases: an automatic phase to generate an initial fragmented document from traces as a first description of the activity and an interactive phase to personalize this description according to the user needs and choices so that to produce an easily exchangeable document. We also propose a specification of this approach for the particular case of redocumentation by text and we present ActRedoc, an authoring tool that we developed by using different technologies of the Semantic Web in order to implement this specific approach. The results of our work were tested in a real environment which concerns redocumenting the activity of browsing a site of archives of newspapers of the XIXth century developed by the municipal library of Lyon. Thus, we present a first evaluation of the approach of redocumentation by text and of the authoring tool ActRedoc by a group of users.

Keywords: *Computer-mediated activity trace, digital document, trace model, document model, redocumentation process, RST, authoring tool.*

Table des matières

TABLE DES FIGURES.....	4
TABLE DES TABLEAUX.....	6
INTRODUCTION GENERALE	7

Première partie : Problématique et état de d'art

CHAPITRE 1: CONTEXTE ET PROBLEMATIQUE : REDOCUMENTER L'ACTIVITE INFORMATIQUE	12
1.1 INTRODUCTION.....	12
1.2 ETAT DE L'ART SUR LA (RE)DOCUMENTATION	13
1.2.1 <i>Le document</i>	13
1.2.2 <i>La documentation</i>	14
1.2.3 <i>De la documentation à la documentarisation</i>	16
1.2.4 <i>De la documentarisation à la redocumentarisation</i>	17
1.2.5 <i>La redocumentation, un nouveau concept</i>	19
1.3 UN CADRE THEORIQUE POUR LA REDOCUMENTATION	20
1.3.1 <i>La théorie des transactions communicationnelles (TC)</i>	20
1.3.2 <i>La redocumentation dans le cadre des TCs</i>	21
1.4 LA DOCUMENTATION DE L'ACTIVITE	23
1.4.1 <i>Définition</i>	23
1.4.2 <i>Le lifelogging comme un système de documentation de l'activité informatique</i>	23
1.4.3 <i>La documentation de l'activité informatique</i>	25
1.5 REDOCUMENTER L'ACTIVITE INFORMATIQUE.....	26
1.5.1 <i>Définition de la redocumentation de l'activité informatique</i>	27
1.5.2 <i>Une vue générale du processus de redocumentation</i>	27
1.5.3 <i>Exemples d'application du processus</i>	28
1.5.4 <i>Questions posées par la redocumentation de l'activité</i>	28
1.6 CONCLUSION	30
CHAPITRE 2 : LA TRACE D'ACTIVITE NUMERIQUE ET SON UTILISATION.....	32
2.1 INTRODUCTION	32
2.2 LA NOTION DE TRACE D'ACTIVITE INFORMATIQUE	33
2.2.1 <i>Notion de trace</i>	33
2.2.2 <i>Notion de trace d'activité numérique</i>	34
2.3 UTILISATION DES TRACES D'ACTIVITE NUMERIQUES	36

2.3.1	<i>Les systèmes traçants</i>	37
2.3.2	<i>Les traces d'activité numériques comme support d'analyse</i>	39
2.3.3	<i>Les traces numériques comme support d'aide à l'activité</i>	45
2.4	SBT : UN CADRE POUR L'INGENIERIE DE LA TRACE D'INTERACTION	48
2.4.1	<i>Notion du système à base de traces modélisées (SBTm)</i>	48
2.4.2	<i>Modélisation formelle de la trace dans le SBTm</i>	49
2.4.3	<i>Architecture et services du SBTm</i>	50
2.4.4	<i>Travaux autour des SBTs</i>	51
2.5	CONCLUSION	56
CHAPITRE 3 : LE DOCUMENT NUMERIQUE : MODELISATION ET CONSTRUCTION		58
3.1	INTRODUCTION.....	58
3.2	LA NOTION DE DOCUMENT NUMERIQUE	59
3.2.1	<i>La notion de document</i>	59
3.2.2	<i>Le document dans son passage au numérique</i>	59
3.2.3	<i>Classification des documents numériques</i>	63
3.3	LA MODELISATION DU DOCUMENT NUMERIQUE	63
3.3.1	<i>Les structures du document numérique</i>	64
3.3.2	<i>Documents multi-structurés</i>	65
3.4	LA CREATION DE CONTENU DE DOCUMENT NUMERIQUE.....	67
3.4.1	<i>Le statut de l'auteur dans le contexte numérique</i>	68
3.4.2	<i>De l'édition à l'authoring du document numérique</i>	68
3.4.3	<i>RST: une théorie de base pour les outils auteur</i>	71
3.4.4	<i>Des exemples d'outils auteurs</i>	73
3.5	L'AUTHORING AU SERVICE DU STORYTELLING	76
3.5.1	<i>Le storytelling dans le contexte numérique</i>	77
3.5.2	<i>Les approches d'authoring d'histoires</i>	79
3.5.3	<i>Le storytelling appliqué aux lifelogs</i>	80
3.6	CONCLUSION	82

Deuxième partie : Contributions

CHAPITRE 4 : UNE APPROCHE SEMI-AUTOMATIQUE ET NARRATIVE POUR LE PROCESSUS DE REDOCUMENTATION.....		85
4.1	INTRODUCTION	85
4.2	NOTRE APPROCHE : OBJECTIFS ET CHOIX	86
4.3	UN CADRE GENERAL POUR LE PROCESSUS DE REDOCUMENTATION	87
4.3.1	<i>La modélisation de la trace d'activité</i>	87

4.3.2	<i>La modélisation du document produit</i>	91
4.3.3	<i>Un processus de redocumentation en deux phases</i>	93
4.4	UNE SPECIFICATION DU CADRE GENERAL POUR UNE REDOCUMENTATION EN TEXTE	96
4.4.1	<i>La phase de redocumentation automatique en texte</i>	96
4.4.2	<i>La phase de redocumentation interactive en texte</i>	99
4.5	CONCLUSION ET DISCUSSION.....	103
CHAPITRE 5: ACTREDOC, UN OUTIL AUTEUR DE REDOCUMENTATION EN TEXTE.....		105
5.1	INTRODUCTION	105
5.2	UN EXEMPLE D'ACTIVITE A REDOCUMENTER : LA NAVIGATION DANS LA « PRESSE ILLUSTRÉE »	105
5.2.1	<i>Présentation de l'application « Presse Illustrée »</i>	106
5.2.2	<i>Le traçage de l'activité de navigation dans la « Presse Illustrée »</i>	109
5.2.3	<i>La modélisation des traces de l'activité de navigation dans la « Presse Illustrée »</i>	112
5.3	ARCHITECTURE ET FONCTIONNEMENT DE L'OUTIL DE REDOCUMENTATION EN TEXTE ACTREDOC	114
5.3.1	<i>L'ontologie de trace</i>	115
5.3.2	<i>L'ontologie de document</i>	115
5.3.3	<i>Le module de transformation automatique</i>	117
5.3.4	<i>Le moteur NaturalOWL</i>	118
5.3.5	<i>Le module de transformation interactive</i>	118
5.3.6	<i>Le module d'export</i>	121
5.3.7	<i>L'interface de l'outil ActRedoc</i>	123
5.4	UN EXEMPLE D'UTILISATION DE ACTREDOC POUR LA REDOCUMENTATION DE L'ACTIVITE «PRESSE ILLUSTRÉE »	124
5.4.1	<i>L'annotation linguistique de l'ontologie de trace</i>	124
5.4.2	<i>La redocumentation d'une trace d'activité via ActRedoc</i>	127
5.5	UNE PREMIERE EVALUATION DE L'OUTIL ACTREDOC	134
5.5.1	<i>Les traces d'activité</i>	135
5.5.2	<i>Les participants</i>	135
5.5.3	<i>L'expérimentation</i>	136
5.5.4	<i>Résultats</i>	137
5.5.5	<i>Discussion</i>	139
5.6	CONCLUSION	141
CONCLUSION ET PERSPECTIVES.....		142
BIBLIOGRAPHIE		149
ANNEXE A		162

Table des figures

<i>Figure 1.1. Schéma de l'évolution de la notion de documentation.</i>	15
<i>Figure 1.2. Vue globale du processus de redocumentation de l'activité informatique</i>	27
<i>Figure 2.1. Fonctionnement d'un Système à Base de Traces modélisées</i>	49
<i>Figure 2.2. Architecture d'un Système à Base de Traces modélisées.</i>	51
<i>Figure 2.3. Architecture du système Abstract.</i>	53
<i>Figure 2.4. La trace première dans le cas d'un conducteur de voiture</i>	53
<i>Figure 2.5. Exemple de reconnaissance de changement de voie de conduite</i>	54
<i>Figure 2.6. Interface du salon synchrone et interface du salon de rétrospection (Visu)</i>	55
<i>Figure 2.7. Conception et visualisation de bilan dans Visu</i>	56
<i>Figure 3.1. Une modélisation du document multi-structuré comme un ensemble de structures mises en correspondance avec une structure première.</i>	66
<i>Figure 3.2. Un méta-modèle du document multi-structuré basé sur des vues.</i>	67
<i>Figure 3.3. Les deux étapes de la construction d'un DVA</i>	74
<i>Figure 3.4. Le processus de composition (tridimensionnelle) d'un DVA.</i>	74
<i>Figure 3.5. Le système DPs, comportant l'agent pédagogique et l'outil d'annotation basé-RST).</i>	75
<i>Figure 3.6. L'interface de l'outil auteur de DPs.</i>	76
<i>Figure 4.1. Un cadre général pour le processus de redocumentation de l'activité informatique, basé modèles (pour les traces et les documents).</i>	88
<i>Figure 4.2. Le modèle structuré dynamique de l'activité.</i>	89
<i>Figure 4.3. Le méta-modèle « activité unifiée » représenté par un graphe.</i>	89
<i>Figure 4.4. Le modèle générique de la trace d'activité.</i>	90
<i>Figure 4.5. Le modèle de document comme une spécification d'un modèle générique, centré sur la structure rhétorique.</i>	92
<i>Figure 4.6. Exemple de texte généré par NaturalOWL pour décrire une instance de l'ontologie d'objets de musée.</i>	98
<i>Figure 4.7. Représentation graphique du document texte initial (D_0) produit de la phase de redocumentation automatique en texte.</i>	99
<i>Figure 4.8. Exemple d'application d'opérations par l'utilisateur sur le document texte initial (D_0) durant la phase de redocumentation interactive en texte.</i>	100
<i>Figure 4.9. Exemple d'export d'un document fragmenté intermédiaire (D_j) en un document texte final (D_F).</i>	103
<i>Figure 5.1. Organisation du corpus numérique « Presse Illustrée ».</i>	106
<i>Figure 5.2. Interface de l'application de navigation dans le corpus « Presse illustrée»</i>	107

Figure 5.3. Les deux modes de présentation d'un fascicule (comme une rubrique de contenu à gauche ou une liste de miniatures de pages à droite).....	108
Figure 5.4. Un extrait du fichier log produit du traçage de l'activité de navigation dans la « Presse Illustrée ».....	110
Figure 5.5. Ontologie de trace de l'activité de navigation dans la « Presse Illustrée ».	113
Figure 5.6. Architecture de l'outil de redocumentation en texte ActRedoc.	114
Figure 5.7. Représentation de l'ontologie OntoReST (Naja-Jazzar et al., 2009).	116
Figure 5.8. Représentation graphique de l'ontologie de document.	116
Figure 5.9. Vue du contenu du document final exporté (XHTML+RDFa).	122
Figure 5.10. Interface de l'outil de redocumentation ActRedoc.	123
Figure 5.11. L'interface d'annotation de NaturalOWL au niveau lexical de l'ontologie (de trace de l'activité de navigation dans la « Presse Illustrée »).....	124
Figure 5.12. Un extrait du fichier RDF des annotations du niveau lexical de l'ontologie (de trace de l'activité de navigation « Presse Illustrée »).	125
Figure 5.13. L'interface d'annotation de NaturalOWL au niveau micro-plans de l'ontologie (de trace de l'activité de navigation dans la « Presse Illustrée »).....	125
Figure 5.14. Un extrait du fichier RDF des annotations du niveau micro-plans de l'ontologie (de trace de l'activité de navigation dans la « Presse Illustrée »).....	126
Figure 5.15. Fenêtre de choix de trace à redocumenter dans l'interface de ActRedoc	127
Figure 5.16. Représentation des actions (obsels) de la trace choisie (trace_5) sur une ligne de temps.	127
Figure 5.17. Un exemple de description textuelle générée par NaturalOWL pour une instance de l'ontologie de trace de l'activité de navigation dans la « Presse Illustrée ».....	128
Figure 5.18. Représentation du document initial fragmenté (D_0) produit de la transformation (redocumentation) automatique de la trace (trace_5).	130
Figure 5.19. Interface d'application d'une opération « Explain Segment » à un segment du document D_0 dans l'outil ActRedoc (avec une relation de justification).....	131
Figure 5.20. Représentation du document intermédiaire (D_I) produit de la redocumentation (transformation) interactive du document initial (D_0).	133
Figure 5.21. Visualisation du document intermédiaire (D_I) comme un document texte dans l'interface de l'outil ActRedoc.....	134
Figure 5.22. Visualisation du document final (D_F) exporté comme un document HTML	134

Table des tableaux

<i>Tableau 1.1. Les niveaux, les techniques et produits de la documentation.</i>	<i>16</i>
<i>Tableau 1.2. Classification des transactions communicationnelles et leurs produits.</i>	<i>20</i>
<i>Tableau 1.3. Synthèse de la comparaison des quatre notions dans le cadre des TC.</i>	<i>22</i>
<i>Tableau 3.1. Les relations rhétoriques définies par Mann et Thompson (1988).</i>	<i>72</i>
<i>Tableau 4.1. Description des différentes opérations que l'utilisateur peut appliquer au document manipulé durant la phase de redocumentation interactive en texte.</i>	<i>101</i>
<i>Tableau 5.1. Description des actions qui peuvent être effectuées dans le cadre de l'activité de navigation dans la « Presse Illustrée » et leurs propriétés.</i>	<i>111</i>
<i>Tableau 5.2. Description de l'ensemble des opérations supportées par le module de transformation interactive de l'outil de redocumentation ActRedoc.</i>	<i>119</i>
<i>Tableau 5.3. Expression des relations rhétoriques contenues dans le document pour la présentation de celui-ci comme un texte.</i>	<i>120</i>
<i>Tableau 5.4. Synthèse de l'expérimentation de redocumentation et de ses résultats.</i>	<i>138</i>

Introduction générale

De la trace d'activité au document

Les activités humaines sont largement supportées par des systèmes informatiques. Nous entendons par « *activité informatique* » toute activité initiée par un humain et supportée par un système informatique permettant l'acquisition, le traitement, le stockage et/ou l'échange de données dans le but de réaliser l'activité en question. Cela inclue les activités de bureautique, la navigation sur le web, le *e-learning*, l'utilisation des applications en ligne ou des systèmes informatiques plus ou moins complexes, etc. Une activité informatique peut être enregistrées automatiquement à travers l'instrumentation du système utilisé en vue d'enregistrer et de collecter des événements qualifiés de pertinents. Ainsi, nous appelons « *trace d'activité* » tout produit de ces enregistrements (fichiers logs, captures d'écran, enregistrements vidéo, etc.). Une trace d'activité (personnelle ou de groupe) peut être utilisée de multiples façons, toutes visant à l'analyse ou à la facilitation de l'activité : assistance à base de traces, confrontation temps réel à sa trace personnel, analyse réflexive de l'activité individuelle ou collective par transformation, etc. Les notions de traces d'activité, de systèmes à base de traces, de transformation et de visualisation de traces sont étudiées au sein de l'équipe Silex du LIRIS¹ depuis plusieurs années, et plusieurs développements convergents sont en cours au sein de cet axe de recherche très actif.

Dans ce contexte, nous nous intéressons à la *documentation* de l'activité informatique à partir de ses traces. Une telle documentation vise à fournir une description persistante, facilement échangeable et personnalisée de l'activité en question selon les choix d'un individu. Le document produit peut permettre de revoir l'activité de l'utilisateur tracé et de réfléchir à son propos ; il peut également servir à communiquer et à échanger des expériences personnelles. Cependant, si les traces d'activité fournissent une documentation de base pour l'activité tracée ; elles manquent le plus souvent de lisibilité, d'intelligibilité et de portée sociale pour des utilisateurs ordinaires (au contraire des concepteurs des systèmes, par exemple). C'est pourquoi nous voulons aller plus loin en concevant des processus de *redocumentation* de l'activité informatique pour pouvoir transformer, corréler et décrire les traces de celle-ci au sein d'une unité cohérente et compréhensible (document) fournissant une description personnalisée de l'activité.

Cette thèse en ingénierie des connaissances s'inscrit dans le cadre général des systèmes à base de traces, en se focalisant plus particulièrement sur les liens entre trace d'activité et document. Il s'agit de considérer *a priori* ces deux types d'éléments numériques comme autonomes pour pouvoir en étudier les similitudes, les différences, les rapports de transformation, etc. Un document appartient à un genre qui en prescrit forme et contenu, relève d'une logique de diffusion, d'échange et de transmission, et a une dimension

¹ LIRIS : <http://liris.cnrs.fr/>

séquentielle liée à l'énonciation. Quant à la trace d'activité, elle décrit plus ou moins précisément une activité, relève le plus souvent du domaine du privé et a une orientation temporelle et séquentielle forte. Les rapports entre traces d'activité et documents sont nombreux, surtout dans un contexte numérique. D'un point de vue théorique, nous proposons une étude des notions sous-jacentes à notre problématique (*trace, document, documentation, documentarisation et redocumentarisation*) et nous introduisons une nouvelle notion (*redocumentation*) pour pouvoir penser théoriquement la transformation de traces en documents. L'idée directrice qui est à la source de notre démarche est de renforcer, via le processus de redocumentation, le statut documentaire des traces sur les dimensions *forme* (présentation), *fond* (contenu à rendre plus intelligible) et surtout *medium* (aspect lié à la portée et la diffusion des traces dans une dimension sociale).

D'un point de vue pratique, nous proposons une approche semi-automatique, narrative, basée modèles et assistée par un outil auteur de redocumentation de l'activité informatique à partir de sa trace. Nous pensons que l'utilisateur doit pouvoir intervenir durant le processus de redocumentation de l'activité tracée pour décider concrètement du contenu à préserver des traces, du contenu à ajouter, et de la forme d'appropriation du document produit. En revanche, étant donnée la complexité potentielle des traces, leur volume et leur nature multimodale, il est difficile de demander à l'utilisateur de construire tout seul un document décrivant l'activité directement à partir de ses traces ; il est alors nécessaire de lui fournir un outil assistant qui permette de minimiser son effort cognitif durant le processus de redocumentation. Nous proposons également que l'utilisateur adopte une approche « naturelle » dans la description de l'activité ; celle-ci est alors basée sur la construction d'une narration en utilisant les principes de la théorie de la structure rhétorique (RST) (Mann and Thompson, 1988). Dans l'approche que nous proposons, les traces d'activité et les documents produits sont modélisés sémantiquement. Le processus de redocumentation est caractérisé par deux phases : une phase automatique qui permet de générer un document fragmenté à partir de la trace comme une description initiale de l'activité, et une phase interactive qui permet à l'utilisateur de s'appropriier la forme et le contenu de la description initiale de l'activité en lui appliquant des opérations (organisationnelles et rhétoriques) pour aboutir à un document final exportable. L'originalité de cette approche réside, d'une part, dans les modèles génériques que nous proposons pour les traces et les documents produits et d'autre part dans la façon de supporter la transformation automatique d'une trace en un document fragmenté et la manipulation de celui-ci selon des principes rhétoriques.

Pour implémenter notre approche, nous détaillons la spécification de celle-ci dans le cas particulier de la redocumentation par le texte, dans laquelle le produit de la redocumentation de la trace d'activité est un document texte (dans un format hypertexte enrichi de métadonnées). Nous décrivons ActRedoc, un outil auteur que nous avons développé pour supporter cette approche spécifique en exploitant différentes technologies du Web Sémantique. Afin d'ancrer la recherche dans une application concrète, nous décrivons le terrain applicatif pris en considération dans cette thèse. Ce terrain est orienté sur l'utilisation d'un environnement spécifique dans un cadre collectif et concerne la redocumentation des traces personnelles de navigation dans un site d'archive de journaux du XIX^{ème} développé par la bibliothèque municipale de Lyon dans le cadre du projet CaNu XIX². Nous pouvons alors présenter une première évaluation de l'outil ActRedoc lors de son utilisation pour ce terrain

² CaNu XIX : les canards numériques du XIX^{ème} siècle

applicatif ; celle-ci montre son *utilisabilité* et son *utilité* pour ses utilisateurs ainsi que les nouveaux besoins réclamés par ceux-ci.

Organisation du manuscrit

Nous associons au cours de cette thèse des propositions théoriques et pratiques. L'ensemble du manuscrit est divisé en cinq chapitres.

Le **chapitre 1** présente le contexte et la problématique de la thèse qui est la *redocumentation de l'activité informatique à partir de sa trace*. Nous définissons la notion de *trace d'activité informatique* et de *document* ainsi que les notions sous-jacentes de *documentation*, de *documentarisation* et de *redocumentarisation*. Nous introduisons une nouvelle notion de *redocumentation* et nous proposons une définition pour celle-ci. Nous étudions l'application du processus de redocumentation à l'activité humaine en général et à l'activité informatique en particulier et nous présentons un cadre général pour celui-ci avec des exemples d'application. Nous essayons, au travers de ce chapitre, de répondre à des questions de fond concernant le principe de la redocumentation de l'activité informatique à partir de sa trace et nous terminons avec une série de questions à propos de la mise en place concrète de ce processus.

Le **chapitre 2** est consacré à un état de l'art sur la notion de trace de l'activité informatique et sur les systèmes utilisant ou créant ce type de traces (systèmes traçants). Nous proposons une définition de cette notion dans un contexte général puis nous raffinons cette définition dans le contexte de l'activité médiée informatiquement. Nous décrivons les caractéristiques de la trace d'activité informatique et les utilisations possibles de celle-ci. Nous évoquons également la problématique de la modélisation de celle-ci et nous présentons un cadre théorique et pratique proposé par notre équipe Silex pour l'ingénierie de ce type de traces baptisé « Système à Base de Traces modélisées ». Des exemples de systèmes qui concrétisent cette notion et son utilisation sont présentés en mettant l'accent sur leurs choix de modélisation.

Le **chapitre 3** est consacré à un état de l'art sur le document numérique, sa création et sa manipulation. Nous étudions la notion de *document* en général puis son évolution dans le contexte du numérique. Nous évoquons la problématique de la modélisation du document numérique à travers la description des composants et des structures qu'il encapsule. Nous étudions également le processus de création de contenu de document numérique (*authoring*) ; un processus qui peut exploiter des bases théoriques empruntées à la rédaction classique de documents, notamment les principes de la Théorie de la Structure Rhétorique que nous décrivons à l'occasion. Nous présentons les différentes approches d'*authoring* proposées dans le contexte du numérique et les outils associés, puis nous évoquons l'apport de tels approches et outils dans la mise en place de la pratique de *storytelling* pour la production de documents numériques.

Le **chapitre 4** présente l'approche générique que nous proposons pour la redocumentation de l'activité informatique à partir de ses traces. Celle-ci est basée sur des choix théoriques qui dépendent des objectifs que nous fixons au début ; elle est semi-automatique, narrative, basée-RST et utilise des modèles sémantiques pour les traces d'activité et les documents. Nous décrivons un cadre général pour cette approche, qui suppose que le processus de redocumentation permet de transformer une trace d'activité informatique en un document numérique décrivant l'activité de façon personnalisée par un utilisateur. Ceci se fait via deux

phase : une phase de transformation automatique de la trace en un document fragmenté intermédiaire et une phase de transformation interactive du document intermédiaire en un document final. Nous proposons également une spécification du cadre général proposé pour une approche de redocumentation en texte.

Le **chapitre 5** présente notre implémentation de l'approche de redocumentation en texte via un outil auteur *ActRedoc* que nous avons développé ainsi que notre terrain applicatif. Ce terrain consiste en la redocumentation d'une activité de navigation dans un site d'archive de journaux du 19^{ème} siècle de la presse illustrée régionale. Nous présentons l'architecture de l'outil ActRedoc, nous décrivons les différentes technologies utilisées pour son implémentation et nous illustrons le fonctionnement de cet outil via un exemple complet de redocumentation d'une trace particulière de l'activité choisie. Nous présentons également une première évaluation de cet outil auprès d'un groupe d'utilisateurs.

Nous terminons ce manuscrit par une **conclusion** de notre travail de thèse. Nous présentons tout d'abord le bilan global de nos contributions, puis une discussion de leurs limites tout en justifiant nos choix et enfin une liste de perspectives pour un futur travail.

Première partie

Problématique et Etat de l'art

Chapitre 1: Contexte et problématique :

redocumenter l'activité informatique

1.1 Introduction

L'évolution des équipements informatiques, l'avènement d'internet et le succès du web ont permis une généralisation de l'exploitation de ces technologies à grande échelle. Ainsi, une bonne partie de nos activités quotidiennes, que ce soit dans un cadre professionnel (secteurs de marketing, de production, de gestion, *etc.*) ou personnel (certains aspects de la vie quotidienne tels que l'apprentissage et la communication) est aujourd'hui supportée par des systèmes informatiques partiellement ou totalement automatisés. Nous appelons ce type d'activité *activité médiée informatiquement* ou simplement *activité informatique*. Cela inclut les activités de bureautique (traitement de texte, tableurs, courriel, *etc.*), le chat, le e-learning, l'utilisation des différentes applications accessibles en ligne, *etc.* Toutefois, cette activité peut être aussi bien simple (tels le calcul et la recherche d'informations) que complexe (tels le contrôle de processus et la prise de décision).

Ce chapitre a pour objectif d'expliquer la notion de *redocumentation de l'activité médiée informatiquement à base de sa trace* ; un sujet qui se présente avec des questions puisque les notions sous-jacentes sont ambiguës. Tout d'abord, nous nous intéressons à la notion de *trace*, aussi bien dans un contexte général, que dans le contexte particulier de l'activité médiée informatiquement ; sans pour autant entrer dans les détails puisque nous consacrerons par la suite tout un chapitre (chapitre 2) à l'étude détaillée de cette notion. Nous nous intéressons également aux notions de *documentation* et de *document*, souvent utilisées, et qui sont visiblement liées à la nouvelle notion de *redocumentation* que nous introduisons ici.

Si nous définissons la documentation comme étant : « *un processus qui permet d'enregistrer et de collecter des informations, pour fournir une description ou une preuve de quelque chose, selon un objectif particulier* » ; cela sous-entend à la fois la création, la recherche et l'organisation de documents. Or, comment peut-on qualifier un produit de document ? En quoi consiste vraiment la documentation ? Qu'est ce qui peut justifier l'introduction d'une nouvelle notion telle que la *redocumentation* ? Quels liens peut-elle avoir avec celle de documentation ou encore avec les notions émergentes de *documentarisation* et de *redocumentarisation* ? Et comment définir toutes ces notions dans notre contexte particulier de l'activité médiée informatiquement ?

Nous essayons de répondre à ces questions à travers une étude de la notion de *documentation* et de son évolution dans un contexte général ; puis nous passons à la documentation de l'activité humaine et plus particulièrement à celle de l'activité médiée informatiquement par sa trace. Notre but est de pouvoir justifier la nécessité d'introduire un nouveau processus dit de *redocumentation*, pour lequel nous proposons une définition précise, une vue générale et des exemples d'application pour l'activité informatique. Nous terminons

ce chapitre avec une série de questions à propos du principe de la *redocumentation* de l'activité informatique à partir de sa trace et de la mise en place concrète de ce processus.

1.2 Etat de l'art sur la (re)documentation

Les notions de *documentation* et de *document* sont étroitement liées ; mais les réflexions théoriques sur le document remontent au 17^{ème} siècle, alors que l'origine du terme *documentation* remonte aux environs de 1870. Il s'avère utile de définir brièvement la notion de *document* et son évolution avant de passer à la notion de *documentation* et aux notions sous-jacentes à celle-ci ; mais nous consacrerons par la suite tout un chapitre (chapitre 3) à l'étude de la notion du document du fait de son importance pour notre travail de recherche.

1.2.1 Le document

Bien que le concept de *document* nous paraisse intuitif du fait que les documents sont omniprésents dans notre vie quotidienne, il s'avère difficile d'en donner une définition précise au lieu des exemples souvent énumérés (livre, article, fichier, photo, *etc*). En partant de l'idée que la racine *DOC* du mot vient du latin *docere* qui signifie *enseigner*, le document a été défini comme : « *tout objet qui enseigne sur quelque chose* »³. D'après Lund et Skare, le premier intérêt pour une théorie du document ne s'est manifesté qu'au début du 20^{ème} siècle avec Paul Otlet et Suzanne Briet (Lund and Skare, 2010). Cette théorie insistait sur les connaissances contenues dans les documents et sur la façon dont quelque chose pouvait devenir document. Une première définition précise du document a été proposée par Briet en mettant la preuve au cœur de cette notion : « *tout indice concret ou symbolique, conservé ou enregistré, aux fins de représenter, de reconstituer ou de prouver un phénomène physique ou intellectuel* » (Briet, 1951). Cela peu bien s'appliquer à une étoile dans le ciel ou à une antilope dans un musée, pourvu qu'elles soient les témoins d'un savoir inscrit.

Une telle définition est peu pratique alors que la plupart des normes et des textes réglementaires optent pour des définitions plus simples et opérationnelles du document telles que : « *un objet sur lequel est consignée une information* ». Cette définition souligne deux dimensions pour la notion de *document* qui sont la forme (l'objet) et le contenu (l'information). Toutefois, un document ne peut se réduire à ces deux dimensions, *sinon tout écrit en serait un* (Salaün, 2010). D'ailleurs, l'objectif de l'enregistrement de l'information sur l'objet est de pouvoir transmettre celle-ci ou s'y référer ; d'où l'importance d'une troisième dimension liée à la fonction de transmission ou de preuve du document.

Depuis les années quatre-vingt-dix, les chercheurs insistent, de plus en plus, sur la nécessité d'articuler ensemble les différentes dimensions physique, culturelle et sociale du document (Lund and Skare, 2010). Avec l'émergence des technologies numériques qui ont fait perdre au document sa stabilité comme un objet matériel, un besoin accru d'adapter la définition de cette notion dans son nouveau contexte est apparu et une nouvelle théorie du document a vu le jour. Cette théorie est supportée par un collectif de chercheurs réunis récemment sous le pseudonyme de Roger Pédaque⁴ et définit le document à travers ses trois dimensions complémentaires : « *la forme comme un objet matériel ou immatériel, le signe (le contenu) comme un porteur de sens et le médium comme un vecteur de*

³ extrait du site « Le document numérique, notions fondamentales » ([http://editer.abcdoc.net/#document numerique](http://editer.abcdoc.net/#document_numerique))

⁴ Réseau Thématique Pluridisciplinaire 33 du département STIC du CNRS (RTP-DOC : <http://rtp-doc.enssib.fr>)

communication » (Pédauque, 2006). A ces trois dimensions se rattachent les trois modalités suivantes : la lisibilité (via la perception) pour la forme du document, l'intelligibilité (via l'assimilation) pour son contenu et la sociabilité (via la diffusion au delà de la barrière de l'intime et du temps) pour son support (Salaün, 2007) ; alors une définition plus compacte du document a été proposée : « *toute chose qui doit pouvoir être vue, lue et sue* » (Salaun, 2012).

1.2.2 La documentation

Nous utilisons le terme *documentation* depuis des années ; pourtant, nous avons du mal à préciser une définition pour celui-ci. Même les encyclopédies et les dictionnaires n'apportent pas une définition complète de ce terme. En prenant le dictionnaire Larousse⁵ par exemple, la documentation est définie comme : « *l'action d'appuyer une assertion, un récit, etc., sur des documents* », « *l'ensemble des documents réunis à cet effet* », « *l'ensemble de documents fournis avec un appareil, un programme... pour renseigner sur son utilisation* », et encore « *l'ensemble des opérations, des méthodes...qui facilitent la collecte, le stockage, la recherche et la circulation des documents* ». En raison de ces définitions multiples, nous avons choisi d'étudier cette notion à travers son évolution dans le temps.

Vers 1870, le terme documentation avait le sens de « *recherche de documents pour faire une étude* » et désignait parfois « *la création de documents pour décrire quelque chose* » ; mais cette notion a été bien établie vers 1930 et désignait : « *l'exploitation méthodique de l'information* ». Ultérieurement, P. Otlet puis S. Briet ont fourni des études profondes de la notion de *documentation*, ce qui a permis d'ailleurs leur qualification de père et de mère de la documentation respectivement.

La documentation selon P. Otlet : ce visionnaire a rattaché, dans son livre *Le Traité de Documentation* (Otlet, 1934), l'histoire de la documentation à celle de l'homme du moment où celui-ci a commencé l'inscription de ses premiers signes. Cette notion a évolué pour inclure celle de la *bibliothèque* née du besoin d'une collection déterminée d'œuvres à décrire par un catalogue ; puis celle de la *Bibliographie* née des besoins de la science de se servir des livres et des études sur leurs ensembles pour se constituer une méthode de leur description. Mais cette évolution ne n'est pas arrêtée à ce stade ; c'est d'ailleurs ce que Otlet a pu représenter dans un schéma de synthèse (Figure 1.1) où il a combiné la description de cette évolution avec celle de la création simple de documents (i.e. l'image classique de la documentation) : « *le sommet dans ce schéma est l'univers à partir duquel se forment les représentations grâce aux intelligences humaines, puis celles-ci s'organisent dans le cadre de la science pour donner naissance aux livres réunis dans des bibliothèques. Au départ, la description de ces documents est faite via des notices bibliographiques à réunir dans un répertoire universel (catalogue), puis l'Encyclopédie constituée d'une série de dossiers de synthèse sur ces documents est réalisée, actualisée et diffusée par des documentalistes ; la classification vient par la suite jouer un rôle important dans cet ordre via l'ordonnancement de la science des livres, de leur bibliographie et de l'encyclopédie* ».

La documentation selon S. Briet : cette bibliothécaire est venue avec une vision de la documentation qui va au-delà de la focalisation de Otlet sur les formes fixes de documents, tel le livre. Elle a supposé plusieurs formes physiques et formats esthétiques pour ceux-ci ; elle a également présenté une multitude de techniques et de technologies pour leur manipulation. Dans son livre *qu'est ce que la documentation?* (Briet, 1951), elle a commencé par définir la notion de *documentation* comme : « *une technique culturelle au sein d'une culture*

⁵ <http://www.larousse.fr/dictionnaires/francais/documentation/26270>

technicienne » ; cela signifie que la documentation est apparue comme une technique culturelle qui a prospéré tout d'abord dans le milieu de la recherche scientifique (la création d'œuvres, d'articles de recherche, *etc.*). Puis cette notion a évolué pour se rattacher de plus en plus à la vie de groupes de travailleurs et d'activités particulières (industrielle, commerciale, *etc.*), et atteindre le statut d'une profession basée sur un ensemble de techniques. Briet s'est alors référée dans sa définition de la documentation à la description de cette profession : « *le documentaliste : 1° est un spécialiste du fond, c'est-à-dire qu'il possède une spécialisation culturelle apparentée à celle de l'organisme qui l'emploie; 2° connaît les techniques de la forme des documents et de leur traitement (choix, conservation, sélection, reproduction); 3° a le respect du document dans son intégrité physique et intellectuelle; 4° est capable de procéder à une interprétation et à une sélection de valeur des documents dont il a la charge, en vue d'une distribution ou d'une synthèse documentaire.* » (Briet, 1951, p.19).

Aujourd'hui on parle de la *fonction documentation* d'un organisme ; une fonction qui est destinée à : « *l'établissement d'un réseau organisé de collecte et de diffusion de l'information venant renforcer et compléter les réseaux d'information propres à chacun des agents de l'organisme considéré* » (Guillot, 1973).

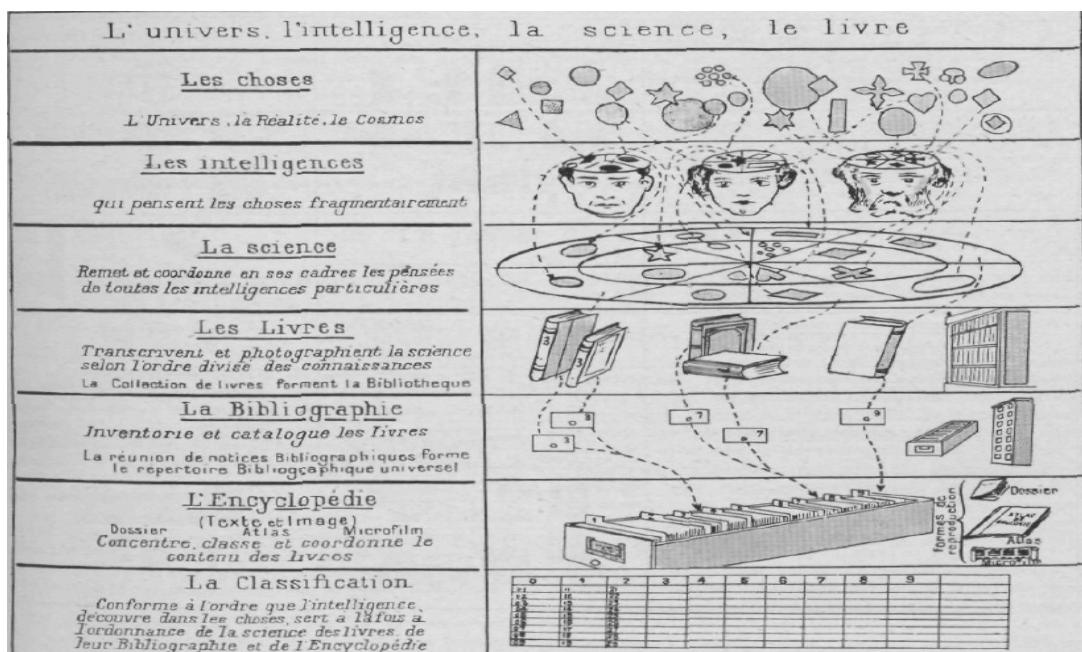


Figure 1.1. Schéma de l'évolution de la notion de *documentation*(Otlet, 1934, p. 41).

Bien que la plupart des définitions présentées soient orientées sur le côté professionnel, S. Briet a conclu quand-même que : « *le point d'application des techniques de la documentation intéresse, non seulement une profession de plus en plus avérée, mais aussi des publics toujours plus vastes - les foules innombrables* ». C'est cette idée qui a donné à la notion de *documentation* une dimension non forcément professionnelle, en se basant toujours sur l'ensemble des techniques qui lui sont rattachées. Pour décrire ces techniques, Briet a supposé que *la documentation fait connaître des objets à quatre niveaux différents* (Briet, 1951). Nous résumons dans le tableau 1.1 les trois premiers niveaux de la documentation, les techniques utilisées à chacun de ces niveaux et les formats des produits de celles-ci. Nous pouvons conclure que la notion de *documentation* ne se limite pas à la génération de

nouveaux documents pour décrire des choses ou des idées ; elle s'étend à la création de documents auxiliaires par sélection, juxtaposition et comparaison de documents existants.

Niveau de documentation	Objets (documentés)	Techniques de documentation	Formats des produits (documents)
1. Instruction	faits / idées	- l'information (verbale, écrite, cinématographique, etc.) ou l'enseignement (verbal/écrit)	communiqués, revues, films, conférences, Catalogues-guides...
	objets / créations artistiques	- l'exposition (directe/reproduite) ou l'audition (directe/enregistrée)	objets, échantillons, photos, animaux...
	personnes/ activités	les renseignements	fiches, dossiers, registres...
	sources de faits	- les Recensements et l'édition (commerciale/ officielle)	annonces, annuaires, dictionnaires, guides, encyclopédies...
2. Prospection	sources de documents	l'orientation bibliographique (localisation de documents et identification de leurs intérêts)	fichiers, registres, catalogues, guides de la recherche...
3. Diffusion	documents exploités par un collectif ou adaptés par un individu	Les productions documentaires (sélection, analyse, traduction, reproduction, groupement et distribution)	sélections, extraits, analyses, comptes rendus, traductions, photos, dossiers ...

Tableau 1.1. Les niveaux, les techniques et produits de la documentation (Briet, 1951).

1.2.3 De la documentation à la documentarisation

Alors que Otlet et Briet ont étendu la notion de *documentation* de la simple création de documents pour décrire ou expliquer des objets ou des actions aux techniques d'exploitation de ces documents ; d'autres chercheurs ont préféré distinguer les deux aspects en introduisant une nouvelle notion, dite de *la documentarisation*. Si la documentation peut être définie comme : « un processus qui permet d'enregistrer et/ou de collecter des informations pour fournir une preuve de quelque chose selon un objectif particulier », la notion de *documentarisation* elle, désigne selon J.M. Salaün les techniques d'exploitation de documents existants :

« *Documentariser c'est traiter, matériellement et intellectuellement, un document comme le font traditionnellement les professionnels de la documentation (le cataloguer, l'indexer, le résumer, le découper, éventuellement le renforcer, etc.). Le but étant d'optimiser l'usage du document en permettant un meilleur accès à son contenu et une meilleure mise en contexte* » (Salaün, 2008).

Dans cette même perspective, M. Zacklad la définit plus précisément comme suit :

« *Documentariser c'est exploiter le support du document pour le doter d'attributs facilitant l'accès à son contenu, à travers son organisation selon une dimension interne (accès aux différentes parties du contenu) et externe (rangement cohérent du document dans des collections)* » (Zacklad, 2006).

Les attributs de la dimension interne permettent de décomposer le document en parties cohérentes (titre, espace, table des matières), de mettre en relief certaines parties permettant l'orientation sémantique du lecteur (typographie, sous-titrage), de déplacer des parties, de

renvoyer sur d'autres parties sémantiquement liées (note, index, renvoi à une ressource externe en particulier ontologique ou terminologique), notamment d'articuler entre eux les fragments de son contenu par des annotations associatives explicitant des liens sémantiques (Zacklad, 2004a). Quant aux attributs de la dimension externe, ils permettent de dater le document, de le localiser (tags), d'identifier son auteur, *etc.*

Dans le but de localiser la première apparition de la documentarisation sur l'échelle de l'évolution du document comme un produit imprimable, Salaun s'est basé sur la proposition de A. Marshall⁶ pour décrire cette évolution à travers quatre moments : l'âge du livre (17^{ème} siècle), l'âge de la presse (19^{ème} siècle), l'âge de la paperasse (20^{ème} siècle) et finalement l'âge des fichiers (21^{ème} siècle). Il a conclu que les premiers exemples de la documentarisation s'inscrivent clairement entre l'âge de la presse et celui de la paperasse. C'est ainsi que Roger. Pédaque⁷ a rattaché la notion de *documentarisation* à une *première modernité* (Pédaque, 2007) qui est marquée par l'esprit scientifique, la construction des États-nations et l'évolution de l'industrie ; une notion qui *sous-entend les techniques de classification et d'indexation sur les documents potentiels de l'époque* tels les règlements, les revues, les contrats de travail, les factures, les brevets, les œuvres, *etc.* Finalement, pour reprendre la définition tridimensionnelle du document (forme, contenu, médium), Salaun a décrit la documentarisation du document (livre) par : son *classement* en tant que forme, son *indexation* en tant que contenu et son *inclusion dans des dispositifs de partage* en tant que médium (Salaun, 2007). L'intérêt de cette documentarisation tridimensionnelle, selon lui, est d'éviter le chaos (le silence ou le bruit lors de la recherche du document), la confusion (la confusion du sens) et l'oubli (du document intime ou éphémère).

1.2.4 De la documentarisation à la redocumentarisation

À l'ère du numérique, les sciences de l'information (documentation, bibliologie, bibliothéconomie, *etc.*) construites sur la base d'un processus de documentarisation se sont confrontées à la nécessité de se renouveler. Ce renouvellement que J.M. Salaun décrit comme un mouvement de *redocumentarisation* (Salaun, 2008) concerne l'offre et les modes de fonctionnement des services d'information documentaire à grande échelle. Pour clarifier cette nouvelle notion, nous reprenons la définition de M. Zacklad :

« *Redocumentariser, c'est documentariser à nouveau un document ou une collection en permettant à un bénéficiaire de réarticuler les contenus selon son interprétation et ses usages à la fois selon la dimension interne (extraction de morceaux musicaux pour les ré-agencer avec d'autres, ou annotations en marge d'un livre suggérant des parcours de lecture différents...) ou externe (organisation d'une collection, d'une archive, d'un catalogue privé croisant les ressources de différents éditeurs selon une nouvelle logique d'association...)* » (Zacklad, 2007).

La redocumentarisation consiste donc en la réappropriation de documents existants en vue de satisfaire les intérêts de nouveaux bénéficiaires ; un processus pour lequel le numérique offre des opportunités inédites. Une définition plutôt philosophique a été proposée par Roger. Pédaque pour donner à la redocumentarisation un sens beaucoup plus étendu :

« *La redocumentarisation est une nouvelle forme de documentarisation qui reflète ou tente de refléter une organisation post-moderne de notre rapport au monde, repérable*

⁶ Intervention au colloque de l'Association québécoise de l'étude de l'imprimé à Montréal – Octobre 2007

⁷ Roger T. Pédaque est le nom collectif d'un réseau de scientifiques francophones travaillant dans les divers domaines des sciences et techniques de l'information et de la communication.

aussi bien dans les sphères privée, collective et publique. Comme dans la précédente modernisation, le document participe au processus et y joue même un rôle clé, mais il s'est transformé au point que l'on peut se demander s'il s'agit encore de la même entité » (Pédaque, 2006).

Cette fois-ci, la redocumentarisation est définie comme une répétition d'un processus de documentarisation ; c'est d'ailleurs ce qui justifie l'utilisation d'un simple préfixe pour distinguer les deux notions. Si la documentarisation se rattache à une première modernité marquant le passage du document entre l'âge de la presse et celui de la paperasse, la redocumentarisation se rattache à une *seconde modernité* marquant le passage du document entre l'âge de la paperasse et celui des fichiers. Au départ, le processus de redocumentarisation est apparu pour traiter à nouveau des documents traditionnels qui ont été transposés sur un support numérique en utilisant les fonctionnalités de ce dernier ; mais le processus ne se réduit pas à cette simple transposition puisque le document peut subir des transformations au point de ne plus pouvoir reconnaître celui-ci. La redocumentarisation introduit alors un vrai *changement de paradigme* par rapport à la documentarisation (Salaun, 2007) puisque la nouvelle modernité qui l'accompagne est caractérisée par la dominance des individus, de leur savoir limité, de l'esprit, des opinions et de la réflexivité. Dans ce contexte, bien des documents du Web ne ressemblent plus que de très loin aux documents traditionnels, surtout que les moyens de composition et d'impression sont mis à la disposition de tout le monde. *Le monde documentaire se retrouve alors envahi par des formes nouvelles* tels les formulaires, les wikis, les blogs, les pages personnelles sur les réseaux sociaux, etc.

La redocumentarisation a ainsi brisé l'image du monde comme étant représenté par un travail de scientifiques (livres, articles d'experts, encyclopédies, etc.) ; d'autant plus que chacun peut représenter le monde à sa façon en créant des documents. Cette image a été illustrée par Salaun à travers une étude comparative⁸ entre les deux notions de documentarisation et de redocumentarisation. Pour cela, il a repris le schéma de Otlet pour la documentation et la *documentarisation* (voir figure 1.1) et celui du Web actuel pour la redocumentarisation pour conclure que : « *alors que dans le schéma de P. Otlet, on trouvait tout en haut les auteurs qui pensaient le monde et le représentaient en concepts, le schéma du Web met à leur place des utilisateurs qui représentent le monde et construisent des réponses à leurs questions à partir des ressources documentaires* ». Aujourd'hui, plus les données sont disponibles, plus il y a de la chance pour que les gens en discutent et les interprètent ; ce qui pose également des questions d'éthique (droit d'accès, vie privée, mauvaise interprétation...). Mais « *avec la puissance du web, nous pouvons faire en sorte que l'interprétation la plus fiable se retrouve mise en avant* »⁹.

De nombreux exemples de redocumentarisation sont exposés dans le blog¹⁰ de J.M. Salaun. Nous présentons ci-dessous ceux qui nous ont intéressés le plus :

- **La redocumentarisation dans Wikipédia** : celle-ci est illustrée par une analyse menée par Olivier Ertzscheid à propos d'un article de wikipédia sur le réacteur EPR de 3^{ème} génération¹¹. Avant le débat télévisé sur son sujet, cet article était un document « *stabilisé* ». Le temps du débat et juste après, il a subi des modifications parfois

⁸ <http://blogues.ebsi.umontreal.ca/jms/index.php/post/2011/03/30/La-redocumentarisation-en-quatre-images>

⁹ tiré d'un entretien avec Michael Cross du Guardian : http://www.rslnmag.fr/blog/2011/2/25/_c-est-une-periode-excitante-pour-l-open-data_entretien-avec-michael-cross/

¹⁰ blog de J.M. Salaun : <http://blogues.ebsi.umontreal.ca/jms/index.php/>

¹¹ http://affordance.typepad.com/mon_weblog/2007/05/wikipdiem_lecto.html

infondées et frauduleuses. Puis, le jour d'après, il est redevenu un document stable, mais désormais non-immédiatement modifiable par n'importe qui. Ertzscheid conclut alors que cette tentative de redocumentarisation déviante n'a pas fait perdre au document son intérêt originel, mais l'a enrichi par contre.

- **La redocumentarisation du monde physique** : celle-ci est illustrée à travers un projet de Nokia¹². Son principe est de permettre à toute personne de récupérer une information sur un objet ou un lieu en prenant simplement une photo de celui-ci et en l'envoyant sur un serveur d'application pour récupérer sa description détaillée.

- **La redocumentarisation des personnes** : celle-ci est illustrée par des projets innovateurs tels que les puces sous-cutanées, les sites traçants, des *réseaux sociaux* documentarisant les personnes, le *dossier médical électronique* pouvant représenter fidèlement un patient, la *reproduction animée des expressions des visages* sur des avatars en 3D, et encore le *traçage de la vie quotidienne* notamment à travers le fameux projet MyLifeBits¹³. J.M. Salaun s'est même posé la question « *suis-je un document?* ». Pour y répondre, il a projeté la définition du document proposée par Bachimont¹⁴ sur des personnes ; une définition qui caractérise le document par deux fonctions : transmettre et prouver. Pour la fonction de transmission, Salaun considère que la personne peut être un document à l'image de sa mémoire et que les réseaux sociaux nous obligent à gérer notre identité numérique faisant ainsi de nous des documents virtuels. Quant à la fonction de preuve, il considère que les faits et les gestes des hommes vivant en sociétés sont utiles pour au moins trois champs de connaissances : le savoir scientifique qui s'appuie sur l'homme comme document (telle la médecine), le commerce documenté par le marketing qui s'appuie sur l'observation des consommateurs, et le politique considérant les individus comme des documents administratifs (d'identité tel le passeport, de droits tel le visa, de compétences tels les diplômes, etc.).

1.2.5 La redocumentation, un nouveau concept...

Nous pouvons affirmer que chacun d'entre nous a fait l'expérience de la *redocumentarisation* en exploitant des ressources du web (photos, vidéos, textes...) pour composer des documents personnels, en indexant des photos, en collaborant sur la rédaction d'un document ; voire-même en se comportant comme un document dans le monde de la vie virtuelle. Toutefois, cette notion nous semble difficilement cernée, d'autant plus que le processus sous-jacent se croise parfois avec celui de la documentation en tant que création de documents ; ou encore avec celui de la documentarisation en tant que technique d'optimisation d'usage et d'accès aux documents.

Parfois, le processus de *redocumentarisation* consiste à s'approprier le contenu, la forme ou la portée de documents existants selon une vision personnelle, tel l'exemple de la redocumentarisation des collections d'images ; alors que d'autres fois, il consiste à créer des documents à part entière pour décrire des choses, tels les exemples de la redocumentarisation du monde physique, des personnes et de l'activité quotidienne. Pour lever toute ambiguïté, nous proposons d'introduire une nouvelle notion dite de *redocumentation* que nous définissons dans un premier temps comme « *un processus de documentation qui permet la*

¹² <http://www.internetactu.net/2007/11/19/les-images-comme-hyperliens/>

¹³ <http://research.microsoft.com/en-us/projects/mylifebits/>

¹⁴ <http://cours.ebsi.umontreal.ca/bachimont2008/documents-diaapos-audio/index.html>

description de documents existants (produits d'un premier processus de documentation) dans de nouveaux documents créés pour répondre à des besoins particuliers ».

De façon plus précise, nous définissons la redocumentation comme suit :

Définition 1.1 : « *La redocumentation est un processus qui englobe à la fois, 1° la redocumentarisation en tant que processus permettant la personnalisation inédite des documents existants (sélection, interprétation, indexation, etc.) selon l'intérêt d'un ou de plusieurs bénéficiaires ; et 2° la documentation en tant que processus permettant de créer de nouveaux documents à part entière pour pérenniser le produit de la redocumentarisation et éventuellement combiner celui-ci à des descriptions d'autres objets, idées, etc. »*

Nous décrivons par la suite un cadre théorique, celui des transactions communicationnelles, pour comprendre au mieux la notion de *redocumentation* et pouvoir comparer théoriquement celle-ci aux notions de documentation, de documentarisation et de redocumentarisation.

1.3 Un cadre théorique pour la redocumentation

Afin de penser la notion de *redocumentation* en tant que telle, nous avons choisi de nous situer dans le cadre de la théorie des transactions communicationnelles proposée par M.Zacklad (Zacklad, 2006). Ce cadre, dont nous présenterons les éléments les plus importants, nous permet de définir clairement cette notion et de la comparer aux notions sous-jacentes utilisées dans le domaine documentaire (documentation, documentarisation et redocumentarisation).

1.3.1 La théorie des transactions communicationnelles (TC)

M. Zacklad suppose que toute action humaine (discussion, déplacement d'un objet, etc.) peut s'inscrire dans un procès transactionnel. Il définit la transaction comme : « *une rencontre productive, à l'issue de laquelle un médium (artefact expressif ou matériel) et des transactants parties prenantes (réalisateurs et bénéficiaires) peuvent être transformés* » (Zacklad, 2006). Une personne individuelle peut être engagée dans une transaction avec elle-même et l'*intentionnalité* des transactants est exprimée par la conscience qu'ils ont de la transaction. Si nous nous limitons au domaine de la communication, les transactions peuvent être médiatisées par des gestes, des paroles ou par l'intermédiaire d'artefacts pérennes (documents). En analysant une situation transactionnelle, nous pouvons identifier en plus des transactants un ensemble de paramètres importants (Zacklad, 2004a) : le projet commun, les compétences et les relations des transactants, les équipements utilisés, etc. La standardisation de ces éléments permet de distinguer deux catégories de transactions (Zacklad, 2004a) : les *transactions communicationnelles symboliques* et *transactions informationnelles codifiées*.

Type de transaction	Caractère	Type de production	Type de document produit
Communicationnelle symbolique (TCS)	Créative, à dominante expressive	Production sémiotique (PS)	Document peu codifié
informationnelle codifiée (TIC)	Routinière, à dominante expressive	Production informationnelle (PI)	Document codifié

Tableau 1.2. Classification des transactions communicationnelles et leurs produits.

Les transactions communicationnelles symboliques (TCS). Ce sont « des transactions créatives à dominante expressive, donnant lieu à des productions sémiotiques ayant un support pérenne ou éphémère » (Zacklad, 2004b). Une production sémiotique est « composée d'un médium caractérisé par une modalité d'expression et d'un support matériel, et d'un contenu sémiotique caractérisé par son pouvoir d'évocation (sa capacité à évoquer des représentations communes) et ses effets potentiels (psychiques et sociaux) » (Zacklad, 2006). Ainsi, la signification d'une production sémiotique est ouverte à l'interprétation. Les productions sémiotiques véhiculées sur des supports pérennes donnent lieu à la production de documents peu codifiés du fait du faible couplage entre les paramètres de la situation transactionnelle et la nature du contenu sémiotique. Ils peuvent être stabilisés (*documents ressources*) ou à actualisation fréquente (*documents pour l'action*) (Zacklad, 2004a).

Les transactions informationnelles codifiées (TIC). Ce sont « des productions à dominante expressive mais à caractère routinier (brèves, répétitives, automatisées). Elles donnent lieu à des productions informationnelles standardisées à faible contenu sémiotique, permettant des traitements automatisés. Cette information est moins investie de la subjectivité des transactants et le vocabulaire utilisé est entièrement défini » (Zacklad, 2006). Les productions informationnelles pérennisées peuvent donner lieu à des pseudo-documents codifiés, pouvant être stables comme les fichiers de programme (*documents de codage*) ou à articulation fréquente comme les BDDs (*documents articulatoires*) (Zacklad, 2004b). Nous utilisons cette classification des transactions, que nous résumons dans le tableau 1.2, pour situer théoriquement le processus de redocumentation et les processus sous-jacents à celui-ci.

1.3.2 La redocumentation dans le cadre des TCs

Dans le cadre de la théorie des transactions communicationnelles, nous définissons les différents processus de *documentation*, de *documentarisation* et de *redocumentation* ; puis nous définissons le nouveau processus de *redocumentation* que nous introduisons.

1.3.2.1 Le processus de documentation

Documenter quelque chose peut renvoyer à l'utilisation de documents existants pour le décrire, mais correspond le plus souvent à la création d'un nouveau document. Cette création implique l'utilisation implicite d'un ensemble d'attributs permettant d'en organiser le contenu et d'en assurer la gestion parmi d'autres (Salain, 2007). Le processus de documentation est souvent réalisé dans le cadre d'une transaction communicationnelle symbolique ; la production sémiotique de celle-ci est toujours pérennisée dans un document peu codifié. Toutefois, si le processus de documentation est automatisé, alors il se réalise dans le cadre d'une transaction informationnelle standardisée ; la production informationnelle de celle-ci est pérennisée dans un document entièrement codifié.

1.3.2.2 Le processus de documentarisation

La *documentarisation*, telle qu'elle a été définie par M. Zacklad (Zacklad, 2006), se limite à l'exploitation du support d'un document pour doter celui-ci d'attributs facilitant l'accès à son contenu. Il s'agit donc d'une optimisation de l'usage du document qui n'implique en aucun cas la création d'un nouveau document ou la perte de valeur du document documentarisé (par suppression ou par reformulation du contenu). Partant de l'idée que l'indexation et l'annotation de documents à base de ressources terminologiques ou ontologiques sont des pratiques de documentarisation, et en se situant dans le cadre des transactions communicationnelles ; le processus de documentarisation peut se réaliser, aussi bien dans le cadre d'une transaction communicationnelle symbolique (avec soi-même), que dans celui d'une transaction

informationnelle standardisée. Cependant, la production d'une telle transaction est non pérennisée dans un document.

1.3.2.3 Le processus de redocumentarisation

La redocumentarisation, telle qu'elle a été définie par Zacklad (Zacklad, 2007), est liée à une problématique d'accès et de mise en contexte comme la documentarisation ; mais l'accès est *second* et plus *subjectif*, par opposition à l'accès *primaire* de la documentarisation éventuellement plus *objectif*. Le processus de redocumentarisation s'effectue dans le cadre d'une transaction communicationnelle symbolique dont le résultat est la ré-articulation du contenu d'une production sémiotique initiale (contenu des documents initiaux) par de nouveaux bénéficiaires. Le transactant peut être singulier (avec soi-même) ou un groupe. La production d'une telle transaction peut être parfois pérennisée dans *un document peu codifié (document pour l'action)* entaché de subjectivité (Zacklad, 2006), d'autant plus si beaucoup d'annotations contributives ont été rajoutées.

1.3.2.4 Le processus de redocumentation

Nous supposons que la redocumentation s'effectue dans le but de réarranger le contenu des documents initiaux, de filtrer ce contenu, de lui rajouter des informations issues d'autres sources extérieures, *etc.* Elle se distingue de la redocumentarisation par la possibilité de reformuler complètement le contenu des documents initiaux (réécriture au sens large), de les présenter autrement, ainsi que de les interpréter explicitement (argumenter/commenter le contenu initial) dans un nouveau document à part entière (par opposition à un document enrichi). Le processus de redocumentation s'effectue dans le cadre d'une transaction communicationnelle symbolique, entre une personne et elle-même ou au sein d'un groupe, donnant naissance à une nouvelle production sémiotique médiatisée sur un support pérenne pour former le nouveau document. Nous pouvons ainsi conclure que :

Définition 1.2 : « la redocumentation sous-entend à la fois : (i) une redocumentarisation au travers de la ré-articulation du contenu des documents initiaux selon la vision des nouveaux bénéficiaires, (ii) une documentation à travers la création de nouveaux documents à partir de documents existants (produits d'une documentation antérieure), et (iii) une documentarisation en permettant un meilleur accès aux documents initiaux et à ceux créés ».

Dans le tableau 1.3, nous présentons une synthèse de l'étude comparative des quatre notions définies ci-dessus dans le cadre des transactions communicationnelles. Maintenant, après avoir précisé la notion de *redocumentation* dans un contexte général, la question qui se pose est : en quoi consiste la redocumentation de l'activité médiée informatiquement ? Pour y répondre, nous allons commencer par nous situer dans le contexte de l'activité en général pour définir la documentation de celle-ci.

	Documentation	Documentarisation	Redocumentarisation	Redocumentation
Transaction CS	X	X		
Transaction IC	X	X	X	X
Production pérennisée (doc)	X			X

Tableau 1.3. Synthèse de la comparaison des quatre notions dans le cadre des TC.

1.4 La documentation de l'activité

Bien que la notion d'activité nous paraisse intuitive, il est important de fournir une définition claire pour celle-ci. De façon simplifiée, une activité est définie comme « *un engagement d'un sujet pour atteindre un certain but* » (Luriiia, 1982). Dans la plupart des contextes où le sujet est un être humain, *l'activité (humaine) est médiée par l'utilisation d'instruments établis dans un cadre culturel* tels que les langages, les artefacts, les procédures, etc. Elle est réalisée à travers un *ensemble d'actions qui sont subordonnées à l'idée d'avoir un but conscient*. Nous définissons la documentation de l'activité humaine avec des exemples d'un tel processus ; puis nous nous situons dans le contexte d'un type particulier d'activité qui est l'activité médiée informatiquement.

1.4.1 Définition

Alors que le processus de documentation peut désigner, à la fois, la création de documents et la collecte d'informations et de documents existants pour décrire quelque chose ; nous adaptons cette définition au cas de l'activité comme suit :

Définition 1.3 : « la documentation de l'activité est un processus qui permet d'enregistrer et de collecter des informations, pour décrire celle-ci ou pour fournir une preuve de son déroulement, sous la forme d'un document ou d'une collection de documents, tout en ayant un objectif particulier pour ce processus ».

Ainsi, le fait d'observer le déroulement d'une activité (telle la fabrication manuelle d'un produit) et de prendre des notes pour décrire celui-ci est une façon de documenter cette activité. Cela indépendamment du type du produit d'un tel processus, que ce soit un compte rendu détaillé, de simples informations notées et préservées dans un document intime, un formulaire complété pour décrire des aspects particuliers de l'activité, etc. En outre, l'existence de moyens d'enregistrement (visuels, sonores, audiovisuels, etc.) a rendu désormais la documentation de l'activité plus facile. Par exemple, nous pouvons documenter une excursion à laquelle nous participons via l'enregistrement vidéo du déroulement de celle-ci et le produit est un document vidéo. Nous pouvons également créer et/ou collecter plusieurs documents et informations à son propos tels que des photos (des lieux visités, des personnes présentes, etc.), des vidéos (des scènes, des événements, etc.), des souvenirs, des notes sur nos agendas décrivant certains détails, etc ; et le produit d'un tel processus est une collection de documents. Aujourd'hui, la documentation de l'activité est au cœur des travaux de recherche, en particulier celle de l'activité quotidienne. Des projets innovateurs visent à fournir des systèmes puissants et faciles à utiliser pour supporter celle-ci, en se basant sur une technologie émergente dite *le lifelogging*.

1.4.2 Le lifelogging comme un système de documentation de l'activité informatique

Les recherches sur la documentation de l'activité remontent à 1945 quand Bush a envisagé le Memex (Bush, 1945), un dispositif dans lequel un individu peut stocker et revoir ses documents et ses communications, fournissant ainsi un support étendu à sa mémoire. Plus d'un demi-siècle plus tard, et avec l'évolution des technologies informatiques, des projets ont pu implémenter cette vision à travers la collecte du plus grand nombre possible de données concernant les activités d'un individu. Aujourd'hui, la technologie du *lifelogging* n'est qu'une illustration de cette possibilité de documentation qui rend désormais une telle pratique accessible à tout le monde.

1.4.2.1 Définition du lifelogging

Le *lifelogging* est une *technique permettant d'enregistrer et d'archiver toutes se qui se passe dans votre vie ou durant des périodes déterminées de celle-ci dans des collections riches appelées lifelogs* (Achilleos, 2010). De façon plus technique, le lifelog est *une machine, un logiciel, ou un service Web dédié à l'archivage chronologique des traces de nos activités sous toutes leurs formes* : annotations, articles, présentations, courriers, vidéo, photos, discours audio, *etc.* Il peut être strictement destiné à un usage privé comme c'est souvent le cas de certains logiciels ; il peut également proposer un partage de nos activités en permettant d'importer et d'héberger des documents numériques personnels.

Le lifelogging permet de capturer des données de différentes natures (Byrne and Jones, 2009a) telles que : l'activité sur l'ordinateur pour mémoriser la durée des activités effectuées et le contenu des documents exploités (emails, pages web, document Word, *etc.*) ; l'activité sur le téléphone portable (applications utilisées, appels effectués/reçus, contenu des sms, *etc.*) ; des données biométriques (changement de pouls d'une personne, mouvements des yeux, *etc.*) ; le contexte et l'environnement social ; et l'entourage (photos et enregistrements vidéo pris de façon passive). Pour cela, différents outils et applications peuvent être utilisés tels les logiciels spécialisés de traçage, les capteurs, les caméras (SenseCam), *etc.* Par la suite, les données produites sont regroupées pour former des collections riches décrivant les expériences de la vie quotidienne. Nous pouvons ainsi considérer le lifelogging comme vrai système, au sens large, de documentation de l'activité humaine.

1.4.2.2 Exemples d'application du lifelogging

Depuis plus d'une trentaine d'années et jusqu'à nos jours, plusieurs personnes ont expérimenté le lifelogging, mais de différentes façons (Kevin, 2007). Commenant par Ted Nelson qui a enregistré en 1980 toutes ses conversations téléphoniques et de face à face ; et passant par Steve Mann qui s'est muni en 1990 d'une camera pour enregistrer sa vie quotidienne sur une cassette vidéo ; pour arriver à Goldon Bell qui a commencé, depuis 2000, l'enregistrement de chacun des aspects de sa vie quotidienne et pour une durée de six ans dans le cadre du fameux projet MyLifeBits (Gemmell et al., 2005). Il a porté une caméra avec des capteurs (SensCam) et il a enregistré et archivé chaque manipulation de son clavier, chaque email, chaque communication téléphonique, les photos qu'il a prises, les films qu'il a regardés, les liens des sites qu'il a visités et même chaque fenêtre sur son ordinateur avec la durée de son affichage. Il a composé ainsi une grande base de données décrivant sa vie quotidienne.

Au-delà des expériences individuelles, des projets innovateurs ont visé à supporter le lifelogging. Parmi ceux-ci, le projet LifeLog¹⁵ financé par la défense américaine et permettant de capturer toute sorte d'information sur la vie quotidienne des individus ; mais ce projet a été abandonné par la suite puisqu'il ne respectait plus le droit de la vie privée. Il existe également des sites web qui offrent des utilitaires dédiés au lifelogging tel que SLife¹⁶ qui permet d'enregistrer toute l'activité d'un utilisateur sur son ordinateur (exécutions d'applications, écriture de texte, travail numérique, *etc.*) puis de visualiser graphiquement cette activité et de résumer le temps passé sur certaines tâches ; Daytum¹⁷ qui offre des outils gratuits pour collecter et communiquer des statistiques à propos de notre vie sous différentes formes (tableau de bord personnel, liste d'événements, résultats sportifs, *etc.*) ; ou encore

¹⁵ Lifelog proposer information pamphlet. Defense Advanced Research Projects Agency, Information Processing Technology, 2003

¹⁶ <http://www.slifeweb.com/>

¹⁷ <http://www.daytum.com/>

myrocasm¹⁸ qui permet de partager des informations sur notre vie quotidienne sous la forme de graphes statistiques simples. Dans le monde des réseaux sociaux, Facebook permet désormais à chacun de ses utilisateurs de redécouvrir des choses qu'il a partagées auparavant et de les collecter dans une seule place pour décrire les meilleurs moments de sa vie : pour cela, un nouveau type de profil visuel appelé *timeline*¹⁹ a été introduit pour composer les photos, les vidéos et les données partagées et intéressantes pour un utilisateur, selon leur chronologie dans le temps, et former une histoire de la vie de celui-ci.

Chacun des exemples présentés ci-dessus peut être vu comme une tentative de documentation d'un ou de plusieurs aspects de la vie quotidienne, y compris les activités médiées informatiquement. Toutefois, des questions restent posées : le lifelogging est-il vraiment une illustration du processus de documentation tel que nous l'avons défini ? Son produit (le lifelog) correspond-il à la définition de la notion de *document* ? Et pouvons-nous simplifier la notion de *documentation* à un processus d'enregistrement et de collecte de données ? Nous essayons par la suite de répondre à ses questions, tout en nous situant dans notre contexte particulier de l'activité médiée informatiquement.

1.4.3 La documentation de l'activité informatique

Avant d'aborder la documentation de l'activité médiée informatiquement, nous précisons tout d'abord ce qu'est « *une activité méditée informatiquement* » :

Définition 1.4 : « *toute activité initiée par un humain et supportée par un système informatique permettant l'acquisition, le traitement, le stockage et/ou l'échange de données dans le but de réaliser l'activité en question* ».

La description des activités médiées informatiquement s'avère intéressante, que ce soit à des fins de contrôle, d'apprentissage ou d'analyse de ces activités. Par ailleurs, le système informatique, bien qu'il offre le plus souvent une opportunité inédite à son utilisateur sur les plans efficacité, rapidité et facilité de travail ; rend certains détails du déroulement de l'activité supportée invisible pour l'utilisateur du système. Ainsi, il n'est possible d'aboutir à une description plus ou moins complète de l'activité informatique que si le système utilisé est capable de fournir explicitement à son utilisateur les données décrivant le déroulement de l'activité dans une forme exploitable. Ce sont ces données que nous appelons *trace de l'activité* médiée informatiquement ou simplement *la trace d'activité numérique*.

1.4.3.1 La notion de trace d'activité médiée informatiquement

Une fois mis en service, un système informatique permet souvent de recueillir de nombreuses données à propos de son utilisation dans le cadre de la réalisation d'une activité particulière. Son instrumentation par un module de traçage permet d'observer et d'enregistrer l'interaction d'un utilisateur avec le système durant son activité pour fournir une trace de celle-ci. La trace d'une activité peut être définie comme « *ce qui reste de l'activité et la preuve de son déroulement* ». En se situant dans le contexte de l'activité médiée informatiquement, nous pouvons raffiner cette définition pour souligner la particularité de la trace de celle-ci :

Définition 1.5 : « *la trace d'activité numérique est un ensemble de données numériques collectées suite à l'instrumentation du système informatique utilisé pour observer et enregistrer l'activité de l'utilisateur médiée par le système. Elle peut avoir différentes formes tels le texte (e.g. les fichiers logs), l'image (e.g. les captures d'écrans), la vidéo* ».

¹⁸ <http://mycro.media.mit.edu/>

¹⁹ <http://blog.facebook.com/blog.php?post=10150289612087131>

(*eg., l'enregistrement vidéo de l'interaction de l'utilisation avec le système*), le sens ou toute autre forme hybride ».

Du fait que cette trace est le résultat de l'observation et de l'enregistrement de l'activité en question, la question qui se pose est : est ce que cette trace est le produit d'un processus de documentation de l'activité médiée informatiquement ? Nous essayons de répondre à cette question dans ce qui suit.

1.4.3.2 La trace d'activité est-elle un produit de documentation ?

Alors que la documentation de l'activité consiste à enregistrer et à collecter des informations pour décrire celle-ci sous la forme d'un (de) document(s), nous pouvons assimiler l'observation et l'enregistrement de l'activité médiée informatiquement pour générer la trace de celle-ci à un processus de documentation automatisé. Cependant, nous ne pouvons parler de documentation que si le produit est un document ; or, comment peut-on affirmer que la trace d'activité numérique a vraiment le statut d'un document ?

En reprenant la définition de la notion de *document* selon Pédaüque (Salaün, 2010), la trace d'activité numérique ne peut être considérée comme un document que si elle est à la fois lisible, compréhensible et échangeable par des personnes ordinaires. Nous pensons que les traces d'activités numériques ne vérifient pas forcément ces propriétés, tel le cas des fichiers logs qui sont difficilement exploitables par des utilisateurs ordinaires (au contraire des concepteurs des systèmes). Par ailleurs, nous pouvons considérer ces traces comme des documents dont le statut documentaire est relativement faible. En outre, ces traces peuvent être réparties sur plusieurs fichiers (*eg., un fichier log et un enregistrement vidéo décrivant la même activité informatique*) ; ce qui ne facilite pas leur exploitation conjointe pour fournir une description plus ou moins complète de l'activité informatique concernée.

Notre objectif est d'assurer un produit de documentation de l'activité informatique (1) lisible et (2) compréhensible par des personnes non forcément qualifiées, (3) décrivant l'activité dans toute sa richesse et (4) facilement échangeable. Cela nous a incité à concevoir des processus de redocumentation de l'activité dont le principe est de transformer et de corréliser les traces numériques de celle-ci (produit d'une première documentation de l'activité) au sein d'une nouvelle unité persistante (document), cohérente et compréhensible, décrivant l'activité dans sa richesse.

1.5 Redocumenter l'activité informatique

Alors que le traçage d'une activité médiée informatiquement permet de recueillir des données décrivant celle-ci de façon plus ou moins pertinente et fournissant ainsi le produit d'une première documentation ; le processus de redocumentation tel que nous l'imaginons permet d'exploiter les traces générées automatiquement pour décrire de façon précise, détaillée et compréhensible cette activité dans toute sa richesse. Ce processus aura en entrée la (les) trace(s) d'activité médiée informatiquement et en sortie un nouveau document décrivant l'activité tracée. Dans la suite, nous proposons une définition précise pour ce processus et nous présentons notre vue générale de celui-ci avec des exemples de son application ; nous posons également les questions qui nous semblent importantes à son propos.

1.5.1 Définition de la redocumentation de l'activité informatique

Nous définissons la redocumentation de l'activité médiée informatiquement comme étant :

Définition 1.6 : « un processus interprétatif qui peut impliquer l'utilisateur effectuant l'activité (utilisateur tracé) ou toute autre personne (amis ou collègues de l'utilisateur tracé, analystes, psychologues, concepteurs de systèmes, etc.). Il permet d'exploiter les traces de l'activité, générées automatiquement, afin de les reprendre au sein d'un nouveau document numérique décrivant l'activité tracée selon l'intention et les choix de celui qui redocumente ».

Par conséquent,

Définition 1.7: « redocumenter implique réorganiser, filtrer et réécrire le contenu des traces, y ajouter de nouvelles informations (pour refléter un point de vue particulier ou pour exprimer le contexte de production des traces), ainsi que choisir une forme d'appropriation pour le document produit » (Yahiaoui et al., 2008).

Il est important de souligner que ce processus peut également s'appliquer à un ensemble de traces, voire même de différents utilisateurs, éventuellement pour un travail collectif.

1.5.2 Une vue générale du processus de redocumentation

Nous schématisons notre vue générale pour le processus de redocumentation de l'activité informatique par la figure 1.2. L'entrée du processus est un ensemble de traces d'activité résultantes de l'enregistrement de l'interaction de l'utilisateur tracé avec le système informatique médiatisant son activité. Sa sortie est un document numérique décrivant l'activité tracée de façon personnalisée et facilement échangeable. La personne qui redocumente l'activité peut garder le document produit à titre personnel (document archivé), le destiner à ses proches (document envoyé par mail ou via les réseaux sociaux à la famille, à des amis/collègues), ou le rendre accessible au grand public (document publié sur le web).

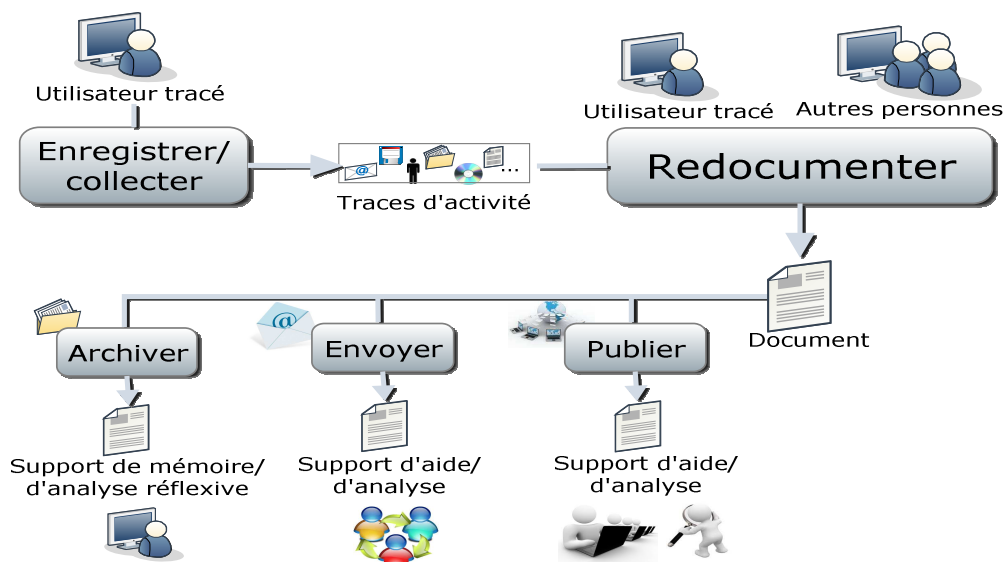


Figure 1.2. Une vue globale du processus de redocumentation de l'activité informatique.

La fonction du document produit dépend de l'objectif de la redocumentation. Lorsque la personne qui redocumente l'activité est l'utilisateur tracé, celui-ci peut conserver le document produit comme *un support de mémoire* ou *d'analyse réflexive* à propos de son activité. Il peut également échanger ce document décrivant son expérience avec d'autres personnes afin de leur servir de *support d'aide à propos de l'activité* (pour des utilisateurs ayant une activité similaire, par exemple), ou encore de *support d'analyse* à propos de l'activité ou du comportement de l'utilisateur tracé (pour des analystes ou des psychologues, par exemple). Le document produit peut garder ces fonctions même si la personne qui redocumente l'activité n'est pas l'utilisateur tracé. Néanmoins, le degré d'engagement dans le processus peut diminuer puisque il ne s'agit plus de redocumenter sa propre activité, et des questions d'éthique et de vie privée se posent (O'Hara et al., 2008). Pour mieux comprendre les fonctions du document produit, nous présentons par la suite quelques exemples d'application du processus.

1.5.3 Exemples d'application du processus

Prenons l'exemple d'un tuteur qui peut redocumenter la trace de son activité d'utilisation d'un système d'apprentissage dans le but de générer un support pédagogique pour les apprenants utilisant le même système. Dans ce document, il peut expliquer la façon de résoudre un problème particulier ; ou encore, il peut décrire les ressources qu'il juge intéressantes à exploiter dans un cas similaire. Toutefois, chaque apprenant peut décrire sa propre activité dans un document personnel où il fournit les détails qui l'intéressent à propos de cette activité (e.g. ce qu'il a fait exactement et pourquoi, les difficultés rencontrées, les erreurs commises, *etc.*). D'une part, ce document peut servir l'apprenant lui-même comme un support de mémoire pour se rappeler de son activité ; il peut également lui servir d'un support pour mener une analyse réflexive à propos de son expérience afin d'améliorer son apprentissage. D'autre part, ce document peut servir d'autres apprenants ou des professionnels du domaine (tuteurs, développeurs de systèmes, analystes, psychologues, *etc.*) concernés par l'analyse de l'activité des apprenants ou de leur comportement.

Parfois, le processus de redocumentation devient plus nécessaire qu'optionnel. Par exemple, si un travailleur du savoir²⁰ doit préparer un rapport d'activité hebdomadaire pour son superviseur, il est évident qu'il ne pourra pas communiquer les traces de son activité dans leur état brut ; il devra plutôt construire un document lisible et cohérent à partir de ces traces dans lequel il pourra résumer et justifier ses actions. En outre, à travers le processus de redocumentation, il pourra se disposer d'une mémoire organisationnelle de ses activités informatiques multiples facilitant ainsi son travail.

1.5.4 Questions posées par la redocumentation de l'activité

Après avoir présenté une étude de la notion de *redocumentation*, ainsi que l'application d'un tel processus pour l'activité médiée informatiquement à base de ses traces ; nous pouvons présenter quelques questions de fond qui exigent des réponses et parfois des suppositions à considérer ou des choix à faire. A travers la définition que nous avons proposée pour le processus de redocumentation et la vue générale que nous avons schématisée pour celui-ci, nous avons pu répondre à deux questions importantes qui sont : qui redocumente ? et pourquoi ? Une autre question importante concerne le moment d'application du processus de redocumentation, durant la réalisation de l'activité tracée ou après son achèvement, mais n'a

²⁰ traduction de *knowledge worker* : un individu qualifié pour sa capacité d'agir et de communiquer avec des connaissances dans un domaine spécifique et utilisant souvent des systèmes informatiques.

pas été évoquée explicitement (quoi que nous ayons supposé une redocumentation *a posteriori* pour des raisons de simplicité²¹).

Toutefois, nous pensons qu'il nous reste à répondre à d'autres questions que nous avons réparti dans quatre catégories comme suit : les questions concernant la faisabilité du processus du point de vue théorique, les questions concernant l'entrée du processus (la trace), les questions concernant la sortie du processus (le document produit) et finalement les questions concernant la mise en place concrète du processus. Chacune de ces questions entraîne d'autres questions plus spécifiques, liées aux différentes possibilités présentes et aux contraintes imposées par le contexte d'application de la redocumentation.

1.5.4.1 Questions sur la faisabilité du processus de redocumentation

La redocumentation de l'activité informatique suppose une mise en correspondance entre la trace de l'activité d'une part, et le document produit d'autre part. Cependant, de nombreuses questions se posent : quel lien peut-il y avoir entre une trace et un document, en particulier dans l'environnement numérique ? Quels sont les points en communs entre les deux notions ? Quelles sont les particularités qui distinguent l'une de l'autre ? Que peut contenir une trace, et qui soit difficilement exprimable dans un document ? En transformant une trace en un document, que peut-on perdre ? Est ce que toutes les traces d'interaction peuvent être transformées en documents numériques, ou juste un sous-ensemble ? Peut on considérer tout document comme une trace ? *etc.*

Pour pouvoir répondre à ces questions, nous devons analyser les notions de trace et de document, en particulier dans le contexte numérique, afin de déduire les points de similarité et de différence entre ces deux notions et pouvoir ainsi justifier le processus de redocumentation en question. Nous consacrons par la suite un chapitre en entier pour chacune des notions, puis nous discutons leur mise en correspondance.

1.5.4.2 Questions sur l'entrée du processus de redocumentation

Alors que le principe du processus de redocumentation de l'activité informatique tel que nous l'avons présenté est d'exploiter les traces de l'activité à l'entrée ; il est temps de se poser des questions sur ces traces : quelle forme auront les traces d'activité ? Quel modèle auront ces traces ? Quel modèle pour le processus de traçage de l'activité ? Faut il supposer un modèle pour l'activité tracée et lequel ? Pour pouvoir répondre à ces questions, nous devons étudier de façon détaillée la notion de *trace* en général, puis de celle de trace d'activité numérique plus particulièrement.

1.5.4.3 Questions sur la sortie du processus de redocumentation

Du fait que le produit du processus de redocumentation de l'activité informatique est un document numérique, nous pouvons nous interroger sur celui-ci : quelle forme choisir pour ce document ? Quelle modalité d'appropriation pour celui-ci ? Comment peut-on modéliser ce document ? Quel genre pourra-il avoir ? Quel lien pourra il avoir avec la trace de l'activité ? Que pouvons nous garder de la trace d'activité dans le document ? ... Les réponses à ces questions exigent avant tout une étude détaillée de la notion de *document* en général, puis de celle du document numérique en particulier.

²¹ L'idée est d'éviter le chevauchement possible entre le processus de redocumentation et l'activité tracée elle-même

1.5.4.4 Questions sur la mise en place du processus de redocumentation

Pour la mise en place concrète du processus de redocumentation, les questions fondamentales qui peuvent se poser sont : quelles sont les étapes à définir pour le processus de redocumentation ? Quelle approche adopter pour celui-ci (manuelle ou automatique) ? Quelles bases théoriques exploiter, quelles technologies et outils utiliser ? *etc.* Toutes ces questions sont liées à la logique du processus de documentation lui-même. Nous pouvons également nous interroger : quelles propriétés de la trace(s) sont à garder partiellement ou totalement ou à ne pas garder du tout dans le document généré ? La personne qui redocumente, qu'il s'agisse de l'utilisateur tracé lui-même ou une autre personne, a-t-elle la possibilité d'intervenir sur les traces ou encore sur le document résultant (possibilité de modifier, d'ajouter, ou de supprimer des parties du document obtenu) ? Cela peut-il avoir une influence sur la vie privée de l'utilisateur tracé puisque des informations intimes contenues dans ses traces d'activité peuvent être manipulées par d'autres personnes ?

En outre, la logique interprétative du processus de redocumentation implique une certaine subjectivité de la personne qui redocumente sur le contenu des traces ; d'autant plus qu'il peut supprimer des parties de ce contenu. Cela peut entraîner une falsification du contenu des traces et fait perdre au document produit sa valeur de preuve héritée de la trace d'origine. Nous essayons par la suite de répondre à ces questions mais nous mettons de côté les questions d'éthique et de la vie privée.

1.6 Conclusion

Une fois mis en service, un système informatique permet souvent de recueillir de nombreuses données à propos de son utilisation ; ainsi, lorsqu'il supporte l'activité d'un utilisateur, il peut être instrumenté pour observer et enregistrer l'interaction de celui-ci sous forme de traces numériques. Ces traces, qui sont des ensembles de données numériques ayant différentes formes (e.g. fichiers logs, captures d'écrans, enregistrement vidéo, *etc.*), peuvent servir à décrire l'activité médiée informatiquement et forment ainsi le produit d'une première documentation de celle-ci. Cependant, la question qui se pose à ce niveau est : qu'est ce qu'une documentation de l'activité informatique ? Pour répondre à cette question, nous avons fait une étude profonde de la notion de *documentation* qui est visiblement liée à celle de *document*. Alors que la documentation peut être définie comme un processus qui produit des documents pour décrire quelque chose ; la notion de *document* est plutôt plus complexe qu'elle le paraît. Le premier intérêt pour une théorie du document ne s'est manifesté qu'au début du XX^{ème} siècle avec Paul Otlet et Suzanne Briet et le document a été défini comme « *tout indice concret ou symbolique, conservé ou enregistré, aux fins de représenter, de reconstituer ou de prouver un phénomène physique ou intellectuel* ». Puis avec l'émergence des technologies numériques qui ont fait perdre au document sa stabilité comme un objet matériel, une nouvelle théorie du document a vu le jour. Celle-ci a défini le document à travers ses trois dimensions complémentaires : « *la forme comme un objet matériel ou immatériel, le signe (le contenu) comme un porteur de sens et le médium comme un vecteur de communication* » ; alors on ne peut considérer quelque chose comme document que s'il peut être vu (lisibilité), lu (intelligibilité) et su (sociabilité). Par ailleurs, les traces numériques n'ont pas souvent ces trois propriétés et cela rend leur statut documentaire faible.

Nous désirons en effet utiliser les résultats de la documentation de l'activité pour des échanges avec soi-même (mémoire, réflexivité) ou avec d'autres personnes (analyse de comportement, partage d'expérience de l'utilisateur tracé) ; alors, deux processus permettent de renforcer le statut documentaire des traces. Tout d'abord, la documentarisation des traces

qui se base sur l'exploitation de leurs supports afin d'en faciliter l'accès au contenu selon une dimension interne et externe (catalogage, indexation, mise en forme, *etc.*). Ensuite la redocumentarisation, qui offre plus de liberté pour réarticuler le contenu des traces selon leur interprétation et leurs usages, tout en préservant la valeur de preuve de ces traces et sans produire de nouveaux documents. Cela n'est pas suffisant pour nos besoins, et nous proposons donc le concept de redocumentation des traces, que nous avons exposé dans le cadre théorique des transactions communicationnelles. Au cours d'un tel processus, un utilisateur (pas forcément l'utilisateur tracé) interprète et réécrit les traces dans un nouveau document qui correspondra à un genre particulier. Un tel document peut décrire l'activité dans toute sa richesse car il est possible de reformuler le contenu des traces, de l'enrichir avec d'autres informations (e.g. commentaires, annotations, justifications ou informations sur le contexte, *etc.*), de supprimer des parties, voire de le réécrire entièrement. On renforce ainsi le statut documentaire du résultat selon les trois dimensions de la lisibilité, de l'intelligibilité et de l'échange sur le plan social.

Toutefois, un certain nombre de questions se posent, notamment : comment réaliser pratiquement la redocumentation ? Quelles formes et quels modèles pour les traces numériques ? Quelles formes et quelles modalités d'appropriation pour les documents résultants ? Quelles technologies et quelles bases théoriques pour implémenter le processus de redocumentation ? Faut-il gérer ces documents en gardant des liens avec les traces qu'ils redocumentent ? Dans quelle mesure peut-on conserver la temporalité de la trace dans le document résultant ? *etc.* Nous essayons de répondre à toutes ces questions dans la suite de ce manuscrit ; mais nous tenons, tout d'abord, à analyser de façon plus profonde les deux notions qui seront mises en correspondance via le processus de redocumentation et qui sont la trace d'activité informatique et le document numérique. Nous consacrons ainsi un chapitre entier à chacune des deux notions.

Chapitre 2 : La trace d'activité numérique et son utilisation

2.1 Introduction

Le concept de « *trace* » semble être une notion bien connue ; pourtant, une simple recherche de sa définition dans le dictionnaire rend compte de l'ambiguïté d'une telle notion qui peut désigner²² à la fois *une marque physique ou morale, une suite d'empreintes sur le sol, une faible quantité d'une substance, et encore l'intersection de deux plans*. Il s'agit de différentes acceptations liées principalement aux domaines d'utilisation de la trace (mathématiques, histoire, chimie, etc). Dans notre contexte particulier de l'activité médiée informatiquement, nous appelons la trace d'une telle activité une *trace numérique*. Pour définir celle-ci, nous commençons par reprendre la définition de Wikipédia²³ qui généralise la notion de *trace* à *l'influence d'un événement sur son environnement*. Ainsi, nous pouvons dire que la trace numérique *est l'influence de l'activité informatique sur son environnement* ; bien que le périmètre de cet environnement dépende de son contexte d'utilisation et « puisse aller d'une simple fenêtre de configuration d'une application jusqu'à l'ensemble des outils disponibles à l'utilisateur à un instant donné » (Mille and Prié, 2006). En outre, il est important de définir en quoi consiste cette influence, d'autant plus qu'elle n'est pas matérielle comme c'est le cas pour les traces des activités réalisées dans des environnements réels.

L'objectif de ce chapitre est de fournir une étude de cette notion complexe de trace d'activité numérique et de son utilisation. Pour cela, nous partons de la notion de *trace* dans un contexte général, puis nous raffinons cette définition dans le contexte de l'activité médiée informatiquement. Nous décrivons les caractéristiques de la trace d'activité numérique et ses utilisations possibles, aussi bien dans le cadre d'une exploitation classique, que dans celui d'une exploitation avancée ; nous évoquons également la problématique de la modélisation de celle-ci. Nous présentons un cadre théorique et pratique proposé par notre équipe Silex pour l'ingénierie de ce type de traces baptisé « Système à Base de Traces modélisées » (SBTm). Nous présentons également des exemples de systèmes qui concrétisent cette notion et son utilisation, en mettant l'accent sur les bases théoriques utilisées et les choix de modélisation adoptés.

²² Définition du mot trace dans le dictionnaire Larousse (<http://www.larousse.fr/dictionnaires/francais/trace>)

²³ Définition du mot trace dans wikipedia (<http://fr.wikipedia.org/wiki/Trace>)

2.2 La notion de trace d'activité informatique

2.2.1 Notion de trace

Alors que le mot « *trace* » est dérivé du latin *tractus*²⁴ qui désigne l'action de tirer, le tracé ou la lenteur ; la signification de ce mot a évolué progressivement à travers les siècles. Depuis 1120, la trace se considérait comme toute *empreinte* ou suite d'empreintes laissées par le passage d'un homme, d'un animal ou une chose. Vers 1530, cette dimension matérielle a été néanmoins étendue à une dimension morale avec l'apparition de la notion de « *manière d'agir* » ou de « *l'exemple à suivre* ». En parallèle, un deuxième sens est apparu vers 1250, pour désigner *la marque laissée par ce qui agit sur quelque chose, puis ce qui subsiste du passé*, notamment dans la mémoire (vers 1679). Quant au troisième sens, celui de *la ligne*, il est apparu vers 1439 avec la transposition de l'idée de trace dans le domaine graphique ; le sens moderne de tracer signifiait alors écrire ou marquer (les contours). Depuis 1847, un autre sens a été utilisé pour désigner une petite quantité lorsqu'on parle de la trace d'une substance ; un sens qui a été développé à la fin du XIX^{ème} siècle dans le cadre du paradigme indiciare (Ginzburg, 1989). Ce paradigme est basé sur la notion de traces infinitésimales permettant de saisir une réalité plus profonde (eg. indices pour les détectives). Récemment, B.Latour a fourni un autre sens à la trace dans le contexte de la traçabilité de la science en action. Il définit les traces comme *des inscriptions ou des traductions, prélevées ou produites de toutes pièces, permettant de reconstituer les processus de transformations entre le monde réel et le langage* (Latour, 2007).

A travers cette histoire du mot « trace », Alexandre Serres a pu fixer quatre points d'entrée faisant appel à différents penseurs pour mieux dessiner les contours de cette notion (Serres, 2002) :

- La trace comme *une empreinte* ou une *marque physique* au sens de Paul Ricoeur ; mais cela englobe également *la trace affective*²⁵, *la trace cérébrale*²⁶ et la trace écrite éventuellement archivée sur un support matériel.
- La trace comme une *petite quantité* ou un *indice* au sens de Carlo Ginzburg.
- La trace comme *une mémoire*, utilisée surtout en histoire, et dont le sens inclut, d'une part, *le témoignage* déposé et critiqué, et d'autre part *l'indice* repéré et décrypté tels les fossiles. Ceci peut renvoyer également à la notion de *document*.
- La trace comme une *ligne* ou une *écriture* au sens de Jacques Derrida qui a élaboré une véritable pensée de la trace, à travers la notion d'archi-écriture (Derrida, 1972) ; une écriture généralisée dans le sens où la structure de la trace fait communiquer sans qu'on puisse les séparer (i) le rapport à l'autre, (ii) le mouvement de la temporalisation et (iii) le langage comme écriture. Cependant, il insiste sur l'idée que *la trace est quelque chose qui part d'une origine, mais qui se sépare aussitôt d'elle pour former un reste qui peut se perdre*²⁷. Cette notion va bien au-delà de ce qu'on appelle l'inscription sur un support connu car il y a trace dès qu'il y a de l'expérience, renvoyant ainsi à une autre chose ou à un autre moment.

²⁴ définition extraite du dictionnaire historique de la langue française d'Alain Rey.

²⁵ Trace affective : l'affection résultant du choc d'un événement

²⁶ Trace cérébrale : trace mnésique servant à la connexion des impressions du monde extérieur et des empreintes matérielles dans le cerveau

²⁷ Extrait d'un dialogue avec J. Derrida (2002) : http://www.jacquesderrida.com.ar/frances/trace_archive.htm

D'après cette synthèse philosophique liée principalement aux sciences humaines et sociales, il apparaît que la notion de *trace* recouvre diverses pensées, pour se situer entre l'empreinte, le reste, la mémoire, l'indice et l'écriture ; voire même combiner ces différents rôles. Pour les disciplines scientifiques, les traces sont les « *output* » de la connaissance, ou les matériaux de la reconstitution de preuves de l'activité scientifique. En technologie de l'information et de la communication plus particulièrement, où tout processus communicationnel produit des traces écrites ou non écrites (textes, données, empreintes, *etc.*), l'observation de ce processus communicationnel passe nécessairement par la collecte de ses traces, leur tri et parfois leur organisation en documents. Cela s'applique également à l'interaction d'un être humain avec un système informatique qu'il utilise pour médier son activité. Dans ce domaine, la trace a sa place, sans pour autant constituer un objet matériel ; alors, comment peut-on définir la trace d'une activité médiée par un système informatique ?.

2.2.2 Notion de trace d'activité numérique

2.2.2.1 Spécificité de la notion de trace d'activité numérique

En essayant de projeter l'une des définitions de la notion de *trace* sur la trace d'activité numérique, nous pensons que cette notion couvre les rôles, à la fois, de *marque* laissée par une activité supportée par un système informatique (ou ce qui *reste* de celle-ci), et *d'écriture* au sens de Derrida, d'autant plus lorsqu'il relie la notion de *trace* à celle d'expérience (Derrida, 1972). Bien que la marque ait souvent une existence matérielle, ce qui est le cas des traces des activités qui se déroulent dans un environnement réel ; dans un environnement numérique virtuel, *la dématérialisation des supports fait disparaître les conditions d'émergence et d'existence des traces d'activité* (Laflaquière, 2009). De ce fait, la trace d'activité numérique ne peut exister que via une écriture (au sens large) permettant de matérialiser et de préserver celle-ci ; mais cette possibilité d'inscription ne vient en second lieu puisque la trace d'activité numérique n'a pas une existence *a priori*. Cela veut dire que cette trace est construite au moment de son inscription comme un ensemble d'informations observées et enregistrées ; à condition que le système informatique médiatisant l'activité ait cette capacité d'inscription.

Si la notion de *trace numérique* est prise dans le sens « *reste* » de l'activité , nous pouvons imaginer que le produit final d'une telle activité forme une trace de celle-ci, tel le cas d'un rapport produit par l'activité d'utilisation d'un éditeur comme Latex. Cependant, cette trace ne fournit en aucun cas des informations sur l'utilisation du système informatique (l'utilisation des commandes et des options de l'éditeur Latex pour notre exemple). Nous constatons, par ailleurs, que la notion de trace d'activité numérique est souvent liée à l'historique des actions effectuées dans le cadre de l'activité (e.g. historique de navigation sur le web, fichier log décrivant la liste des commandes exécutées par un système, *etc.*) ; sans pour autant négliger les produits de l'activité en question. Ainsi, une trace peut comporter les informations décrivant en détails l'utilisation du système informatique médiatisant l'activité (actions de l'utilisateur, commandes du système utilisées, *etc.*) et les produits de cette utilisation. A un niveau plus haut, nous parlons plutôt de l'interaction d'un utilisateur avec un système informatique médiatisant son activité et nous définissons la trace d'activité numérique dans un premier temps comme suit :

Définition 2.1 : « *une trace d'activité numérique est un ensemble de données enregistrées à propos de l'interaction d'un utilisateur avec un système informatique médiatisant son activité, et dont l'enregistrement est provoqué par cette interaction* ».

2.2.2.2 La trace d'activité numérique comme une trace d'interaction

Selon Baker et Lund, une interaction est une suite d'actions (verbales ou non-verbales) entre deux ou plusieurs sujets, qui sont interdépendantes (Baker and Lund, 1997). Les sujets peuvent être des humains ou un humain et une machine ; mais dans le second cas, Alain Mille préfère parler plutôt *d'actions-réactions* (Mille, 2006a). Dans tous les cas, il est important de souligner le mot « *suite* », qui sous-entend une relation d'ordre entre les actions effectuées dans le cadre de l'interaction.

La trace d'activité numérique, en tant que trace l'interaction, est ainsi composée d'un ensemble de données enregistrées à propos des actions de l'utilisateur d'un système informatique médiatisant son activité et des réactions de celui-ci. Pour que l'enregistrement de ces données soit provoqué par l'interaction en question, il est impératif de pouvoir observer cette interaction ; alors le croisement entre le processus d'observation de l'interaction et celui de l'enregistrement de données à propos de celle-ci forme ce que nous appelons par la suite le *processus de traçage* de l'activité informatique. Les données enregistrées à propos de l'activité peuvent décrire chacune des actions effectuées par l'utilisateur (à travers son type, des informations sur les éléments qu'elle manipule, ses produits éventuellement, *etc.*) ; elles peuvent également décrire chacune des réactions du système utilisé (à travers des informations sur l'état de celui-ci suite à sa réaction, sa transition, le résultat ou le produit d'une telle transition, *etc.*). Mais l'information primordiale à ne pas négliger c'est bien la chronologie selon laquelle se réalisent ces actions-réactions (Settouti, 2010), d'autant plus que c'est cet ordre-là qui détermine la réalisation de l'activité en question. Ainsi, nous raffinons la définition de la trace d'activité numérique comme suit :

Définition 2.2 : « *une trace d'activité numérique est un ensemble de données enregistrées pour décrire les actions-réactions entre un utilisateur ayant une activité à réaliser et un système informatique médiatisant cette activité, issues de l'observation de cette interaction et ordonnées selon la chronologie de celle-ci pour fournir une description plus ou moins fiable de l'activité réalisée* ».

Parfois, la notion de *trace numérique d'interaction* peut désigner un sens différent du nôtre que nous préférons décrire ici pour éviter toute confusion. Elle peut être considérée comme un ensemble de données inscrites par un humain suite à une observation, dans le cadre d'un travail intellectuel. Un exemple simple est l'annotation d'un document numérique produite suite à l'interprétation d'une observation faite du document par un humain interagissant avec un système informatique dans le cadre d'une activité de lecture. Pour les psycholinguistes et cognitivistes, cette annotation constitue une « *trace de l'état mental du lecteur et une trace de ses réactions vis-à-vis du document* » (Azouaou, 2003) ; or, ce n'est pas le sens qui nous intéresse.

2.2.2.3 Propriétés d'une trace d'activité numérique

En prenant la trace d'activité numérique telle que nous l'avons définie, nous résumons les propriétés principales de celle-ci comme suit :

a) **Une trace passive et non intentionnelle** : les utilisateurs d'un système informatique (site, logiciel, *etc.*) prennent parfois l'initiative de laisser explicitement des données à propos de l'utilisation de celui-ci (un courrier électronique adressé aux gestionnaires de l'application par exemple) pour former, une fois récoltées, des traces actives de cette utilisation. Cependant, la trace d'activité numérique est souvent passive dans le sens où elle est laissée involontairement par l'utilisateur d'un système informatique ; c'est le système informatique lui-même qui doit pouvoir enregistrer et collecter des informations à propos de l'interaction de

son utilisateur (avec lui) sous forme de trace d'activité. La trace d'activité numérique est également non intentionnelle du fait qu'elle ne représente, ni un produit direct des actions de l'utilisateur, ni une marque laissée par son activité. Il s'agit plutôt de données enregistrées et ouvertes à une interprétation plus ou moins subjective. D'ailleurs, depuis plusieurs années, le CNIL²⁸ a mis en évidence la notion « *de trace passive* », à côté de celle de « *données structurées* » comme suit : « *les traces passives sont considérées comme des éléments parcellaires, recueillis ou non dans un fichier local, formant un ensemble diffus et éclaté de mémoire que l'on pourra exploiter et décrypter en cas de besoin* » (Lemoine, 2005). En raison de l'importance de l'interprétation pour ce type de traces, Laflaquière (2009) préfère définir la trace numérique comme « *un faisceau d'indices formant un signe interprété par un observateur sujet à l'erreur* » puisque, selon Ferrer (Ferrer, 1997), c'est la propriété des indices « *de produire de la signification de manière involontaire* ».

b) ***Une trace composée et inscrite*** : la trace d'activité numérique est une trace composée dans le sens où il s'agit d'une trace artificielle (contrairement à une trace réelle), constituée d'un ensemble de données collectées par le système informatique médiatisant l'activité à propos du déroulement de celle-ci. Ainsi, dans un environnement numérique, le système informatique doit être instrumenté pour pouvoir créer artificiellement une possibilité d'inscription pour ces données et former des traces similaires à celles laissées dans un environnement matériel ; mais cette possibilité exige du concepteur du système de décrire clairement en quoi va consister cette trace et de quelle manière elle sera construite. En d'autres termes, il faut déterminer exactement ce qui sera enregistré (et non enregistré) à propos de l'interaction de l'utilisateur avec le système médiatisant son activité ; bien que ces choix fragilisent le statut de ce type de trace comme *tout ce qui reste de l'activité* en question.

c) ***Une trace structurée temporellement et conservée*** : en partant du constat que l'interaction d'un utilisateur avec un système informatique médiatisant son activité est définie à base d'une suite d'actions-réactions ; il est important que la trace d'activité numérique puisse refléter cette chronologie. Pour cela, elle sera composée de données enregistrées à propos de ces actions-réactions et structurées temporellement selon la chronologie de celles-ci afin de former un *historique de l'interaction*. Cette trace est par la suite conservée souvent pour une durée déterminée, mais aussi longtemps que nécessaire pour servir à un objectif particulier. Les traces numériques peuvent aussitôt se cumuler pour former des collections riches et parfois volumineuses. Leur exploitation peut servir différents domaines comme nous allons le montrer dans ce qui suit.

2.3 Utilisation des traces d'activité numériques

Si les traces des activités numériques sont conservées, c'est bien pour servir à quelque chose²⁹. Les intérêts sous-jacents à l'exploitation des traces d'interaction ont évolué et se sont multipliés au cours du temps. Au départ, ils se concentraient plus autour de l'évaluation et de la maintenance des systèmes informatiques utilisés, que ce soit pour un besoin correctif ou évolutif de ceux-ci, et la forme la plus utilisée pour les traces d'interaction était « *le fichier log* » (ou *fichier journal*) ; un *fichier texte qui reprend de façon chronologique l'ensemble des événements qui ont affecté le système informatique utilisé* (un logiciel, une application, un

²⁸ Commission Nationale de l'Informatique et des Libertés : <http://www.cnil.fr/index.php?id=1>

²⁹ S ans pour autant oublier les problèmes soulevés par la confidentialité et la protection de la vie privée puisque ces traces sont des données personnelles. Il est important (voire obligatoire) d'informer les utilisateurs du traitement qui peut être fait sur leurs données et d'agir en toute transparence, conformément aux règles éthiques

serveur, etc.) et l'ensemble des réactions qui ont résulté de ces événements³⁰. Par la suite, ces intérêts se sont concentrés de plus en plus autour des activités tracées elles-mêmes et des comportements des utilisateurs concernés par celles-ci. Avec les progrès technologiques, les moyens d'enregistrement se sont multipliés, les formes de traces d'activité sont devenues de plus en plus variées (enregistrements vidéo/audio, fichiers structurés, etc.) et les modes d'utilisation de celles-ci ont également évolué. Nous parlons plutôt de systèmes traçants ; des dispositifs mis en place explicitement pour enregistrer les interactions des utilisateurs pour une utilisation spécifique des traces d'activité enregistrées. En se référant à l'objectif sous-jacent à l'exploitation des traces d'interaction, nous pouvons déjà distinguer deux grandes familles de travaux : ceux dont l'objectif est l'analyse d'un sujet (à étudier) à base des traces d'activité et ceux dont l'objectif est de faciliter l'activité tracée elle-même. Mais avant de présenter ces travaux, nous commençons par introduire les systèmes traçants.

2.3.1 Les systèmes traçants

2.3.1.1 Notion de système traçant

Un système traçant est un dispositif qui enregistre systématiquement les interactions d'un utilisateur avec un système informatique, tout en s'intéressant à *la finalité de ces enregistrements* (Laflaquière, 2009). Bien que le système informatique utilisé puisse être instrumenté (par programmation directe ou par rajout d'un plugin) pour pouvoir effectuer ces enregistrements ; des applications voire-même des plate-formes indépendantes peuvent être dédiées à cet objectif. Le système traçant doit pouvoir enregistrer l'interaction de l'utilisateur avec un système informatique comme des données de forme(s) particulière(s), collecter les données enregistrées pour constituer des traces numériques et visualiser celles-ci si besoin ; cela sans pour autant oublier leur exploitation prévue. Ainsi, nous considérons la trace d'interaction numérique comme un objet ayant un cycle de vie qui décrit son évolution à travers le temps.

2.3.1.2 Cycle de vie de la trace d'activité numérique

L'évolution de la trace d'activité numérique comporte trois phases : la collecte des données sur l'interaction, la transformation de ces données, et finalement l'utilisation de la (des) trace(s) résultante(s) (visualisation, exploration, etc.).

a) **La collecte des traces d'interaction** : elle permet de regrouper des informations enregistrées à propos de l'utilisation d'un système informatique (des fichiers log, des enregistrements vidéo ou audio à propos de l'interaction, des annotations de l'utilisateur, des captures d'écran, etc.) ; mais il est important de bien choisir les données à conserver et de décider quand et comment ces données seront collectées. Parfois, l'aspect statique du système utilisé (ses états) est pris en considération avec son aspect dynamique (ses transitions suite à ses réactions) durant la collecte ; mais c'est l'aspect dynamique qui fournit les données temporelles (Ottogalli and Vincent, 1999) souvent utilisées dans la construction des traces d'interaction.

b) **La transformation des traces d'interaction** : elle vise l'aboutissement à des traces plus significatives pour un être humain en permettant à celui-ci de se situer à un certain niveau d'abstraction, plus ou moins adapté à la description de l'activité tracée. Cela par rapport aux données de bas-niveau collectées durant la première phase. La transformation implique la

³⁰ Définition du fichier log : <http://www.dicodunet.com/definitions/hebergement/fichier-log.htm>

sélection, l'abstraction et le ré-encodage (réécriture) des données collectées à propos de l'interaction (Hilbert and Redmiles, 2000) afin de faciliter leur exploitation ultérieure (par l'être humain ou la machine). La sélection sépare les données d'intérêt du bruit, l'abstraction relie ces données à des concepts d'intérêt de haut niveau pour donner un sens à l'utilisateur et le ré-encodage génère de nouvelles données à partir de celles existantes.

c) **La visualisation des traces d'interaction** : c'est une représentation structurée et/ou graphique des données des traces qui permet aux êtres humains d'exploiter leurs capacités d'analyse visuelle et d'interprétation sur celles-ci et parfois d'interagir directement avec la trace graphique. L'objectif peut être, par exemple, l'étude du comportement de l'utilisateur d'un système informatique par un analyste ou l'assistance à cet utilisateur pour s'approprier son environnement informatique afin de franchir la distance entre l'utilisation prévue et l'utilisation réelle du système (Cram, 2007). Bien qu'il existe différents modes de représentation des traces numériques d'interaction, nous pensons qu'il est utile de présenter ceux les plus utilisés.

2.3.1.3 Modes de représentation des traces d'activité numériques

Parmi les modes de représentation les plus utilisés pour les traces numériques nous avons :

- **La ligne de temps** qui utilise un axe de temps et des couleurs différentes pour indiquer les différents types d'événements de la trace, positionnés séquentiellement selon leur chronologie temporelle. Ce mode de représentation est utilisé par le Système LifeLine (Plaisant et al., 1996) qui permet à son utilisateur de parcourir chronologiquement les étapes de sa vie, d'accéder à des informations du passé et de déduire des relations de causalité.
- **La spreadsheet** qui utilise les cellules d'un tableau pour représenter des résultats statistiques calculés à partir des données des traces numériques (tels les logs) ; cela en utilisant différents objets géométriques (diagrammes, cartes, graphiques, etc.). Ce mode de représentation est utilisé par l'outil Log Analyzer (Hanoune and Benabbou, 2006) permettant l'étude des usages le Web ; ou encore par le système MacSHAPA (Sanderson et al., 1994) permettant l'étude des événements de l'interface utilisateur, en positionnant verticalement les événements de la trace d'interaction dans les cellules d'un tableau selon leur temporalité et en utilisant différentes colonnes d'événements pour correspondre aux différents niveaux d'abstraction employés pour la même trace.
- **La visualisation 2D/3D** qui est souvent utilisée pour représenter des résultats statistiques calculés à partir des données des traces, ou à partir de la comparaison de ces données avec un modèle prédéfini. Différents objets géométriques peuvent être utilisés tels les diagrammes, les cartes, les graphiques, la vidéo, etc ; en se référant parfois à un repère de temps. Ce mode de représentation est utilisé par l'outil Log Analyser (Hanoune and Benabbou, 2006) pour modéliser les types d'utilisation d'un site et des statistiques sur les habitudes des internautes ; le système PadPrints (Hightower et al., 1998) qui fournit une carte d'aide à la navigation sur le Web en temps réel ; le système Abstract (Georgeon et al., 2006) qui permet l'interprétation du comportement d'un conducteur de voiture en utilisant des graphiques et de la vidéo ; ou encore le projet CoursVis (Mazza and Dimitrova, 2003) qui représente les données issues de la discussion des étudiants d'une formation à distance et permet de visualiser leurs comportements sociaux avec une représentation matricielle des données de grande taille.

2.3.2 Les traces d'activité numériques comme support d'analyse

Les traces d'activité numériques peuvent faire l'objet de différents types d'analyses que J. Laflaquière a classés selon la nature du sujet étudié (Laflaquière, 2009). Ce sujet peut être le système informatique médiatisant l'activité tracée (interface et fonctionnalités), les comportements des utilisateurs de ce système (usages et utilisations), ou encore les utilisateurs eux-mêmes et leurs activités individuelles ou collectives. Le résultat de cette analyse peut être *la caractérisation* ou *l'évaluation* du sujet étudié (Sanderson and Fisher, 1994). La caractérisation vise à formaliser (ou à modéliser) la description du sujet étudié en s'appuyant sur l'observation de celui-ci et/ou sur des postures théoriques ; alors que l'évaluation de ce sujet repose sur l'utilisation d'un ensemble de critères pour comparer celui-ci à un modèle préétabli. Les techniques d'analyse des traces d'interaction employées sont souvent quantitatives (statistiques) et considèrent ces traces comme des données temporelles séquentielles ; mais le besoin de techniques d'analyse qualitatives n'a cessé de s'accroître.

2.3.2.1 Les traces pour l'analyse des systèmes informatiques

Analyse des systèmes classiques. Les premières exploitations des traces d'interaction avec des systèmes informatiques visent à analyser ces systèmes par leurs concepteurs et/ou administrateurs. Ces traces sont souvent des fichiers log, générés automatiquement par les systèmes (Système d'exploitation, SGBD, application, *etc.*), qui comportent des informations sur les phases d'authentification des utilisateurs, le lancement d'applications, *etc.* Ainsi, leur analyse par les administrateur aide ceux-ci à optimiser les performances de leurs systèmes, à prendre des décisions, à fournir une bonne ressource en cas d'audit (Charbonnaud and Mercier, 2005), à gérer des incidents de sécurité système (Ottogalli and Vincent, 1999 ; Charbonnaud and Mercier, 2005 ; Touch, 2006), *etc.* ; d'autant plus que leur exploitation est rendue facile par des outils appropriés (e.g. *Intel trace analyzer/Collector*³¹, *Oracle trace analyzer*³², *etc.*) qui permettent de produire des statistiques sur l'utilisation d'un système, de mémoriser son évolution et d'étudier l'influence de certains facteurs sur celui-ci. Pour les concepteurs et les développeurs, l'analyse de ces traces leur facilite le travail de conception (Lee, 1996) et de programmation (Étiévant, 2004), ainsi que le débogage et le test de leurs applications (Antipolis, 1990; Bates, 1995; Ducasse et al., 2006). Ils peuvent détecter les erreurs de programmation et améliorer certains aspects de leurs applications, surtout qu'ils disposent d'outils assistants tels que JProbe³³ ; alors que dans le domaine de la rétro-ingénierie, les traces d'interaction leur permettent de compléter la vue statique du système par une vue dynamique (Ducasse et al., 2006).

Analyse des systèmes à interfaces basées-fenêtres. Avec la massification des interfaces à fenêtres dans les années quatre-vingt-dix, l'analyse des systèmes informatiques s'est focalisée sur l'étude de l'ergonomie de celles-ci. Cela sous-entend l'analyse des interfaces de ces systèmes ; mais sans pour autant négliger des contenus fonctionnels accessibles via ces interfaces, en particulier dans le cadre du Web. Ce type d'analyse se base sur deux mesures de qualité : *l'utilité* et *l'utilisabilité*. Selon J. Nielsen, l'utilité d'un système mesure le fait que celui-ci puisse (ou non) fournir à ses utilisateur les fonctionnalités demandées ; alors que son

³¹ Intel Trace Analyzer/collector : un outil qui permet l'analyse des interactions des processus et la visualisation des problèmes de synchronisation dans Windows (<http://software.intel.com/en-us/articles/intel-trace-analyzer/>)

³² Oracle trace analyzer : un outil qui permet de générer des rapports lisibles et bien structurés (en html) à partir des logs d'un SGBD Oracle (http://www.psoug.org/reference/trace_analyzer.html)

³³ JProbe : outil permettant d'analyser la performance d'un programme Java (<http://www.quest.com/jprobe/>)

utilisabilité³⁴ mesure à quel point ce système est facile et agréable à utiliser (Nielsen, 1994). Mais cette analyse nécessite souvent de mettre en place des tests coûteux auprès des utilisateurs ; et l'exploitation des traces d'interaction est présentée comme une approche alternative. Les chercheurs en IHM ont développé des logiciels pour capturer et associer les événements des périphériques d'entrée avec ceux des objets de l'interface utilisateur (pression de boutons, sélection dans une liste, mouvement de fenêtres, *etc.*) (Hilbert and Redmiles, 2000; Brinkman et al., 2006a). Ces données recueillies permettent par la suite une analyse³⁵ des opérations effectuées ; et par conséquent une évaluation des qualités et des défauts de l'interface du système utilisé en se référant à des critères prédéfinis ou à un modèle idéal (e.g. identifier les éléments susceptibles de créer des bugs). Toutefois, il s'agit d'événements de bas niveau qui manquent de sémantique ; c'est pourquoi ces données sont souvent collectés et transformés avant qu'elles acquièrent un niveau d'abstraction significatif.

Parmi ces premiers systèmes traçants, nous avons Playback (Neal and Simons, 1983) ; un système comportant un dispositif de traçage des interactions des utilisateurs qui permet à un analyste de *rejouer a posteriori et pas-à-pas* l'ensemble de ces interactions et de les analyser tout en ayant la possibilité d'y inclure des notes. Ce système permet également d'associer ces interactions à un enregistrement audio-vidéo de l'utilisateur durant la session étudiée, ce qui permet une navigation croisée dans les deux sources de données. Le système MIKE (Olsen and Halversen, 1988) permet, quant à lui, de collecter les événements de l'interface utilisateur puis de les associer aux composants de l'interface qui les ont déclenchés et aux commandes de l'application déclenchées ; cela à travers une description abstraite de l'interface qui modélise explicitement les liens entre les aspects de l'application et les événements de l'interface, de telle sorte à pouvoir interpréter les données collectées dans les logs et de générer des rapports décrivant l'activité. Le système CHIME (Badre and Santos, 1991) permet également d'enregistrer les événements issus de l'interaction avec l'interface d'un système et de transformer ceux-ci en des unités d'interaction abstraites ; des modèles sont construits et réutilisés de façon automatique durant l'analyse de ces traces pour servir au test automatique de l'interface du système utilisé. La plateforme MacSHAPA (Sanderson et al., 1994) à son tour permet la synchronisation d'un enregistrement vidéo et des mouvements de la souris d'un utilisateur ; elle regroupe également un certain nombre d'outils pour traiter (réécrire, encoder, filtrer, *etc.*) les traces d'interaction. Toutefois, il est désormais possible d'effectuer une analyse quantitative des traces interactions en utilisant des outils simples tels que l'éditeur de commande modifié par (Siochi and Roger, 1991) qui permet de générer une transcription automatique des commandes tapées par un utilisateur et des réponses fournies par la machine puis d'appliquer à celle-ci un algorithme de détection de répétition de patterns pour détecter les problèmes d'interaction ; ou encore l'outil Experiscope (Guimbretière et al., 2007) qui permet la visualisation et le traitement des logs d'interaction, tout en offrant à un analyste le choix des types d'opérations à représenter par des digrammes de temps. Au delà de l'analyse des systèmes, l'exploitation des traces d'interaction a fait l'objet de travaux de (re)conception de ces systèmes. Dans le domaine des EIAH en particulier, de nombreux systèmes ont proposé de scénariser *a priori* les activités pédagogiques au sein du système (Koper et al., 2003; Ferraris et al., 2007) ; puis les traces d'interaction ont été

³⁴ L'utilisabilité d'un système est définie par cinq composants : l'apprenabilité de l'utilisation du système, l'efficacité de celui-ci, la mémorabilité de son utilisation, le taux d'erreurs de ses utilisateurs avec les facilités de recouvrement et la satisfaction de ses utilisateurs.

³⁵ Cette analyse peut se faire via des techniques de synchronisation et de recherche, de transformation (par sélection, abstraction et ré-encodage), de calculs statistiques, de détection, de comparaison et de caractérisation de séquences d'événements, de visualisations, etc.

utilisées pour suivre le déroulement effectif du scénario lors d'une session réelle d'utilisation et de le comparer avec le déroulement prévu (Marty et al., 2004, 2007).

Analyse des systèmes basés-web. Les systèmes permettant l'accès au contenu du Web représentent une particularité parce que : (i) l'environnement informatique inclut, à la fois, un navigateur et un contenu informationnel ; (ii) le but de l'utilisation de tels systèmes est avant tout ce contenu Web (i.e. l'information) alors que pour les systèmes interactifs traditionnels c'est la manipulation et/ou la modification de données ; et (iii) les utilisateurs de ces systèmes forment une population non spécifique et leurs activités sont mal définies (il ne s'agit plus d'une situation classique de travail). Par conséquent, l'analyse de ces systèmes ne peut pas se focaliser sur les aspects graphiques de leurs interfaces. Les traces d'interaction, appelées dans ce cas « *traces de navigation* », peuvent comporter des données de natures différentes (e.g., logs enregistrées du côté client ou du côté serveur) à propos des interactions des utilisateurs avec les objets de l'environnement Web (URL, pages, métadonnées, etc.). Elles sont exploitées directement par des spécialistes (Dubois et al., 2000), ou via des systèmes d'analyse automatique (Pirolli et al., 2002), pour étudier l'ergonomie des sites Web. Cette exploitation permet de mettre en évidence les principaux dysfonctionnements et problèmes d'utilisation de ces sites, ce qui permet leur amélioration pour répondre aux besoins de leurs utilisateurs (suivre la logique de ces derniers et prendre en considération les contraintes qui lui sont imposées par le Web telles que les contraintes d'affichage, de temps, de débit, etc.).

2.3.2.2 Les traces pour l'analyse des comportements des utilisateurs

L'exploitation des traces d'interaction dans le but d'analyser les comportements des utilisateurs se matérialise en particulier dans le cadre des systèmes distribués. Mais l'exploitation des traces d'interaction devient difficile lorsque ces données sont collectées à partir de différentes machines ; alors un système de monitoring du système distribué peut servir à surmonter cette difficulté. C'est dans le domaine du Web que les travaux les plus avancés sur le sujet de l'analyse des comportements ont été développés (Srivastava et al., 2000) ; l'interaction se manifeste par une navigation qui vise souvent une recherche d'information. Le traçage de celle-ci est nativement pris en charge, ce qui engendre des fichiers logs largement exploités. Ainsi, cette interaction représente le comportement principal à analyser (Hawkey and Inkpen, 2005) et les traces de navigation sont dénotées « *traces de comportement* » (Pirolli et al., 2002) ; mais l'étude du comportement utilisateur désigne, à la fois, l'analyse de l'utilisation des interfaces des systèmes informatiques (i.e., les navigateurs Web) et l'analyse de l'usage du contenu informationnel accessible (i.e., le contenu Web).

Les traces pour le monitoring de l'utilisation de systèmes distribués. Pour montrer le rôle du monitoring de l'utilisation d'un système distribué dans l'analyse des comportements des utilisateurs de celui-ci, nous prenons l'exemple du projet GRUMPs (Gray et al., 2004). Il s'agit d'un système de monitoring de l'utilisation d'un système distribué où les questions des investigateurs peuvent évoluer selon les réponses du système après l'analyse des traces d'interaction (issues de logs, d'une caméra et de protocoles *thinkaloud*) qui sont distribuées. Ce système de monitoring permet la capture et le transfert des données sur l'interaction ainsi que la préparation et l'analyse de celles-ci tout en offrant différentes possibilités de filtrage, d'abstraction, d'agrégation, de stockage, de visualisation et de génération de rapports hypertextes à partir de ces données. Son principe est de développer un modèle d'étude basé-utilisation où l'activité relie les données sur l'interaction aux objectifs d'investigation en cherchant les patterns pertinents. Ce système a été utilisé pour interpréter les comportements d'un groupe réparti d'étudiants de programmation (Thomas et al., 2003).

Analyse de l'utilisation des navigateurs Web. De nombreux chercheurs se sont intéressés à l'analyse de l'utilisation des navigateurs Web et cela depuis l'apparition des premiers navigateurs (Catledge and Pitkow, 1995; Tausher and Greenberg, 1997; Cockburn et al., 2002). Ils ont exploité les données enregistrées nativement par ces navigateurs (fichiers logs) à propos de leur utilisation pour caractériser ou évaluer celle-ci. Weinreich et al. (2006), par exemple, ont réalisé une étude expérimentale (avec vingt-cinq internautes observés durant plus de trois mois) pour laquelle le navigateur Firefox (1.0) a été instrumenté pour enregistrer les logs de navigation de ses utilisateurs ; puis des traitements systématiques (calculs statistiques, mesures de corrélation entre des variables du log, etc.) ont été appliqués à ces logs pour caractériser le comportement de navigation. Cette étude a montré une baisse significative de l'utilisation du bouton « retour » du navigateur par rapport aux études antérieures, ce qui a été justifié par la fréquence d'utilisation des onglets et des nouvelles fenêtres du navigateur pour maintenir les pages sur lesquelles les internautes pensaient revenir. Hawkey et Inkpen ont également exploité les logs de navigation (Hawkey and Inkpen, 2005) en se basant sur des mesures statistiques (e.g. le nombre de pages visités, le nombre de fenêtres actives, etc.) qu'ils ont représentées graphiquement pour mettre en évidence des patterns temporels susceptibles d'être caractéristiques du comportement de navigation observé.

Analyse de l'usage du Web. L'analyse des interactions des utilisateurs avec le contenu Web est souvent réalisée dans le but d'étudier les parcours des internautes ou le trafic des données sur le Web ; bien que cette analyse puisse être réalisée pour d'autres fins (e.g. la prédiction automatique des actions de l'utilisateur). Les traces de navigation exploitées ne sont pas limitées aux traces d'interaction enregistrées par les navigateurs ; bien que l'histoire de navigation puisse donner une idée claire sur l'exploitation des ressources Web. Elles peuvent provenir de nombreuses sources sur le Web (serveurs, caches, logiciels serveur, etc.). Le fichier log d'un serveur Web, par exemple, conserve les traces des requêtes et des opérations traitées par celui-ci en regroupant les demandes d'accès à chacun des fichiers du serveur et les réponses fournies par celui-ci (Hanoune and Benabbou, 2006). Ainsi, il comporte des données telles que la date et l'heure de la tentative d'accès, l'adresse IP de l'utilisateur, le fichier ciblé, le moteur de recherche utilisé, les erreurs souvenues, etc. Ces traces de navigation peuvent être présentées de façon plus digeste à l'aide de certains outils de synthèse graphique qui peuvent proposer des fonctions basiques (e.g. le comptage du nombre de visiteurs d'un site) ou des analyses plus poussées tels que WebAlizer³⁶, Analog³⁷, ClickTracks³⁸, etc.

Pour étudier des usages du Web, Cockburn et ses collègues se sont basés sur le nombre de fois qu'une page Web a été visitée (Cockburn et al., 2002) ; alors que Hanoune et Benabbou ont développé un analyseur sophistiqué des logs (Hanoune and Benabbou, 2006) et se sont intéressés à la découverte des habitudes des internautes à travers les combinaisons de pages les plus populaires, les navigateurs et les systèmes d'exploitation les plus utilisés, etc. D'autres travaux se sont intéressés à des cas particuliers tels que l'analyse de l'impact de la musique sur les internautes (Galan, 2002) ; ou encore l'étude du trafic des données sur le Web (Patarin, 1999) en caractérisant les échanges d'une communauté répartie d'utilisateurs. Dans son travail de thèse, T. Beauvisage (Beauvisage, 2004) a traité la problématique de la « *sémantique des parcours Web* » en appliquant des traitements statistiques sur les traces de navigation pour

³⁶ Webalyzer : <http://www.dicodunet.com/definitions/hebergement/webalyzer.htm>

³⁷ Analog : <http://www.analog.cx/>

³⁸ ClickTracks : <http://www.clicktracks.com/>

reconstituer des parcours à enrichir ultérieurement à travers le typage des URLs en fonction d'une classification similaire à celle proposée par les annuaires Web ; l'analyse des parcours est faite en tenant compte du contenu à l'aide de techniques de visualisation graphiques. D'autres travaux (Chi, 2002; Chen et al., 2004; Rossi et al., 2005) ont employé des techniques de visualisation des traces de navigation pour faire émerger les points critiques des sites Web (e.g., partie isolée ou peu visitée) ou mettre en évidence les cheminements les plus empruntés (pour rendre facile la modification de la structure de ces sites en fonction des besoins de leurs utilisateurs). Toutefois, nous ne pouvons pas affirmer que l'analyse des traces de navigation permet de caractériser le comportement de l'utilisateur puisque les objectifs et les tâches de celui-ci restent souvent cachés (Weinreich et al., 2006, p. 141). Cela a incité des chercheurs à analyser le comportement des utilisateurs en fonction de leurs activités.

2.3.2.3 Les traces pour l'analyse des utilisateurs et de leurs activités

L'exploitation des traces numériques d'interaction des utilisateurs avec des systèmes informatiques peut servir l'analyse de ces utilisateurs ou de leurs activités. L'analyse des utilisateurs permet la caractérisation de ceux-ci via des modèles utilisateurs plus ou moins formels, ou la validation de modèles existants. Quant à l'analyse des activités des utilisateurs, elle permet la caractérisation ou l'évaluation de la réalisation de celles-ci.

Les traces pour l'analyse des utilisateurs. Durant l'interaction d'un utilisateur avec un système informatique médiatisant son activité, le fait de pouvoir se rendre compte des processus mentaux ou comportementaux de cet utilisateur permet de comprendre et d'expliquer l'activité effectuée. Cela requiert, avant tout, une observation de cet utilisateur durant son interaction ; une chose qui peut se réaliser de façon indirecte par le biais des traces d'interaction. Ainsi, ces traces peuvent être exploitées pour créer des modèles plus ou moins formels de l'utilisateur, ou simplement pour valider ou améliorer des modèles existants (Halvey et al., 2005). Les modèles mentaux ou comportementaux sont à l'origine des concepts en psychologie et en sciences cognitives qui ont acquis un aspect opérationnel dans le domaine informatique. Toutefois, les travaux sur la modélisation de l'utilisateur se confrontent souvent au problème d'inférence des tâches et des buts de l'utilisateur ; alors, différentes techniques sont utilisées, allant des techniques basées-règles aux techniques d'apprentissage machine. Par exemple, des *grammaires d'actions de tâche* (Payne and Green, 1986) ont été utilisées pour spécifier la relation entre les interactions de l'utilisateur et les objectifs/tâches de celui-ci.

Pour l'activité de navigation sur le Web par exemple, le travail de modélisation de l'utilisateur (Pirolli et al., 2002) a cumulé un modèle cognitif et un modèle comportemental. D'une part, les logs de navigation ont été synchronisés et indexés avec un enregistrement vidéo et celui d'un *eye-tracker* pour pouvoir situer (à chaque fois) le point de fixation du regard d'un utilisateur sur l'écran ; la trace d'interaction produite est une suite d'actions de navigation qu'un analyste transcrit à la main pour aboutir à un tableau décrivant les différents événements survenus et leurs sources (log de navigation, vidéo ou *eye-tracker*). D'autre part, le modèle utilisateur proposé est fondé sur un modèle cognitif qui rend compte des phénomènes perceptifs et un modèle comportemental de recherche d'information ; il est implémenté de façon à créer un simulateur d'internaute. Par la suite, les traces d'interactions sont utilisées pour affiner ce modèle de telle sorte à aboutir au modèle utilisateur le plus proche de la réalité. Dans un autre travail (Rauterberg and Fjeld, 1998), les traces d'interaction ont été exploitées pour générer des modèles de tâches réalisées et construire « *le modèle mental de tâche* » d'un utilisateur lors d'une activité de résolution de problème. D'autres travaux ont proposé d'établir des profils utilisateurs en exploitant les traces d'interaction pour déterminer

des comportements types et catégoriser les utilisateurs en fonction de leur type de comportement. Dans le domaine du *Web usage mining*, par exemple, Brinkman et ses collègues se sont intéressés à la création de profils d'internautes (Brinkman et al., 2006b) ; alors que dans le domaine des EIAH, le profilage concerne les apprenants.

Les traces pour l'analyse de l'activité. Pour pouvoir évaluer une activité informatique, il faut disposer d'un ensemble de critères précis ou d'un modèle de référence. Cependant, il est souvent très difficile de disposer à priori d'un tel modèle ; bien qu'il existe parfois des exceptions. Pour les activités pédagogiques dans les EIAH par exemple, les critères d'évaluation de telles activités peuvent être définis en fonction des objectifs pédagogiques visés par le concepteur de l'activité ; cela rend possible la conception de systèmes d'évaluation automatique gérée par les EIAH eux-mêmes. Mais pour réaliser une évaluation qualitative de l'activité pédagogique, seul un enseignant-tuteur directement présent au sein de l'EIAH est capable d'analyser les traces de l'activité des apprenants. Pour accéder à ces traces, il peut utiliser des dispositifs traçants permettant de rejouer la session d'un apprenant tels que DREW (Baker et al., 2003), SimPLE (Plaisant et al., 1999), *etc* ; ou des moyens pour visualiser le parcours de l'apprenant dans l'activité pédagogique tels que les outils REFLET (Després and Coffinet, 2004), Collablogger (Morse and Steves, 2000), *etc*.

Dans le cas le plus général, l'analyse de l'activité sous-entend la caractérisation de celle-ci ; une caractérisation qui se fait le plus souvent avec des indicateurs. Ces indicateurs sont des variables auxquelles sont attribuées une série de caractéristiques (Bratitsis and Dimitracopoulou, 2006) ; ils sont calculés sur les traces numériques de l'activité et mis à la disposition d'un analyste pour que celui-ci puisse tirer une caractérisation de l'activité analysée. Comme exemples d'indicateurs calculés nous avons le nombre d'accès à une ressource en ligne ou le temps passé pour la réalisation de chaque opération dans le travail de Renié (Renié, 2000), le temps passé par un apprenant sur chaque étape de l'activité pédagogique dans l'environnement d'apprentissage ESSAIM (Després and Leroux, 2003)? *etc*. Bien que ces indicateurs soient largement utilisés pour caractériser des activités pédagogiques, ils sont également utilisés pour caractériser d'autres types d'activités telles que celles de recherche d'information sur le Web (Jansen and Pooch, 2000).

Pour caractériser une activité collective, certains chercheurs ont adopté une démarche similaire à celle de la caractérisation des activités individuelles ; par exemple, le travail de (Vortac et al., 1994) sur la caractérisation de l'activité de contrôleurs aériens à partir de l'analyse des logs système en se focalisant sur la caractérisation des comportements caractérisés). Toutefois, d'autres chercheurs ont opté pour des démarches différentes ; dans le domaine des EIAH par exemple, des outils tels que TACSI (Laperrousaz, 2006) et SimPLE (Plaisant et al., 1999) permettent au tuteurs de suivre la progression de plusieurs apprenants en parallèle). Les indicateurs de la collaboration au sein d'un groupe portent souvent sur des dimensions communicatives et participatives supportées par l'environnement informatique utilisé ; par exemple, l'indicateur « *facteur de collaboration* » est basé sur le nombre de messages émis dans l'outil Synergo (Avouris et al., 2004). Cela a incité certains chercheurs (Anjewierden and Efimova, 2006; Mayer et al., 2008) à analyser profondément les traces de communication (i.e. traces d'utilisation de chats et de forums) pour caractériser au mieux la collaboration. Toutefois, le fait que les indicateurs soient des mesures quantitatives produites par des calculs statistiques sur les traces d'activité, met en doute leur capacité à fournir une analyse qualitative de cette activité.

2.3.3 Les traces numériques comme support d'aide à l'activité

Les traces d'une activité médiée par un système informatique peuvent être exploitées pour faciliter et supporter cette activité ; cela en présentant ces traces de façon implicite ou explicite aux utilisateurs du système. Toutefois, la modification de la situation de l'activité par l'intégration des traces de celle-ci ne doit, en aucun cas, alourdir l'interaction ou gêner la réalisation de l'activité. De façon plus précise, la réutilisation des traces d'activité dans ce contexte implique une réutilisation des expériences des utilisateurs tracés ; cela se fait souvent pour l'un des deux objectifs suivants : l'adaptation automatique du système informatique aux besoins de ses utilisateurs ou l'assistance aux utilisateurs du système dans leur activité. Nous détaillons dans ce qui suit chacun de ces objectifs avec des exemples de travaux.

2.3.3.1 Les traces pour l'adaptation du système informatique

Alors que nous avons parlé auparavant du rôle de l'analyse des traces d'activité dans la réingénierie des systèmes informatique utilisés, l'utilisation de ces traces dans l'adaptation automatique du système à sa propre utilisation est un cas différent. Le système informatique peut être considéré comme un ensemble de contenus manipulés par un ensemble d'outils. Alors l'adaptation du système à une utilisation ou à un utilisateur particulier peut désigner une personnalisation de ses contenus ou une adaptation des ses fonctionnalités à travers des processus de recommandation ; une adaptation qui peut se baser sur l'exploitation des traces d'interaction des utilisateurs du système.

La personnalisation des contenus d'un système informatique. Pour un utilisateur particulier, cela consiste à modifier le système de telle sorte à fournir à cet utilisateur des contenus qui correspondent au mieux aux besoins de celui-ci. Des profils utilisateur sont souvent utilisés pour atteindre cet objectif. Dans le cadre du WEB, plusieurs travaux se sont intéressés à l'adaptation automatique des sites Web et de leurs contenus (Chatterjee et al., 2003; Hauser et al., 2009) en utilisant un mécanisme simple qui est celui des *cookies*. Le principe consiste à analyser les parcours de l'internaute sur le site et d'enregistrer cette information sur le poste client, de telle sorte que le serveur puisse consulter celle-ci par la suite (au cours des prochaines visites du site par l'internaute) pour proposer à l'internaute un contenu et une mise en forme adaptés aux préférences de celui-ci. Dans le cadre des EIAH, la personnalisation des contenus des systèmes d'apprentissage se base souvent sur les profils apprenant ; ceux-ci permettent de définir les contenus et l'interface à proposer à chacun des utilisateurs.

L'adaptation des fonctionnalités du système via des processus de recommandation. Celle-ci consiste à proposer à l'utilisateur des actions à faire en fonction du contenu des traces d'interaction de celui-ci. Dans le cadre du Web par exemple, cela consiste à proposer à l'internaute des sites intéressants en fonction des sites déjà visités par celui-ci. Pour cela, les traces de navigation de l'internaute, formées principalement de suites d'URLs, sont analysées statistiquement (en utilisant des règles d'association, des classifications, *etc.*) pour pouvoir anticiper la navigation de celui-ci (Mobasher et al., 2000). En outre, les recommandations destinées à un utilisateur peuvent être déduites de l'analyse des traces d'autres utilisateurs, mais ayant des profils ou des activités similaires. Cela est bien illustré par le système Histview (Terveen et al., 2002) qui fournit des *playlists* de morceaux musicaux qui correspondent au mieux aux goûts d'un utilisateur donné ; cela en fonction des choix antérieurs de celui-ci et de ceux d'autres utilisateurs ayant des *playlists* comportant l'un des choix de cet utilisateur.

2.3.3.2 Les traces pour l'assistance aux utilisateurs dans leur activité

Les traces d'interaction avec un système informatique peuvent être exploitées pour guider ou assister les utilisateurs de ce système dans la réalisation de leur activité. Cette exploitation peut prendre différentes formes, allant d'une simple présentation de données permettant de renseigner au mieux les utilisateurs sur leurs interactions à un soutien explicite de l'activité engagée par ces utilisateurs. Dans le premier cas, l'assistance aux utilisateurs est implicite puisque cette assistance est basée sur une contextualisation et une présentation des interactions de ces utilisateurs ou de certains aspects de celles-ci. Alors que dans le deuxième cas, un soutien de l'activité engagée par ces utilisateurs est explicitement proposé.

La contextualisation et la présentation des interactions pour faciliter l'activité. Cette contextualisation peut concerner les objets manipulés durant les interactions des utilisateurs, les opérations effectuées par ces utilisateurs, ou encore les deux aspects. D'une part, la contextualisation des objets manipulés consiste à utiliser les traces d'interaction pour enrichir ces objets avec des informations sur leur utilisation ; ainsi, lorsque un objet est à nouveau utilisé, l'affichage de *l'histoire interactionnelle* qui le concerne devient une partie de l'objet lui-même (Hill et al., 1992). Cela permet de guider les utilisateurs dans la manipulation de ces objets ; par conséquent, cela permet d'assister de façon indirecte ces utilisateurs dans la réalisation de leur activité. D'autre part, la conceptualisation des opérations effectuées durant les interactions des utilisateurs consiste à créer des historiques d'application qui présentent de façon temporelle les opérations effectuées par un utilisateur dans une application. Ces historiques sont souvent associés à des mécanismes « undo/redo » dans les applications facilitant l'activité de l'utilisateur. Ils se présentent comme une liste de textes ou selon une présentation plus élaborées (e.g. une suite de captures d'écran (Kurlander and Feiner, 1992), une suite de vignettes annotées (Nakamura, 2008), etc.).

Dans le cadre du Web, où les pages sont souvent revisitées, les historiques de navigation créés automatiquement offrent une solution peu coûteuse pour relocaliser les pages déjà consultées. Mais pour redonner plus de sémantique à ces historiques formés de suites d'URLs, des travaux (Hightower et al., 1998; Wexelblat and Maes, 1999) ont opté pour un regroupement des pages dans l'historique en fonction de certains critères (e.g. leur site, leur proximité temporelle, etc.) afin de former des arbres de navigation. Leur objectif est de présenter les utilisations antérieures de ces pages comme faisant partie de l'environnement de l'utilisateur et de pouvoir partager l'expérience que les utilisateurs font des sites. Shirai et al. (2006) ont également proposé une présentation de ce type d'historique sous forme de ligne de temps (Shirai et al., 2006), en mettant en avant la séquence des résultats de recherches ; alors que Lettkeman et al. (2006) a proposé une solution pour construire des historiques de navigation plus utiles en utilisant une technique de combinaison qui segmente de façon semi-automatique l'historique de navigation en tâches, lui applique des heuristiques pour éliminer les pages qui n'ont pas d'intérêt pour l'utilisateur, puis utilise un modèle d'apprentissage sensible aux utilisateurs individuels et à leurs tâches permettant de prévoir quelle est la page Web qui sera visitée une autres fois.

Une autre façon d'enrichir l'interaction d'un utilisateur est de confronter celui-ci avec une trace numérique de l'activité sous-jacente à cette interaction. Par exemple, dans le domaine des EIAH, le système PIXED (Heraud et al., 2004) permet de présenter à l'apprenant la trace de son activité pédagogique pour l'aider à se situer dans celle-ci. Mais lorsque la trace d'activité concerne plusieurs interactions avec différentes applications, cela nécessite une certaine centralisation. Ainsi, Kaptelinin (2003) a créé un environnement qui récupère des événements issus de MS-Office™ pour regrouper ceux-ci par projets avant de les présenter à

l'utilisateur ; tandis qu'une application dédiée, telle que Slife³⁹, permet d'observer et de représenter à l'utilisateur d'un ordinateur ses interactions avec les applications, les documents et les sites Web dans le but d'aider cet utilisateur à prendre conscience du temps passé sur chaque application. Cet utilitaire offre également différentes formes de présentation (une ligne de temps, des diagrammes, *etc.*) et permet à l'utilisateur de créer des catégories de ses activités auxquelles il peut assigner des applications et des documents de la trace de ses interactions.

La ré-exploitation des traces d'interaction pour soutenir l'activité. La ré-exploitation des traces d'interaction des utilisateurs d'un système peut servir à soutenir l'activité engagée par ses utilisateurs, et cela de façon directe ou indirecte. Pour un soutien direct, la ré-exploitation des traces d'interaction se matérialise par une assistance automatique basée sur une réexécution (en partie) de celles-ci (par un utilisateur particulier) afin d'éviter la répétition de certaines séquences d'opérations réalisées auparavant ; ou par des conseils de systèmes dédiés. La réexécution des traces d'interaction peut se faire à travers la sélection d'une partie (à réexécuter) de la trace d'interaction tel que le cas dans le système Collagen (Rich and Sidner, 1997) ; ou via l'utilisation d'une forme d'abstraction semblable à une macro pour un ensemble d'opérations de la trace à répéter tel le cas dans le système CoScripter⁴⁰. Ce système permet d'enregistrer, d'automatiser et de partager des processus effectués dans le navigateur Firefox (e.g. rechercher des informations, compléter des formulaires, *etc.*) ; les actions enregistrées sont stockées sous forme d'instructions dans un script textuel facile à lire, sur le site de CoScripter, pour permettre à toute personne de s'en servir pour réaliser un processus similaire.

Lorsque l'assistance automatique est supportée par des systèmes dédiés, nous parlons plutôt de systèmes conseillers. Ceux-ci exploitent les traces d'interaction en faisant appel à des données (sur les utilisateurs et leur contexte d'interaction) et à des calculs plus ou moins complexes pour pouvoir proposer à un utilisateur particulier des actions ou des opérations à effectuer. Il s'agit ainsi d'assistants capables de prédire les actions des utilisateurs d'un système tels que le système Letizia (Lieberman, 2001) pour la navigation sur le Web ; ou encore le système TaskTracer (Stumpf et al., 2005) pour le travail intellectuel multitâches. Dans le domaine des EIAH et de l'apprentissage collaboratif en particulier, plusieurs systèmes (Goodman et al., 2005; Bratitsis and Dimitracopoulou, 2006) ont été conçus dans le but de proposer aux apprenants des actions pour remédier à certaines situations. Leur principe est de comparer l'état courant de l'interaction à un modèle désiré, maintenu par le système et mis à jour en fonction des connaissances acquises des expériences des apprenants, puis de prendre des décisions à propos de la modération de l'interaction d'un groupe d'apprenants et la manière de guider ceux-ci.

La ré-exploitation des traces d'interaction peut également servir à assister les utilisateurs dans leur activité, mais de façon indirecte. Cela est bien illustré par les systèmes mnésiques ; des dispositifs qui ne permettent ni la réexécution d'opérations (des traces), ni la proposition explicite de conseils à l'utilisateur. Ils permettent tout simplement à l'utilisateur de se rappeler d'une séquence d'opérations afin de mobiliser l'expérience associée à cette séquence. Ainsi, en proposant explicitement cette assistance mnésique, ces systèmes soutiennent indirectement l'activité de l'utilisateur. Le système SPECTER (Schneider et al., 2005) par exemple, permet à son utilisateur d'accéder à la trace de son activité (d'achat d'un CD musical), tout en lui fournissant des épisodes passés dont la similarité avec le contexte présent est grande. De façon similaire, dans le système SHERLOCK (Lesgold et al., 1992) qui propose des activités

³⁹ Slife : <http://www.slifeweb.com/>

⁴⁰ CoScripter : <http://coscripter.researchlabs.ibm.com/coscripter>

pédagogiques pour lesquelles il est capable de donner des explications grâce à un système de dialogue ; les traces d'interaction ont été exploitées pour augmenter les explications fournies à l'utilisateur. Cela en utilisant des explications fournies au passé par le système sur une situation similaire à la situation actuelle et en générant automatiquement un texte comparant les deux situations pour soutenir l'activité d'apprentissage de l'utilisateur.

2.4 SBT : un cadre pour l'ingénierie de la trace d'interaction

Le laboratoire LIRIS⁴¹ est parmi les premiers qui se sont intéressés à l'utilisation de l'expérience des utilisateurs à travers les traces d'interaction dans la conception des systèmes informatiques ; une approche qui s'est avérée utile face à la divergence constatée entre les usages prévus du système (par ses concepteurs) et les usages réels (par ses utilisateurs) de celui-ci (Mille and Prié, 2006). Les premiers travaux du LIRIS concernaient la modélisation de l'expérience de l'utilisateur à travers l'approche MUSETTE⁴² (Champin et al., 2004; Laflaquière et al., 2005) ; une approche dont l'objectif est la réutilisation de cette expérience en contexte, pour assister l'utilisateur dans la réalisation de sa tâche. Par ailleurs, cette approche impose une forte contrainte sur la structuration de la trace d'interaction en modélisant celle-ci comme une séquence d'états et de transitions. De plus, l'objet trace, ayant une existence à part entière, n'est pas étudié dans un cadre qui lui soit propre avec les différents mécanismes nécessaires à sa modélisation, à son traitement et à ses usages. Dans cette perspective, les recherches au sein de l'équipe SILEX⁴³ ont ciblé la proposition d'un cadre général permettant une formalisation des traces et de leur manipulation. Cela a donné naissance à une vraie théorie de la trace informatique supportée par un cadre aussi bien pratique que théorique baptisé « *Système à Base de Traces modélisées (SBTm)* » (Settouti, 2010). Dans ce qui suit, nous décrivons ce cadre, sa modélisation pour les traces d'intégration, son architecture et ses services ; ainsi que des exemples de travaux basés sur le SBTm.

2.4.1 Notion du système à base de traces modélisées (SBTm)

La notion de « *Système à Base de Traces modélisées* » désigne une classe particulière de systèmes à base de connaissances qui nécessitent, à la fois, la modélisation des connaissances constituant les traces d'interaction et la manipulation de ces traces pour inférer de nouvelles connaissances. Le but est de pouvoir penser les traces d'interaction de façon générique et de leur faire jouer pleinement un rôle de soutien, d'enrichissement et de facilitation du travail intellectuel informatiquement médié. Cependant, la formalisation des traces et de leur manipulation engendre le besoin de disposer d'un langage formel de représentation et d'un moteur d'inférence spécifique aux traces. Ainsi, le SBTm est défini comme « tout système informatique dont le fonctionnement implique à des degrés divers la gestion et la transformation des traces modélisées explicitement en tant que telles » (Settouti, 2010, p. 78). Son fonctionnement, décrit par la figure 2.1, est basé sur trois phases : l'acquisition des traces, l'inférence de celles-ci et la restitution des traces résultantes pour différents objectifs. L'acquisition des traces consiste à collecter une trace qualifiée de *première* pour décrire les interactions de l'utilisateur avec le système informatique observé ; cela en utilisant une ou plusieurs sources de collecte (keylogger, capteur logiciel, etc.) et une modélisation formelle

⁴¹ Laboratoire d'InfoRmatique en Images et Systèmes d'information (LIRIS) : <http://liris.cnrs.fr/>

⁴² MUSETTE : Modéliser les Usages et les Tâches pour Tracer l'Expérience

⁴³ Silex (Supporting Interaction and Learning by Experience) : équipe du laboratoire LIRIS

pour la trace. L'inférence des traces consiste à transformer la trace première selon des règles pour produire de nouvelles traces. Quant à la restitution des traces dans l'univers observé, elle consiste à utiliser les traces résultantes à travers leur visualisation, leur analyse ou leur ré-exploitation pour des raisons d'assistance aux utilisateurs.

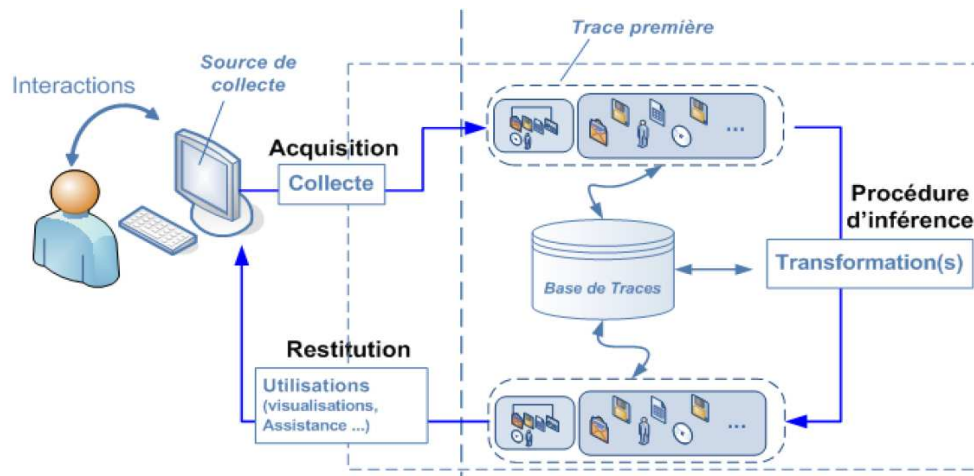


Figure 2.1. Fonctionnement d'un Système à Base de Traces modélisées (Settouti, 2010, p.75).

2.4.2 Modélisation formelle de la trace dans le SBTm

L'automatisation de la génération des traces, tout en les rendant intelligibles et réutilisables dans le cadre d'un travail intellectuel, nécessite l'orientation de leur modélisation vers un type d'activité particulier, afin que la trace fasse sens pour l'utilisateur. Cela exige une démarche proche de celle de la modélisation en Ingénierie des connaissances (Bachimont, 2004). Cependant, Laflaquière et al. (2007) pensent que cette démarche de modélisation doit être à la fois descendante, dans le sens de partir d'un modèle de l'activité pour atteindre un modèle de l'utilisation de l'environnement informatique ; et ascendante, dans le sens de partir du modèle de conception de l'environnement observé et des éléments techniquement enregistrables (logs, vidéo, etc.) pour atteindre un niveau de description de la trace faisant sens pour l'utilisateur. Ils ont également posé le problème de la matérialité des traces dans le contexte numérique, qu'ils pensent résoudre en considérant la trace elle-même comme une inscription de connaissances⁴⁴ (Mille, 2006b) ayant une représentation structurée. Dans le cadre du SBTm, cette représentation structurée obéit à un méta-modèle qui définit la trace comme *une collection d'observés temporellement situés* (Settouti, 2006).

2.4.2.1 La notion d'observé dans la trace d'interaction

« Un observé dénote toute information structurée issue de l'observation d'une interaction de l'utilisateur avec un système informatique » (Settouti, 2010, p. 76). Il est temporellement situé dès qu'il est associé à une partie de l'extension temporelle de sa trace et qui peut être un instant (d'occurrence), un intervalle de temps (dates de début et de fin de l'observation), ou une séquence d'éléments quelconques (pour mettre l'accent sur la succession des observés).

⁴⁴ Une inscription de connaissances peut être un document, une ressource, etc.

Par exemple, l'observé peut dénoter une action réalisée par l'utilisateur telle que l'ouverture d'un fichier ; il peut également dénoter un état du système, une transition de celui-ci, *etc.*

2.4.2.2 Le modèle de trace et la trace modélisée

Dans un SBTm, la trace numérique d'interaction obéit à son propre modèle formel. Ce modèle est *le vocabulaire* de celle-ci qui permet sa compréhension ; cela en décrivant de façon abstraite les éléments qui composent cette trace (observés et relations). De façon plus précise, « *un modèle de trace est une spécification formelle d'une structure d'observés décrivant comment sera représenté le résultat de l'observation d'une situation, sous la forme d'observés et de relations* » (Settouti, 2010, p. 77). Ainsi, la trace modélisée est l'association d'une collection d'observés temporellement situés et d'un modèle explicite de cette collection. Elle est définie comme « *toute trace issue d'un processus de collecte, composée d'observés temporellement situés, et conforme à un modèle de trace* » (Settouti, 2010, p. 77).

2.4.3 Architecture et services du SBTm

Comme tout système informatique, le SBTm est constitué d'un ensemble de composants qui permettent la manipulation des traces d'interaction. Son architecture, présentée par la figure 2.2, met en lien les éléments suivants (Settouti, 2006) :

a) **Le système de collecte** : il permet de sélectionner et d'intégrer des sources de traçage pour générer des traces premières. A partir des sources de traçage qui constituent des flux d'informations structurées décrivant l'interaction, le processus de collecte transforme ces données (de façon automatique, semi automatique ou manuelle) en une trace première conforme à un modèle de trace. Cela nécessite de recourir à des sélections et à des techniques de synchronisation (surtout des bases de temps) des différentes sources de traçage ; et parfois à l'utilisation d'un modèle de collecte qui définit les objets à collecter.

b) **Le noyau du SBTm (SBT Kernel)**: il est constitué d'un système de transformation et d'une base de traces avec leurs modèles. Du fait que la trace première n'est pas toujours exploitable directement, elle peut subir une ou plusieurs transformations, manuelles ou automatiques, pour obtenir une trace d'un niveau d'abstraction significatif pour l'utilisateur. Une transformation manuelle désigne toute modification impliquant un changement dans la composition de la trace (un ajout, une suppression ou une modification de ses observés) ; alors qu'une transformation automatique est appliquée par l'intermédiaire d'un modèle de transformation constitué d'un ensemble de règles (filtres de sélection ou de réécriture de motifs⁴⁵). Ainsi, la transformation des traces peut se faire par sélection ou filtrage, par réécriture ou enrichissement, par fusion temporelle, *etc.*

c) **Le système de requête** : il permet l'interrogation de la base des traces et supporte des modèles de requêtes à partager entre les utilisateurs.

d) **Le système de gestion des traces** : il permet la gestion des différents modèles (de trace, de transformation ou de requête) ; ainsi que l'ajout et la suppression de traces. Il gère les droits d'administration et d'accès aux traces, le cycle de vie de celles-ci et assure la traçabilité des transformations subites par ces traces.

e) **Le système de visualisation** : il permet la visualisation des traces et facilite leur analyse. Pour cela, il peut employer différents modes de visualisation avec la possibilité ou non d'interagir avec le résultat affiché. A ce propos, Ollagnier-Beldame (2006) a proposé une

⁴⁵ Une représentation d'une séquence ou d'un sous ensemble d'observés de la trace.

classification des systèmes traçant en fonction de leur mode de visualisation des traces. Cette classification comporte quatre catégories qui sont : Les systèmes utilisant l'histoire interactionnelle sans la présenter aux utilisateurs, les systèmes présentant une visualisation de l'histoire interactionnelle destinée à l'analyste de la situation, les systèmes présentant une visualisation de l'histoire interactionnelle destinée à l'utilisateur et lui proposant la possibilité d'y naviguer, et les systèmes présentant une visualisation de l'histoire interactionnelle pour l'utilisateur et proposant la possibilité d'agir dessus.

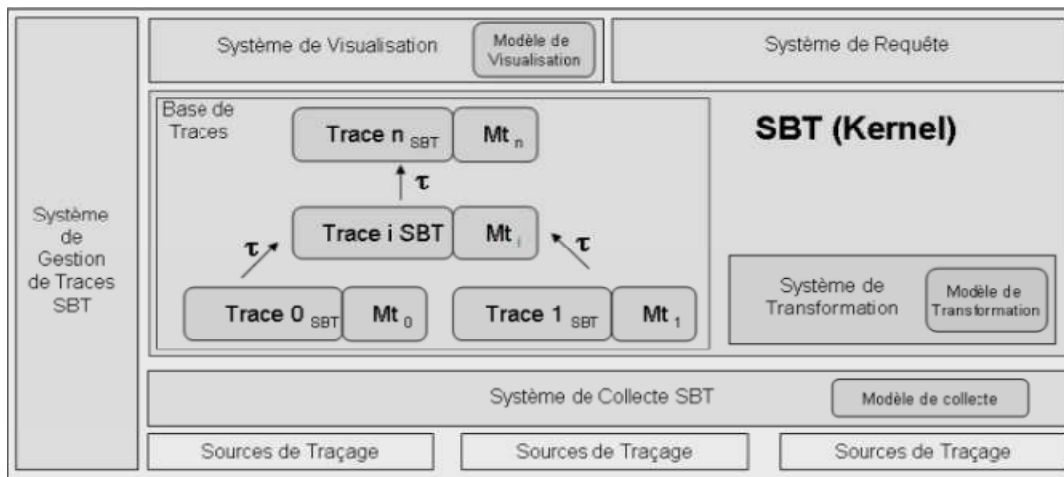


Figure 2.2. Architecture d'un Système à Base de Traces modélisées (Settoui, 2006).

2.4.4 Travaux autour des SBTs

Les travaux concernés par l'implémentation des SBTs sont nombreux au sein de l'équipe SILEX et leur objectif varie entre l'analyse et la facilitation de la tâche de l'utilisateur. Un SBT pour l'analyse des traces permet de comprendre l'activité et/ou le comportement de l'utilisateur ; alors qu'un SBT pour la facilitation de l'activité permet de transformer les traces d'interaction afin de fournir une assistance automatique à l'utilisateur, ou de présenter celles-ci à un spécialiste capable de paramétrer ou de modifier le système informatique utilisé. Nous avons choisi deux projets sur les SBTs pour les décrire de façon plus détaillée : le projet Abstract qui concerne l'interprétation du comportement d'un conducteur (humain) de véhicule, et le projet Visu qui concerne le tutorat synchrone dans le cadre de l'enseignement des langues.

2.4.4.1 Le projet Abstract

Description du projet. Le projet Abstract (Analysis of Behaviour and Situation for menTal Representation Assessment and Cognitive activity modelling) (Georgeon et al., 2006) développe à la fois une méthodologie et un outil. Son objectif est de comprendre le comportement de l'utilisateur d'un artefact technique complexe⁴⁶ réalisant une tâche déterminée. Dans ce travail, l'accent est mis sur les comportements tactiques⁴⁷ et une approche de modélisation basée sur le constat que l'utilisateur agit en fonction d'un modèle mental. Ce modèle est construit en mémoire par l'utilisateur à partir des connaissances de

⁴⁶ Complexe : n'est pas réductible à quelques paramètres et engagé dans une situation de forte imprédictibilité.

⁴⁷ Tactique : se déroule en quelques secondes

celui-ci et des éléments perçus dans l'environnement. Cependant, la description de ce modèle et des mécanismes qui permettent son élaboration implique souvent l'intervention de psychologues et d'ergonomes ; cela est le cas dans l'expérimentation ayant un véhicule comme artefact complexe et la conduite en sécurité d'un point à l'autre comme tâche. Le véhicule a été instrumenté pour permettre de collecter des informations sur le comportement du conducteur, du véhicule et de l'environnement ; puis ces données sont analysées pour inférer ou valider les hypothèses concernant la modélisation cognitive du conducteur. Les résultats peuvent être confrontés à une évaluation subjective du conducteur lui-même.

Architecture du système Abstract. Cette architecture, présentée par la figure 2.3, inclut un modèle d'utilisation (une ontologie des concepts de la modélisation) et des règles de transformation applicables aux traces. Cette architecture distingue également deux niveaux :

a) *Le niveau « système de collecte »* : il permet la production d'une séquence d'observés à partir des différentes sources de collecte avec une possibilité de visualisation de la trace collectée. Dans le cas du véhicule, les données sont obtenues à partir du volant, de la boîte de vitesse, de l'accumulateur, des clignotants, et des regards du conducteur (rétroviseurs). Une trace première de bas niveau est obtenue après nettoyage ; elle est constituée d'une séquence d'observés dont la transformation permet de passer d'un niveau d'abstraction à un autre niveau plus haut (figure 2.4).

b) *Le niveau « système à base de trace »* : il permet la manipulation des traces sous forme de graphes RDF⁴⁸ et regroupe les différentes fonctionnalités de transformation de celles-ci. Il comporte un éditeur d'ontologie pour spécifier les modèles des traces, un éditeur de transformation pour spécifier les règles de transformations applicables aux traces, un moteur de transformation pour l'application des transformations, un système de visualisation de traces et un outil de requêtes (en SPARQL⁴⁹) pour chercher les occurrences de signatures de schéma (de conduite) dans les traces.

Transformation de la trace. Cette transformation peut se faire par enrichissement en appliquant des règles d'inférence spécifiées par l'analyste (le psychologue) ; cela permet l'ajout de nouveaux nœuds et d'arcs plus abstraits dans la trace en fonction des signatures (correspondantes aux schémas de conduite) retrouvées dans celle-ci. Cette transformation peut également se faire par filtrage, ce qui permet de masquer les observés de bas niveau inutiles pour l'analyste. En effet, il existe deux niveaux de traces transformées : la *trace métier* qui décrit l'activité dans le langage de l'opérateur, et la *trace analysée* structurée en une succession d'états et de transitions pour décrire l'activité dans le langage de l'analyste. Cette dernière supporte la recherche de patterns de schémas tactiques ; ainsi, il est possible de reconnaître un schéma de comportement cognitif dans les traces tel la reconnaissance d'une configuration de changement de la voie de conduite par exemple (figure 2.5).

⁴⁸ le graphe RDF (Resource Description Framework) comporte des nœuds(ressources) et des arcs(relations)

⁴⁹ SPARQL : langage de requêtes pour RDF

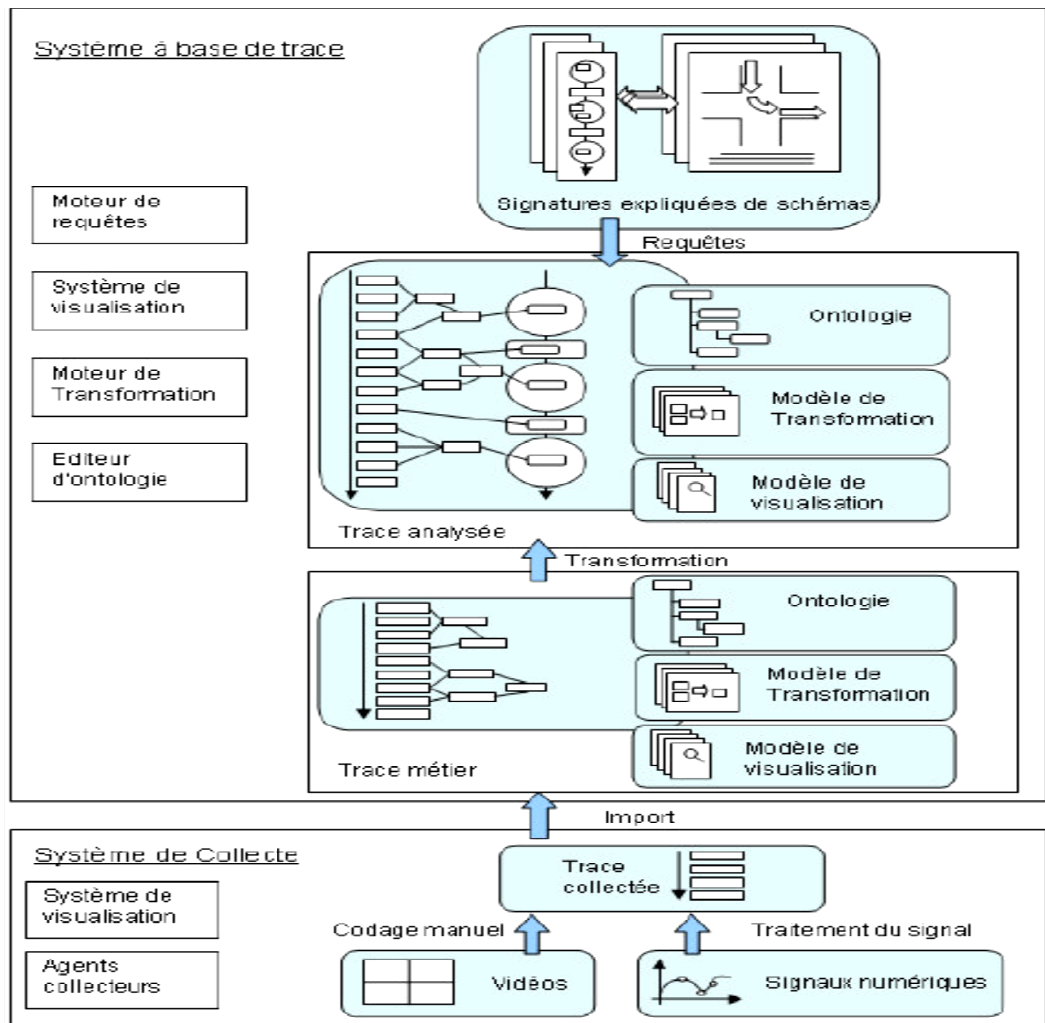


Figure 2.3. Architecture du système Abstract (Georgeon et al., 2006).

5876	3806.32	18496	112	5	Speed	subtype	Min	value	111.81	property	0
5877	3807.21	18523.4	112	3	Accelerator	subtype	Max	value	50.36	property	0
5878	3807.71	18539.6	113	4	Eye_Left	duration		0.049995			
5879	3807.76	18540.8	113	4	Eye_Far_Left	duration		0.148996			
5880	3807.77	18540.6	113	4	Speed	subtype	Max_Variation	value	112.58	property	0.81
5881	3807.91	18545.8	113	3	Eye_Left_Minor	duration		0.116997			
5882	3808.03	18549	113	3	Eye_Far_Left	duration		0.016995			
5883	3808.04	18549.6	113	3	Eye_Left	duration		0.066998			
5884	3808.05	18549.6	113	3	Speed	subtype	Max_Variation	value	112.76	property	0.69
5885	3808.11	18561.4	113	3	Eye_Ahead	duration		2.40493			
5886	3808.77	18572.2	113	5	Accelerator	subtype	Min	value	46.98	property	0
5887	3808.81	18573.4	113	5	Speed	subtype	Max_Variation	value	113.33	property	0.76
5888	3808.93				Close_Left_Up						

Figure 2.4. La trace première dans le cas d'un conducteur de voiture (Georgeon, 2008)

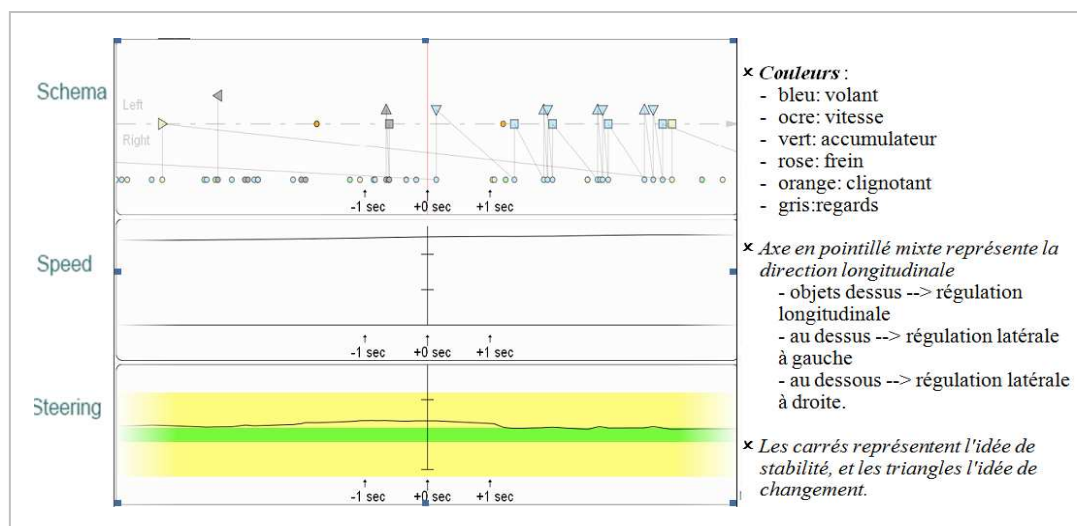


Figure 2.5. Exemple de reconnaissance de changement de voie de conduite (Georgeon, 2008)

2.4.4.2 Le projet Visu

Description du projet. Le projet Visu (Prié, 2011) est une application de tutorat synchrone à base de traces qui a été utilisé dans le cadre de l'enseignement du français comme langue étrangère. Dans ce contexte, des apprenants à distance (étudiants étrangers) ont une interaction directe par visio-conférence avec des apprenti-tuteurs français qui réalisent à cette occasion leurs premiers tutorats. Les séances de la formation sont préparées par les apprenti-tuteurs qui mettent en place chaque semaine un plan de séance (pendant sept semaine). Ce plan est composé de quatre activités pédagogiques pouvant mobiliser différents documents (images, vidéos), mots-clés et instructions. Pendant la séance de tutorat, les apprenti-tuteurs dirigent celle-ci et fournissent aux apprenants des feedback à travers une interaction synchrone. En fin de séance, chaque apprenti-tuteur dresse un résumé sur les éléments importants de la séance ; et après la séance, les apprentis-tuteurs font une analyse réflexive sur leurs performances (en utilisant un enregistrement de cette séance) dans le but de préparer une séance de débriefing avec le responsable de la formation.

L'outil Visu et les traces modélisées. Cet outil implémente un SBTm qui permet de soutenir l'ensemble des tâches décrites ci-dessus (la gestion de plans de séances, la gestion des séances synchrones, l'analyse *a posteriori* de l'activité, *etc.*). Les traces d'interaction sont collectées pendant la séance synchrone ; elles sont éventuellement enrichies par des marqueurs posés par les utilisateurs. Ces traces peuvent servir comme un support de remémoration pour les tuteurs (dans la préparation des résumés) ou de réflexivité sur leur pratique (dans la préparation du débriefing). Elles peuvent également servir dans la construction de bilans (bilans des tuteurs vers les apprenants, bilans des apprenants vers les tuteurs, ou bilans des tuteurs vers le responsable de la formation). Les traces modélisées sont de trois types, en plus des enregistrements audio et vidéo de la vidéoconférence (Bétrancourt et al., 2011) :

- *Les traces d'interaction collectées automatiquement* à partir de l'activité de l'utilisateur (e.g., lancer une vidéo par un apprenant, afficher une image reçue, commencer une activité, utiliser le chat...) ; elles sont représentées sur une *timeline*.

- *Les traces de marqueurs* contenant des observés similaires aux notes prises par l'utilisateur pour marquer des moments importants de l'activité telles qu'un texte libre qui porte sur un élément de l'activité (pour exprimer une remarque du genre « X ne parle pas beaucoup », une incompréhension d'un apprenant, un besoin de retour sur un moment passé, etc.) ; les traces des tuteurs sont privées et celles des apprenants sont partagées.
- *Les traces de commentaires* contenant des observés commentaires définis par l'utilisateur après l'activité pour décrire celle-ci (e.g. « bon dialogue entre les étudiants », « expression bien dite », etc.) ; ces traces sont le produit d'une transformation manuelle, par réécriture, des traces disponibles dans le but d'interpréter celles-ci.

Interface de l'outil Visu. L'outil visu offre la possibilité de créer et de partager des plans de séances, de gérer des utilisateurs, de planifier des séances, de mener les séances dans le *salon synchrone* et surtout d'interagir avec les traces collectées dans le *salon de rétrospection*. La figure 2.6 présente l'interface du salon synchrone tuteur (à gauche) et celle du salon de rétrospection (à droite) dans Visu.

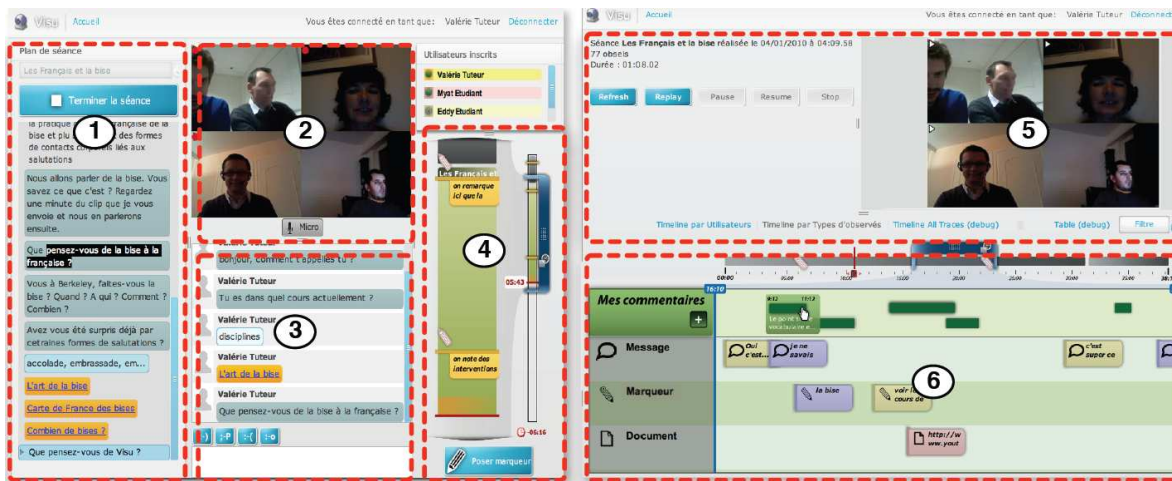


Figure 2.6. Interface du salon synchrone tuteur et interface du salon de rétrospection dans Visu (Prié, 2011, p.185)

L'interaction synchrone des apprenants et des tuteurs se déroule au sein du salon synchrone qui offre, en plus d'un outil classique de visioconférence(2), un gestionnaire de plans de séances (1), une fenêtre de chat (3) et une *timeline* verticale qui présente différents observés issus de la trace d'interaction ou de marqueurs (4) ; cette *timeline* permet également de poser des marqueurs pour prendre des notes sur des moments importants de l'activité et y revenir plus tard. Après l'interaction, les utilisateurs peuvent accéder de façon asynchrone au salon de rétrospection pour interpréter les traces collectées durant la séance ; ce salon offre un lecteur qui permet de lire les vidéos de la séance (5) et une *timeline* horizontale (6) qui permet de contrôler le lecteur, de présenter les observés issus de la séance par types ou par utilisateurs, d'accéder rapidement aux marqueurs et de commenter la trace (i.e. ajout des observés commentaires dans la trace des commentaires).

L'activité de redocumentation dans Visu. L'interprétation de la trace dans Visu ne se résume pas à l'ajout de commentaires ; elle peut entraîner la construction de vraies structures

documentaires qui sont les bilans. Cela en utilisant le module de redocumentation manuelle multimédia de l'activité offert par Visu ; bien que le modèle documentaire de son produit soit très simple. Le bilan est une simple séquence de segments textuels enrichis de deux types d'éléments multimédia ; ces segments peuvent être de type Titre, Texte (paragraphe), Fragment vidéo (issu de l'enregistrement de la séance pour illustrer un commentaire avec un texte explicatif éventuel), ou Fragment audio (enregistrement audio fait au moment de la redocumentation pour faire un commentaire oral avec un texte explicatif éventuel). Les bilans sont construits depuis le salon de rétrospection avec la possibilité de glisser-déposer les observés de la trace à partir de la *timeline* ; ils peuvent être visualisés (figure 2.7) et partagés.

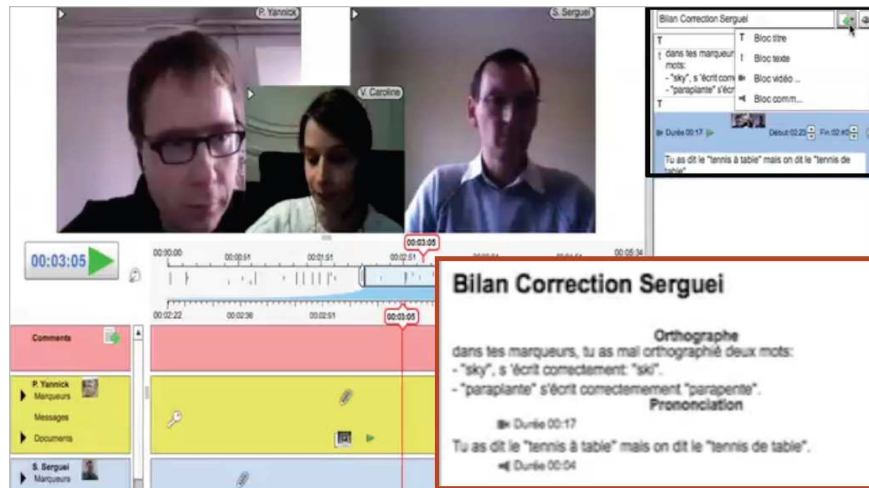


Figure 2.7. Conception et visualisation de bilan dans Visu (Prié, 2011, p. 196)

2.5 Conclusion

La notion de *trace* recouvre divers concepts pour se situer entre l'empreinte, le reste, la mémoire, l'indice et l'écriture. En informatique, la notion de trace d'activité numérique désigne plus une *marque* laissée par une activité supportée par un système informatique. Nous définissons cette trace comme *un ensemble de données enregistrées pour décrire l'interaction (actions-réactions) entre un utilisateur et un système informatique médiatisant son activité ; ces données sont issues de l'observation de cette interaction et sont ordonnées selon la chronologie de celle-ci pour fournir une description plus ou moins fiable de l'activité réalisée.* Il s'agit donc d'une trace d'interaction passive, structurée temporellement, inscrite et conservée par le système instrumenté à cet égard.

Au départ, les intérêts sous-jacents à l'exploitation de ce type de traces se concentraient plus autour de l'évaluation et de la maintenance des systèmes informatiques utilisés ; la forme la plus utilisée pour ces traces était alors « *le fichier log* ». Par la suite, ces intérêts se sont concentrés de plus en plus autour des activités tracées elles-mêmes et des comportements des utilisateurs concernés par celles-ci ; les formes de ces traces et leurs modes d'utilisation ont également évolué. Nous parlons plutôt de systèmes traçants ; des dispositifs mis en place pour enregistrer les interactions des utilisateurs pour une utilisation spécifique des traces résultantes. Nous distinguons deux familles de travaux exploitant les traces d'interaction : les travaux dont l'objectif est l'analyse d'un sujet et ceux dont l'objectif est la facilitation de la réalisation de l'activité pour l'utilisateur. Le sujet analysé peut être le système informatique

utilisé (interface et fonctionnalités), les comportements des utilisateurs (usages et utilisations), ou encore les utilisateurs eux-mêmes et leurs activités individuelles ou collectives ; alors que la modification de la situation de l'activité par l'intégration des traces de celle-ci pour faciliter l'activité peut se réaliser à travers l'adaptation automatique du système informatique à son utilisation ou l'assistance directe ou indirecte aux utilisateurs du système.

Le LIRIS, qui s'intéresse à la problématique des traces d'activité numérique et à leur étude en tant que telles, a insisté aussi bien sur l'aspect traçage (la collecte) que sur l'aspect ingénierie (la transformation et la visualisation des traces). Son idée est d'automatiser la génération des traces, tout en les rendant intelligibles et réutilisables ; bien que cela nécessite l'orientation de leur modélisation à un type d'activité particulier. Une ingénierie de la trace a été proposée ; elle est inspirée de l'ingénierie des connaissances puisque les traces d'interaction dans le cadre d'un travail intellectuel sont considérées comme des inscriptions de connaissances. Cette ingénierie est supportée par un cadre théorique et pratique baptisé « Système à Base de Traces modélisées (SBTm) » ; et plusieurs implémentations de ce cadre sont actuellement réalisées, en particulier dans le contexte des EIAH. Les efforts sont concentrés sur la visualisation interactive des traces et leur ré-exploitation pour des raisons d'analyse ou d'assistance ; bien que beaucoup de problèmes restent à résoudre concernant la collecte des traces, leur intégration, leur utilisation en temps réel, *etc.*

Finalement, nous pouvons dire que la problématique de la redocumentation de l'activité informatique via l'exploitation des traces de celle-ci n'a pas vraiment été résolue ; même si des approches peu élaborées, automatiques (cas de l'outil AAAnalyzer et du système GRUMPs qui permettent de générer des rapports hypertexte à partir des traces) ou manuelles (cas du projet Visu) ont été proposées. Nous pensons que la résolution d'une telle problématique nécessite une étude minutieuse de la notion du document, en tant que produit du processus de redocumentation ; ainsi qu'une prise en main des bases théoriques et des moyens technologiques permettant la construction de celui-ci. Nous détaillons cela dans le chapitre suivant consacré au document numérique et son *authoring*.

Chapitre 3 : Le document numérique : modélisation et construction

3.1 Introduction

La problématique de la gestion documentaire devient de plus en plus importante avec l'évolution technologique et le développement du Wide World Web. La notion de document, qui demeure un concept de base, puisqu'il s'agit d'un élément commun entre l'univers du papier et le monde du numérique, semble être une notion ambiguë et est souvent utilisée sans que l'on soit réellement conscient du sens qu'elle désigne. Pratiquement, différentes appellations ont été attribuées aux documents telles que : information, donnée, ressource, fichier, écrit, texte, image, papier, article, œuvre, livre, journal, feuille, page, etc. Vue cette profusion de termes, une classification plus précise semble nécessaire à travers une réflexion pluridisciplinaire. Notre objectif est de clairement définir le terme « *document* », en particulier dans le contexte du numérique. Un tel contexte fait en effet perdre au document son statut d'objet matériel et apporte de nouvelles pratiques de manipulation et d'échange pour celui-ci. Un document numérique n'est plus désormais une simple transposition d'un document classique sur un support numérique via des techniques de numérisation ou d'enregistrement audio ou vidéo ; il s'agit plutôt d'une entité créée en tant que telle, via un processus d'*authoring* (i.e. de création de contenu) partiellement ou totalement automatisé, en se servant des facilités technologiques offertes. Toutefois, des pratiques traditionnelles associées à la création de documents classiques sont empruntées et adaptées à ce nouveau contexte. C'est le cas du *storytelling*, méthode utilisée en communication et permettant la production de narrations (contes, récits, etc.) qui est depuis récemment supportée par les technologies numériques pour assurer une approche naturelle de création d'histoires plus vivantes via une nouvelle forme d'interactivité.

L'objectif de ce chapitre est de fournir une étude minutieuse de la notion de « *document numérique* », ainsi que de la production et de la manipulation de celui-ci. Pour cela, nous partons de la notion de « *document* » dans un contexte général, puis nous raffinons la définition de cette notion dans le contexte des technologies numériques et nous décrivons les différentes classifications des documents numériques. Nous évoquons également la problématique de la modélisation du document numérique à travers la description des composants et des structures qu'il peut encapsuler. Nous focalisons notre étude sur les processus de création de contenus numériques ; qui peuvent exploiter des bases théoriques empruntées à l'*authoring* de documents classiques telles que la Théorie de la Structure Rhétorique que nous décrivons. Nous présentons en outre différentes approches d'*authoring*, plus ou moins automatiques, proposées dans le contexte du numérique et les outils développés à cet égard. Nous revenons en particulier sur l'apport de tels approches et outils dans la mise en place de la pratique de *storytelling* pour la production de documents numériques.

3.2 La notion de document numérique

3.2.1 La notion de document

Un document est défini par Buckland (1997) comme toute expression d'une réflexion humaine, ce qui permet d'étendre cette notion au-delà d'un simple texte écrit. Rappelons que la racine « *doc* » vient du latin « *docere* » qui signifie « *enseigner* » ; ainsi *tout objet qui enseigne est un document*. Avec une analyse plus profonde, Paul Otlet et d'autres chercheurs ont développé une vue fonctionnelle du document (Otlet, 1934) ; celle-ci considère que les enregistrements graphiques et les écrits sont des représentations d'idées ou d'objets et que les objets eux-mêmes peuvent être vus comme des documents s'ils nous informent à travers leur observation. En 1937, l'Institut International de Coopération Intellectuelle a défini le document comme étant : « *toute base de connaissance, fixée matériellement, susceptible d'être utilisée pour consultation, étude ou preuve* » (Anon, 1937, p. 234) ; cette définition regroupe les manuscrits, les imprimés, les représentations graphiques ou figurées, les objets de collections, *etc.* Mais ce n'est qu'en 1951 qu'une définition précise et complète pour la notion de « *document* » a été proposée par Suzanne Briet ; une définition qui met la preuve au cœur de cette notion : « *un document est une preuve à l'appui d'un fait* » et « *tout indice concret ou symbolique, conservé ou enregistré, aux fins de représenter, de reconstituer ou de prouver un phénomène physique ou intellectuel* » (Briet, 1951, p.7).

En se basant sur la multitude de définitions proposées, et qui sont souvent abstraites, nous pouvons conclure que la notion de « *document* » s'appuie sur deux fonctions principales : *la preuve* comme une pièce à conviction et *le renseignement* comme une représentation du monde ou un témoignage. Bien qu'il n'existe pas de définition unique regroupant toutes ces idées, grâce à certains efforts de normalisation, des définitions plus pratiques pour le document ont été proposées telles que : « *le document est la preuve littérale, ou preuve par écrit, qui résulte d'une suite de lettres, de caractères, de chiffres ou de tous autres signes ou symboles dotés d'une signification intelligible, quels que soient leur support et leurs modalités de transmission* »⁵⁰. En passant par l'appareillage technique de la numérisation, la notion de « *document* » a acquis de nouvelles propriétés impliquées par cette nouvelle technologie et que nous essayons de cerner dans ce qui suit.

3.2.2 Le document dans son passage au numérique

L'expression « *document numérique* » apparaît avec la généralisation de l'encodage numérique aux différents types de documents (écrits, audiovisuels et tridimensionnels) ; cette technologie se caractérise par la manipulation d'un système d'unités discrètes indépendantes les unes des autres puisque tout objet numérique est stocké sous forme d'une séquence de bits. Ainsi, les formes physiques usuelles (papier, microfilm, *etc.*) ne sont plus exigées pour dire qu'un objet est un document. Un document est plutôt tout ce qui peut être imprimé ou affiché sur écran, en s'intéressant plus à sa fonction qu'à son format physique (Buckland, 1997). De façon plus précise, c'est « *une structure formelle constituée d'unités discrètes à laquelle sont associées des règles algorithmiques formalisant les propriétés de celle-ci* » (Bachimont, 1999). Aujourd'hui, la télévision et Internet nous font concevoir des documents qui n'existent que le temps de leur diffusion, tels qu'une émission en direct ou un document web construit à la volée. Par conséquent, avec le numérique est apparue une nouvelle phase qui a imposé un

⁵⁰ Code Civil, Article 1316 : <http://www.legifrance.gouv.fr/WAspad/UnCode?code=CCIVILL0.rcv>

changement radical ; un changement qui a entraîné la perte de la stabilité du document comme objet matériel et sa transformation en *un processus construit à la demande* (Pédauque, 2006) tout en ayant une possibilité de retour au document papier via l'impression.

Différentes définitions ont été proposées pour le document numérique selon le support, la forme, le format et les fonctionnalités de celui-ci. Par exemple, Linda Schamber a insisté dans sa définition sur l'*usage* et les propriétés du document : « *un document numérique consiste en un contenu dynamique, flexible, non-linéaire, représenté comme des unités d'information liées, sauvegardées sur un ou plusieurs médias ou sites web ; créées et utilisées par un ou plusieurs individus dans la facilitation d'un processus ou d'un projet* » (Gallezot, 2000). Un document numérique est ainsi une représentation numérique d'une preuve, qui doit pouvoir être réutilisée dans un autre processus de traitement ; mais qui doit aussi renfermer l'information nécessaire à son repérage dans une collection (sa localisation). Le document numérique a également été défini comme « *un support d'informations enregistrées à titre permanent et susceptible d'être classé, consulté et éventuellement reproduit* » (Buckland, 1997) pour mettre l'accent sur les pratiques documentaires ; ou encore comme « *une micro-pensée enregistrée sur un papier ou sur un autre support, qui permet une manipulation physique facile, un transport dans l'espace et une préservation dans le temps* » (Ranganathan, 1963, p. 41). Face à ces définitions plutôt *ad hoc* du document numérique, des définitions plus théoriques sont exigées ; alors, un travail collectif de réflexion a été mené au sein du réseau thématique pluridisciplinaire 33 du département STIC du CNRS (RTP-DOC⁵¹). Nous avons expliqué auparavant (section 1.2.1) que les chercheurs de ce réseau ont proposé de préciser la notion de *document* dans son passage au numérique à travers trois dimensions complémentaires : *la forme, le signe et le médium* (Pédauque, 2006) ; ainsi, nous décrivonsci-dessous ces dimensions de façon plus détaillée.

3.2.2.1 Le document comme forme

La dimension « *forme* » du document concerne les approches qui analysent celui-ci comme un objet matériel ou immatériel et qui en étudient la structure pour mieux analyser, utiliser ou manipuler celui-ci. Parmi ceux qui s'intéressent à cette dimension, nous avons les spécialistes de typographie, de classement et de gestion des documents, les techniciens de la musique et de la vidéo, ainsi que les informaticiens qui partent des objets matériels pour les numériser. Le document est vu comme un objet de communication régi par des règles de mise en forme plus ou moins explicites, qui matérialisent un contrat de lecture entre un producteur et un lecteur ; il est étudié sous l'angle de ce protocole quelque soit son contenu. En outre, la notion de *document traditionnel*, formé d'un *support* manipulable sur lequel est fixée une trace interprétable (*inscription*), est étendue puisque le support n'a pas gardé sa faculté d'appropriation directe et la représentation se rapproche de la perception humaine immédiate grâce à la naissance de dispositifs de lecture plus sophistiqués. Une autre conséquence sur les dispositifs est l'entrelacement des supports et des signaux (i.e. on peut lire et imbriquer du texte, de l'audio, de la vidéo, etc.), ce qui a rendu la notion du support ambiguë. Sur le plan inscription (i.e. codage), le document est considéré comme *une structure et des données*. L'étude de cette structure varie selon le type de document et le type de son média (e.g. l'audiovisuel introduit une dimension temporelle absente dans le document texte). Deux niveaux fondamentaux de la structuration du document sont soulignés : la structure logique (i.e. les parties et les sous-parties du document), et la représentation formelle de la présentation (i.e., les styles). Par la suite, la normalisation dans le cadre du *Web via XML* a

⁵¹ <http://rtp-doc.enssib.fr>

reformulé la notion de *document* en une *mise en forme de données structurées* pour que le document soit lisible par tout type d'ordinateurs ou d'applications.

Pour conclure, un document numérique est du point de vue « *forme* » un ensemble de données organisées selon une structure stable, associée à des règles de mise en forme permettant une lisibilité partagée entre son concepteur et ses lecteurs. Ainsi, le contrat de lecture pour cette dimension anthropologique se concentre plus sur la *lisibilité* du document comme étant le rapport de notre corps et de nos sens à cet objet (Salaun, 2012) ; la forme privilégie le repérage et un objet doit pouvoir être vu pour acquérir le statut d'un document.

3.2.2.2 Le document comme signe

La dimension « *signe* » ou « *contenu* » du document concerne les approches où celui-ci est perçu, avant tout, comme un porteur de sens doté d'une intentionnalité. Considéré ainsi, on ne s'intéresse à la forme du document que lorsque celle-ci est porteuse de sens. Les spécialistes de cette dimension regroupent les linguistes et les sémioticiens⁵², ainsi que les informaticiens travaillant dans le domaine de la modélisation du raisonnement et la construction des outils. Le fait de mettre l'accent sur le sens du document a permis le passage de la gestion des espaces documentaires à la gestion des connaissances ; du Web au Web sémantique ; et de l'information à la connaissance. En effet, l'explosion documentaire a conduit à l'invention des « *langages documentaires* » tels que les références bibliographiques, les index, les thésaurus, etc ; mais le terme « *information* » s'est retrouvé mal défini à mi-chemin entre « *donnée* » et « *connaissance* ». Dans ce contexte, le document *traditionnel* est considéré comme une *inscription* et un *sens* ; l'inscription représente le contenu, le support est accessoire, et le sens se construit par rapport au contexte de production ou de diffusion du document. Quant au document numérique, il est plutôt considéré comme un *texte informé* et *des connaissances* ; ici, le *texte informé* a remplacé l'*inscription* pour signifier que le texte (y compris audiovisuel) a été soumis à un traitement permettant d'en repérer les unités d'information et *les connaissances* ont remplacé le *sens* pour introduire la notion de *personnalisation* pour un lecteur ou un usage. Dans le cadre du Web sémantique en particulier, le document est considéré comme étant un *texte informé* et *des ontologies* ; celles-ci permettent un raisonnement automatique sur les documents assuré par la formalisation.

Pour conclure, un document numérique selon la dimension « *signe* » ou « *contenu* » est un *texte dont les éléments sont potentiellement analysables par un système de connaissances, en vue de son exploitation par un lecteur compétent, dans le but d'une recherche d'informations ou d'un accès aux documents*. Ainsi, le contrat de lecture pour cette dimension intellectuelle se concentre plus sur l'*intelligibilité* du document comme étant le rapport de notre cerveau et de ses capacités de raisonnement au contenu du document quelle que soit la façon dont celui-ci est représenté (Salaun, 2012). Le contenu privilégie l'interprétation et un objet doit pouvoir être lu et compris pour acquérir le statut d'un document.

3.2.2.3 Le document comme médium

La dimension « *médium* » du document évoque la question du statut de celui-ci dans les relations sociales où le document est considéré comme une *trace, construite ou retrouvée, d'une communication qui s'est affranchie de l'espace et du temps*. Les approches qui s'intéressent à cette dimension analysent le document comme étant un *phénomène social* ; un élément tangible d'une communication entre des personnes. Quant aux spécialistes concernés, ils appartiennent à des organisations et/ou des collectivités dans lesquelles les documents

⁵² Les spécialistes en analyse de discours, linguistique de corpus, sémantique, TALN, etc.

circulent (e.g. les archivistes, les éditeurs, les sociologues, les historiens, les psychologues, etc.). Dans ce contexte, un *document donne un statut à une information, à un signe matérialisé ; il est porté par un groupe social qui le suscite, le diffuse, le sauvegarde et l'utilise*. C'est une preuve qui fait foi d'un état de choses, une annonce qui prévient d'un événement, ou un discours dont la signature le rattache à un auteur (i.e. un témoignage). Il est considéré, avant tout, comme *une inscription munie d'une légitimité ; l'inscription dépasse la communication intime pour devenir légitime et la légitimité s'affranchit de l'éphémère via l'enregistrement de celle-ci*. Bien qu'il ne soit pas nécessairement publié, le document a un caractère social dans le sens où il est rédigé selon des règles établies (légitimité). Inversement, sa publication rend sa valeur appréciée collectivement. Deux courants de recherche se sont intéressés à la dimension « *médium* » du document. Le premier courant se concentre sur *la communication organisationnelle* qui étudie le document dans un processus de travail et considère celui-ci comme étant *un texte et une procédure ;* alors que le second courant analyse *la communication des médias* et s'intéresse au processus de publication et au droit d'auteur du document. Dans le cadre du Web en particulier, le document est considéré comme *une publication avec un accès repéré* puisque la publication ne peut accomplir la légitimité que si elle est adjointe à la notoriété par repérage de l'accès.

Pour conclure, un document numérique selon la dimension « *médium* » est *la trace de relations sociales reconstruites par les dispositifs informatiques*. Ainsi, le contrat de lecture pour cette dimension sociale se concentre plus sur la portée du document (Salaun, 2012) et l'appropriation par laquelle le lecteur, en prenant connaissance d'un document, marque sa participation à une société humaine. Le médium privilégie le partage et un objet doit pouvoir être *su* pour acquérir le statut d'un document.

3.2.2.4 La synthèse des trois dimensions

Il reste à établir une synthèse qui englobe les trois points de vue sur le document, décrits ci-dessus. En tant que forme, contenu et médium, le document numérique est étudié selon différents points de vue qui semblent être contradictoires. Pourtant, aucune des trois dimensions étudiées n'est indépendante ; au contraire, la notion de *document numérique* ne s'éclaire réellement que dans la superposition de ces dimensions. Chacun des trois points de vue sur le document a insisté sur l'idée de contrat de lecture ; cela est traduit par une propriété particulière du document qui est la *lisibilité* pour la dimension « *forme* », la *compréhension* pour la dimension « *contenu* », et la *sociabilité* pour la dimension « *médium* ». Pour cela, R. Pédaïque (2006) affirme qu'« *un document ne serait finalement qu'un contrat entre des hommes dont les qualités anthropologiques (lisibilité – perception), intellectuelles (compréhension – assimilation) et sociales (sociabilité – intégration) fonderaient une part de leur humanité, de leur capacité à vivre ensemble* » ; alors que le numérique n'est qu'une modalité de multiplication et d'évolution de ces contrats bien que sa performance et sa rapidité de diffusion l'aient rendu très important. Pour définir le document numérique de façon plus précise, J.M. Salaün (2012) a introduit la notion de *protodocument* : « *un protodocument est une trace permettant d'interpréter un événement passé à partir d'un contrat de lecture* » ; il a défini le document comme étant « *la représentation d'un protodocument sur un support, pour une manipulation physique facile, un transport dans l'espace et une préservation dans le temps* ». Dans cette définition, la trace exprime la dimension matérielle du document, l'interprétation exprime sa dimension intellectuelle et le contrat de lecture sa dimension sociale ; toutefois, c'est la préservation du document sur un support maniable qui permet vraiment sa reproductibilité et son traitement.

3.2.3 Classification des documents numériques

Les documents numériques sont avant tout des fichiers créés par les utilisateurs au moyen d'un logiciel applicatif. Un fichier est caractérisé par un format de données (i.e. la manière utilisée en informatique pour représenter et stocker les données de celui-ci) qui peut rendre celui-ci dépendant du logiciel utilisé. Un classement de ces formats permet de distinguer différents types de fichiers, et par conséquent, de documents numériques (considérés du point de vue de la forme). On peut ainsi distinguer les fichiers texte, image, multimédia, bases de données, ou encore les fichiers composites pouvant intégrer plusieurs formes tels que les hypermédias. Ces derniers sont des documents universels sur le plan forme, dans le sens où ils peuvent inclure à la fois plusieurs médias (images, son, vidéo, texte). D'un point de vue structurel (Balasubramanian, 1994), un document hypermédia est un système composé de nœuds et de liens ; les nœuds (i.e. les pages) peuvent être composés d'informations textuelles (alors nous parlons d'hypertexte) ou multimédia (image, graphique, animation de vidéo, programme, *etc.*) et les liens (unidirectionnels ou bidirectionnels) peuvent être typés avec leur sémantique. Il s'agit ainsi d'un document interactif (Rhéaume, 1993) qui n'est jamais globalement perceptible et dont l'actualisation d'une des potentialités est conditionnée par l'effectivité de la lecture. Lorsque les pages et les liens du document hypermédia sont prédéfinis et ne changent que sur une décision de l'auteur du document, nous parlons d'un *hypermédia statique* ; alors que dans le cas où ces pages et/ou ces liens sont construits dynamiquement, nous parlons d'un *hypermédia dynamique* qui peut être adaptatif à ses utilisateurs (Brusilovsky et al., 1998).

D'autres typologies de classifications des documents numériques ont été proposées en se basant sur des différents critères. Selon *la nature* du document, nous distinguons les documents créés à l'état natif et ceux obtenus par un processus de transformation de documents existants (tel le cas d'un document numérisé) ; nous trouvons également des documents primaires (i.e. originaux) et des documents secondaires qui indiquent où l'on peut trouver l'information dans les documents primaires. Alors que selon *le genre*, la classification des documents se base sur les technologies utilisées, les modes de communication et de présentation de ceux-ci (e.g. hypertexte, courrier électronique, *etc.*) et les formes complexes de communications utilisées (e.g. revues scientifiques, rapports annuels, *etc.*). Le genre est une catégorie de classement de textes définie par une tradition (Adam, 2001) qui détermine les types relativement stabilisés d'énoncés élaborés au sein de chaque sphère d'utilisation de la langue (Bakhtine, 1984). En édition classique, il existe une ligne éditoriale qui donne un statut au document par son affiliation à un genre particulier (e.g. roman, essai, *etc.*) et la notion de *genre* est souvent utilisée en lien avec celle d'usage (Araszkievitz, 2003). Certains genres ont passé sans heurts le cap du passage au numérique, tandis que d'autres sont nés avec celui-ci tel le cas du courrier électronique (Prié, 2000). Dans ce contexte, le genre permet de mieux caractériser les contenus documentaires du point de vue de leur production et de leur interprétation ; il peut prendre en compte les applications utilisant des ressources pour mieux cibler les types adéquats de celles-ci et permet également d'anticiper les besoins de maintenance au niveau représentation des connaissances (Aussenac and Condamines, 2004).

3.3 La modélisation du document numérique

Un document numérique est un ensemble plus ou moins structuré d'informations. La description de la structure de celui-ci consiste à identifier et à décrire chacun des éléments qui le constituent ; mais cette description peut prendre plusieurs formes puisque plusieurs types de structures documentaires ont été mis en évidence (Bertrand, 2005) dans un document. Il

existe, en premier lieu, un type de structures informatiques de fichiers propres aux formats dans lesquels sont codés les documents (image, texte, vidéo ou son). D'autres usages, tels que l'impression et l'édition de documents, ont nécessité de mettre en évidence d'autres types de structures que nous décrivons dans ce qui suit. Face à cette multitude de structures pouvant cohabiter au sein d'un même document numérique, des travaux de recherche se sont intéressés à la modélisation de cette entité complexe en essayant de mettre en évidence ses différentes structures. Nous présentons ceux qui nous intéressent le plus.

3.3.1 Les structures du document numérique

Dans un document numérique, plusieurs structures peuvent coexister ; ces structures sont de types différents et sont souvent exploitées de façon individuelle. Les structures les plus exploitées dans le monde documentaire sont les structures physiques et logiques ; mais il existe d'autres structures qui dépendent de l'usage ou de la nature du document. Nous décrivons dans ce qui suit les quatre types de structures les plus importants.

3.3.1.1 La structure logique

Cette structure organise les éléments du contenu intellectuel du document en leur assignant un rôle dans la signification. Cela correspond, par exemple, à l'organisation du document en une hiérarchie de blocs logiques (e.g. titre, chapitre, section, paragraphe, auteur, *etc.*).

3.3.1.2 La structure physique

Cette structure désigne la segmentation d'un document en zones homogènes partageant les mêmes propriétés typographiques ou graphiques à des fins d'édition du document sur papier ou sur écran. Il s'agit d'un ensemble d'attributs de présentation qui permet de restituer une mise en forme rendant le document intelligible pour l'homme et la machine (Lalanne et al., 2005) ; Cela consiste, par exemple, à définir les différentes zones d'un document texte, leur agencement les unes par rapport aux autres, leurs types et couleur de police, *etc.* Ainsi, les facettes « *contenu logique* » et « *présentation* » du document peuvent être indépendamment manipulées.

3.3.1.3 La structure sémantique

Avec l'apparition d'usages nécessitant la mise en évidence de la sémantique du document, d'autres types de structures ont été proposés. Il s'agit des structures sémantiques (Poullet, 1997) qui permettent d'exprimer la structure des éléments du document en fonction de leur sens. Celles-ci incluent *la structure thématique* qui concerne le contenu textuel et correspond à une segmentation du document en blocs sémantiquement homogènes formant des thèmes ; et *la structure rhétorique* qui organise le contenu textuel en mots et motifs pour mettre en évidence les moyens d'expression et de persuasion dans le texte. La notion de structure rhétorique a été appliquée par la suite à d'autres types de documents numériques tels que les hypermédias. Les *structures d'annotations* sont une autre sorte de structures sémantiques qui sont nées du besoin d'annoter le contenu du document numérique.

3.3.1.4 La structure temporelle

Cette structure est souvent liée aux documents audiovisuels et peut concerner différents niveaux (e.g. succession des images, des plans, des scènes, *etc.*). Ainsi, elle peut être exploitée dans un processus d'analyse pour documenter ou structurer ces documents. Elle permet également de considérer toutes les opérations effectuées sur un document quelconque pour temporaliser celui-ci (Lalanne et al., 2005) telles les opérations de modification ou de projections de ses parties lors d'un diaporama.

3.3.2 Documents multi-structurés

Un document numérique peut donc comporter plusieurs structures à la fois dont chacune est souvent abordée de manière individuelle. Cela a incité des chercheurs du domaine documentaire à proposer des modèles formels pour le document numérique en tant qu'entité multi-structurée (Barrutieta et al., 2002; Iksal and Garlatti, 2002; Abascal et al., 2004; Djemal et al., 2009). Parmi ces travaux, nous tenons à en présenter deux qui nous ont servi dans le développement de nos idées à propos de la modélisation du document. Le premier travail (Abascal et al., 2004) concerne des recherches collectives sur la «*multi-structuralité*» des documents numériques menées au sein de l'Institut des Sciences du Document Numérique ; ce travail a abouti à une définition formelle du document à structures multiples et à un certain nombre d'opérations sur celui-ci (e.g. édition, fusion, etc.). Quant au deuxième travail (Djemal et al., 2009), il propose un méta-modèle pour le document multi-structuré basé sur des vues.

3.3.2.1 Une définition formelle du document numérique multi-structuré

Selon Abascal et al. (2004), un document numérique est un ensemble de structures documentaires mises en correspondance ; une structure documentaire est une description d'un document par un ensemble d'éléments en relation les uns avec les autres, au cours ou en vue d'un usage. D'un point de vue formel, ces chercheurs modélisent le document comme un ensemble d'éléments et de relations binaires ; et chaque structure documentaire dans celui-ci comme un multi-graphes étiqueté $S(N, L_N, I_N, L_A, A)$. Dans ce multi-graphes, N est l'ensemble des nœuds du graphe qui représentent les éléments de la structure, L_N est l'ensemble des étiquettes (labels) des nœuds et qui représentent les contenus des éléments, $I_N (: N \rightarrow L_N)$ est la fonction qui associe à chaque nœud son étiquette, L_A est l'ensemble des étiquettes des arcs et qui représentent les noms des relations, et $A (\subseteq N * N * L_A)$ est l'ensemble des arcs qui représentent les relations nommées entre les éléments du document. Les différentes structures du document, qui représentent les différents usages de celui-ci, sont mises en correspondance. Il existe une structure particulière, nommée *la structure première*, qui est constitutive du document en tant qu'unité ; et toute autre structure documentaire s'appuie sur celle-ci par le biais d'une correspondance directe ou indirecte avec elle.

Le document multi-structuré dans lequel sont considérés plusieurs usages possibles, et donc plusieurs décompositions structurelles, a été formalisé comme un triplet $D(S_0, \Sigma, C)$. Dans ce triplet, S_0 est la structure première du document, $\Sigma = \{S_i, i=1..n\}$ est l'ensemble des autres structures du document, et $C = \{C_{ij} \in corr(S_i, S_j)\}$ est l'ensemble des correspondances qui existent entre les structures du document et qui assurent, à la fois, la connexité ($\forall i \neq 0, \exists j < i / C_{ij} \in C$) et l'absence de circuits ($\forall i \leq j, C_{ij} \notin C$) dans le document. La figure 3.1 présente, à gauche, un exemple de document multi-structuré où les différentes structures sont en relation par des correspondances avec la structure première S_0 ; et à droite, un exemple particulier de document bi-structuré où la structure S_0 correspond à un texte sans une mise en forme, enrichi par la structure S_1 . Cette modélisation du document numérique permet également de formaliser les différentes opérations pouvant être effectuées sur le document telles que : les opérations d'édition (e.g. ajout ou suppression d'éléments, d'arcs, de structures ou de relations de correspondances), de fusion et d'éclatement, de duplication (e.g. recopier une structure documentaire pour la compléter), etc.

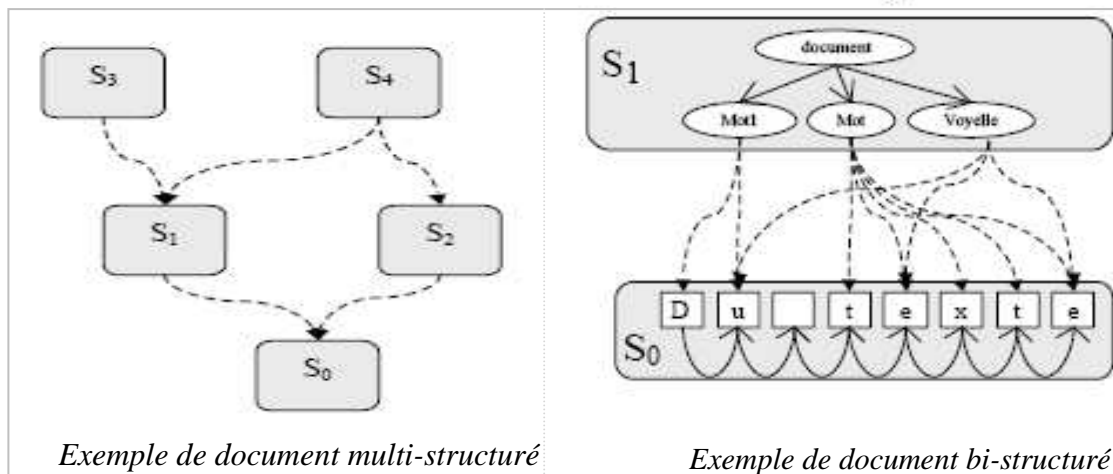


Figure 3.1. Une modélisation du document multi-structuré comme un ensemble de structures mises en correspondance avec une structure première (Abascal et al., 2004).

3.3.2.2 Un méta-modèle du document multi-structuré basé sur les vues

Du fait que chaque document numérique admet, d'une part, une structure logique composée par des éléments et leurs attributs, et d'autre part, une ou plusieurs structures sémantiques composées de métadonnées associées à un élément de la structure logique ; Djemal et al. (2009) ont conclu que la structure logique joue le rôle d'une structure pivot dans le document. Ils ont alors proposé de fragmenter le document en granules élémentaires (i.e. fragments) pour que la gestion de la multi-structuralité du document revienne à la gestion des relations qui relient ces différents fragments. Ils ont également proposé de créer des vues pour gérer différents types de relations afin de reconstituer les différentes structures rattachées à un même document.

Dans le méta-modèle qu'ils ont proposé pour le document numérique, représenté par la figure 3.2, les chercheurs ont distingué deux niveaux : un niveau générique et un niveau spécifique. Au niveau générique, une structure générique comporte des nœuds génériques typés (des éléments, des composants, des métadonnées ou des attributs) liés entre eux par des relations génériques typées (de composition, de synchronisation, d'agencement, etc.). Ces nœuds et relations génériques appartiennent à des vues typées dont chacune représente un type particulier de structures (une vue logique, une vue sémantique, une vue physique, une vue temporelle, une vue spatiale, etc.). Pour la vue temporelle du document, ces chercheurs ont proposé d'utiliser les relations d'Allen⁵³ pour gérer l'agencement temporel entre les nœuds du document ; alors que pour la vue spatiale (de disposition) de celui-ci, ils ont décrit trois types de relations à savoir topologique (e.g. « devant », « derrière », « touche », etc.), directionnelle (e.g. « à droite », « partie de », « au-dessus de », etc.) et de distance (e.g. « près », « loin », etc.). Au niveau spécifique, un document est caractérisé par sa déclaration et est composé de plusieurs structures spécifiques (comme des spécialisations de structures génériques). Chaque structure spécifique comporte plusieurs nœuds spécifiques liés par des relations spécifiques dont chacune appartient à une vue spécifique particulière. Ainsi, le document numérique est modélisé comme une entité multi-structurée dont les différentes structures sont considérées ensemble et non individuellement.

⁵³ Les treize relations d'allen permettent d'identifier un ensemble complet de relations temporelles qui peuvent exister entre deux intervalles temporels (e.g. « Précède », « Rencontre », « Chevauche », « Débute », etc.).

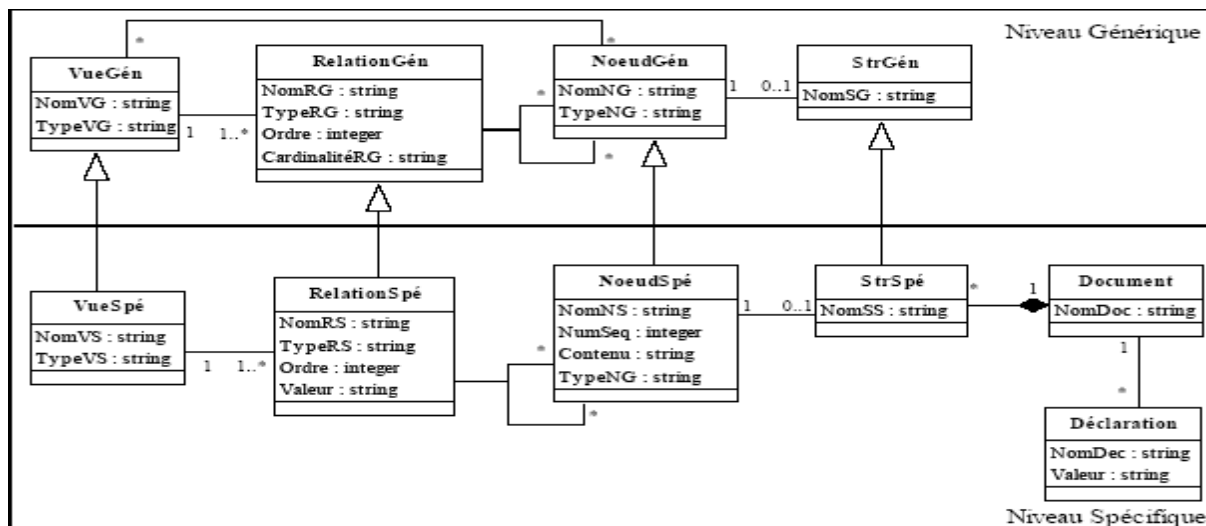


Figure 3.2. Un méta-modèle du document multi-structuré basé sur des vues (Djemaï et al., 2009).

Bien que différents modèles soient proposés pour prendre en considération la multi-structuralité du document numérique, le problème qui se pose vraiment c'est la manière de concevoir, d'élaborer et d'intégrer ensemble ces différentes structures afin d'aboutir à un document au sens propre du mot (i.e. lisible, compréhensible et ayant une portée sociale). Pour les documents classiques, tels les livres, le processus de création de contenu ou d'*authoring* de ceux-ci est un processus cognitif mené par un auteur ayant un savoir-faire dans le domaine et des choix d'organisation et de présentation. Mais, dans le contexte numérique, toute personne est censée pouvoir créer des documents, sans pour autant avoir les compétences d'un auteur talentueux. Cette possibilité est supportée en partie via la possibilité de réutiliser des documents existants et la disposition de différents outils d'édition de ceux-ci tel l'éditeur de traitement de texte *Word* ; mais il reste à supporter le travail cognitif de l'auteur dans la création de contenu de document en se servant des sources d'informations qui sont à sa disposition. C'est cette problématique que nous étudions dans la section qui suit.

3.4 La création de contenu de document numérique

Nous nous sommes intéressés jusque-là au statut du document dans son passage au numérique ; mais que peut-on dire du statut et de la fonction de l'auteur de celui-ci ? En effet, la publication électronique a fait perdre à l'auteur son autorité sur sa production puisque du moment où le document pénètre sur un réseau, il devient potentiellement un document public. C'est ainsi que Bourgeois s'est interrogé sur la liberté de l'auteur dans *la divulgation de sa production personnelle dans ce vernis d'universalité de la diffusion qui rend le statut de cet être créateur mal défini* (Bourgeois, 2002). En outre, le processus de création de contenus de documents, à la base encapsulé dans la fonction *auteur* et défini par son savoir-faire, a besoin d'être supporté dans le contexte numérique puisque cette création n'est pas, et ne devra pas être, conditionnée par l'acquisition de compétences très particulières. Dans cette section, nous commençons par étudier le statut de l'auteur dans le contexte numérique, puis nous passons à l'analyse de son travail cognitif et de la façon dont celui-ci est supporté par les outils numériques.

3.4.1 Le statut de l'auteur dans le contexte numérique

L'auteur a été défini comme une autorité et un rédacteur dont les écrits sont reconnus comme des monuments par l'institution littéraire (Compagnon, 1998). Par ailleurs, Foucault le considère plutôt comme une fonction (Foucault, 1969), en particulier pour le lecteur qui lit le livre en fonction de ce qu'il en sait et de ce que l'hypothèse de l'auteur permet comme opérations de lecture et d'interprétation. Cette fonction est une construction non spontanée, mais qui résulte d'opérations complexes qui construisent la figure d'un certain être de raison qu'on appelle « auteur » dans le texte produit par celui-ci. En 1968, Barthes a proclamé que « *la naissance du lecteur devait se payer de la mort de l'auteur* » (Barthes, 1984) ; trente cinq ans plus tard, une multitude de débats a amené Antoine Compagnon à avancer que « *le point le plus controversé en études littéraires, c'est la place qui revient à l'auteur* » (Compagnon, 1998). Par la suite, il s'est affirmé que l'auteur reste bien le personnage le plus mal connu de ce qui pourrait être appelé le système-livre (Barbier, 2002). L'auteur a ainsi combattu pour la reconnaissance de ses droits patrimoniaux et moraux sur son œuvre.

Avec l'arrivée des technologies numériques, la notion de « publication » et les pratiques d'utilisation des outils de communication ont rendu floues les frontières entre les étapes de création, de sélection et de diffusion des documents. De plus, la présence de l'auteur et sa représentation dans le document numérique pose un problème puisque il semble y avoir, à la fois, un désir d'une plus forte présence de l'auteur au sein du document et un phénomène de perte d'identité de cet auteur (Pédauque, 2005). Le passage du document au numérique a imposé une évolution de la notion d'auteur dans ses implications pratiques (i.e. extension de la sphère auctoriale vers la mise en forme et la publication), juridiques (i.e. relation entre droit et contrats dans le domaine de la propriété intellectuelle), littéraires ou scientifiques (i.e. à qui appartiennent les idées) et sociales (i.e. un nouveau contre-pouvoir de la parole publique) ; avec un très fort bouclage entre l'auteur et le lecteur. A cet égard, une classification des documents numériques et des outils d'écriture en termes de relation de l'auteur à la manifestation physique et perceptive du document (i.e. en fonction du degré de contrôle que l'auteur exerce sur la forme et la présentation du document) semble être intéressante. Nous pouvons ainsi conclure que le numérique a imposé à l'auteur d'assumer des tâches multiples (édition, classement et référencement) ; alors qu'il est également utile d'intégrer l'ensemble de la chaîne du document, de sa rédaction à son insertion dans l'univers documentaire (traitement de texte, blogs, wikis, puis archives ouvertes). Toutefois, l'imbrication des pratiques et des techniques qui caractérisent cette évolution a favorisé l'émergence de nouvelles pratiques actoriales et de lecture ; c'est ce que nous allons étudier dans ce qui suit en commençant par le processus d'*authoring* du document numérique.

3.4.2 De l'édition à l'*authoring* du document numérique

L'*authoring* d'un document désigne la création du contenu de celui-ci sans pour autant oublier sa présentation dans une forme particulière lisible et compréhensible. Alors que cela sous-entend une fonction d'écriture explicite pour les documents classiques, cette fonction est plutôt abstraite dans le contexte numérique. D'une part, les trois niveaux sémantique, logique et physique ne sont pas dissociables dans un document classique alors qu'ils le sont dans un document numérique ; cela rend possible leur traitement séparément en considérant une structure spécifique pour chacun de ces niveaux. D'autre part, l'*authoring* des documents classiques est un processus cognitif basé principalement sur les connaissances et les pratiques d'individus compétents (i.e. les auteurs) alors que celui des documents numériques est censé être supporté par des outils et des technologies favorisant le partage de la connaissance et facilitant la création, l'organisation et la présentation de documents à grande échelle. Dans un

premier temps, cette facilitation s'est traduite par la disponibilité de logiciels éditeurs, tels que PowerPoint et Word alors que dans un second temps, elle s'est étendue au fait d'encourager des individus ordinaires à développer des compétences métacognitives et procédurales de véritable *auteur*. C'est ainsi que la notion de « *système d'authoring* » ou encore « *système auteur* » est apparue.

3.4.2.1 La notion de système ou d'outil auteur

Un système auteur est un système informatique de création de contenu de documents qui permet à ses utilisateurs de créer facilement des documents en utilisant des fonctions souvent accessibles via l'interface graphique du système ; cela sans pour autant avoir des compétences particulières en programmation. De façon plus précise, un outil auteur est défini comme un « *un programme qui aide ses utilisateurs à écrire en utilisant des applications hypertexte ou hypermédia et permet de créer un document ou une application en reliant ensemble des objets (paragraphes de texte, illustrations, images, sons, etc.) et en arrangeant ceux-ci dans un ordre approprié* » (Khademi et al., 2011). Ainsi, les utilisateurs de ce type de programme sont considérés comme des auteurs assistés ; alors, pour créer une application multimédia par exemple, il est intéressant d'utiliser un système auteur mieux que de se lancer dans un mélange de genres (e.g. mixer Word avec Visuel Basic et Powerpoint). Un système auteur multimédia doit pouvoir afficher au moins des images, des textes et des sons ; le tout chapeauté par des fonctions programmées dans un langage caché à l'utilisateur pour réaliser des manipulations plus poussées du document produit. Les outils et systèmes auteur englobent et dépassent de loin les outils éditeur et les scripts spécialisés dans la création de contenu (Treviranus, 2008), ainsi que les outils de création de documents multimédia, les outils de gestion et de publication de sites Web, les sites permettant à leurs utilisateurs l'ajout de contenu (blogs, wikis...), *etc.* Cependant, les travaux de recherche à propos des systèmes et outils auteur ne se focalisent pas sur le traitement des problèmes d'*authoring* (e.g. la proposition des principes généraux d'*authoring*, la classification des outils et des systèmes auteur existants, *etc.*) ; ils se concentrent plutôt sur la proposition de nouveaux outils auteurs spécialisés (Spierling and Szilas, 2009).

Les systèmes et outils auteur sont conçus pour faciliter le travail de création de contenus documentaires ; ainsi, ils supportent souvent des facilités d'interaction pour leurs utilisateurs. Ces outils sont basés sur trois principes importants (Treviranus, 2008) : le choix approprié de formats et de technologies à exploiter, la création de contenus équivalents dans des formats différents (e.g. photo et description textuelle) et la description et la structuration appropriées pour le contenu (e.g. tableaux, structures, *etc.*). Pour cela, ils doivent comporter les fonctions standards d'*authoring* (couper, copier, coller, et déplacer) ainsi que d'autres fonctions spécifiques (e.g. la fonction de contrôle de prononciation linguistique) ; ils peuvent également comporter des modules assistants ou des agents intelligents basés sur des modélisations formelles des pratiques d'*authoring* (e.g. modèles de grammaires) et de documents. En outre, les utilisateurs de ces outils peuvent bénéficier de différents choix et suggestions, de contenus réutilisables, de modèles de contenu et de présentation, de documentation, d'une assistance dans le contrôle et la révision des contenus produits, *etc.* Par ailleurs, un outil auteur ne doit pas s'imposer à son utilisateur.

3.4.2.2 Domaines d'utilisation des systèmes et outils auteur

Les systèmes et outils auteur sont utilisés dans différents domaines, et pour différents objectifs, que nous ne pouvons pas tous énumérer ; cependant, nous avons pu distinguer deux domaines pour lesquels ces outils jouent un rôle important et le travail de recherche sur le

sujet ne cesse de progresser. Le premier domaine est celui de la création de contenus Web alors que le deuxième est celui de la création de matériels d'enseignement de type tutoriel.

Les outils auteurs pour la création de contenu Web. Les outils auteur jouent deux rôles critiques dans le cadre du Web (Treviranus, 2008) : ils offrent un mécanisme puissant pour promouvoir la création de contenu web et sont la clé d'une participation équitable à la communication via le Web. Avec l'émergence de la notion de « Web participatif »⁵⁴ en particulier, le besoin que les personnes qui sont à la base des consommateurs sur le Web puissent produire des informations et participer à des conversations sur le Web s'est accru. Aujourd'hui, les auteurs du Web forment une partie majoritaire de la population ; celle-ci regroupe des auteurs et des éditeurs professionnels, des employés dont le travail occasionnel est la création de contenu Web, des amateurs, des parents, des grands-parents, des enfants, *etc.* Alors que les auteurs professionnels peuvent créer des contenus Web sans soucis (puisqu'ils maîtrisent le langage HTML par exemple), les autres personnes trouvent une difficulté puisqu'elles ne sont pas initiées au travail d'auteur. C'est à ce niveau que les outils auteurs (tels que NetObjects Fusion, Microsoft FrontPage et Macromedia Dreamweaver) peuvent jouer un rôle incontournable pour motiver ces personnes à devenir des producteurs d'informations sur le Web (Gandhe et al., 2009). Parfois, le travail de création de contenu est collaboratif ; alors si ce contenu est un document texte par exemple, l'outil auteur doit pouvoir suivre et visualiser (par des changements de couleurs et d'autres aspects visuels) la trace des modifications apportées par les auteurs collaborateurs sur le contenu produit, et fournir des moyens de communication pour rendre l'information et la collaboration accessibles.

Les outils auteurs pour la création de contenus pédagogiques. Dans les situations pédagogiques centrées sur le e-learning, les documents d'enseignement de type tutoriel jouent un rôle très important. Mais pour que les tuteurs ou les enseignants puissent créer ces contenus pédagogiques et informatiques, ils sont souvent obligés de maîtriser des langages de programmation et d'avoir des compétences spécifiques. Face à cette contrainte, des outils auteurs ont été mis en place pour faciliter la création de contenus pédagogiques à forte valeur ajoutée (Sharma, 2005) ; leur principe est de répertorier des principes de base qui peuvent constituer un cadre méthodologique pour cette activité créatrice. Ces outils permettent également de scénariser les formations selon des cheminements complexes et de produire des contenus en plusieurs langues simultanément. Souvent, ils utilisent des aspects multimédia (e.g. la technologie flash) ; d'ailleurs, « *multimédia et autoformation jouissent à l'heure actuelle d'une vogue simultanée au point que l'on conçoit difficilement l'un sans l'autre* » (Demaiziere, 1996). Dans ce domaine, Joseph Rézeau parle plutôt de langages auteurs et de systèmes auteurs (Rézeau, 2001). Un langage auteur (tel que Toolbook⁵⁵) est un métalangage informatique spécialisé qui permet aux concepteurs de didacticiels d'éviter d'avoir à programmer dans un langage informatique (tel que Pascal) ; il offre des outils de gestion du matériel et de conception de l'interface, permet la gestion des aspects multimédias (son, image fixe ou animée) et comporte les outils nécessaires à la conception des exercices les plus typiques des tutoriels (e.g. la fabrication de QCM, l'analyse de réponses, *etc.*). Quant au système auteur (tel que la série de programmes Wida Authoring Suite), c'est un système plus ou moins complexe et spécialisé ; il permet de générer des exercices simples plutôt que des didacticiels complets. Ces deux types forment ainsi une continuité entre une

⁵⁴ « participatory Web » : une notion définie par Kelly (http://www.wired.com/wired/archive/13.08/tech_pr.html)

⁵⁵ Toolbook : un environnement de programmation d'applications multimédias orientées vers l'apprentissage assisté par ordinateur qui est basé sur la métaphore du livre (i.e. chaque livre est composé d'une suite de pages à travers lesquelles l'utilisateur navigue en cliquant sur des boutons, des liens, etc.)

simplicité d'emploi d'une part, et une performance de médiatisation des contenus didactiques et de la démarche pédagogique des enseignants de l'autre. Les langages et systèmes auteurs orientés vers la création de didacticiels en général et de didacticiels de langues en particulier offrent la possibilité de créer différents types d'activités (Rézeau, 2001), en s'appuyant sur des supports multimédias et des liens hypertexte ; mais les modèles et les protocoles proposés ne sont que des choix de concepteurs, ce qui risque de poser une limite pour les enseignants.

Nous constatons, d'après ce que nous venons de présenter à propos des outils auteurs, que ces outils sont capables d'assurer de l'assistance au travail d'auteur ; mais pour cela, un outil auteur doit exploiter certaines bases théoriques telles que les principes de la théorie de la structure rhétorique RST (Mann and Thompson, 1988) que nous décrirons par la suite. En effet, c'est le niveau sémantique du document qui compte le plus dans la construction de celui-ci puisque les deux autres niveaux (logique et physique) peuvent être construits selon des modèles prédéfinis.

3.4.3 RST: une théorie de base pour les outils auteur

3.4.3.1 Définition de RST

La théorie de la structure rhétorique (RST) est une théorie qui a été proposée par Mann et Thompson initialement pour analyser les textes (Mann and Thompson, 1988). Elle permet de diviser un texte en segments avec des relations rhétoriques entre ceux-ci, de telle sorte que les effets combinés de ces segments et relations assurent la cohérence de l'ensemble. Les relations rhétoriques sont souvent utilisées pour développer une argumentation liant ensemble des éléments d'un contenu ; cela inclut la cause et la conséquence, l'interprétation et la justification, la jonction et le contraste, *etc.* La majorité de ces relations sont binaires et tiennent souvent entre un segment qui est plus indispensable à la compréhension du texte (segment Noyau) et un segment plus secondaire (segment Satellite). C'est ainsi qu'elles sont classées comme des relations de type *Satellite à Noyau* (S-N) ou de type *Noyau à Noyau* (N-N) (Taboada and Mann, 2006a). Cependant, ces relations sont des constructions abstraites qui relient deux segments de discours entre eux (i.e. deux parties minimales d'un texte inférieures à la phrase ou deux ensembles de phrases) mais qui ne sont pas forcément signalées par un indice linguistique dans le texte (tels que les connecteurs linguistiques). En prenant l'exemple de la phrase « *j'ouvre mon parapluie parce qu'il pleut* », le connecteur linguistique « *parce que* » permet de repérer une relation rhétorique de causalité entre les deux parties de la phrase ; alors que pour une phrase similaire, telle que « *il pleut, j'ouvre mon parapluie* », ce repérage n'est pas possible. Nous décrivons les relations rhétoriques en détail dans ce qui suit.

3.4.3.2 Les relations définies par RST

Mann et Thompson (1988) n'ont volontairement pas défini un nombre fixe de relations rhétoriques ; ils ont simplement proposé un ensemble de relations de base permettant d'analyser la plupart des textes anglais. Les définitions de ces relations peuvent être modifiées et leur nombre également pour assurer une flexibilité ; c'est d'ailleurs cet aspect qui permet une analyse plus ou moins fine des textes. Dans le tableau 3.1, nous décrivons les relations rhétoriques tout en les classant selon leurs types.

	Nom de la relation	Noyau	Satellite (ou Noyau)
Relation S-N	Préparation (<i>Preparation</i>)	texte qui va être présenté	texte préparant le Lecteur à anticiper et à interpréter le texte qui va être présenté.
	Contraste (<i>contrast</i>)	une possibilité dans une alternative	l'autre possibilité
	Anti-condition (<i>Otherwise</i>)	situation résultante de la non-occurrence d'une situation	la situation conditionnante
	Antithèse (<i>Antithesis</i>)	idées approuvées par l'auteur	idées rejetées par l'auteur
	Arrière-plan (<i>Background</i>)	texte dont la compréhension est facilitée	texte servant à faciliter la compréhension
	But (<i>Purpose</i>)	une situation cible	l'intention sous-jacente à la situation
	Cause délibérée (<i>Volitional Cause</i>)	une situation	une autre situation, cause de la première, du fait de l'action délibérée de quelqu'un
	Cause non délibérée (<i>non-volitional</i>)	une situation	une situation provoquant la première mais pas du fait d'une action délibérée
	Circonstance (<i>Circumstance</i>)	texte exprimant les idées dans le cadre interprétatif	un cadre interprétatif temporel ou situationnel
	Concession (<i>Concession</i>)	situation défendue par l'auteur	situation apparemment incompatible, mais également défendue par l'auteur
	Condition (Condition)	Action/situation résultante de l'occurrence d'une situation	la situation conditionnante
	Démonstration (<i>Evidence</i>)	une affirmation	information destinée à accroître la croyance du lecteur (l'affirmation)
	Élaboration (<i>Elaboration</i>)	information de base	information supplémentaire
	Évaluation (<i>Evaluation</i>)	une situation	un commentaire évaluatif de la situation
	Facilitation (<i>Enablement</i>)	une action	information destinée à aider le lecteur à accomplir cette action
	Interprétation (<i>Interpretation</i>)	une situation	une interprétation de la situation
	Justification (<i>Justify</i>)	un texte	information légitimant l'énonciation du texte par l'auteur
	Motivation (<i>Motivation</i>)	une action	information destinée à accroître chez le lecteur le désir d'accomplir l'action
	Reformulation (<i>Restatement</i>)	une situation	une reformulation de la situation
	Résultat délibéré (<i>Volitional Result</i>)	une situation	une autre situation, causée par celle-ci, du fait de l'action délibérée de quelqu'un
Résultat non-délibéré	une situation	une situation provoquée par la première, mais pas du fait d'une action délibérée	
Résumé (<i>Summary</i>)	un texte	un court résumé de ce texte	
Solution (<i>Solutionhood</i>)	un procédé apportant une satisfaction au besoin	un problème, une question, ou tout autre besoin exprimé	
Relation N-N	Nom de la relation	Noyau	Noyau
	Contraste (Contrast)	une possibilité dans une alternative	l'autre possibilité
	Jonction (Joint)	(non-contraint)	(non-contraint)
	Liste (List)	un item	l'item suivant
	Séquence	un item	l'item suivant

Tableau 3.1. Les relations rhétoriques définies par Mann et Thompson (1988)⁵⁶.

3.4.3.3 Les différents domaines d'applications de RST

La théorie de la structure rhétorique est caractérisée par sa simplicité et la diversité de ses applications parmi lesquelles : la génération et l'analyse de textes (Taboada and Mann, 2006b)

⁵⁶ Tableau extrait du site de RST (<http://www.sfu.ca/rst/07french/introduction.html>)

génération de documentaires vidéos (Bocconi et al., 2005), l'aide à l'écriture (De Silva and Henderson, 2005) et le développement de modèles pour des applications de *storytelling* (Nakasone and Ishizuka, 2006). RST est également utilisée pour le maintien de la cohérence de documents produits (Taboada and Mann, 2006a) ; ainsi que pour le soutien du travail de création de contenus. C'est d'ailleurs ce que nous allons montrer par la suite à travers la description de l'un des outils auteurs qui se base sur les principes de cette théorie.

3.4.4 Des exemples d'outils auteurs

Plusieurs outils et systèmes auteurs ont été développés pour des domaines et des besoins différents. Parmi ceux-ci, nous citons quelques exemples qui nous ont intéressés tels que : l'outil Artequakt (Kim et al., 2002) qui permet de générer des biographies d'artistes appropriées à partir de fragments Web annotés automatiquement, le système DP (Rizzo et al., 2002) qui aide les petits enfants à préparer des présentations multimédia à partir de leurs cours, le logiciel M-PIRO (Androutsopoulos et al., 2006) qui permet de générer automatiquement et en plusieurs langues des descriptions textuelles pour des objets de musée, le système d'apprentissage réflexif STfWP (Mahmud, 2003) qui permet de révéler automatiquement la structure des relations de discours pour aider des étudiants à structurer leurs essais et le système de composition de documents virtuels personnalisables DVP (Iksal and Garlatti, 2002). Chacun de ces systèmes et outils se base sur des technologies et des principes théoriques plus ou moins différents ; quant au processus d'*authoring* qu'il supporte, il peut être totalement automatisé (cas de Artequakt, M-PIRO et le système de composition de DVP) ou partiellement automatisé (cas de DP et STfWP).

Le système Artequakt se base sur la réutilisation de fragments documentaires (contenus) disponibles sur le Web selon des modèles rhétoriques et utilise les technologies de recherche et d'annotation sémantiques sur ces fragments. Le système DP implémente les principes de RST pour la création de contenus et utilise des technologies multimédia telles que la production de speech à partir du texte. Le logiciel M-PIRO se base sur les principes de la génération du langage naturel à partir de modèles formels et exploite des technologies du Web Sémantique. Le système STfWP se base sur la recherche et l'intégration de différents attributs linguistiques et les principes de RST ; il utilise un analyseur linguistique, un dictionnaire et des représentations graphiques structurant les essais. Quant au système de composition de DVP, il se base sur des principes de RST et une composition tridimensionnelle (sémantique, logique et physique) du document ; les auteurs utilisent les technologies du Web sémantique (ontologies) et des modèles prédéfinis d'organisation et de présentation de documents. Dans ce qui suit, nous décrivons ce système de façon plus détaillée ainsi que le système DP car ils nous ont servi davantage dans notre travail de recherche sur le sujet de cette thèse.

3.4.4.1 Le système de composition de DVP

Iksal et Garlatti (2002) ont proposé un environnement déclaratif intéressant pour la spécification et la composition de documents virtuels personnalisables (DVP) ; un DVP est un ensemble d'éléments (fragments) associés à des mécanismes de filtrage, d'organisation et d'assemblage qui respectent un modèle de l'utilisateur et des principes rhétoriques (Ranwez and Crampes, 1999) ; il se présente le plus souvent comme un document hypermédia. Ce système favorise la réutilisation des fragments documentaires disponibles sur le Web et automatise la construction de documents à partir de ces données. Il s'agit ainsi d'un système d'*authoring* automatique où la construction d'un DVP est fondée sur deux étapes (figure 3.3) : la spécification d'un modèle de document en définissant les fragments qui vont constituer le document réel puis la composition de ce document à partir de sa spécification et des critères de personnalisation de l'utilisateur.

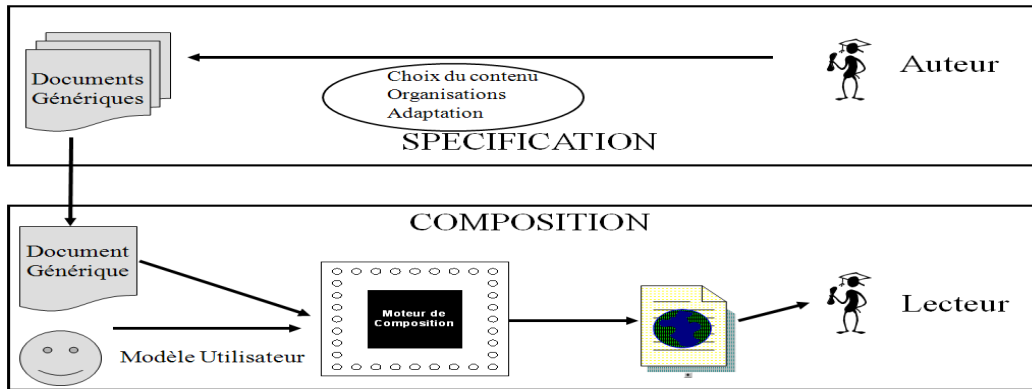


Figure 3.3. Les deux étapes de la construction d'un DVA (Iksal and Garlatti, 2002).

Le modèle de document. Il permet de modéliser le savoir-faire de l'auteur sous la forme d'une structure sémantique représentée par un graphe de nœuds et de relations rhétoriques ; le contenu de ces nœuds est personnalisé en fonction de l'utilisateur et calculé durant la construction du document réel. Ce modèle de document est instancié comme un document générique contenant une spécification déclarative des règles de sélection, d'organisation et de filtrage. La spécification de la sélection permet de choisir le contenu des nœuds dans le document ; elle est réalisée en définissant les propriétés sémantiques des segments documentaires associées à chaque nœud. Quant aux critères d'adaptation, ils sont spécifiés par des propriétés sémantiques associées aux documents génériques.

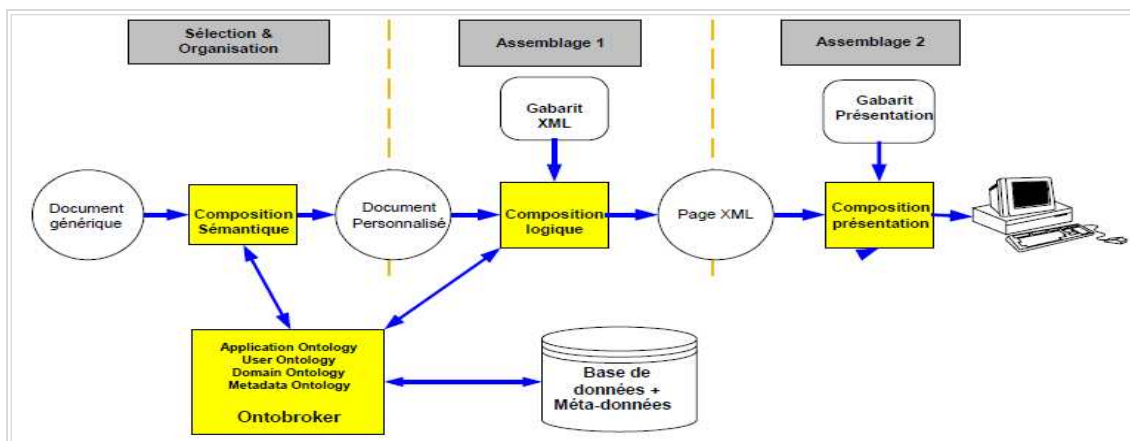


Figure 3.4. Le processus de composition (tridimensionnelle) d'un DVA (Iksal and Garlatti (2002).

Le processus de composition du document. Ce processus prend en considération les trois structures du document numérique (sémantique, logique et physique) et comporte trois phases (figure 3.4) : la sélection, l'organisation et l'assemblage. A ce niveau, quatre modèles (ontologies) sont utilisés : un modèle de documents, un modèle de domaine, un modèle utilisateur et un schéma de métadonnées. La phase de sélection permet de retrouver les informations (fragments documentaires) pertinentes selon la demande de l'utilisateur pour constituer un document réel ; cela via une recherche basée sur le schéma de métadonnées associées aux fragments documentaires et le modèle utilisateur. La phase d'organisation permet de calculer le résultat de la phase de sélection (l'ensemble de fragments sélectionnés liés par des relations sémantiques) pour une représentation dans le système et repose sur le modèle de document. La phase d'assemblage permet la présentation du document réel et se décompose en deux étapes effectuées par la composition logique et la composition de présentation. La composition logique

parcourt le document personnalisé et engendre pour chaque nœud une page Web avec ses liens de navigation en utilisant un gabarit de page et le modèle utilisateur afin de générer une page XML ; tandis que la composition de la présentation construit une page HTML en appliquant des règles de présentation (e.g. typologie, couleur, *etc.*) dépendantes du lecteur.

3.4.4.2 Le système auteur de présentations multimédia (DPs)

Le système DPs (Rizzo, Shaw et Johnson, 2002) fournit un outil pédagogique interactif, développé dans le but d'aider les petits enfants à apprendre à créer des présentations structurées pour expliquer des concepts de leurs cours. Il est basé sur la théorie de la structure rhétorique (RST) pour pouvoir analyser les pages Web des cours et permet, à la fois, la création et la présentation de contenu multimédia supporté par une marionnette digitale ; un caractère animé qui aide l'apprenant à comprendre le sujet. Dans ce système, présenté par la figure 3.5, trois types d'utilisateurs sont considérés : le concepteur, l'auteur et le visionneur. Le concepteur annote le texte de la page Web de cours avec des relations rhétoriques, l'auteur crée une présentation multimédia basée sur une marionnette digitale pour enrichir la page Web et le visionneur (l'auteur, un apprenant ou un enseignant) fait jouer la présentation créée. Par conséquent, ce système est composé de trois parties : l'outil d'annotation de texte basé-RST du concepteur, l'outil auteur qui embarque l'agent pédagogique pour assister l'auteur et l'environnement où l'on fait jouer la présentation produite.

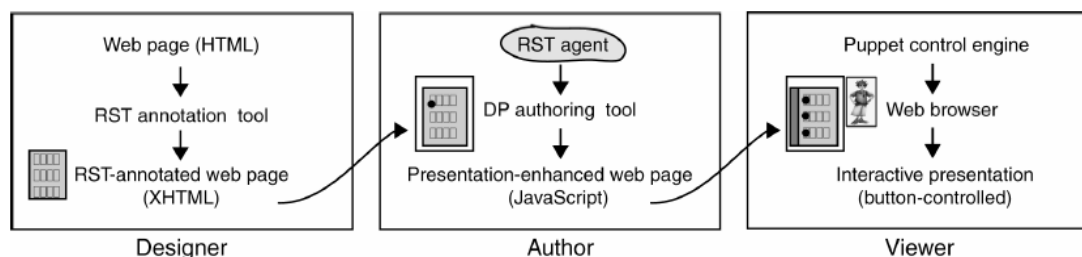


Figure 3.5. Le système DPs, comportant l'agent pédagogique et l'outil d'annotation basé-RST (Rizzo et *al.*, 2002).

Le déroulement des opérations dans le système. Au début, une page Web sur le sujet de cours est sélectionnée (ou créée) par l'enseignant ; elle est soumise à une annotation manuelle par le concepteur en utilisant un outil d'annotation basé-RST, ce qui produit une analyse rhétorique du texte exprimée par un marquage des relations rhétoriques dans celui-ci. Puis la page Web annotée avec des relations rhétoriques est affichée par l'outil auteur du système alors que l'agent RST interagit avec l'auteur (apprenant ou enseignant) pour lui expliquer le sens des relations rhétoriques, surligner la structure de la page et proposer des façons de structurer les présentations. L'outil auteur est une application Java qui permet à l'apprenant de rajouter de nouvelles relations rhétoriques à la page Web annotée avec des textes pour expliquer ou introduire des parties (paragraphes) de cette page ; les textes ajoutés et les boutons interactifs associés à ceux-ci sont insérés dans la page avec du JavaScript. L'outil auteur crée un affichage pour la page avec deux cadres. Dans le premier cadre, il insère une fonction JavaScript qui permet de contrôler le comportement animé d'une marionnette digitale et de communiquer avec un moteur de conversion de texte en discours ; alors que dans le deuxième cadre, il affiche la page Web annotée qui inclut une synthèse des contenus texte qui correspondent aux relations rhétoriques ajoutées par l'apprenant. La figure 3.6 présente, à gauche, l'interface de l'outil auteur du système DPs et, à droite, la page Web

enrichie et la marionnette digital qui permet d'exprimer le texte ajouté via des relations rhétoriques. A la fin, l'outil auteur fait appel à un navigateur pour afficher les résultats.

Les relations rhétoriques ajoutées et leur expression. Deux types de relations rhétoriques sont proposés à l'auteur pour annoter la page Web : des relations explicatives (*Cause, Result, Evidence, Contrast, Restatement et Elaboration*) pour les parties de la page et des relations introductives (*Introduction, Background et Motivation*) pour toute la page. Chaque relation entraîne la saisie d'un texte qui s'attache à une partie de la page (par un bouton) et que la marionnette digitale peut exprimer par un discours et des gestes en fonction du type de la relation rhétorique utilisée. L'outil auteur permet également de produire une synthèse (un résumé) de tous les textes ajoutés via des relations rhétoriques avec l'expression de ces relations par des mots ou des phrases (e.g., « *Why?* » pour la relation *Cause*).

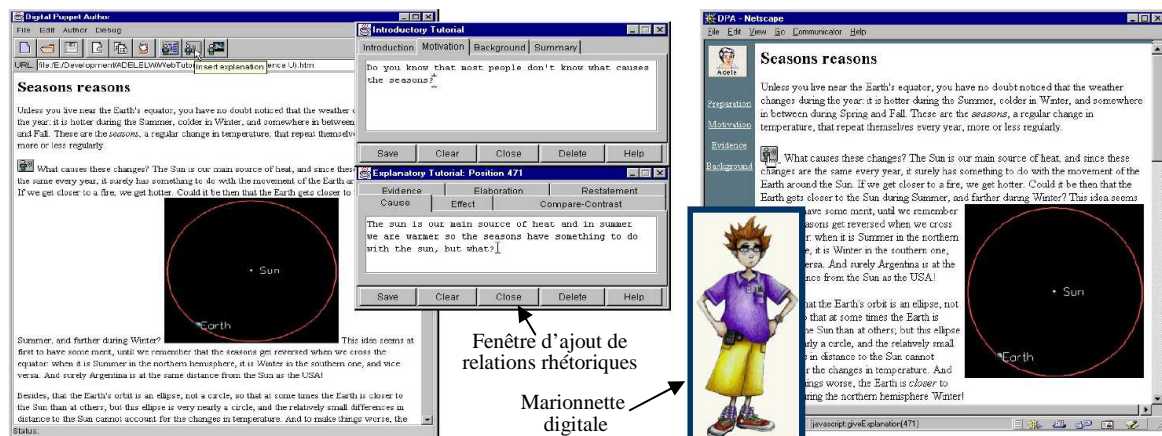


Figure 3.6. L'interface de l'outil auteur de DPs (Rizzo, Shaw et Johnson, 2002).

Maintenant que nous avons fourni des détails sur le processus d'*authoring* de documents numériques, ses outils, ses domaines d'application et certaines technologies et bases théoriques exploitées ; nous pouvons passer à la description d'une pratique traditionnelle étroitement liée à ce processus. Il s'agit du *storytelling* qui a de tout temps eu une grande importance dans la production d'histoires ; mais qui prend également sa place dans le contexte numérique. Nous décrivons ainsi dans la section suivante comment le processus d'*authoring* peut servir concrètement la mise en place d'une pratique de *storytelling*.

3.5 L'authoring au service du storytelling

Les hommes ont depuis toujours communiqué, cherché et donné du sens au monde avec des récits. Ainsi, Roland Barthes⁵⁷ a considéré le récit comme l'un des grands moyens que nous utilisons pour comprendre et ordonner le monde. Cette idée s'est imposée sous le terme anglais « *Storytelling* » qui désigne simplement « *l'art de raconter des histoires* ». Il s'agit d'une méthode basée sur l'application de procédés narratifs dans la technique de communication pour renforcer l'adhésion du public au fond du discours (Frenzel et al., 2004). Le paradigme narratif (Fisher and Arnold, 1989) introduit par Walter Fischer suppose que les récits ne forment pas juste une partie de la communication ; mais que toute communication est une forme de narration (*Storytelling*). Ce paradigme affirme également que l'homme n'est pas

⁵⁷ écrivain et sémiologue français (1915-1980)

un animal rationnel mais un animal narratif puisque, d'une part, il crée des récits et raconte des histoires pour donner du sens à ses actions et, d'autre part, il base ses actions et ses décisions sur des récits. Le *Storytelling* est ainsi une pratique naturelle qui remonte à un passé très lointain mais qui a pu subsister au fil du temps puisqu'elle facilite l'apprentissage, la mémorisation et l'appropriation du savoir et des messages. Cependant, cette pratique a subi quand même certains changements introduits par l'évolution de la société et des moyens mis à sa disposition et s'est imposée dans plusieurs domaines tels que la politique, le management, la publicité, *etc.* Avec l'émergence des technologies numériques, d'autres termes ont apparus pour désigner cette pratique, en particulier « *storytelling numérique* » ; cela a incité des chercheurs tels que Julien Daubert et Eliot Jacquin à analyser la montée en puissance de cette nouvelle forme de récit dans le contexte numérique. Ils se sont alors posés de nombreuses questions telles que : *Quel rapport pertinent peut-on tisser entre les « histoires numériques » et les narrations d'autrefois ? Outre les nouvelles techniques qui permettent des résolutions plus élevées, y a-t-il une révolution dans la construction du message ?* (Daubert and Eliot, 2010). Pour répondre à ces questions, nous étudions l'évolution de cette notion dans le contexte numérique.

3.5.1 Le storytelling dans le contexte numérique

Le *storytelling* a été pendant une longue période le seul moyen que les gens ont utilisé utilisaient pour apprendre les uns des autres ; mais avec le développement de la société industrielle, cette pratique est devenue peu populaire. L'émergence des technologies numériques et des services du Web 2.0 a introduit de nouveaux moyens de communication adaptés à cette pratique (e.g. les blogs, les wikis, les sites de vidéos tel Youtube, *etc.*) ; le *storytelling* a vite repris une place privilégiée. Plusieurs projets (e.g. TALE, HiStory, *etc.*) ont été proposés dans le but d'encourager les gens à créer des histoires et à partager celles-ci comme un moyen d'apprentissage pour différents objectifs (Strahovnik and Mecava, 2009). Dans ce contexte, l'histoire est toujours considérée comme un moyen fondamental pour garder, organiser, donner du sens et communiquer des informations ; cependant, les nouvelles technologies ont introduit une nouveauté dans sa mise en scène (i.e. le *storytelling*). En prenant l'exemple d'un jeu vidéo, Daubert et Jacquin pensent que celui-ci est considéré comme une histoire ; mais « *ce qui fascine le plus dans cette histoire c'est le décor, la voix énigmatique, les cinématiques et surtout la non-linéarité du discours. Le spectateur ou le joueur a le sentiment d'être libre tout en étant dans un récit cohérent...* » (Daubert et Jacquin, 2010). Alors comment cette pratique est-elle supportée concrètement dans le contexte numérique ? Une question dont la réponse nécessite de commencer par définir l'histoire en tant que produit et le *storytelling* en tant que processus de mise en scène de celle-ci dans le contexte traditionnel.

3.5.1.1 L'histoire et le storytelling dans le contexte traditionnel

D'après l'étude de Brooks (Brooks, 1997), le mot « *histoire* » est souvent utilisé pour désigner « *toute explication d'événements, de personnes et/ou d'objets* » ; ou encore « *une référence à une description générale ou abstraite d'une collection significative d'événements, de personnes et/ou de choses* ». Le mot « *significative* » dénote une liaison temporelle ou causale entre ces événements, ces personnes et ces objets (i.e. un événement précède un autre, une personne cause un événement, *etc.*) ; cela crée une structure dans laquelle les éléments de l'histoire sont interconnectés et l'histoire peut être vue comme un système d'associations entre ces éléments. Cependant, raconter une histoire (*storytelling* ou narration) signifie choisir un support et une manière pour exprimer celle-ci. A ce propos, Branigan caractérise la relation entre l'histoire et la narration de celle-ci comme celle qui existe entre l'organisation de

l'information et le mode d'expression pour cette organisation (Branigan, 1992, p. 106) ; ce mode décide finalement de ce qui sera dit et de comment ce sera dit. Autrement dit, l'histoire représente un univers d'éléments interconnectés et le *Storytelling* représente une navigation à travers cet univers en adoptant certaines décisions éditoriales. Avec les ordinateurs, des choix éditoriaux complexes peuvent se faire rapidement ; on peut alors se demander si l'ordinateur peut supporter le *storytelling*. A ce propos, Brooks suppose que si l'ordinateur dispose de moyens pour être guidé dans ce domaine alors il pourra créer et raconter des histoires. Pour lui, un système de storytelling est « *un système d'éléments d'une histoire stockés et organisés, que l'ordinateur extrait et rassemble selon une forme exprimée de narration.* » (Brooks, 1997) ; mais le problème est comment mettre en place concrètement un tel système.

3.5.1.2 L'histoire et le *Storytelling* dans le contexte numérique

Les machines exigent un haut niveau de formalisation pour les connaissances afin de pouvoir les utiliser et les partager ; ainsi, pour qu'elles puissent supporter le storytelling, elles doivent disposer au moins d'une modélisation formelle de l'histoire. L'un des modèles les plus intéressants du récit est celui proposé par Bal qui le voit comme une superposition de trois couches (Bal, 1997) : le *Fabula*, l'histoire et le récit. Le *Fabula* décrit les événements chronologiques de bas niveau (ou les objets) qui ont été représentés. L'histoire est un sous-ensemble du *Fabula*, restructuré et arrangé dans une nouvelle séquence pour assurer un effet (objectif) particulier ; ainsi, pour un seul *Fabula* plusieurs histoires peuvent exister. Le récit, qui représente le niveau le plus haut dans ce modèle, est l'histoire munie d'une forme particulière (e.g. monologue, livre, présentation multimédia, etc.). Pour que la machine puisse utiliser ce modèle, les ontologies qui sont des moyens de modélisation puissants du Web Sémantique peuvent être utilisées et différents systèmes peuvent se charger des différents niveaux du récit. Le système global qui supporte la production du récit avec ses différentes couches est appelé *un système de storytelling digital* ou *un système de storytelling numérique*.

Tuffield et ses collaborateurs ont décrit les caractéristiques des modèles ontologiques de chacun des trois niveaux du récit. Pour le niveau *Fabula*, ces chercheurs supposent que les annotations sémantiques des items multimédia et des sites web et permettant de décrire les entités et les événements dans ces items et sites forment un type de *Fabula* qui peut servir à la présentation d'histoires. Pour le niveau Histoire, ces chercheurs considèrent que les modèles ontologiques de ce niveau sont concernés par l'objectif de l'arrangement des items du *Fabula* ; il s'agit ainsi d'une connaissance structurelle à modéliser qui peut se baser sur le genre d'histoires auquel le lecteur d'attend. Toutefois, ils favorisent l'utilisation des grammaires d'histoire existantes souvent implémentées sous forme de modèles ; celles-ci contiennent des règles à propos de la manière d'arranger les parties d'une histoire pour un genre particulier. Par exemple, une grammaire basée sur le modèle de Toulmin et al. (1979) a été utilisée pour générer une argumentation rhétorique pour des documentaires vidéo (Bocconi et al., 2005). Pour le niveau récit qui concerne la présentation de l'histoire à travers un support, ces chercheurs pensent que la modélisation sémantique doit se concentrer sur les choix de la présentation de l'histoire ; ainsi, les modèles ontologiques de ce niveau dépendent de la forme à choisir et peuvent être dérivables du genre de l'histoire.

D'après cette étude de la mise en place du *storytelling numérique* et notre étude du processus d'*authoring* de document (voir section 3.4) ; nous pouvons conclure qu'il existe un lien étroit entre le *storytelling* et l'*authoring*. Le storytelling numérique est réalisé via la création de contenus d'histoires et leurs présentations sous différents formes ; cette possibilité est supportée par la machine via un processus d'*authoring* de documents ayant le modèle d'un récit. Par exemple, l'outil Artequakt (Kim et al., 2002) que nous avons décrit auparavant, et

qui permet de générer des biographies d'artistes à partir de fragments Web annotés automatiquement, n'est en fait qu'un outil de *storytelling numérique* puisque les biographies produites ont le modèle d'un récit. Dans la section qui suit, nous décrivons comment le *storytelling numérique* est supporté par différentes approches d'*authoring*, automatiques ou semi-automatiques (interactives), ainsi que des exemples de travaux sur le sujet.

3.5.2 Les approches d'*authoring* d'histoires

Les approches d'*authoring* de documents numériques en général peuvent être classées en deux catégories : les approches purement automatiques et les approches semi-automatiques (interactives). Du fait que les systèmes auteurs sont conçus pour aider les auteurs à créer des contenus cohérents et de présenter ceux-ci, les choix de ces auteurs doivent être pris en considération par ces systèmes. Pour un système d'*authoring* automatique, ces choix sont souvent supportés via un modèle utilisateur établi à l'avance. L'outil Artequakt (Kim et al., 2002) décrit auparavant est un exemple de ce type de système. Dans le contexte d'un système d'*authoring* interactif, les choix de son utilisateur (l'auteur) sont plutôt recueillis et traités de façon interactive et peuvent concerner le contenu, l'organisation et la présentation du document produit ; le système DPs décrit auparavant est un exemple de ce type de système. Cependant, pour le cas particulier des systèmes auteurs qui supportent le *storytelling*, on peut les classer selon un autre critère. Tuffield et ses collaborateurs ont proposé une classification des systèmes de *storytelling* qui distingue trois catégories : les systèmes de *storytelling* basé sur le caractère (le comportement), les systèmes de *storytelling* basé sur l'histoire et les systèmes de *storytelling* basé sur le modèle utilisateur (Tuffield, Millard, et al., 2006).

3.5.2.1 Les systèmes de *storytelling* basé sur le comportement

Le principe de ce type de systèmes auteurs est de modéliser les subtilités d'êtres (personnages) autonomes complexes et de stimuler les interactions entre ceux-ci dans le but d'aboutir à des histoires émergentes (Tuffield, Millard, et al., 2006). Le paradigme le plus utilisé pour concevoir ces entités rationnelles est le calcul basé-agent ; mais dans la plupart des cas, cette approche échoue à générer des histoires intéressantes. Cela est dû au fait que la modélisation des caractéristiques d'un être humain dans le système de raisonnement d'un agent n'est pas une tâche facile. De plus, ce type de système ne dispose pas d'un modèle de structure de l'histoire qui lui permette de contrôler la cohérence de celle-ci. Brooks parle plutôt d'histoires computationnelles (Brooks, 1997) générées par un système constitué d'un ou de plusieurs agents autonomes (Maes, 1990) où chaque agent détient des compétences de bas niveau et interagit avec les autres agents pour résoudre une partie du problème. Ainsi, pour pouvoir produire une histoire, l'agent navigue dans le domaine de l'histoire en choisissant une séquence de parties de celle-ci ; un choix qui dépend principalement du comportement de cet agent (i.e. ses compétences). Dans ce contexte, Brooks a proposé un système de production d'histoires computationnelles qu'il a appelé « Story agents » (agents d'histoire) ; il s'agit d'un environnement de conception et de présentation pour des histoires filmiques non linéaires et multi-points-de-vue, dans une forme textuelle ou vidéo. Cet environnement est destiné aux écrivains d'histoires non linéaires pour les encourager à structurer et à réécrire des histoires avant ou pendant la réalisation audio ou vidéo de celles-ci. Il s'agit ainsi d'un système auteur d'histoires, qui permet à son utilisateur de commencer par créer une structure simple (un cadre) pour l'histoire, puis d'utiliser ce cadre pour créer des récits multiples à partir de la même collection d'éléments de l'histoire ; cela pas le biais d'agents autonomes dont chacun a un style d'édition et de séquençement unique.

3.5.2.2 Les systèmes de *storytelling* basé sur l'histoire

Le but de ce type de système auteurs est d'aboutir à la génération et à la compréhension de récits ; cela en adoptant et en mettant sous une forme procédurale des théories narratives (Tuffield, Millard, et al., 2006). Ainsi, ces systèmes sont conçus sur des structures narratives explicites ; les méthodes les plus utilisées pour représenter de telles connaissances sont des méthodes basées-règles (Szilas, 2002). Cette approche se concentre plus sur la modélisation de la connaissance que sur la modélisation du comportement. Différentes structures narratives qui ont été implémentées pour aider les systèmes auteurs supportant cette approche à générer des récits. La théorie la plus utilisée dans ce domaine est la théorie de la structure rhétorique RST (Mann et Thompson, 1988). Celle-ci a été utilisée par exemple dans un système auteur de génération de documentaires vidéo (Bocconi, Nack, Hardman, 2005) et dans les systèmes DPs (Rizzo, Shaw et Johnson, 2002) et STfWP (Mahmud, 2004) que nous avons décrit auparavant (voir section 3.4.4).

3.5.2.3 Les systèmes de *storytelling* basé sur le modèle utilisateur

L'approche supportée par ce type de systèmes se concentre sur la modélisation de la connaissance comme c'est le cas pour l'approche basée sur l'histoire. Cependant, dans les systèmes de *storytelling* basé sur l'histoire, la conceptualisation explicite se fait sur la structure narrative ; alors qu'ici cette conceptualisation se fait sur la perception de l'utilisateur final (profil utilisateur) du récit produit. Toutefois, ce type de systèmes comporte souvent un modèle explicite de la structure narrative qu'il adapte aux connaissances provenant du modèle utilisateur afin de mettre à jour le contexte de production du récit : l'objectif est d'aboutir à un récit personnalisé selon les besoins de l'utilisateur final. Comme exemple de ce type de système auteur, nous citons le système de composition de documents virtuels personnalisés (Iksal et Garlatti (2002) que nous avons décrit auparavant (section 3.4.4.1) ; ou encore le système de génération automatique d'histoire (Bailey, 1999) basé sur un modèle intuitif des états et des processus cognitifs dans l'esprit d'un lecteur imaginaire de l'histoire.

Maintenant que nous avons présenté les différentes approches de *storytelling* numérique, nous revenons un peu en arrière sur la technologie qui nous intéresse puisqu'elle est étroitement liée à la problématique de notre sujet de thèse ; il s'agit du *Lifelogging* (voir section 1.4.2). Nous avons constaté qu'il existe plusieurs travaux sur l'application du *storytelling* au *lifelogs* dans le but de produire des histoires significatives pour l'utilisateur. Nous décrivons dans ce qui suit le principe de ce processus, les différentes approches utilisées et des exemples de travaux existants.

3.5.3 Le *storytelling* appliqué aux *lifelogs*

La technologie émergente du *lifelogging* assure une capture de différents aspects de la vie quotidienne dans des collections numériques riches et multimodales appelées *lifelogs* (emails, historiques de navigation, documents, photos, vidéos, données de localisation, *etc.*). Toutefois, ces *lifelogs* posent un problème sérieux.

3.5.3.1 La problématique des *lifelogs*

Bien que les *lifelogs* fournissent une première documentation de l'activité d'un individu ; leur taille souvent importante et leur nature hétérogène rendent leur utilisation problématique (Byrne and Jones, 2009b). Pour surmonter le problème, certains projets ont opté pour l'annotation des données collectées, tels que SemanticLIFE (Ahmed et al., 2004) qui permet de les enrichir automatiquement avec des annotations sémantiques en vue d'interrogation avancée ; ou Phothocopain (Tuffield, Chakravarthy, et al., 2006) un système

d'annotation de collections de photos personnelles. Ce dernier système s'est plutôt concentré sur la génération d'annotations que l'utilisateur peut modifier ou enrichir afin de décrire les événements observables de la vie d'une personne. Les annotations produites sont des combinaisons de métadonnées générées pour décrire le contenu des photos et de métadonnées décrivant le contexte dans lequel ont été capturées ces photos (données de localisation, entrées d'agendas, emails, *etc.*). Or, documenter l'activité humaine ne peut se réduire à annoter les données enregistrées à propos de celle-ci ; cela implique notamment l'organisation et la visualisation de ces données de façon à les rendre plus *intelligibles* pour les utilisateurs destinataires. Une solution naturelle repose sur le *storytelling* puisque les êtres humains sont des narrateurs en particulier lorsqu'il s'agit de décrire leurs expériences.

3.5.3.2 Le storytelling : une solution naturelle au problème des lifelogs

Le *storytelling* vise la construction d'histoires pour décrire des idées, des émotions, des connaissances et des expériences personnelles à partager. Appliqué au domaine des lifelogs, il permet à un utilisateur de transformer une multitude d'observations, d'impressions et de données collectées pour former une unité cohérente ayant un sens pour lui (Frenzel et al., 2004). C'est d'ailleurs la technologie du *lifelogging*, l'accessibilité des réseaux sociaux et la disponibilité d'outils auteurs qui ont participé au renouvellement de cette tradition sous une forme numérique (Strahovnik and Mecava, 2009). Plusieurs travaux s'intéressent au *storytelling* appliqué aux lifelogs ; certains se limitent à des études expérimentales visant l'analyse du comportement de participants sollicités à décrire leurs activités à base de leurs lifelogs (Harper et al., 2007; Lindley et al., 2009), alors que d'autres s'intéressent à supporter automatiquement cette possibilité.

3.5.3.3 Les approches et travaux de storytelling appliqué au lifelogs

Nous pouvons classer les travaux sur le sujet de *storytelling* appliqué aux lifelogs selon l'approche adopté par ceux-ci. Bien que cette approche puisse être manuelle ; elle est le plus souvent automatique ou semi-automatique (interactive).

Les travaux basés sur une approche automatique. Certain travaux ont opté pour une approche purement automatique de *storytelling* appliqué aux *lifelogs*. Appan et al. (2004) ont proposé un environnement de conception et de présentation d'histoires filmiques à base d'agents computationnels de Brooks (Brooks, 1997) ; cet environnement utilise trois composants de *storytelling* —un modèle narratif (structure dramatique), une organisation des parties de l'histoire avec des représentations de leurs sens, et une stratégie de navigation à travers ces parties pour générer des narrations multi-points-de-vue. Ils ont utilisé un modèle de données simples (photos et texte), simplifié le modèle narratif à exploiter par l'utilisateur pour catégoriser les données (introduction, conflit, *etc.*) et proposé des relations à ajouter entre celles-ci (ordre, conflit-résolution, *etc.*) pour que des agents programmés puissent construire des histoires (diaporamas) selon des règles particulières à chacun. Cependant, les histoires générées sont disjointes puisque la structure dramatique n'était pas adéquate aux données du *lifelog* et la relation de causalité entre événements était difficile à expliciter.

Les travaux basés sur une approche semi-automatique. La plupart des travaux ont opté pour une approche semi-automatique de *storytelling* appliqué aux lifelogs. Dans le projet MyLifeBits, une option « d'histoire interactive par requête » (Gemmell et al., 2005) a été ajoutée pour permettre à l'utilisateur d'appliquer des requêtes sur le lifelog, de sélectionner graphiquement des photos du résultat puis de mettre ces photos en séquence, avec une possibilité de leur attribuer des légendes et des clips audio, pour composer une histoire en diaporama. Un travail plus spécifique (Kelliher and Davenport, 2007) a décrit une variété de

méthodologies et de bonnes pratiques pour solliciter et enregistrer les témoignages personnels, ainsi que des stratégies de construction d'histoires avec des critères d'évaluation pour celles-ci. L'application développée permet à l'utilisateur de charger et d'éditer des données personnelles (photos, films, fichiers audio) et de construire des histoires par sélection graphique et arrangement de ces données selon des canevas en 2D ; des relations peuvent exister entre les données et des modèles prédéfinis d'histoires sont exploités.

Il existe également d'autres travaux plus poussés sur le sujet. Par exemple, lorsque Appan *et al.* (2004) on constaté que l'approche automatique de *storytelling* qu'il ont adoptée produisait des histoires disjointes ; ils ont proposé l'utilisation d'une structure *d'histoire émergente* qui évolue à travers l'interaction de l'utilisateur ; l'outil de *storytelling* interactif qu'ils ont développé est basé sur un modèle d'événement caractérisant celui-ci par une temporalité, une localisation, des données du *lifelog* (photos, sons et texte) et des participants pour distinguer des points de vue ; les événements sont liés temporellement et structurellement pour permettre à l'utilisateur de varier ses navigations dans cet ensemble. Cela permet l'émergence d'histoires (diaporamas), composées progressivement à partir des données attribuées aux événements parcourus, selon différents points de vue. Par ailleurs, l'utilité de toutes les données du *lifelog* a été mise en doute, d'où la proposition de réduire ce contenu aux données les plus importantes. A leur tour, Byrne et Jones ont opté pour l'approche de *storytelling* basé-événement (Byrne and Jones, 2009a), mais ils ont critiqué l'idée de surmonter la complexité du *lifelog* en réduisant son contenu. Ils ont développé un moteur de génération de narrations basée-événements pour lequel les données du *lifelog* doivent être structurées et alignées selon trois niveaux : artéfacts, épisodes et thèmes. Les artéfacts (photos, sms, documents, *etc.*) sont alignés temporellement et un traitement thématique leur est appliqué afin d'extraire un thème saillant pour chacun. L'utilisateur localise et sélectionne ensuite des épisodes (événements) pertinents pour l'histoire dans cet ensemble ; il fait également des choix de présentation pour que le système puisse générer l'histoire qui sera présentée comme un montage thématique qu'il pourra ensuite personnaliser.

3.6 Conclusion

La notion de « *document* » a connu une évolution importante avec l'émergence des technologies numériques. Les formes physiques usuelles (papier, microfilm, *etc.*) ne sont plus exigées : le passage à la forme numérique a fait perdre au document sa stabilité comme objet matériel au point qu'il s'est transformé en un processus construit à la demande. Son support matériel lui-même est remplacé par une chaîne de logiciels permettant la construction et la visualisation du document. Tous ces changements ont affecté aussi bien la forme que le sens du document et il a fallu redéfinir cette notion dans son nouveau contexte numérique. C'est ainsi que les chercheurs du RTP-DOC ont proposé une analyse du document numérique à travers trois dimensions : la *forme* comme un objet matériel ou immatériel, le *signe* comme un porteur de sens et le *médium* comme un vecteur de communication. Ils ont alors affirmé que le document est tout ce qui peut être vu, lu, et su. D'un point de vue pratique, les documents numériques sont stockés dans des fichiers pouvant avoir différents formats et formes (texte, image, audio, vidéo, hypermédia, *etc.*) et des données sémantiques (i.e. métadonnées) peuvent être attribuées à ces documents pour faciliter leur localisation ou décrire leurs contenus. Le document numérique est également caractérisé par une multi-structuralité ; sa structure sémantique correspond au sens de son contenu, sa structure logique à l'organisation de ce contenu et sa structure physique à la présentation de ce contenu. Par ailleurs, il est à l'origine de l'émergence de nouveaux problèmes. La notion de « *publication* » a rendu les frontières floues entre les étapes de création, de sélection et de diffusion de documents et le statut de

l'auteur est devenu ambigu puisque celui-ci a perdu son autorité sur sa production. Le numérique a également imposé à l'auteur des tâches multiples (édition, classement et référencement) ; mais il lui a fourni les outils appropriés (outils d'édition, d'indexation, *etc.*).

Avec l'émergence de la notion de « *Web participatif* » en particulier, le besoin que les personnes qui sont à la base des consommateurs de l'information sur le Web puissent produire des documents est devenu accru ; mais le processus de création de contenu de documents est à la base un processus cognitif basé sur le savoir-faire de l'auteur. C'est ainsi que des systèmes et des outils auteurs ont été conçus pour aider les personnes qui ne sont pas des professionnels de la production de documents. Un outil auteur n'est pas simplement un éditeur ; il guide et peut apprendre à son utilisateur les bonnes pratiques de création de contenu. Pour cela, il peut employer des fonctions simples, des modules assistants, ou encore des agents intelligents basés sur des modélisations formelles. Les outils auteurs sont utilisés dans différents domaines mais plus souvent pour la création de contenu Web et de matériels d'enseignement de type tutoriel ; ils utilisent différentes technologies et bases théoriques pour pouvoir supporter leur rôle. La théorie de la structure rhétorique est l'une des théories les plus exploitées dans ce domaine puisque elle permet l'analyse et le contrôle de la cohérence sémantique de textes.

Alors que des personnes ordinaires sont censées produire des informations et des documents à diffuser, il est utile d'analyser la façon de raisonner de ces personnes. D'après le paradigme narratif de Fisher, l'être humain est un animal narratif (*storyteller*) puisque, d'une part, il crée des récits et raconte des histoires pour donner du sens à ses actions et, d'autre part, il base ses actions et ses décisions sur des récits. Le *Storytelling* est ainsi une pratique naturelle qui remonte à un passé très lointain mais qui a pu subsister au fil du temps puisque elle facilite l'apprentissage, la mémorisation et l'appropriation du savoir et des messages. L'émergence des technologies numériques et des services du Web 2.0 en particulier ont introduit de nouveaux moyens de communication adaptés à cette pratique (e.g. les blogs, les wikis, les sites de vidéos tel Youtube, *etc.*). Par ailleurs, les machines exigent un haut niveau de formalisation des connaissances pour pouvoir les utiliser et les partager ; ainsi, pour qu'elles puissent supporter le *storytelling*, elles doivent disposer au moins d'une modélisation formelle de l'histoire. A ce niveau, nous soulignons le lien étroit qui peut exister entre le *storytelling* et l'*authoring* de document dans le contexte numérique ; le *storytelling* peut être supporté par la machine via un processus d'*authoring* ayant une représentation ontologique du modèle de l'histoire à produire et pouvant être totalement ou partiellement automatisé.

En prenant cette fois-ci une autre pratique très populaire dans le contexte numérique, le *lifelogging*, qui permet de tracer la vie quotidienne des individus et de garder cette information dans des entrepôts riche en données (*lifelogs*) ; nous avons constaté que plusieurs chercheurs se sont intéressés à l'application du *storytelling* à ces *lifelogs*. Leur justification repose, d'une part, sur la nature de l'être humain (un narrateur) et d'autre part, sur la taille importante des *lifelogs* et leur nature hétérogène qui rendent leur utilisation difficile. Si nous nous sommes intéressés au *lifelogging* en particulier, ce n'est pas dû seulement à la popularité de cette technologie. La vraie raison c'est que cette technologie permet le traçage de l'activité quotidienne et que le *storytelling* appliqué au *lifelogs* permet de produire des documents (lisibles, compréhensibles et échangeables) à partir de cette trace ce qui correspond à une documentation de l'activité quotidienne. Ceci répond en quelque sorte à notre problématique de la redocumentation de l'activité médiée informatiquement pour laquelle nous proposons des solutions à partir du chapitre suivant.

Deuxième partie

Contributions

Chapitre 4 : Une approche semi-automatique et narrative pour le processus de redocumentation

4.1 Introduction

Dans le premier chapitre de ce manuscrit, consacré à la présentation de notre problématique de la redocumentation de l'activité informatique à base de ses traces, nous avons justifié la nécessité du processus de redocumentation. Nous avons constaté que les traces d'activité informatique manquent le plus souvent de lisibilité, d'intelligibilité et de portée sociale pour des utilisateurs ordinaires (au contraire des concepteurs des systèmes, par exemple) et que ces traces sont souvent de nature multimodale et réparties sur plusieurs fichiers. Alors, en les considérant comme le produit d'une première documentation de l'activité, nous avons proposé d'appliquer sur ces traces des processus de *redocumentation* dans le but de renforcer leur statut documentaire et d'améliorer leur description de l'activité informatique tracée selon les besoins d'un individu. Nous avons également soulevé quatre questions clés concernant ce processus : qui redocumente ? Quand ? Pourquoi ? Et comment ? Mais nous n'avons pu répondre qu'aux trois premières questions à travers la présentation de notre vue globale du processus (voir la figure 1.2).

Dans cette vue, nous supposons que le processus de redocumentation de l'activité informatique à base de sa trace peut être appliqué par n'importe quelle personne, y compris l'utilisateur qui a réalisé l'activité informatique (i.e. l'utilisateur tracé). Nous supposons également que ce processus peut être appliqué une fois que l'activité informatique tracée est achevée (i.e. *a posteriori*). Quant à l'objectif sous-jacent à l'application de ce processus, nous supposons qu'il peut être la production d'un support mémorial ou d'un support d'analyse de l'activité réalisée ou du comportement de l'utilisateur tracé par des spécialistes tels que les psychologues, les analystes, les concepteurs de systèmes informatiques, *etc.* Cependant, la question la plus importante n'a pas été résolue ; c'est celle de la mise en place effective du processus de redocumentation. La réponse à celle-ci nécessite de faire des choix pour ce processus, aussi bien sur le plan théorique que sur le plan pratique.

L'objectif de ce chapitre est de proposer une approche générique pour la redocumentation de l'activité informatique à partir de ses traces. Nous commençons par la description de nos objectifs et des choix théoriques que nous adoptons en fonction de ces objectifs. Nous décrivons par la suite notre cadre général pour le processus de redocumentation qui permet de transformer une trace d'activité informatique (à l'entrée du processus) en un document numérique (à la sortie) décrivant l'activité de façon plus appropriée pour un utilisateur. Nous proposons enfin une spécialisation de ce cadre général pour une approche de redocumentation par le *texte*.

4.2 Notre approche : objectifs et choix

Nous supposons que le processus de redocumentation de l'activité informatique à base de sa trace doit encourager la personnalisation et le partage des expériences, et ainsi soutenir la créativité et le maintien des relations sociales. Nous pensons que la mise en place effective d'un tel processus doit alors vérifier certains critères :

- Être à la fois facile à appliquer et utile pour les utilisateurs.
- Préserver la liberté des utilisateurs dans l'appropriation du contenu et de la forme du document produit pour décrire l'activité informatique tracée de façon personnalisée.
- Fournir un produit de qualité sur les plans de la lisibilité, de la compréhension, de l'organisation et de la facilité d'échange.

Pour répondre à ces exigences, nous adoptons les principes suivants :

- **Une approche narrative (basée sur le *Storytelling*) pour le processus** : d'après notre étude bibliographique sur le *storytelling* (voir section 3.5), nous avons constaté que la narration est identifiée comme un élément central dans la manière dont les humains donnent du sens à leur monde et à leurs expériences. Ainsi, nous optons pour une approche narrative pour la redocumentation de l'activité informatique à partir de ses traces ; celle-ci permet à l'utilisateur de décrire de façon naturelle l'activité informatique à travers la construction d'une sorte de récit à partir des traces de celle-ci.
- **Un processus semi-automatique (interactif) assisté par un outil auteur** : d'après notre étude bibliographique sur les traces (chapitre 2), nous avons constaté que différents projets et outils – tels que Oracle Trace Analyser et GRUMPs (Gray et al., 2004) – ont adopté pour une approche de redocumentation automatique ; leur principe est de générer des rapports organisés (hypertextes) à partir des traces d'activité. Cependant, cette approche est restrictive pour des utilisateurs qui préfèrent souvent s'approprier le contenu et la forme des traces selon des choix personnels. En outre, il est impossible de modéliser formellement tout ce qui peut être impliqué dans une activité. Nous pensons que l'utilisateur doit pouvoir intervenir durant le processus de redocumentation de l'activité tracée pour décider concrètement du contenu à préserver des traces, du contenu à ajouter, et de la forme d'appropriation du document produit. En revanche, étant donné la complexité potentielle des traces, leur volume et leur nature multimodale, il est inconcevable de demander à l'utilisateur de construire tout seul un document décrivant l'activité directement à partir de ses traces. C'est ainsi que nous optons pour un processus de redocumentation semi-automatique, interactif et assisté par un outil auteur (voir section 3.4) ; l'objectif est de préserver la liberté de l'utilisateur, faciliter son travail d'auteur et diminuer son effort.
- **Une approche de modélisation sémantique pour les traces et les documents** : nous avons également vu (voir section 3.5.3.2) que la machine ne peut produire des histoires que si on lui fournit une compréhension de la narration à travers des représentations sémantiques pour ses différentes couches. Nous optons pour la vision de Bal (1997) qui considère que tout modèle complet de la narration doit prendre en compte trois niveaux : le *Fabula* pour décrire les objets/événements de base et leurs relations, l'histoire pour décrire l'arrangement des objets/événements

pour un objectif particulier et la narration pour décrire comment cela est réalisé dans une forme particulière. Dans notre cas, la modélisation du *Fabula* sera assurée via la modélisation sémantique des traces d'activité ; ceci permet leur visualisation et leur transformation automatique. Quant à la modélisation de l'histoire (de l'activité), elle sera assurée via la modélisation sémantique du document produit ; une modélisation qui sera basée plus particulièrement sur les principes de la théorie de la structure rhétorique RST (voir section 3.4.3). Nous avons choisi RST parmi d'autres théories pour sa simplicité et la possibilité de son application pour le maintien de la cohérence des documents produits. Ainsi, une modélisation sémantique basée-RST des documents produits par le processus de redocumentation permet un traitement automatisé de ces documents et un maintien automatique de la cohérence de leurs contenus.

- **Un format hypermédia pour le document produit** : il s'agit d'un format riche et flexible qui permet de représenter différentes formes de traces en profitant notamment du multimédia ; les relations entre traces (ou au sein d'une même trace) peuvent être exprimées au travers de liens hypertextes dans le document.

Nous décrivons dans ce qui suit un cadre général pour le processus de redocumentation de l'activité informatique à partir de sa trace ; celui-ci décrit de façon plus détaillée l'approche que nous adoptons pour la redocumentation et dont les principes sont décrits ci-dessus.

4.3 Un cadre général pour le processus de redocumentation

Le cadre général que nous proposons pour le processus de la redocumentation de l'activité informatique implémente une *approche narrative semi-automatique basée-modèles* (Yahiaoui et al., 2011). Dans ce cadre, que nous représentons par la figure 4.1, trois éléments sont à considérer (Yahiaoui et al., 2009) : l'entrée du processus qui est un ensemble de traces modélisées de l'activité informatique, la sortie du processus qui est le document produit modélisé et décrivant l'activité, et les deux phases du processus de redocumentation. La première phase du processus (P0) supporte la transformation automatique de la trace(s) d'activité choisie par l'utilisateur (l'utilisateur tracé ou une autre personne) en un document initial fragmenté (D_0). La deuxième phase (P1) est interactive et assistée par un outil auteur. Elle permet à l'utilisateur de transformer le document initial via un ensemble d'opérations que l'utilisateur peut exécuter jusqu'à ce qu'il soit satisfait du document produit (D_1), et que ce dernier soit exporté comme un document final (D_F). Nous décrivons tout d'abord nos modélisations des traces d'activité et des documents produits avant de détailler les deux phases du processus.

4.3.1 La modélisation de la trace d'activité

Les traces des activités informatiques résultent de l'enregistrement des interactions des utilisateurs avec les systèmes informatiques médiatisant leurs activités. La modélisation de celles-ci dépend de l'activité tracée et de l'approche de modélisation adoptée. Si l'on dispose d'un modèle de l'activité informatique, ce modèle va sûrement nous rendre plus facile la modélisation de ses traces qui ne sont, en fait, que l'image numérique du déroulement de l'activité dans l'environnement informatique. C'est ainsi que nous nous sommes intéressée dans un premier temps à la modélisation de l'activité informatique, avant de passer à la proposition d'un modèle générique pour les traces de celle-ci.

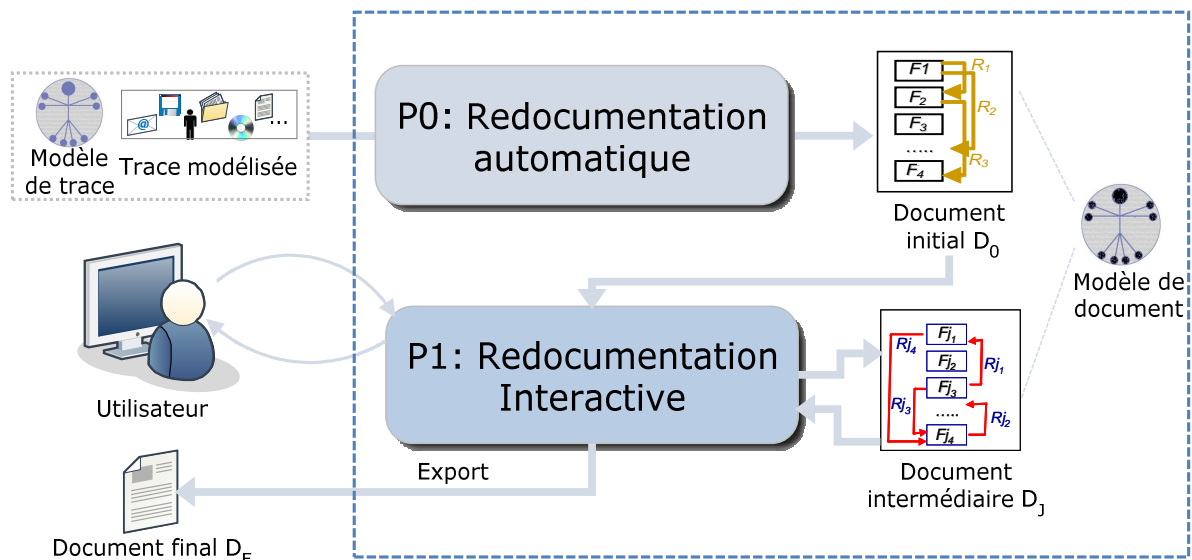


Figure 4.1. Un cadre général pour le processus de redocumentation de l'activité informatique, basé modèles (pour les traces et les documents).

4.3.1.1 La modélisation de l'activité informatique

L'activité médiée informatiquement est un cas particulier de l'activité humaine, qui se base sur l'exploitation d'un environnement informatique par des utilisateurs ; cet environnement (artéfact) contient entre autre « *son histoire culturelle et transmette des connaissances sociales qui peuvent influencer ses utilisateurs et leur collaboration* » (Kaptelinin, 1996). La modélisation de cette activité n'est ainsi qu'un cas particulier de la modélisation de l'activité humaine pour laquelle différentes théories ont été proposées. La plus ancienne et la plus connue est la théorie de l'activité (Leontiev, 1972) ; celle-ci modélise l'activité comme une structure hiérarchique à trois niveaux interactifs de relations entre des sujets et des objets : le niveau supérieur de *l'activité* intentionnelle est orienté vers les motifs, le niveau intermédiaire de *l'action* est orienté vers les buts et le niveau inférieur des *opérations* est orienté vers les conditions pratiques de réalisation des actions. Du fait que cette théorie décrive la dimension sociale de l'activité et de la connaissance ; elle a contribué au renouvellement de la conception des interfaces Hommes-machines et à la modélisation du travail coopératif assisté par ordinateur (Linard, 2002). Pour Bruner (1973), l'action humaine est un processus séquentiel en forme de cycle récursif auto - piloté par ses propres buts et auto - régulé par un mécanisme comparateur entre les effets attendus et les effets obtenus (feedback) ; alors que c'est l'intention (anticipation du but final) qui gouverne et donne sens aux phases logiques de l'action. Comme une combinaison de ce modèle cyclique et du modèle hiérarchique proposé par Léontiev, Linard a proposé un modèle dynamique complexe de l'activité humaine. Ce modèle, représenté par la figure 4.2, est doublement structuré et entraîné par deux axes dynamiques (Linard, 2001) : un axe horizontal qui définit l'enchaînement séquentiel logique des phases de réalisation du but (de l'activité) et un axe vertical qui définit l'interaction hiérarchique des trois niveaux (*Activité, Action, Opération*). Le décalage entre les effets attendus et les effets obtenus par l'action entretient la dynamique du système jusqu'à satisfaction ou échec final.

Processus séquentiel récursif (réalisation du but par l'action) auto-piloté par ses propres buts et auto-régulé par le feedback (Bruner, 1973).



Figure 4.2. Le modèle structuré dynamique de l'activité (Linard, 2001).

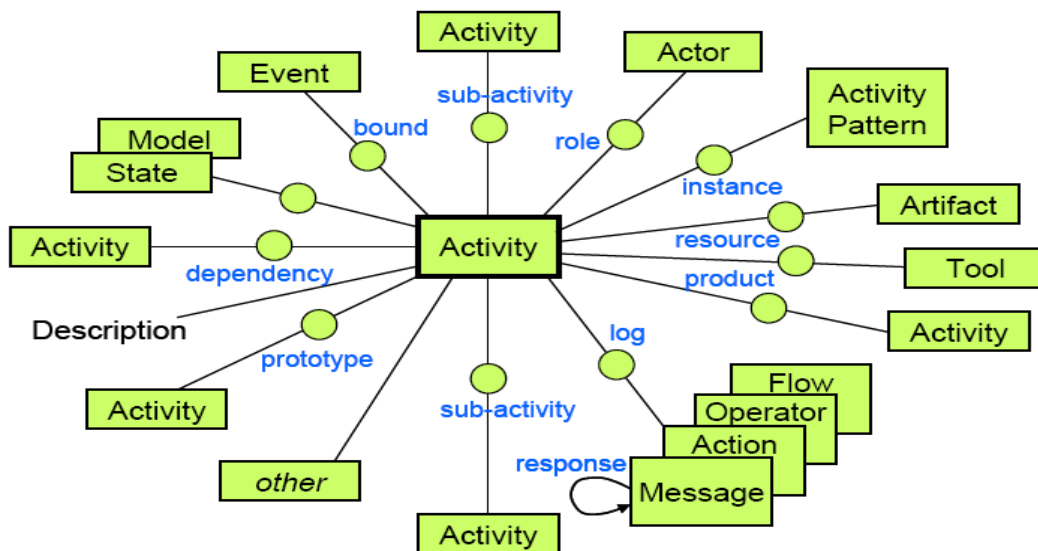


Figure 4.3. Le méta-modèle « activité unifiée » représenté par un graphe (Moran, 2005).

Cependant, nous optons pour une modélisation plus opérationnelle de l'activité ; notamment le méta-modèle baptisé « Unified Activity » (Moran, 2005). Celui-ci considère le niveau *activité* comme un niveau intermédiaire entre un niveau supérieur *processus* (étapes avec une initiative intrinsèque) et un niveau inférieur *action* (parties du travail effectuées à des moments bien définis de façon réactive, structurées selon une temporalité ou une causalité précise) ; l'activité fournit ainsi un contexte pour l'organisation d'un ensemble d'actions dans une structure significative qu'elle relie à un processus particulier. En outre, ce méta-modèle est bien adapté à l'activité médiée informatiquement ; il représente celle-ci par un modèle formel en RDF (figure 4.3) comme une association de propriétés et de relations avec des entités. L'activité est caractérisée par un objectif et des états ; elle peut impliquer plusieurs acteurs dans des rôles, utiliser différentes ressources (outils, objets, etc.) et produire des résultats (documents, artefacts, etc.). Elle est également délimitée par des événements et elle est constituée d'un ensemble d'actions (log d'actions) dont chacune est réalisée via un

ensemble d'opérations. Ainsi, une représentation de l'activité associe des acteurs (personnes), des ressources, et des événements avec une description de la façon dont tous ces éléments sont liés. Par exemple, une secrétaire peut programmer une réunion avec la proposition de son directeur ; elle peut utiliser un calendrier et un système de réservation et produire un événement planifié. En outre, une activité n'est pas isolée ; elle peut être reliée à d'autres activités de différentes façons (composition, spécification, dépendance, utilisation, etc.) et cela permet la réutilisation des activités.

A partir de ces différents modèles, nous avons constaté que l'action est considérée comme l'élément clé dans la modélisation de l'activité ; alors que le méta-modèle de *l'activité unifiée* met l'accent sur d'autres éléments importants tels que : les ressources et les produits de l'activité, les acteurs, etc. Cela nous a servi dans un premier temps à identifier les éléments descriptifs de l'activité à modéliser dans la trace de celle-ci.

4.3.1.2 Un modèle générique pour la trace d'activité informatique

Plusieurs travaux ont traité la question de la modélisation de la trace d'activité informatique (Stumpf et al., 2005; Anjewierden and Efimova, 2006; Choquet and Iksal, 2007) ; cependant, leurs façons de collecter, de modéliser et d'utiliser les traces d'activité diffèrent. Notre modélisation de la trace est basée sur la modélisation de l'activité (modèle hiérarchique de Léontiev et le méta-modèle de *l'activité unifiée*) que nous venons de décrire ci-dessus et le méta-modèle de la trace proposé dans le cadre du Système à Base de Traces modélisées (SBTm) que nous avons décrit auparavant (voir section 2.4.2). A partir du méta-modèle de la trace du SBTm, nous retenons la définition de la trace d'activité informatique comme « *un ensemble d'observés, temporellement situés...* » où chaque *élément observé* est caractérisé par une propriété temporelle qui peut être le moment ou l'intervalle temporel décrivant son occurrence ; alors que nous utilisons la modélisation de l'activité pour raffiner cette définition en considérant que les éléments observés de la trace sont des *actions* qui manipulent des *entités* (des objets ou des ressources) et que chaque trace concerne un *utilisateur* particulier.

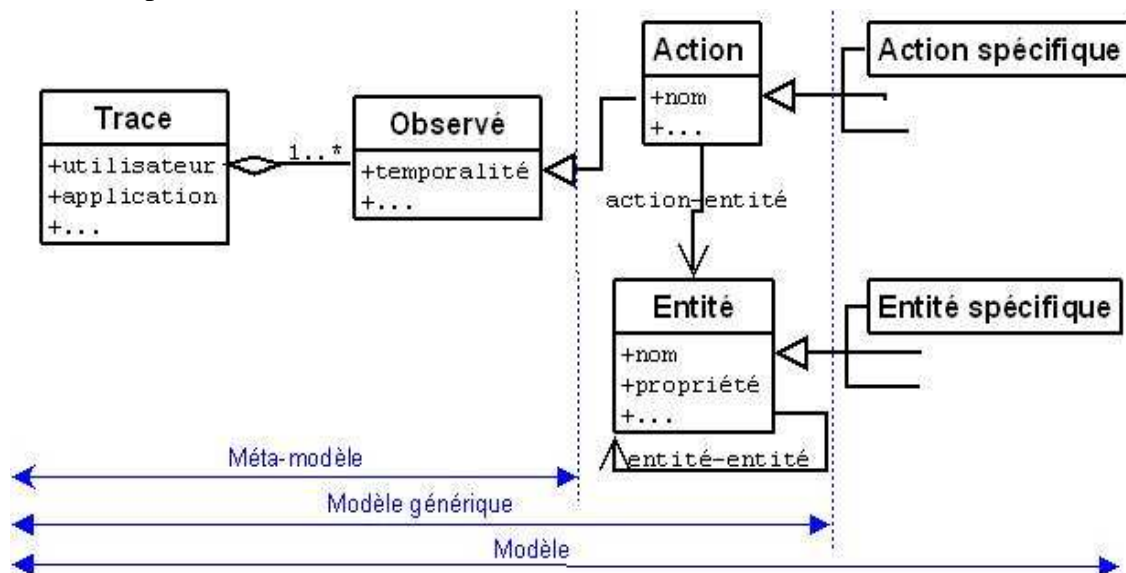


Figure 4.4. Le modèle générique de la trace d'activité (à spécialiser pour des applications).

Afin de rendre possible la spécialisation de notre modèle de la trace, nous supposons que les actions et les entités peuvent être organisées dans des hiérarchies et que des relations structurelles peuvent exister entre les entités (par exemple, une ressource peut composer une autre tel le cas pour un fichier et le répertoire qui le comporte). La figure 4.4 représente notre modèle de la trace d'activité informatique ; celui-ci peut être implémenté comme un modèle formel (éventuellement une ontologie). Cependant, pour pouvoir produire des traces modélisées, il est important d'utiliser un processus pour collecter les traces de base (e.g. les fichiers log) de l'activité informatique selon ce modèle.

4.3.2 La modélisation du document produit

Comme tout document numérique, le produit du processus de la redocumentation de l'activité informatique est une structure d'information dont le contenu peut inclure des objets simples ou composites ayant des formes différentes (texte, graphique, vidéo, audio, *etc.*), ou même des groupes d'objets (Martin and Alpay, 1996). Par conséquent, ce document est fragmenté en plusieurs unités d'information inter-liées, appelées « *fragments d'information* » ou simplement « *segments* ».

4.3.2.1 La définition du segment de document

Selon Ranwez et Crampes, un segment dans un document est « *une brique d'information disponible sous un média qui peut être insérée dans un document réel pour former une partie cohérente de son contenu* » (Ranwez et Crampes, 1999). Cette vision est liée à une approche de composition du document ; contrairement à une approche de segmentation de celui-ci ; mais dans les deux cas, le concept « *segment* » est le même puisque la segmentation vise à restructurer l'information dans des unités avec une granularité optimale en terme d'utilisation (Ioannides, 2007). Ainsi, l'une des caractéristiques importantes d'un segment est son niveau de granularité qui dépend de son usage prévu ; ce niveau de granularité doit assurer que le segment soit exploitable, ait un sens, ait une taille raisonnable et soit autonome dans son contexte d'utilisation. En outre, les segments de documents peuvent être classés selon différents critères tels que leurs formes (texte, image, vidéo, mixte, *etc.*), leurs types (atomiques ou composés) et leur valeur de précision ou de subjectivité (un fait, une opinion, *etc.*).

4.3.2.2 Le modèle du document

Le document numérique peut être décrit selon trois niveaux différents : sémantique, logique et physique (Christophides, 1998), et une structure particulière peut exister pour chacun des ces niveaux. La (les) structure(s) sémantique(s) organise(nt) le sens du contenu du document, une structure narrative est une sorte de structure sémantique. La structure logique décrit la structure syntaxique du document (e.g. en titres, chapitres, paragraphes, *etc.*), tandis que la structure physique définit l'apparence du document et sa présentation (e.g. la typographie, les couleurs, *etc.*).

Nous avons expliqué auparavant (voir section 3.3) qu'il est important de considérer toutes ces structures dans la construction d'un document et que plusieurs chercheurs (Djermal et *al.*, 2009; Barrutieta et *al.*, 2002; Garlatti et Iksal, 2003) ont opté pour une modélisation multi-structurée du document en considérant le segment comme l'unité de base sur laquelle reposent ces différentes structures documentaires. Nous nous intéressons plus particulièrement au sens du contenu du document produit à travers le processus de redocumentation de l'activité informatique et comment ce contenu peut être maintenu lorsqu'il est manipulé par l'utilisateur final (i.e. la personne qui effectue le processus). Ainsi, notre modélisation du document est plus centrée sur la structure sémantique de celui-ci. Par ailleurs, nous n'avons pas l'intention

de négliger les structures logique et physique du document puisque nous admettons le fait que la construction de n'importe quel document implique la définition d'une application entre la structure sémantique de celui-ci et sa structure finale (Nanard and Nanard, 1989).

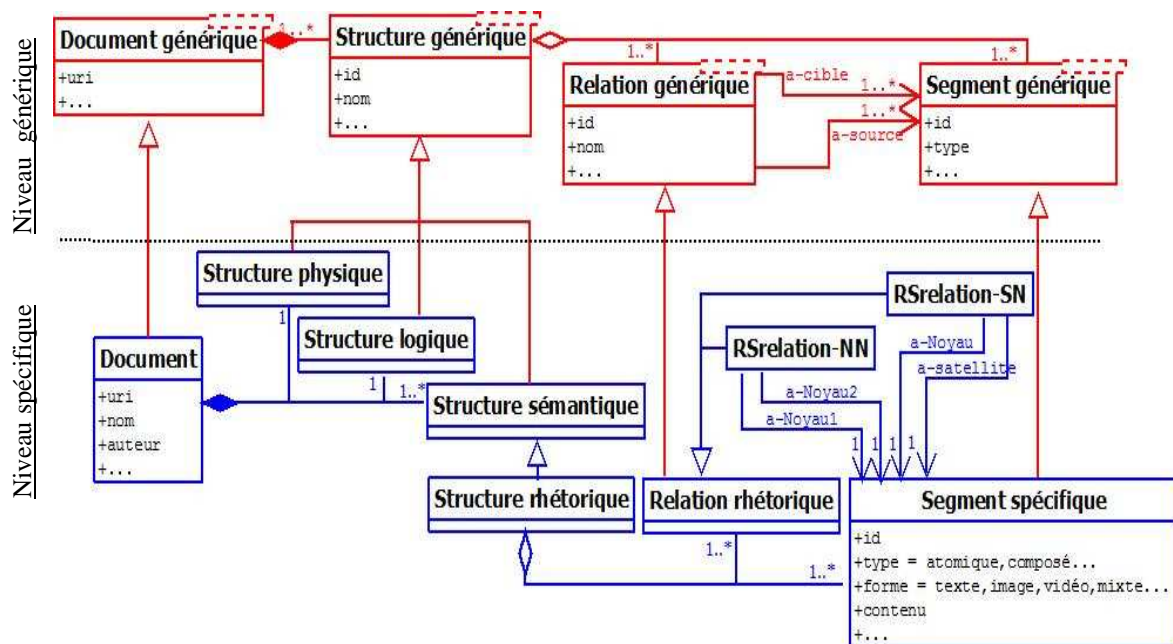


Figure 4.5. Le modèle de document comme une spécification d'un modèle générique, centré sur la structure rhétorique.

La figure 4.5 représente notre modèle générique de document (la partie supérieure du schéma) que nous avons spécialisé en notre modèle de document (partie inférieure du schéma). Au niveau générique, le document est composé de plusieurs structures typées dont chacune est composée de segments et de relations entre ces segments ; chaque relation peut avoir un ou plusieurs segments initiaux ou finaux. Au niveau spécifique, le document comporte trois structures : la structure sémantique, la structure logique et la structure physique (ou de présentation). La structure sémantique du document relie un ensemble de segments d'information avec un ensemble de relations sémantiques ; le type de chacune de ces relations est déduit du type de la structure sémantique à laquelle la relation appartient. En effet, plusieurs théories ont été proposées pour analyser le sens du contenu d'un document afin de l'explicitier.

Nous avons choisi parmi celles-ci la théorie de la structure rhétorique RST (voir section 3.4.3) parce qu'elle est simple à utiliser et répond au mieux à notre besoin de produire des documents tout en maintenant la cohérence de ceux-ci. En effet, les relations rhétoriques sont souvent utilisées pour développer une argumentation liant ensemble les éléments d'un contenu et leurs effets combinés assurent la cohérence de celui-ci. Bien que RST (Taboada and Mann, 2006b) ait été proposée initialement pour l'analyse de documents textes en divisant chaque texte en segments (de type Noyau ou Satellite) et relations rhétoriques ; elle est facilement utilisable pour les documents ayant des formes différentes du texte (e.g. des documents multimédia (Bocconi et al., 2005). Ceci nous convient parfaitement puisque nous supposons que le produit de notre processus de redocumentation est un document hypermédia. Ainsi, la structure sémantique dans notre modèle de document se limite à la structure

rhétorique de celui-ci ; elle comporte deux types de relations rhétoriques : les relations de type noyau-à-noyau (RSrelation-NN) et les relations de type satellite-à-noyau (RSrelation-SN).

La structure rhétorique du document transmet le sens de son contenu puisqu'elle attribue une fonction particulière à chacun des segments de ce contenu. En outre, cette structure peut être facilement implémentée comme un modèle formel (éventuellement une ontologie) ; cela rend facile la création de documents cohérents en se basant sur des règles rhétoriques à implémenter et à respecter.

Pour la structure logique du document, les segments et les relations définis par la structure rhétorique sont transformés et organisés selon un modèle prédéfini (un modèle XML par exemple).

De façon équivalente, un modèle prédéfini de présentation peut être utilisé pour la structure physique du document (e.g. une feuille de style) avec une possibilité d'intervention de l'utilisateur pour le choix de certaines propriétés du modèle (e.g. couleur, font, fonctionnalités, etc.).

4.3.3 Un processus de redocumentation en deux phases

Le processus de redocumentation de l'activité médiée informatiquement à partir de sa trace est réalisé à travers deux phases (voir figure 4.1). Alors que la première phase de ce processus est automatique, la deuxième phase est interactive et assistée par un outil auteur.

4.3.3.1 La phase de redocumentation automatique (transformation T0)

Cette phase représente la partie automatique du processus de redocumentation et permet de transformer une trace d'activité en entrée (à choisir par l'utilisateur) en un document fragmenté initial (D_0). Ceci est rendu pour nous possible par la modélisation formelle des traces et la disponibilité d'outils dédiés à la génération de fragments d'information à partir de données modélisées formellement.

Le document initial (D_0) produit de la redocumentation automatique. Nous supposons que chaque segment ou fragment (F_i) généré dans le document initial D_0 est une unité d'information qui décrit un ou plusieurs éléments observés (*obsels*) de la trace d'activité (i.e. une ou plusieurs actions de la trace d'activité). Un segment est caractérisé par un contenu, une forme et d'autres propriétés (e.g. l'identifiant de l'*obsel* décrit par ce fragment pour garder des liens avec la trace d'activité, une valeur temporelle pour exprimer la propriété temporelle de l'*obsel* décrit, etc.). Les relations (R_i) générées automatiquement entre les segments du document initial (D_0) expriment des relations existantes entre les éléments de la trace d'activité en entrée. Ces relations peuvent être de deux types : structurelle ou rhétorique. Les relations structurelles décrivent des relations qui existent explicitement entre les éléments de la trace d'activité ; par exemple, une relation de composition entre deux objets manipulés par deux actions dans la trace d'activité. Quant aux relations rhétoriques, elles expriment des relations déduites de la trace ; par exemple, les relations d'ordre temporel entre les (*obsels*) actions de la trace d'activité peuvent être exprimées par des relations rhétoriques de type *Séquence (Sequence)* entre les segments documentaires qui décrivent ces actions dans le document D_0 .

Paramétrage de la phase de redocumentation automatique. La phase de redocumentation automatique peut être paramétrée pour permettre à l'utilisateur de ne choisir qu'une partie de la trace à redocumenter. Par exemple, en donnant à l'utilisateur la possibilité de choisir au départ du processus de redocumentation les types d'actions de la trace à redocumenter, seuls les segments qui décrivent les actions ayant ces types seront générés et

insérés dans le document D_0 . De façon similaire, en permettant à l'utilisateur de choisir un intervalle de temps à l'intérieur de celui de la trace d'activité (i.e. intervalle de temps entre le moment d'occurrence de la première action de la trace et celui de la dernière action de celle-ci), seules les actions effectuées durant cet intervalle seront décrites dans le document D_0 .

Le document D_0 n'est ainsi que le produit d'une transformation automatique de la trace d'activité informatique via la phase de redocumentation automatique ; ce document sert de donnée d'entrée pour la phase de redocumentation interactive.

4.3.3.2 La phase de redocumentation interactive (transformation T1)

Le produit final du processus de redocumentation de l'activité informatique est un document hypermédia. Nous utilisons le document (D_0) produit par la phase de redocumentation automatique comme un espace d'information initial pour construire le document final. Durant la phase de redocumentation interactive, l'utilisateur est assisté par un outil auteur et la création du contenu du document final est à la fois interactive et itérative. L'idée de cette construction est inspirée du principe de la composition tridimensionnelle (sémantique, logique et de présentation) des documents hypermédia adaptatifs ou personnalisés (Garlatti and Iksal, 2002 ; Ranwez and Crampes, 1999). Une telle composition exploite souvent un modèle utilisateur pour supporter les choix de l'utilisateur, nous préférons cependant que l'utilisateur agisse de façon directe sur le document et décide du contenu et de la structure de celui-ci (i.e. sans se servir de modèle utilisateur). La manipulation du document par l'utilisateur est focalisée sur la structure sémantique (rhétorique) de celui-ci. L'utilisateur est assisté par l'outil auteur pour réaliser des opérations sur le document initial (D_0) ou sur tout autre document intermédiaire (D_j).

Les opérations à réaliser sur le document pendant la redocumentation interactive.
Ces opérations peuvent concerner soit :

- un seul segment documentaire : par exemple, supprimer un segment ou insérer un nouveau segment avec une nouvelle relation rhétorique.
- plusieurs segments documentaires : par exemple, fusionner les contenus de deux ou de plusieurs segments dans un seul segment ou réordonner des segments dans le document selon un critère particulier tel que l'ordre temporel des actions de la trace qui sont décrites par ces segments.
- une relation entre deux segments du document : par exemple, supprimer une relation existante ou créer une nouvelle relation entre deux segments documentaires.
- le document en entier : par exemple, introduire ou résumer le document en ajoutant un nouveau segment documentaire pour cet objectif.

Nous supposons qu'il existe deux types de relations dans le document Initial (D_0) qui sont les relations structurelles et les relations rhétoriques ; nous distinguons également deux types d'opérations qui peuvent être appliquées à ce document : les opérations organisationnelles et les opérations rhétoriques.

- *les opérations organisationnelles* permettent la suppression ou le remplacement d'un segment, la fusion de plusieurs segments, la création d'une relation structurelle ou la suppression d'une relation dans le document manipulé.
- *les opérations rhétoriques* permettent, quant à elles, l'ajout de nouveaux segments au document via des relations rhétoriques. Chaque opération rhétorique à appliquer par l'utilisateur est basée sur le choix de celui-ci d'une relation rhétorique particulière à

créer. Nous proposons l'utilisation d'un sous-ensemble des relations rhétoriques définies par RST (voir tableau 3.1) que nous jugeons pertinent pour la redocumentation d'une activité médiée informatiquement ; ces relations sont : *séquence, contraste, jonction, justification, élaboration, arrière-plan, facilitation, évaluation, interprétation, but, solution, introduction et résumé.*

Nous justifions ces choix de relations rhétoriques par un compromis entre le pouvoir descriptif de l'activité informatique et la facilité d'exploitation d'un tel ensemble de relations par l'utilisateur effectuant la redocumentation. La réalisation d'une opération rhétorique implique la création d'un nouveau segment documentaire dont le contenu est à fournir par l'utilisateur ; ce segment peut être lié par la relation rhétorique choisie à tout le document ou à un segment particulier de celui-ci. Par exemple, l'utilisateur peut *justifier, élaborer* ou *évaluer* le contenu d'un segment particulier du document, qui décrit une action de la trace d'activité informatique ; il peut également *introduire* ou *résumer* tout le contenu du document manipulé.

Le produit de la redocumentation interactive. Suite aux opérations appliquées au document initial (D_0) de façon itérative, un document intermédiaire (D_j) est produit à chaque itération (J). Dans ce document (D_j), chaque fragment d'information peut être soit :

- un fragment directement issu de la trace d'activité, qui décrit un ou plusieurs éléments observés (i.e. actions) de celle-ci.
- un fragment qui décrit une relation entre deux fragments d'information dans le document (D_{j-1}) produit durant une itération précédente.
- un fragment d'information remplacé ou composé (par fusion) par l'utilisateur à partir d'un (des) fragment(s) du document (D_{j-1}) produit à une itération précédente ;
- un segment créé par l'utilisateur via une opération rhétorique.

Les relations entre les fragments du document intermédiaire (D_j) décrivent des relations existantes dans le document (D_{j-1}) produit à l'itération précédente ou des relations ajoutées explicitement par l'utilisateur, que ce soit des relations rhétoriques ou structurelles.

L'export du document final. Une fois que l'utilisateur est satisfait du document intermédiaire obtenu, il peut exporter celui-ci comme un document hypermédia final. Pour la structure logique et la structure physique (de présentation) de ce document, nous supposons l'utilisation de modèles prédéfinis. Cette idée est inspirée de la composition des documents virtuels personnalisables (Iksal et Garlatti, 2002) que nous avons décrite auparavant (voir section 3.4.4.1) ; mais sans pour autant se baser sur un modèle utilisateur. Un gabarit XML par exemple peut être utilisé pour décrire la structure logique du document ; alors, une page peut être engendrée pour chaque fragment ou groupe de fragments d'information du document, de telle sorte que la disposition spatiale des contenus des fragments d'une seule page va dépendre des relations existantes entre ces fragments dans le document. Par exemple, les relations rhétoriques de type *Séquence* entre les fragments d'information du document définissent une relation d'ordre entre ces fragments ; celle-ci peut être exprimée en mettant les contenus de ces fragments d'information les uns à la suite des autres dans la page en fonction de leur ordre. Les relations (rhétoriques et structurelles) entre les fragments du document peuvent également être exprimées par des liens de navigation internes (à l'intérieur d'une page) ou externes (entre les pages du document). Pour la représentation visuelle du document final, une feuille de style peut être utilisée ; celle-ci permet d'appliquer des règles de présentation aux éléments du document pour engendrer un document HTML. A ce niveau, nous supposons que l'utilisateur peut

intervenir (i.e. sur la feuille de style) pour exprimer certains choix tels que ceux de la typographie, des couleurs, des modèles de liens utilisés, *etc.*

4.4 Une spécification du cadre général pour une redocumentation en texte

Dans la section précédente, nous avons proposé un cadre général pour le processus de redocumentation de l'activité informatique ; celui-ci utilise en entrée une trace modélisée de l'activité et génère en sortie un document hypermédia qui décrit cette activité. Cependant, nous nous intéressons en particulier à une redocumentation en texte.

Notre objectif est de considérer l'approche de redocumentation la plus « naturelle » en proposant que le document produit par cette approche narrative ait une forme textuelle (Yahiaoui et al., 2012) : forme qui est familière et facilement échangeable pour les êtres humains sachant lire et écrire.

La spécialisation de notre cadre général de la redocumentation pour produire des documents textuels introduit des modifications sur les deux phases (automatique et interactive) du processus de redocumentation. Toutefois, le modèle de la trace d'activité (voir figure 4.4) et le modèle de document (voir figure 4.5) que nous avons proposés sont maintenus mais avec une seule restriction sur le modèle de document : c'est que la forme du segment spécifique (qui peut être un texte, une image, une vidéo, une forme mixte, *etc.*) ne peut être que du texte dans ce cas. Nous décrivons dans la suite les particularités des deux phases du processus de redocumentation de l'activité informatique dans le cas d'une approche de redocumentation en texte.

4.4.1 La phase de redocumentation automatique en texte

La phase automatique du processus de redocumentation en texte de l'activité médiée informatiquement permet de transformer automatiquement une trace de l'activité informatique en un document texte fragmenté initial (D_0). Ceci est rendu pour nous possible par la modélisation formelle de la trace d'activité et la disponibilité d'outils permettant la génération de fragments d'information textuels à partir de données modélisées formellement.

Plusieurs travaux sur la génération du langage naturel sont focalisés sur la production de descriptions textuelles à partir d'éléments (instances et classes) d'ontologies ; c'est le cas de l'outil Ilex (O'donnell et al., 2001) qui a été testé avec une ontologie des objets de musée et celui du projet M-PIRO (Androutsopoulos et al., 2006) qui a développé une extension multi-langues pour Ilex et qui a été testé dans différents domaines (e.g. pour décrire des objets de musée, des équipements informatiques, *etc.*). Le rôle des ontologies utilisées par ces outils ne se limite pas à fournir un vocabulaire sémantique ; il s'étend également à fournir un entrepôt de connaissances dont les parties peuvent être automatiquement exprimées, à la fois, en langage naturel (et en plusieurs langues) et sous une forme exploitable par la machine. Un autre outil plus sophistiqué dans ce domaine est NaturalOWL (Galanis and Androutsopoulos, 2007). Fondé sur les idées de Ilex et M-piro, il fournit un support complet pour le langage d'ontologies OWL-DL ; il est également extensible et permet de considérer d'autres langues que l'anglais et le grec supportés actuellement. En outre, l'outil NaturalOWL est plus simple à utiliser que les générateurs Ilex et M-piro puisque il est entièrement basé sur des modèles. Ceci permet son utilisation par des personnes qui ne sont pas forcément initiées en linguistique ; alors que ces générateurs sont plutôt basés sur des grammaires moins évidentes à manipuler. Nous décrivons dans la suite la génération des fragments textuels du document

initial (D_0) en utilisant un outil de génération du langage naturel, puis nous décrivons l'organisation de ces fragments au sein de ce document.

4.4.1.1 La génération des fragments textuels du document initial (D_0)

Nous supposons que la génération des fragments textuels du document initial (D_0) à partir de la trace d'activité est réalisée par un outil de génération du langage naturel. Nous décrivons le principe de fonctionnement de ce type d'outil à travers un exemple concret où l'outil NaturalOWL est utilisé.

Le principe de l'outil de génération de descriptions textuelles (NaturalOWL). Le principe de NaturalOWL est d'annoter une ontologie (en OWL-DL) en RDF pour associer les éléments de celle-ci (i.e. les classes, les instances et les propriétés de l'ontologie) à des ressources linguistiques dépendantes du domaine (les noms qui peuvent être utilisés pour référer les classes et les instances, ainsi que les modèles qui peuvent être utilisés pour exprimer les propriétés de ces classes) et à des données sur les préférences de l'utilisateur afin de produire des descriptions textuelles pour les éléments de l'ontologie. Cet outil est muni d'un *plugin* pour l'éditeur d'ontologies *Protégé*⁵⁸ qui permet aux concepteurs d'ontologies de définir, de façon visuelle, toutes les annotations (linguistiques et de préférences) dont le générateur du langage naturel a besoin ; ce plugin permet également la génération et la visualisation des textes qui en résultent. Le processus de génération d'un document texte par NaturalOWL est caractérisé par trois étapes : la planification du document, la micro-planification et la réalisation de surface.

a) *La planification du document* : lorsque NaturalOWL est invoqué pour produire une description textuelle d'une instance particulière, il commence par sélectionner (dans l'ontologie) toutes les assertions qui concernent directement cette instance en respectant la distance d'inférence fixée (dans le graphe des classes et des instances de l'ontologie). Par exemple, si cette distance est égale à deux, le moteur NaturalOWL doit inclure dans la description de l'instance concernée : la description textuelle de sa classe et celle de sa superclasse, la description de chacune des propriétés et des relations de l'instance, la description de chacune des instances avec lesquelles cette instance est reliée et la description de chacune des propriétés et des relations de ces instances avec d'autres instances (sans décrire ces dernières). Les assertions sélectionnées de distance *un* (i.e. dont le sujet est l'instance à décrire) sont ordonnées en fonction des annotations linguistiques d'ordre (*owl:order*) qui spécifient un ordre partiel entre les propriétés de l'ontologie ; puis les assertions de distance *deux* sont placées juste après les assertions de distance *un* dont elles dépendent et ainsi de suite. La figure 4.6 représente l'exemple d'une description textuelle (en anglais) générée par l'outil NaturalOWL pour décrire une instance (*exhibit24*) de l'ontologie des objets de musée. Dans cet exemple, la distance d'inférence fixée est *deux* et les chiffres figurants sur les arcs représentent l'ordre de priorité de description des relations et des propriétés de l'instance (déduit des annotations linguistiques d'ordre).

b) *La micro-planification* : pour chacune des propriétés de l'ontologie, un micro-plan est à spécifier pour chaque langage (anglais et grec) pendant l'annotation linguistique de l'ontologie. Le micro-plan est un modèle constitué d'une suite de parties qui décrivent la propriété ou la relation ; ces parties sont à remplacer par le sujet (qui peut être de type nom ou pronom), la valeur de la propriété (le verbe qui décrit la propriété avec les détails sur sa conjugaison et sa forme passive ou active) et une chaîne de caractères. Ce sont ces micro-

⁵⁸ <http://protege.stanford.edu/>

plans qui permettent à NaturalOWL de décrire par des phrases les propriétés d'une instance et les relations de celle-ci avec d'autres éléments de l'ontologie. Pour notre exemple de la figure 4.6, le micro plan (en anglais) qui correspond à la propriété *current-location* de l'instance *exhibit24* est constitué de trois parties (le sujet : *This aryballos*, la valeur de la propriété : *is exhibited*, la chaîne de caractères : *in the Archaeological Museum of Delos*).

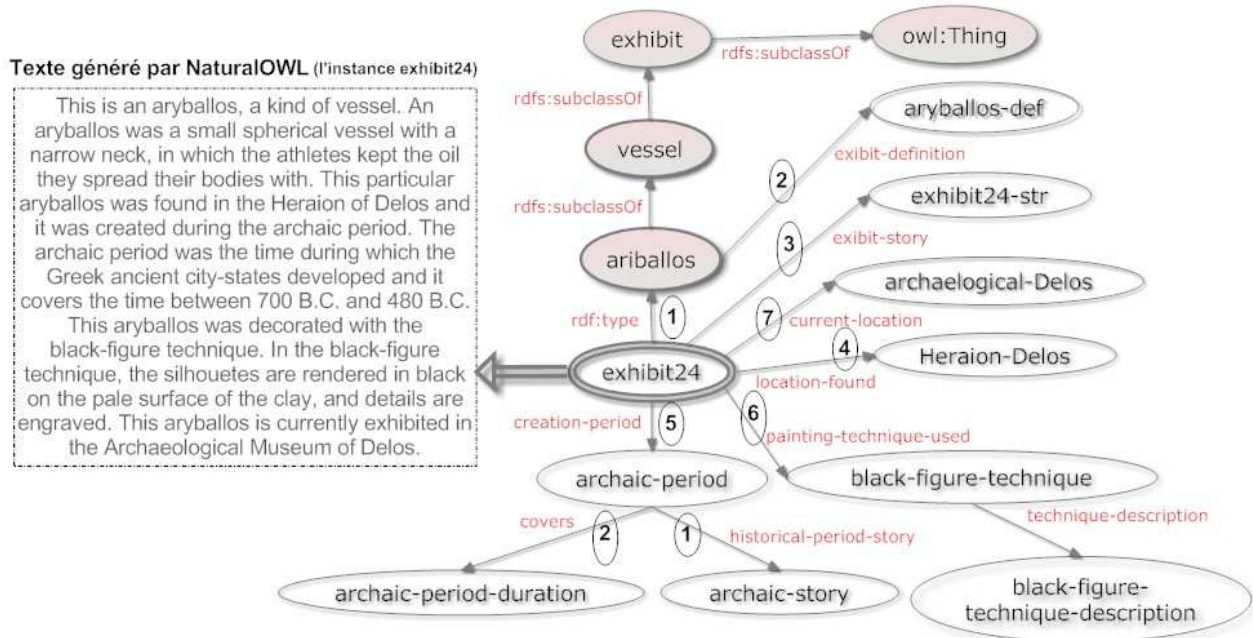


Figure 4.6. Exemple de texte généré par NaturalOWL pour décrire une instance de l'ontologie d'objets de musée (Galanis and Androutsopoulos, 2007).

c) *La réalisation de surface* : NaturalOWL emploie des algorithmes simples pour générer des expressions de référence du type « *This aryballos* » ; mais pour cela, il a besoin des annotations lexicales assignées aux classes de l'ontologie (nom de la classe au singulier et au pluriel, genre de la classe : masculin, féminin ou neutre, etc.). Les phrases des micro-plans sont organisées par NaturalOWL dans des phrases plus longues en utilisant des règles d'agrégation pour produire le texte final. Au moment de la génération du texte, NaturalOWL décide du nombre de faits à exprimer par une ligne de texte et du nombre de lignes à produire par page ; cela en fonction des annotations du niveau préférences de l'utilisateur. Pour notre exemple de la figure 4.6, la description de l'instance *exhibit24* commence par la description de sa classe (*aryballos*) et celle de sa superclasse (*vessel*), suivies par la description de la relation *exhibit-definition* ayant la priorité d'ordre supérieure et ainsi de suite pour les autres propriétés de l'instance. Toutefois, pour décrire la relation *creation-period*, NaturalOWL décrit également les relations *covers* et *historical-period-story* de l'instance *archaic-period* avec laquelle l'instance *exhibit24* est reliée puisque la distance d'inférence choisie est deux.

L'utilisation de NaturalOWL pour générer les fragments du document initial (D_0). Le modèle de la trace d'activité que nous avons proposé (figure 4.4) est facilement exprimable sous forme d'une ontologie-OWL ; alors l'utilisation d'un outil tel que NaturalOWL permettra de générer une description textuelle (en anglais) pour chacun des éléments observés (i.e. actions) de la trace. Ces descriptions textuelles peuvent constituer les contenus des fragments d'information du document initial (D_0). Cependant, pour que l'outil NaturalOWL soit capable de produire de telles descriptions, il va falloir procéder *a priori* à l'annotation linguistique de

l'ontologie de la trace à trois niveaux : *le niveau lexical* (pour exprimer le genre et le nombre des classes et des instances de l'ontologie), *le niveau micro-plans* (pour exprimer les propriétés des classes et les relations entre celles-ci selon des modèles du langage naturel, tout en assignant un ordre de priorité à ces propriétés et relations pour déterminer l'ordre de leur expression dans la description textuelle d'une instance ayant ces propriétés et relations au même temps) et le niveau *préférences de l'utilisateur* (pour préciser des paramètres qui influencent directement le processus de génération des descriptions textuelles tels que le langage, la profondeur des inférences dans la description des instances, le nombre maximum d'assertions à décrire par phrase, etc.). Cette annotation permet de produire trois fichiers de métadonnées (en RDF) exploitables par le générateur du langage naturel NaturalOWL.

4.4.1.2 La construction du document texte initial (D₀)

Nous avons proposé un modèle de document (figure 4.5) qui est centré sur la structure rhétorique de celui-ci. Alors, si nous supposons l'utilisation d'un outil de génération du langage naturel pour produire des descriptions textuelles à propos des éléments observés de la trace d'activité ; il sera utile de constituer des fragments textuels à partir de ces descriptions et d'organiser ces fragments selon une structure rhétorique de base pour le document. Nous supposons que cette organisation se réalise dans un premier temps de façon automatique via des relations rhétoriques de type *Séquence* qui expriment les relations temporelles implicites entre les éléments observés (i.e. les actions) de la trace d'activité. Nous considérons en effet que la relation d'ordre temporel entre les actions de la trace est une propriété importante à exprimer dans le produit de la redocumentation ; ce que nous exprimons sous une forme textuelle en utilisant la relation rhétorique adaptée (*Séquence*). La figure 4.7 est une représentation graphique du document texte initial (D₀) produit de la phase de redocumentation automatique ; celui-ci est constitué de l'ensemble des fragments textuels décrivant les éléments observés de la trace d'activité, organisés selon des relations rhétorique de type *Séquence* qui expriment les relations d'ordre temporel entre ces éléments.

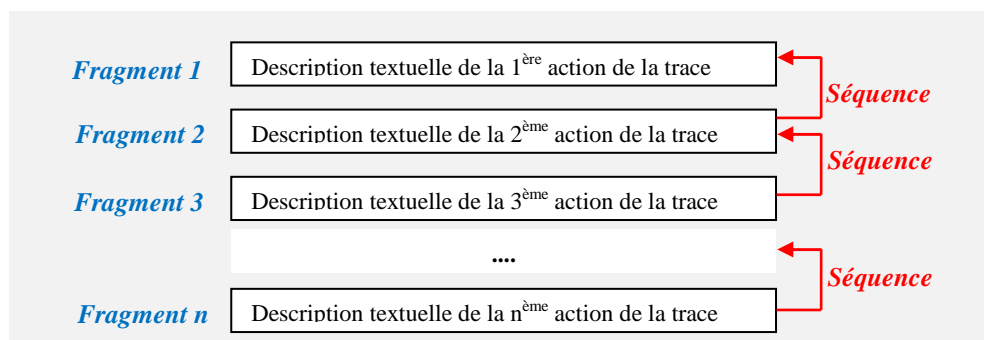


Figure 4.7. Représentation graphique du document texte initial (D₀) produit de la phase de redocumentation automatique en texte.

4.4.2 La phase de redocumentation interactive en texte

La phase interactive du processus de redocumentation en texte de l'activité médiée informatiquement permet d'assister l'utilisateur pour transformer de façon itérative et interactive le document texte initial (D₀), produit par la phase de redocumentation automatique, en un document texte final qui décrit l'activité de façon personnalisée par cet utilisateur. Cette transformation est basée sur l'application d'un ensemble d'opérations sur le

document initial (D_0), puis sur le document intermédiaire (D_j) produit à chaque itération. Ces opérations visent la manipulation de la structure rhétorique du document manipulé.

4.4.2.1 Les opérations à appliquer au document (D_0) par l'utilisateur

Les opérations que l'utilisateur peut appliquer au document manipulé durant la phase de redocumentation interactive en texte sont celles que nous avons décrites pour le cadre général de la redocumentation (voir section 4.3.3.2) mais avec quelques restrictions. Ces opérations peuvent être de deux types : rhétorique ou organisationnelle. Les opérations rhétoriques s'appliquent à un fragment textuel du document ou au document en entier et permettent la création d'un nouveau fragment textuel et d'une nouvelle relation rhétorique ; alors que les opérations organisationnelles s'appliquent à une relation, à un fragment ou à plusieurs fragments du document. Ces opérations sont décrites en détail dans le tableau 4.1.

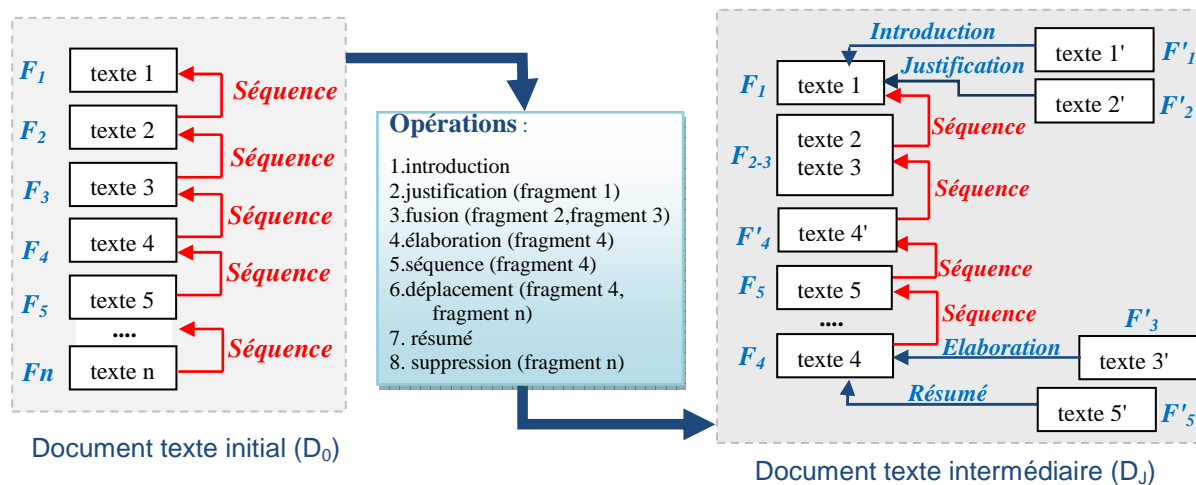


Figure 4.8. Exemple d'application d'opérations par l'utilisateur sur le document texte initial (D_0) durant la phase de redocumentation interactive en texte.

Nous présentons dans la figure 4.8 un exemple d'application de différentes opérations. Nous supposons que l'utilisateur a appliqué huit opérations sur le document (D_0) :

1. une opération rhétorique qui a produit le fragment textuel F'_1 et la relation rhétorique de type *Introduction*.
2. une opération rhétorique qui a produit F'_2 et la relation rhétorique de type *Justification*.
3. une opération organisationnelle qui a fusionné les deux fragments F_2 et F_3 en F_{2-3} avec une suppression de la relation du type *Séquence* qui existait entre F_2 et F_3 ,
4. une opération rhétorique qui a produit F'_3 et la relation rhétorique de type *Elaboration*.
5. une opération rhétorique qui a produit le fragment F'_4 et la relation de type *Séquence* entre F'_4 et F_4 ; la relation de type *Séquence* entre F_5 et F_4 est devenue entre F_5 et F'_4 .
6. une opération organisationnelle qui a échangé les fragments F_4 et F_n ; la relation de type *Séquence* entre F'_4 et F_4 est devenue entre F'_4 et F_n , celle entre F_n et F_{n-1} est devenue entre F_n et F_{2-3} et celle entre F_4 et F_{2-3} est devenue entre F_4 et F_{n-1} .
7. une opération rhétorique qui a produit F'_5 et la relation rhétorique de type *Résumé*,
8. une opération organisationnelle qui a supprimé le fragment F_n ; la relation de type *Séquence* qui existait entre F'_4 et F_n est devenue entre F'_4 et F_{2-3} .

Type opération	Élément manipulé	Nom de l'opération	Effet de l'opération
Organisationnelle	une relation	suppression	- suppression d'une relation entre deux fragments. - suppression du fragment source de cette relation. - mise à jour des relations de type <i>Séquence</i> concernées.
		modification	- modification du type de la relation rhétorique. - si le nouveau type de la relation est <i>Séquence</i> ; alors mise à jour des relations de type <i>Séquence</i> concernées.
	un fragment	suppression	- suppression du fragment et des relations qu'il a avec les autres fragments du document. - mise à jour des relations de type <i>Séquence</i> concernées. - suppression des fragments isolés dans le document.
		remplacement	remplacement du texte du fragment avec le texte fourni par l'utilisateur.
	deux fragments	déplacement	mise à jour des relations de type <i>Séquence</i> qui relient ces fragments avec les autres fragments du document.
	plusieurs fragments	fusion	(<i>condition</i> : les fragments à fusionner doivent être successifs, donc liés par des relations de type <i>Séquence</i>). - fusion des textes des fragments pour former un seul fragment. - mise à jour ou suppression des relations de type <i>Séquence</i> concernées.
Rhétorique	un fragment	<i>séquence, contraste, jonction, justification, élaboration, arrière-plan, facilitation, évaluation, interprétation, but, solution</i>	- création d'un nouveau fragment dont le contenu textuel est fourni par l'utilisateur. - création d'une nouvelle relation rhétorique (dont le type dépend du nom de l'opération) entre le nouveau fragment et le fragment choisi du document. - si le nom de l'opération est <i>séquence</i> ; alors mise à jour des relations de types <i>Séquence</i> qui concernent le fragment choisi du document.
		<i>introduction</i>	- création d'un nouveau fragment dont le contenu textuel est fourni par l'utilisateur. - création d'une nouvelle relation rhétorique de type <i>Introduction</i> entre le nouveau fragment et le premier fragment du document (selon les relations <i>Séquence</i>).
	le document	<i>résumé</i>	- création d'un nouveau fragment dont le contenu textuel est fourni par l'utilisateur. - création d'une nouvelle relation rhétorique de type <i>Résumé</i> entre le nouveau fragment et le dernier fragment du document (selon les relations <i>Séquence</i>).

Tableau 4.1. Description des différentes opérations que l'utilisateur peut appliquer au document manipulé durant la phase de redocumentation interactive en texte.

4.4.2.2 Le produit de la redocumentation interactive en texte

L'utilisateur applique au document initial (D_0) un ensemble d'opérations de façon itérative durant la phase de redocumentation interactive ; celles-ci produisent à chaque itération un document texte fragmenté intermédiaire (D_j).

Les documents texte intermédiaires (D_j). Dans ces documents, chaque fragment d'information peut être :

- un fragment textuel du document (D_{j-1}) produit à une itération précédente ; celui-ci peut être issu de la trace d'activité (cas des fragments du document D_0) et décrire un ou plusieurs éléments observés (i.e. actions) de celle-ci.
- un fragment textuel remplacé ou composé (par fusion) par l'utilisateur à partir d'un (des) fragment(s) du document (D_{j-1}) produit à une itération précédente ;
- un fragment textuel créé par l'utilisateur via une opération rhétorique.

Quant aux relations entre les fragments textuels du document intermédiaire (D_j) ; elles sont purement rhétoriques. Elles décrivent :

- des relations existantes dans le document (D_{j-1}) produit à l'itération précédente;
- des relations ajoutées explicitement par l'utilisateur.

L'export du document texte final. Une fois que l'utilisateur est satisfait du document intermédiaire produit, il peut exporter celui-ci comme un document texte final (dans un format hypertexte éventuellement). Pour la structure logique et la structure physique de ce document, nous supposons l'utilisation de modèles prédéfinis simples.

Tout d'abord, pour la structure logique qui organise les éléments du contenu du document en leur assignant un rôle dans la signification, nous proposons l'organisation du contenu du document comme une suite de paragraphes qui représentent les contenus textuels des fragments du document. L'ordre de disposition de ces paragraphes dans le document final va dépendre de l'ordre défini par les relations rhétoriques de type *Séquence* entre les fragments textuels du document. Cependant, pour pouvoir exprimer les autres types de relations rhétoriques existantes au sein du document sous une forme textuelle, nous proposons l'utilisation de connecteurs linguistiques. Nous avons expliqué auparavant (voir section 3.4.3.1) que l'identification d'une relation rhétorique entre deux parties de texte est facile lorsqu'un connecteur linguistique est utilisé et nous avons donné l'exemple du connecteur « *parce que* » qui permet de repérer une relation rhétorique de *causalité*. Ainsi, nous pouvons assigner à chaque type de relation rhétorique un connecteur linguistique (i.e. une expression textuelle) pour pouvoir exprimer cette relation par du texte dans le document final. Par exemple, nous pouvons utiliser les connecteurs « *En outre* » pour exprimer une relation rhétorique de type *Elaboration* ; « *Ainsi* » pour exprimer une relation de type *Evaluation* ; « *Cela veut dire que* » pour exprimer une relation de type *Interprétation*, etc. Nous pouvons également permettre à l'utilisateur d'ajouter un titre au document final pour assurer une bonne structuration à celui-ci.

Pour la présentation visuelle du document (i.e. sa structure physique), nous supposons l'utilisation d'un modèle prédéfini qui assigne à chaque partie du contenu du document final des propriétés typographiques particulières (i.e. des attributs de présentation). Par exemple, ce modèle peut appliquer la même police et la même couleur pour tous les paragraphes du document final ; alors qu'il applique une police différente pour le titre du document et certains marqueurs linguistiques figurants dans le document (e.g. Introduction, Résumé, etc.). La

figure 4.9 présente un exemple de document fragmenté intermédiaire (D_J) exporté comme un document texte final.

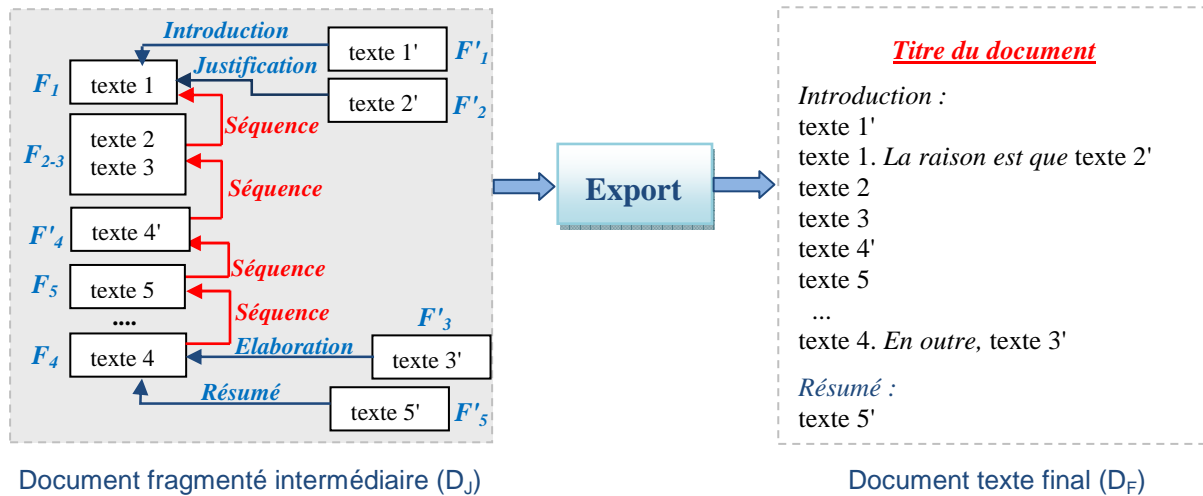


Figure 4.9. Exemple d'export d'un document fragmenté intermédiaire (D_J) en un document texte final (D_F).

4.5 Conclusion et discussion

Dans le premier chapitre de ce manuscrit, nous avons décrit notre problématique de la redocumentation de l'activité médiée informatiquement à base de sa trace et nous avons défini ce processus de redocumentation ainsi que notre approche générale de celui-ci. Cela nous a permis de déterminer les objectifs d'un tel processus, les acteurs humains pouvant être concernés par celui-ci et le moment de l'application du processus par rapport au déroulement de l'activité informatique. Cependant, la question la plus importante, qui est celle de la manière dont le processus pouvait être mis en place, n'avait pas été abordée.

Pour répondre à cette question au travers de ce chapitre, nous avons fixé dès le début les propriétés que doit vérifier un tel processus. En fonction de ces propriétés, nous avons adopté des choix particuliers concernant sa mise en place effective. Nous avons supposé que le processus de redocumentation de l'activité informatique devait être facile à appliquer et utile pour ses utilisateurs, et qu'il devait préserver la liberté de ceux-ci dans l'appropriation du contenu et de la forme du document produit qui est censé fournir une description de qualité de l'activité et facilement échangeable. Par conséquent, nous avons opté pour une approche de redocumentation naturelle, semi-automatique et assistée par un outil auteur, dont le produit est un document cohérent de format universel (hypertexte). D'un point de vue théorique, cette approche de redocumentation interactive est narrative (i.e. basée sur le Storytelling) ; elle utilise les principes de la théorie de la structure rhétorique (RST) pour maintenir la cohérence du document produit. Elle utilise également des modèles formels pour les données d'entrée (la trace d'activité) et de sortie (le document produit) du processus de redocumentation pour permettre une automatisation en partie de celui-ci. C'est ainsi que le processus de redocumentation est caractérisé par deux phases : la première phase est automatique et génère un document fragmenté initial à partir de la trace d'activité ; tandis que la deuxième phase est interactive et permet à l'utilisateur de s'appropriier le contenu et la forme du document produit selon ses besoins et ses choix, tout en maintenant la cohérence de ce document qu'il peut exporter dans un format hypertexte.

En outre, nous avons proposé une spécialisation de notre approche de redocumentation *en texte* puisque le texte est une forme très familière pour les être humains. Notre objectif est de pouvoir produire un document texte cohérent et personnalisé par l'utilisateur pour décrire l'activité informatique à partir de sa trace. Dans cette spécification, nous avons maintenu le modèle de la trace et celui de document que nous avons proposés pour l'approche générale et nous avons décrit les restrictions concernant l'application des deux phases du processus de redocumentation pour produire un document texte. Nous avons proposé l'utilisation des technologies du Web Sémantique (les ontologies) et un outil de génération du langage naturel tel que NaturalOWL pour supporter la phase de redocumentation automatique en texte. Nous avons également décrit, avec des exemples, les opérations que l'utilisateur peut appliquer au document initial (produit de la redocumentation automatique) durant la phase de redocumentation interactive en texte, avant d'exporter le produit en un document texte final.

Dans le chapitre qui suit, nous proposons une implémentation de notre approche de redocumentation en texte de l'activité informatique à travers un outil auteur que nous baptisons *ActRedoc*. Une activité informatique particulière, qui est celle de la navigation dans la « *Presse illustrée* » nous servira d'exemple pour illustrer le fonctionnement de cet outil et présenter les résultats d'une première évaluation de celui-ci.

Chapitre 5: ActRedoc, un outil auteur de redocumentation en texte

5.1 Introduction

Dans le chapitre précédent, nous avons proposé une approche générique narrative et semi-automatique pour la redocumentation de l'activité informatique à partir de sa trace. Nous avons également spécifié cette approche pour une redocumentation en texte ; nous avons décrit la modélisation de la trace d'activité à redocumenter et du document texte produit, ainsi que les deux phases du processus de redocumentation. Cependant, pour rendre cette approche concrètement utilisable, il est impératif de l'implémenter en utilisant des technologies et les outils adéquats. C'est ainsi que nous avons développé un outil de redocumentation en texte que nous avons baptisé *ActRedoc* (une abréviation de *Activity Redocumentation*). Il s'agit d'un outil auteur qui permet à son utilisateur de choisir une trace modélisée de l'activité informatique à redocumenter ; puis de la transformer de façon interactive et itérative pour produire un document texte final, cohérent et personnalisé, décrivant l'activité en question.

Nous consacrons le présent chapitre à une description détaillée de notre outil de redocumentation en texte *ActRedoc*. Nous commençons par une présentation de l'activité informatique cible de redocumentation que nous avons choisie : une activité de navigation dans un site d'archive de journaux du 19^{ème} siècle de la presse illustrée régionale. Puis nous présentons l'architecture de notre outil et décrivons les différentes technologies utilisées pour son implémentation. Nous décrivons également le fonctionnement de cet outil au travers d'un exemple complet de redocumentation d'une trace particulière de l'activité choisie. Nous terminons le chapitre par une évaluation de l'outil auprès d'un groupe d'utilisateurs dans le cadre d'une étude préliminaire.

5.2 Un exemple d'activité à redocumenter : la navigation dans la « Presse Illustrée »

L'exemple concret que nous avons choisi comme activité informatique particulière à redocumenter est une activité de navigation dans un site d'archive de journaux du XIX^{ème}. Ce site destiné au grand public a été développé par la bibliothèque municipale de Lyon dans le cadre du projet CaNu XIX⁵⁹. L'objectif principal de ce projet était de valoriser et de mettre en ligne des fonds patrimoniaux de la presse illustrée régionale du XIX^{ème} siècle, disponibles au département Documentation Lyon et Rhône-Alpes de la Bibliothèque Municipale de Lyon, pour permettre l'accès gratuit et à distance de ces fonds. Une base de données contenant les versions textes et images de ces collections a été construite, et l'accès à celle-ci via l'application « Presse Illustrée » permet aux lecteurs une reconstruction du contexte spatial et temporel dans lequel ces fonds ont été produits et notamment une construction de leurs

⁵⁹ CaNu XIX : les canards numériques du XIX^{ème} siècle

propres documents à partir de ces sources. Nous nous intéressons à l'activité de navigation dans ce corpus numérique, c'est pourquoi nous présentons dans la suite les fonctions offertes à l'utilisateur par l'application « Presse Illustrée ».

5.2.1 Présentation de l'application « Presse Illustrée »

Le corpus « Presse Illustrée » est constitué d'un ensemble de journaux numérisés dont *Le Progrès illustré* est le premier titre intégré. Pour chaque journal, quatre types d'unités documentaires sont considérés : les fascicules, les pages, les articles et les illustrations. L'application sous-jacente à ce corpus propose un feuilletage de ces journaux tel que les lecteurs le pratiquent depuis longtemps avec les microfilms. Elle offre de plus des accès à valeur ajoutée tels que la recherche en plein texte d'articles, la recherche des illustrations par mots-clés ou par nom d'auteur, des parcours de découverte, des services tels que le téléchargement immédiat de pages en couleur, *etc.*

5.2.1.1 La description des données du corpus « Presse Illustrée »

La figure 5.1 représente l'organisation du corpus « Presse Illustrée » qui est une collection de journaux. Chaque journal est constitué de plusieurs fascicules (numéros), le fascicule est constitué de plusieurs pages et chaque page peut comporter plusieurs articles et/ou illustrations. De plus, chaque élément dans ce corpus est caractérisé par un ensemble de métadonnées qui permettent son identification et sa recherche. L'article est l'unité sémantique de base. Son contenu est le texte produit de la numérisation de la page du journal qui le comporte, suivi d'un traitement particulier pour aboutir à un texte formaté (balisé en TEI⁶⁰) ; celui-ci permet d'indexer les noms des personnes et des lieux figurant dans l'article. En outre, cette unité documentaire est décrite par des métadonnées dont le schéma choisi en l'occurrence est le Dublin Core⁶¹. Ainsi, chaque article est identifié par son titre, son (ses) auteur(s), des mots clés associés à celui-ci (des thèmes), sa date de publication, *etc.* L'illustration est décrite par des métadonnées de la même façon qu'un article ; mais elle est caractérisée par une *description textuelle* au lieu d'un *texte* original. Cette description textuelle permet une recherche sémantique des illustrations au sein du corpus. Les pages sont identifiées par leurs numéros, les fascicules par leurs numéros et leurs dates de parution ; et les journaux par leurs noms.

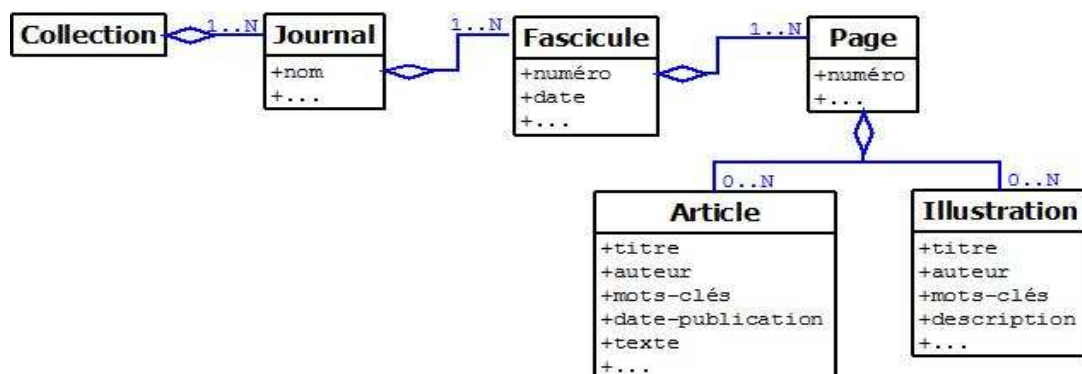


Figure 5.1. Organisation du corpus numérique « Presse Illustrée ».

⁶⁰ TEI (*Text Encoding Initiative*) : des recommandations qui fournissent le moyen de rendre explicites certaines caractéristiques d'un texte pour faciliter son traitement par des programmes. Cette tâche d'explicitation est appelée *balisage* ou *codage*.

⁶¹ Dublin Core: <http://dublincore.org/documents/dces/>

5.2.1.2 Les fonctions supportées par l'application « Presse Illustrée »

L'application « Presse Illustrée » offre à l'utilisateur la possibilité de naviguer dans le corpus numérique de journaux que nous avons décrit ci-dessus. Elle permet la recherche des éléments de ce corpus (fascicules, pages, articles illustrations) selon différents critères ainsi que la présentation de ces éléments selon différents modes. A travers l'interface de cette application, présentée sur figure 5.2, nous identifions les fonctions de recherche les plus importantes pour l'utilisateur :



Figure 5.2. Interface de l'application de navigation dans le corpus « Presse illustrée» (<http://collections.bm-lyon.fr/presseIllustrée/>).

1. la fonction « *recherche* » permet d'afficher la page initiale de l'application pour pouvoir effectuer des recherches dans le corpus des journaux;
2. la fonction « *Découverte* » permet de consulter des articles construits à partir de différents articles et illustrations du corpus.
3. la fonction « *Recherche par année* » permet de rechercher les fascicules (numéros) d'un journal particulier (dont le nom est à choisir dans une liste) pour une année précise (à saisir). Le résultat de l'utilisation de cette fonction se présente comme une liste de fascicules comme illustré par la figure 5.2.
4. la fonction « *Accès à un numéro* » permet d'afficher un fascicule particulier en saisissant son numéro et en choisissant le nom du journal qui le comporte dans une liste. Le résultat de l'utilisation de cette fonction se présente comme un ensemble de pages du fascicule.
5. la fonction « *Parcours thématique* » est basée sur le choix d'un thème particulier dans le menu de thèmes proposé. Ces thèmes, organisés dans un mini-thésaurus, représentent les mots-clés avec lesquels les articles et les illustrations du corpus ont été indexés auparavant. Ainsi, une recherche par un thème particulier (e.g. « arts et loisirs/théâtre ») produit une liste des articles et illustrations indexés par ce thème.

6. la fonction « *Index des noms cités* » permet de rechercher tous les articles qui citent le nom d'une personne ou d'un lieu particulier (à saisir). Ainsi, le résultat de l'utilisation d'une telle fonction est une liste d'articles.
7. La fonction « *recherche rapide* » permet deux types de recherches : une recherche par éléments et une recherche par pages. La recherche par éléments permet de rechercher les articles et/ou les illustrations qui comportent une chaîne de caractères spécifique (à saisir) qui représente l'équation de la recherche ; celle-ci peut également être une expression de métadonnées (e.g. titre : moulin). La recherche par pages permet de rechercher toutes les pages qui comportent un mot particulier (à saisir). Le résultat de l'utilisation de la fonction *de recherche rapide* est ainsi une liste de pages ou une liste d'éléments selon le type de la recherche.

L'affichage des éléments du corpus peut se faire selon différents modes de présentation. Ceci dépend principalement du (des) type(s) de(s) élément(s) à afficher et de l'action de l'utilisateur provoquant cet affichage.

La présentation des fascicules : lorsqu'il s'agit d'une liste de fascicules à présenter à l'utilisateur, celle-ci est affichée sous forme d'une liste de miniatures de pages (la première page de chaque fascicule) dont chacune est accompagnée en légende du nom du journal, du numéro du fascicule et de sa date, et du numéro de la page (figure 5.2). L'action de cliquer sur un élément de cette liste permet d'afficher le contenu détaillé du fascicule dans une rubrique à part. Cette rubrique comporte une miniature de la première page du fascicule et le sommaire du fascicule sous forme d'une liste de numéros de pages cliquables avec la liste des articles et des illustrations comportés par chacune de ces pages. La présentation d'un fascicule peut également se faire sous forme d'une liste de miniatures de pages de celui-ci. Ceci dans le cas de l'utilisation de la fonction « *Accès à un numéro* » par exemple. De plus, un menu contextuel permet à l'utilisateur de sauvegarder ce fascicule dans un fichier compressé et l'action de cliquer sur l'une des miniatures de pages du fascicule permet d'afficher cette page. La figure 5.3 représente les deux modes de présentation d'un fascicule (rubrique de contenu à gauche et liste de miniatures de pages à droite).



Figure 5.3. Les deux modes de présentation d'un fascicule (comme une *rubrique de contenu* à gauche ou une *liste de miniatures de pages* à droite)

La présentation des pages : lors de la présentation d'une page particulière à l'utilisateur, cette page est affichée en entier avec le nom du journal, le numéro du fascicule et la date de celui-ci ainsi que le numéro de la page. Un menu contextuel permet de naviguer sur la page (par un zoom et un déplacement du focus), d'imprimer celle-ci dans un fichier PDF ou d'afficher les pages du même fascicule. Mais lorsqu'il s'agit d'une liste de pages à présenter, celles-ci sont affichées sous forme d'une liste de prévisualisations de pages dont chacune est constituée d'une miniature de la page et d'une rubrique d'informations sur celle-ci (nom du journal, numéro du fascicule et numéro de page). L'action de cliquer sur la miniature de la page ou sur sa rubrique d'informations permet d'afficher la page en question.

La présentation des articles et des illustrations : lorsqu'il s'agit d'une liste d'articles à présenter à l'utilisateur (suite à l'utilisation de la fonction de « *recherche rapide* » par exemple), celle-ci est affichée sous forme d'une liste de prévisualisations d'articles dont chacune est constituée d'une miniature d'article et d'une rubrique d'informations sur celui-ci (nom du journal, numéro du fascicule, numéro de la page, titre de l'article, auteur de l'article, un extrait du texte de l'article et les mots clés qui lui sont attachés). L'action de cliquer sur la miniature d'un article ou sur sa rubrique d'informations permet d'afficher le contenu de l'article en question ainsi que le contenu du fascicule qui le comporte. Les informations *auteur* et *mots-clés* sont également cliquables et permettent d'afficher la liste des articles et des illustrations ayant le même mot-clé (thème) ou auteur. Lorsqu'un article particulier est affiché, un menu contextuel permet d'afficher la page de celui-ci, d'imprimer l'article dans un format PDF ou de télécharger celui-ci dans le format balisé TEI. En outre, les noms propres (des personnes et des lieux) qui figurent dans le texte de l'article sont des *indexes* qui permettent l'accès aux définitions de ces noms dans Wikipedia. Les illustrations sont présentées de la même façon que les articles, à l'exception que l'illustration est caractérisée par une description textuelle au lieu d'un texte original dans le cas de l'article.

5.2.2 Le traçage de l'activité de navigation dans la « Presse Illustrée »

Nous avons travaillé en collaboration avec le développeur de l'application « Presse Illustrée » dans le but d'instrumenter cette application avec un module de traçage permettant d'enregistrer les interactions des utilisateurs avec celle-ci. Pour cela, nous avons commencé par recenser les différentes actions qu'un utilisateur peut effectuer lors de son utilisation de l'application et la caractérisation de celles-ci par des propriétés significatives. Ceci nous a permis d'identifier les informations importantes à enregistrer à propos de ces actions lors du traçage de l'activité de navigation. Le module de traçage développé permet de produire des traces d'activité de bas niveau sous forme d'un fichier log.

5.2.2.1 Identification et caractérisation des actions des utilisateurs

En exploitant les fonctions supportées par l'application de navigation dans la « Presse Illustrée », nous avons identifié un ensemble d'actions que l'utilisateur peut effectuer. Nous avons caractérisé chacune de ces actions par des propriétés pour aboutir à une la description plus ou moins complète de l'action en question. Dans le tableau 5.1, nous décrivons ces actions ainsi que les ressources manipulées par chacune d'entre elles. Cette description détaillée nous a permis de guider le développeur de l'application « Presse Illustrée » dans l'instrumentation de celle-ci avec un module de traçage pour récupérer toutes les informations que nous jugeons utiles (le fichier log).

5.2.2.2 Le fichier log produit du traçage de l'activité de navigation

L'instrumentation de l'application « Presse Illustrée » par un module de traçage nous a permis de récupérer un fichier log, dont le contenu est accessible en ligne⁶², qui représente une trace de bas-niveau de l'activité de navigation d'un ensemble d'utilisateurs dans le corpus des journaux. La figure 5.4 représente une partie de ce fichier dans lequel chaque ensemble de lignes correspond à la trace d'activité d'un utilisateur particulier ; alors que les colonnes décrivent les informations suivantes :

- *Date et heure* : la date et l'heure de l'action effectuée.
- *Adresse IP* : l'adresse IP de l'utilisateur (le numéro de session est également enregistré mais il n'est pas affiché dans ce log).
- *Action ou URL* : l'identifiant de l'action effectuée (e.g. < pdf > pour afficher une page en PDF) ou l'URL⁶³ de la ressource affichée (l'URL d'un article, d'une illustration, d'une liste de résultats de recherche, etc.).
- *Type ressource* : le type de la ressource affichée (fascicule, page, article ou illustration)
- *Propriétés ressource* : les propriétés de la ressource affichée (titre, numéro, date...).

Date et heure	Adresse IP	Action ou URL	Type ressource	Propriétés ressource
16/07/2008 12:30	77.91.224.7	/pressellustree/search?query=fullname_subject:"soci%C3%A9t%C3%A9/coutumes+et+savoir-vivre"		
16/07/2008 12:30	65.55.210.151	/PER0012495	page	Le Progrès Illustré, n°101, pp.5
16/07/2008 12:30	81.247.174.25	/PER0011787	page	Le Progrès Illustré, n°37, pp.2
16/07/2008 12:31	81.247.174.25	/PER00110015	item/illustration	La famille impériale de Russie 1891/08/30
16/07/2008 12:31	65.55.210.151	/PER0013376	page	Le Progrès Illustré, n°190, pp.6
16/07/2008 12:31	81.247.174.25	<pleine page>		
16/07/2008 12:31	81.247.174.25	<page précédente>		
16/07/2008 12:32	81.247.174.25	/PER0011786	page	Le Progrès Illustré, n°37, pp.1
16/07/2008 12:32	81.247.174.25	<PDF>		
16/07/2008 12:32	81.247.174.25	/PER0011786	page	Le Progrès Illustré, n°37, pp.1

Figure 5.4. Un extrait du fichier log produit du traçage de l'activité de navigation dans la « Presse Illustrée ».

Nous pouvons interpréter les données affichées par cette partie du fichier log comme suit :

- le 16/07/2008 à 12:30, l'utilisateur dont l'adresse IP est 77.91.224.7 a effectué une action de recherche par thème (« *société/coutumes et savoir vivre* »).
- à 12:30, l'utilisateur dont l'adresse IP est 65.55.210.151 a effectué une action d'affichage d'une page (page n°5 du fascicule n°101 du journal *Le Progrès Illustré*, url de la page : <http://collections.bm-lyon.fr/pressellustree/PER0012495>). Puis, à 12:31, il a effectué une action d'affichage de la page qui suit la précédente (page n°6 du fascicule n°190 du même journal, url de la page : <http://collections.bm-lyon.fr/pressellustree/PER0013376>).

⁶² Le fichier log de l'activité « Presse Illustrée » : http://collections.bm-lyon.fr/temp/users_trace.log

⁶³ L'URL complète est formée du préfixe (<http://collections.bm-lyon.fr/pressellustree>) suivi de la valeur de l'url affichée dans le tableau (e.g. /PER0012495)

Action	Ressources manipulées	
	En entrée	En sortie
Recherche par année	Année : valeur saisie Nom journal : valeur choisie.	Liste de prévisualisations de fascicules : URL liste
Recherche par numéro	Numéro fascicule : valeur saisie Nom journal : valeur choisie	Liste de miniatures de pages du fascicule : URL liste
Recherche par thème	Thème : valeur choisie	Liste de prévisualisations d'articles et d'illustrations : URL liste
Recherche par nom indexé	Type index : valeur choisie (lieu ou personne) Nom index : valeur saisie	Liste de prévisualisations d'articles : URL liste
Recherche rapide	Type recherche : valeur choisie (articles, illustrations, articles et illustrations ou tout) Equation recherche : valeur saisie	Liste de prévisualisations articles et/ou d'illustrations : URL liste Ou Liste de prévisualisations de pages : URL liste
Affichage fascicule	Miniature de fascicule : cliquable	Contenu de fascicule : URL fascicule
Compression fascicule	Contenu de fascicule (affiché) Commande « zip » : cliquable	Fichier ZIP fascicule : URI fichier
Affichage page	Miniature de page : cliquable	Contenu de page : URL page
Navigation sur la page	Contenu de page (affiché) Commande « naviguer sur page » : cliquable	Contenu de page zoomé : URL page
Affichage PDF page	Contenu de page (affiché) Commande « PDF » : cliquable	PDF de la page : URL page en PDF
Affichage article	Prévisualisation de l'article : cliquable ou Elément de sommaire de fascicule : cliquable	Contenu de l'article : URL article
Affichage TEI article	Contenu de l'article (affiché) Commande « TEI » : cliquable	TEI de l'article : URL article en TEI
Affichage page article	Contenu de l'article (affiché) Commande « voir la page » : cliquable	Contenu de la page de l'article : URL page
Impression article	Contenu de l'article (affiché) Commande « imprimer » : cliquable	
Affichage illustration	Prévisualisation de l'illustration : cliquable ou Elément de sommaire de fascicule : cliquable	Contenu de l'illustration : URL illustration
Affichage page illustration	Contenu de l'illustration (affiché) Commande « pleine page » : cliquable	Contenu de la page de l'illustration : URL page
Page suivante/précédente	Contenu de la page (affiché) Commande « page précédente » ou « page suivante » : cliquable	Contenu de la page (précédente ou suivante) : URL page
Fascicule suivant/précédent	Contenu de fascicule (affiché) Commande « numéro précédent » ou « numéro suivant » : cliquable	Contenu de fascicule (précédent ou suivant) : URL fascicule
Affichage Aide	Commande « Aide » : cliquable	Contenu page d'aide : URL page d'aide
Affichage découverte	Commande « découverte » : cliquable	Liste d'articles de synthèse : URL liste

tableau 5.1. Description des actions qui peuvent être effectuées dans le cadre de l'activité de navigation dans la « Presse Illustrée » et leurs propriétés.

- à 12:30, l'utilisateur dont l'adresse IP est 81.247.174.25 a affiché une page (page n°2 du fascicule n°37 du même journal, url de la page : <http://collections.bm-lyon.fr/presseIllustrée/PER0011787>). Puis, à 12:31, il a affiché une illustration figurant sur cette page (le titre de l'illustration est *La famille impériale de Russie*, sa date de création est le 30/08/1891 et son url est <http://collections.bm-lyon.fr/presseIllustrée/PER00110015>). L'utilisateur est revenu ensuite à la page de l'illustration par l'action <pleine page> et il a effectué l'action <page précédente> pour afficher la page précédente (page n°1 du fascicule n°37 du même journal, l'url de la page : <http://collections.bm-lyon.fr/presseIllustrée/PER0011786>). A 12:32, il a effectué l'action <PDF> pour afficher la page dans le format PDF puis il a affiché à nouveau la page en question.

L'interprétation du contenu du fichier log produit du traçage de l'activité de l'utilisateur de l'application « Presse Illustrée » permet de fournir une description de cette activité. Cependant, cette interprétation exige un savoir faire technique lié plus à l'implémentation de l'application en question, ce qui n'est pas un acquis pour tous les utilisateurs de cette application. C'est ainsi que nous considérons ce fichier log comme une trace de l'activité, mais de bas-niveau ; nous pensons également qu'une modélisation sémantique du contenu de ce fichier permettra d'aboutir à des traces de haut niveau d'abstraction (i.e. plus significatives pour les utilisateurs ordinaires qui ne sont pas des concepteurs d'applications). Nous supposons que la modélisation des traces de l'activité de navigation dans la « Presse Illustrée » se fait par le biais d'une ontologie (en OWL) que nous décrivons dans la suite.

5.2.3 La modélisation des traces de l'activité de navigation dans la « Presse Illustrée »

Dans le chapitre précédent, nous avons décrit notre approche générique de redocumentation de l'activité informatique à partir de sa trace ainsi que la spécification de cette approche pour une redocumentation en texte. Cette approche est basée sur une modélisation de la trace d'activité pour permettre une transformation semi-automatique de celle-ci via le processus de redocumentation. Le modèle que nous avons proposé pour la trace (figure 4.4) est générique dans le sens où il peut être spécialisé pour modéliser des traces d'une activité concrète telle que l'activité de navigation dans la « Presse Illustrée » que nous décrivons ci-dessus. Bien que ce modèle puisse prendre différentes formes, nous avons choisi d'implémenter le modèle de trace de l'activité de navigation dans la « Presse Illustrée » sous forme d'une ontologie (en OWL). Les ontologies offrent un mécanisme de conceptualisation et de formalisation de données, à la fois naturel et puissant. En outre, plusieurs outils sont disponibles dans le cadre du Web Sémantique pour la création et la manipulation de ces ontologies (éditeurs, raisonneurs, APIs, etc.).

5.2.3.1 L'ontologie de trace de l'activité de navigation dans la « Presse Illustrée »

L'ontologie de la trace de l'activité de navigation dans la « Presse illustrée » que nous avons développée correspond à notre modèle générique (figure 4.4) ; mais avec une spécialisation des classes *Action* et *Entité* de ce modèle. Dans cette ontologie, que nous représentons sur figure 5.5, nous distinguons les différents types d'actions qu'un utilisateur de l'application « Presse illustrée » peut effectuer et nous classons ceux-ci dans trois catégories sous la classe *Action* :

- les actions de recherche (*Search*) : la recherche par thème, par nom indexé, par année de fascicule, par numéro de fascicule, par equation de recherche et par métadonnée (nom, auteur, mot-clé, etc).
- les actions de manipulation (*Manipulate*) : la compression de fascicule, l'impression d'un article et le zom d'une page.
- les actions d'affichage (*Display*) : l'affichage par une commande (e.g. par clic sur le bouton PDF pour une page ou le bouton TEI pour un article), par un élément graphique (e.g. par clic sur une miniature de page ou une prévisualisation d'un article), par une métadonnée (e.g. par clic sur le nom d'auteur d'un article ou un mot-clé attaché à une illustration) et par une URL (e.g. pour afficher la page d'accueil ou celle d'aide de l'application)

Nous classons également les types d'entités qui peuvent être manipulées par ces actions dans une hiérarchie sous la classe *Entity* (e.g. Article, Illustration, Liste de résultats, etc.). Selon cette ontologie, une trace d'activité est caractérisée par des propriétés (un numéro et une description de l'activité informatique tracée) ; elle concerne un utilisateur particulier (caractérisé par son nom et adresse IP) et elle est composée de plusieurs éléments observés qui sont, au niveau spécifique, des actions. Chaque action est caractérisée par des propriétés (e.g. une propriété temporelle qui exprime la date et le temps de début de celle-ci) ; elle peut manipuler une ou plusieurs entités dont chacune est également caractérisée par des propriétés (e.g. l'URL de l'entité).

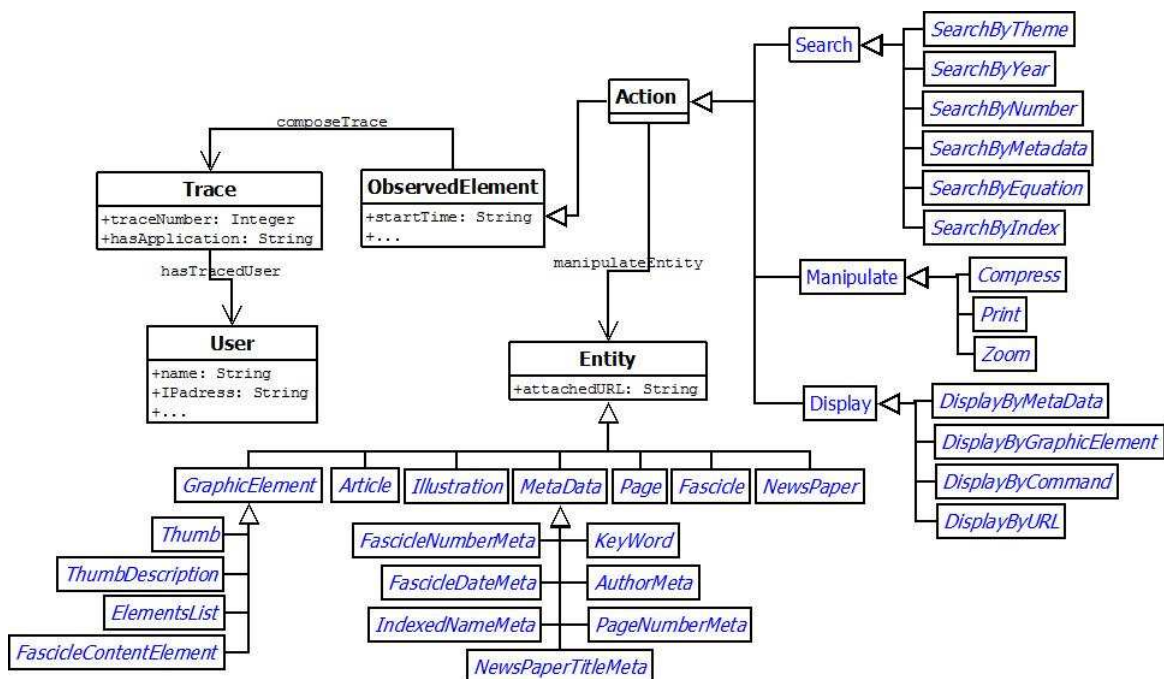


Figure 5.5. L'ontologie de trace de l'activité de navigation dans la « Presse Illustrée ».

5.2.3.2 La génération des traces modélisées de l'activité de navigation

Le modèle de trace que nous avons proposé est une ontologie qui comporte une classe *Trace* ; les traces modélisées de l'activité de navigation dans « Presse Illustrée » seront simplement des instances de cette ontologie. Nous réalisons cette instanciation via un processus de collecte qui exploite les données du fichier log, produit du traçage de l'activité,

pour créer des traces modélisées selon cette ontologie. Ce processus de collecte est *ad hoc* puisque les traces de base (dans notre cas le fichier log) peuvent différer d'une activité à une autre, de même que le modèle de la trace.

Après avoir présenté un exemple d'activité informatique à redocumenter et dont les traces sont modélisées comme une spécialisation de notre modèle générique de trace, nous pouvons maintenant décrire l'outil de redocumentation ActRedoc que nous avons développé comme implémentation de l'approche de redocumentation en texte que nous avons présentée dans le chapitre précédent.

5.3 Architecture et fonctionnement de l'outil de redocumentation en texte ActRedoc

L'outil ActRedoc que nous avons développé pour la redocumentation en texte de l'activité informatique est un outil *auteur* implémenté sous forme d'une application Java (Yahiaoui et al., 2012). Il assure, à la fois, une présentation intelligible des traces d'activité facilitant ainsi leur manipulation, et une assistance à l'utilisateur pour définir le contenu et la forme du document produit et maintenir sa cohérence. Cet outil est une implémentation de l'approche de redocumentation en texte que nous avons proposée dans le chapitre précédent (section 4.4). Il permet la manipulation d'une trace d'activité modélisée selon notre modèle de trace (figure 4.4), à travers les deux phases du processus de redocumentation, pour aboutir à un document texte final modélisé selon notre modèle de document (figure 4.5) et qui décrit l'activité tracée de façon personnalisée par l'utilisateur de cet outil.

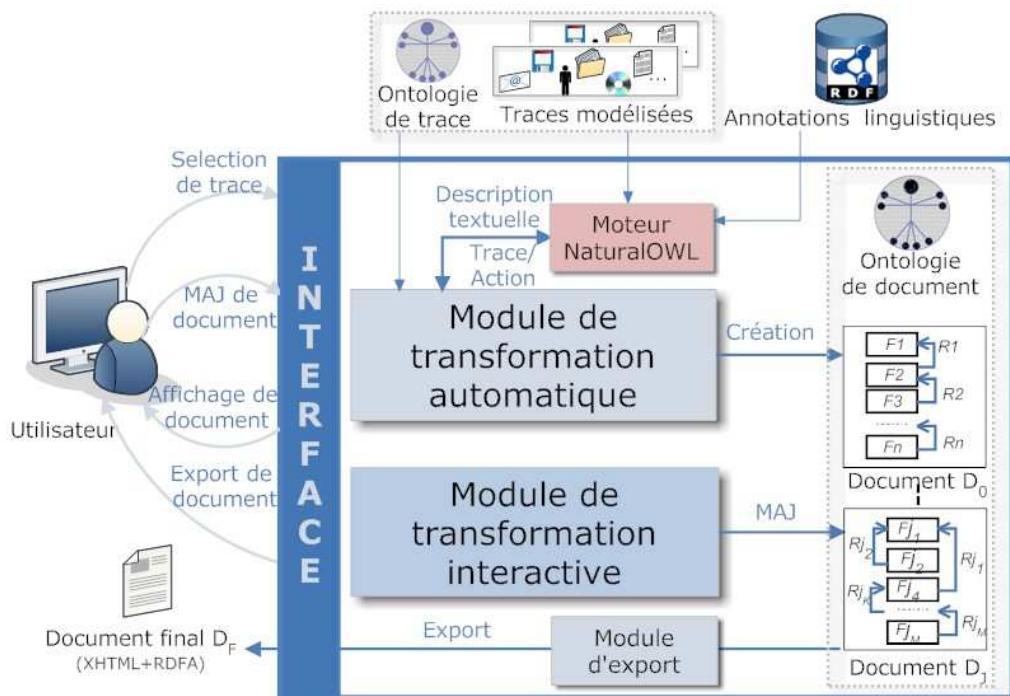


Figure 5.6. Architecture de l'outil de redocumentation en texte ActRedoc.

L'architecture de l'outil ActRedoc, représentée par la figure 5.6, est centrée autour de deux modules : le module de transformation automatique et le module de transformation interactive. Chacun de ces deux modules correspond à une phase de redocumentation de notre

cadre général (figure 4.1) et il est accessible à travers l'interface graphique de l'outil. L'entrée de l'outil ActRedoc est un ensemble de traces d'activité modélisées sémantiquement par l'ontologie de la trace d'activité (en général) dans lequel l'utilisateur peut choisir une trace particulière à redocumenter. Pour pouvoir automatiser en partie le processus de redocumentation de l'activité, le module de redocumentation automatique fait appel à l'outil de génération du langage naturel NaturalOWL (Galanis et Androutsopoulos, 2007) que nous avons décrit auparavant (section 4.4.1.1). Rappelons que NaturalOWL est un outil capable de générer des descriptions textuelles (en Anglais) à partir des éléments d'une ontologie en OWL (l'ontologie de la trace dans notre cas). Cependant, avant de pouvoir utiliser le générateur (moteur) NaturalOWL, il est nécessaire de mettre en place une annotation linguistique préalable de l'ontologie en utilisant un des modules de NaturalOWL. La sortie de l'outil ActRedoc est un document texte, modélisé sémantiquement par une ontologie de document, décrivant l'activité tracée. Ce document peut être exporté dans un format hypertexte enrichie avec des métadonnées par le biais du module d'export. Nous décrivons ci-dessous chacun des composants de l'architecture de ActRedoc en insistant sur les technologies et les bases théoriques qu'ils exploitent.

5.3.1 L'ontologie de trace

Nous supposons que le modèle de trace d'activité à redocumenter est une ontologie en OWL qui correspond à notre modèle générique de la trace d'activité (figure 4.4) ; mais avec une spécialisation des classes *Action* et *Entité* de ce modèle. Ainsi, cette modélisation dépend de l'activité à redocumenter. Pour cela, nous avons représenté un exemple de cette ontologie par la figure 5.5 pour l'activité de navigation dans la « Presse Illustrée ». Quant aux traces d'activité, elles représentent des instances de cette ontologie.

5.3.2 L'ontologie de document

L'ontologie de document (produit de la redocumentation) est une spécialisation du modèle générique de document que nous avons proposé (section 4.3.2.2). Dans le cas présent, cette ontologie ne modélise que la structure rhétorique de celui-ci. Nous avons fait ce choix car nous nous intéressons plus à la modélisation du contenu du document et à rendre explicite la cohérence d'un tel contenu ; nous pensons que des modèles prédéfinis peuvent être utilisés pour modéliser les deux autres structures du document (physique et logique).

Notre ontologie de document est inspirée en partie de l'ontologie OntoReST (Naja-Jazzar et al., 2009) qui modélise les relations de RST dans un document texte construit en collaboration et permet de détecter automatiquement les incohérences qu'il contient. OntoRest définit cinq concepts de base (figure 5.7) : *document* (un ensemble de *spans* et un ensemble de relations rhétoriques), *segment* (caractérisé par son contenu textuel), *element* (un segment ou un span), *span* (couvre des segments adjacents par une relation rhétorique et est caractérisé par une première et une dernière positions des segments qui le composent) et *RhetoricalRelation* (une relation rhétorique entre deux *spans*). L'objectif d'une telle modélisation est d'aboutir à une structure rhétorique du document sous forme d'un arbre et de pouvoir détecter les incohérences créés par les auteurs durant la manipulation du document par les opérations d'instanciations : *addSegment*, *delSegment*, *addSpan*, *delSpan*, *addRelation* et *DelRelation*. Par exemple, l'opération *addSegment* (*position*, *hasID*, *content*, *sid*) ajoute une instance de type *Segment* avec une position spécifique et un contenu textuel alors que *sid* est l'identifiant du site qui génère l'opération.

L'ontologie de document que nous proposons est plus simple que l'ontologie OntoRest puisque notre objectif est de fournir une modélisation sémantique simple de la structure

rhétorique du document manipulé par un seul utilisateur. Pour cela, notre ontologie modélise le document comme un ensemble de segments reliés par des relations rhétoriques classées en deux catégories. En outre, nous n'avons pas considéré les mêmes types de relations rhétoriques que celles utilisées par OntoReST puisque notre besoin est d'utiliser des relations rhétoriques qui peuvent être intéressantes dans le cas particulier de la description d'une activité informatique.

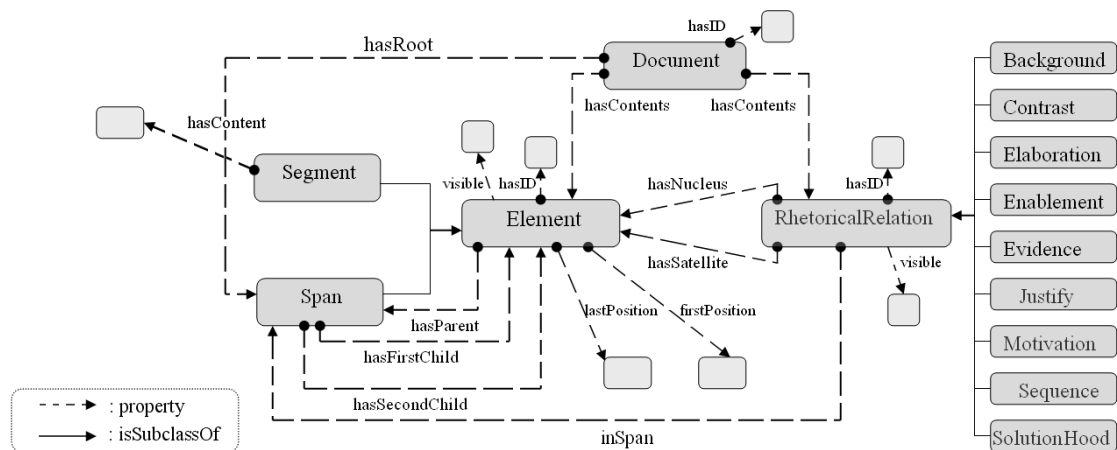


Figure 5.7. Représentation de l'ontologie OntoReST (Naja-Jazzar et al., 2009).

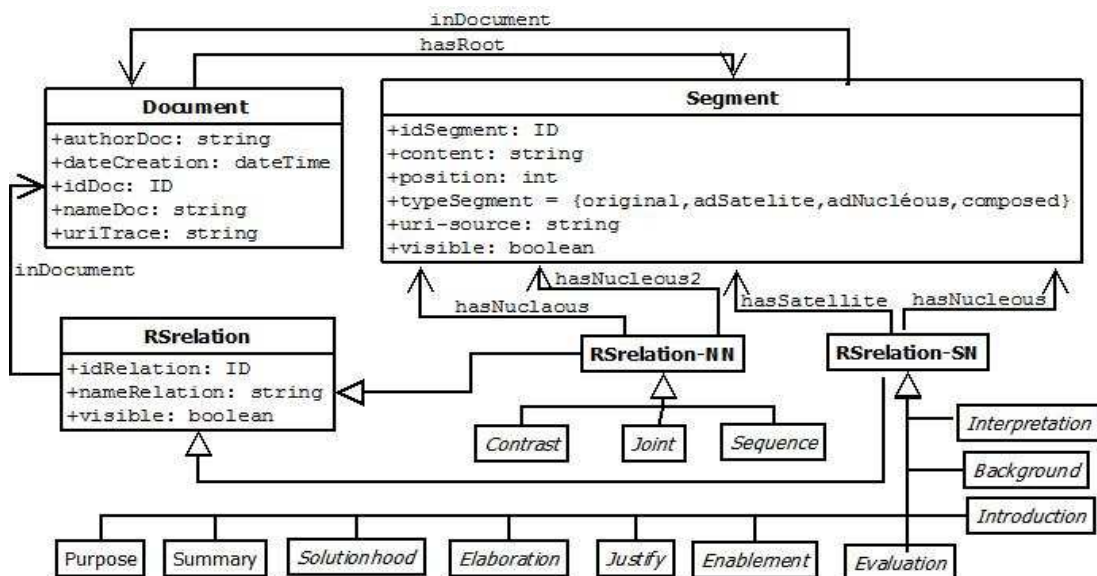


Figure 5.8. Représentation graphique de l'ontologie de document.

La figure 5.8 est une représentation graphique de notre ontologie-OWL de document dans laquelle chaque document est modélisé comme une structure rhétorique. Il a un identifiant unique et est lié à la trace qu'il décrit par la propriété *uriTrace*. Le document a un segment particulier, sa racine, auquel les autres segments du document sont liés par des relations rhétoriques de façon directe ou indirecte (par des relations rhétoriques transitives de type *Séquence*). Chaque segment appartient à un seul document et est caractérisé par des propriétés. La propriété *Uri-source* réfère l'instance de type *Trace* ou *Action* décrite par le segment ; alors que la propriété *typeSegment* indique si le segment est original (i.e. issu de la

trace), composé (par fusion de segments), ajouté ou remplacé (par l'utilisateur de l'outil ActRedoc). Chaque segment a également un contenu textuel et une position (d'ordre) dans le document qu'il compose. Quant aux relations rhétoriques entre les segments, elles sont réparties sur deux catégories : les relations rhétoriques de type noyau-à-noyau (*RSrelation-NN*) et les relations rhétoriques de type satellite-à-noyau (*RSrelation-SN*) ; l'ensemble des relations rhétoriques sont décrites dans le tableau 3.1. Toutefois, nous prenons seulement en considération dans notre ontologie de document le sous-ensemble de relations rhétoriques que nous jugeons intéressant selon notre approche de redocumentation en texte (voir section 4.3.3.2). Ce sous-ensemble inclut les relations : *Séquence*, *Contraste*, *Jonction*, *Justification*, *Elaboration*, *Arrière-plan*, *Facilitation*, *Evaluation*, *Interprétation*, *But*, *Solution*, *Introduction* et *Résumé*. La propriété *visible* qui caractérise les classes *Segment* et *RSrelation* permet d'exprimer la suppression d'un segment ou d'une relation du document (en rendant celui-ci ou celle-ci invisible) ; alors d'un document particulier n'est qu'une instance de l'ontologie de document.

5.3.3 Le module de transformation automatique

Ce module permet de transformer, de façon automatique, la trace d'activité choisie par l'utilisateur de l'outil ActRedoc (une instance de l'ontologie de trace) en un document fragmenté initial D_0 . Pour cela, il procède comme suit :

1. pour la trace choisie, il exploite l'ontologie de trace pour extraire tous les éléments observés (instances) de type *Action* qui la composent ;
2. il ordonne temporellement les actions de la trace selon leurs valeurs de propriété temporelle (*startTime*) ;
3. il invoque le moteur NaturalOWL avec l'*url* de la trace choisie pour générer une description textuelle de celle-ci ;
4. il améliore cette expression textuelle et lui ajoute un texte pour introduire le reste du document (la description des actions de la trace) ;
5. pour chacune des actions (*obsels*) de la trace choisie, il invoque le moteur NaturalOWL pour générer une description textuelle de celle-ci.
6. il améliore ces descriptions textuelles en leur appliquant automatiquement un ensemble de règles linguistiques de réécriture (e.g. éviter la répétition d'une même date dans la description de deux actions consécutives de la trace ayant la même date).

Le module de transformation automatique utilise l'ensemble des descriptions textuelles résultantes pour composer un document texte fragmenté initial D_0 , comme une instance de l'ontologie de document. Pour cela il procède comme suit :

1. il crée une nouvelle instance de type *Document* ;
2. il crée un premier segment, la racine de ce document, dont le contenu correspond à la description textuelle de la trace choisie ;
3. il crée un deuxième segment et le relie au premier par une relation rhétorique de type *Séquence*. Le contenu du nouveau segment correspond à la description textuelle de la première action de la trace ;

4. il crée un troisième segment et le relie au deuxième par une relation *Séquence*. Le contenu du nouveau segment correspond à la description textuelle de la deuxième action de la trace ;
5. et ainsi de suite, il crée un nouveau segment pour chacune des descriptions textuelles des actions de la trace et relie ces segments par des relations rhétoriques de type *Séquence* selon l'ordre temporel de ces actions.

La valeur de la propriété *typeSegment* des segments créés est *original* puisque les contenus de ces segments sont directement issus de la trace d'activité ; alors que la valeur de la propriété *position* correspond au numéro d'ordre du segment dans le document (e.g. 1 pour le premier segment qui décrit la trace, 2 pour le deuxième, *etc.*). Le document initial D_0 est ainsi composé d'une séquence de segments textuels issus de la trace d'activité choisie.

5.3.4 Le moteur NaturalOWL

Le moteur NaturalOWL est le module de l'outil NaturalOWL qui permet de générer des descriptions textuelles à partir des éléments d'une ontologie en OWL. Nous avons décrit auparavant (section 4.4.1) le principe de fonctionnement de ce générateur. Dans notre cas, ce module exploite l'ontologie de la trace, en réponse à son invocation par le module de transformation automatique, pour générer des descriptions textuelles (en anglais) pour la trace choisie et pour chacune de ses actions (qui sont des instances de l'ontologie de trace). Cependant, nous avons également expliqué que ce module a besoin d'un ensemble d'annotations linguistiques de l'ontologie, sous forme de trois fichiers en RDF, pour pouvoir générer des textes à partir des instances de celle-ci. Ces annotations sont à préparer, au préalable, par le concepteur de l'ontologie de trace. Nous décrivons dans la section qui suit comment nous avons annoté linguistiquement l'ontologie-OWL de trace de l'activité de navigation dans la « Presse illustrée » (figure 5.5) en utilisant le module d'annotation de l'outil NaturalOWL⁶⁴ ; nous décrivons également les trois fichiers de métadonnées (en RDF) produits qui correspondent à trois niveaux différents: le niveau lexical de l'ontologie, le niveau micro-plans de l'ontologie et le niveau préférences concernant des paramètres de la génération des descriptions textuelles par NaturalOWL.

Toutefois, ce qui est important à retenir à ce stade, c'est que l'invocation du moteur NaturalOWL se fait par deux paramètres : l'url de l'instance de l'ontologie à décrire et *la distance d'inférence* qui fixe au moteur NaturalOWL une limite dans son parcours du graphe des instances de l'ontologie de trace lors de la génération de la description textuelle d'une instance particulière. Dans la section qui suit, nous montrons à travers un exemple concret comment le moteur NaturalOWL exploite l'ontologie de trace de l'activité de navigation dans la « Presse illustrée » et les fichiers d'annotations linguistiques sous-jacents pour générer la description textuelle d'une instance particulière de cette ontologie.

5.3.5 Le module de transformation interactive

Ce module permet à l'utilisateur d'appliquer, de façon itérative, des opérations de transformation sur le document initial (D_0) pour obtenir un document intermédiaire (D_j) après chaque itération ; ceci jusqu'à ce que l'utilisateur soit satisfait du document produit et puisse exporter ce dernier comme un document final. Le document manipulé (D_j) par l'utilisateur lui est représenté comme une suite de segments textuels parmi lesquels il est possible de choisir

⁶⁴. Le module d'annotation de NaturalOWL s'intègre comme un plugin dans notre éditeur d'ontologies Protégé-owl (<http://protege.stanford.edu/overview/protege-owl.html>)

un (plusieurs) segment(s) pour lui (leur) appliquer une opération particulière. Les opérations de transformations supportées par le module de transformation interactive sont accessibles via l'interface de l'outil ActRedoc et peuvent être rhétoriques ou organisationnelles. Elles correspondent aux opérations que nous avons définies pour notre approche de redocumentation en texte et que nous avons décrites dans le tableau 4.1. Le tableau 5.2 décrit ces opérations telles qu'elles sont identifiées via l'interface de notre outil de redocumentation ActRedoc. Pour comprendre le principe des opérations rhétoriques, il est utile de comprendre la signification des relations rhétoriques utilisées par ces opérations (puisque chaque opération rhétorique permet de créer un nouveau segment avec une nouvelle relation rhétorique de type particulier ; la signification de chacun des types des relations rhétoriques est fournie par le tableau 3.1). Suite à l'application de chaque opération de transformation sur le document manipulé, le module de transformation interactive met à jour l'instance de type *Document* concernée dans l'ontologie de document.

	Opération	Description
Rhétorique	Add segment	<p>Ajoute un nouveau segment textuel au document avec une relation rhétorique de type noyau-à-noyau.</p> <ul style="list-style-type: none"> - Le type spécifique de la relation rhétorique à créer est à choisir par l'utilisateur parmi : <i>Joint</i>, <i>Contrast</i> et <i>Sequence</i>. - Le segment créé est de type (<i>adNucleous</i>) et son contenu est à saisir par l'utilisateur - Le nouveau segment est relié au segment (du document) choisi par l'utilisateur avec la nouvelle relation rhétorique créée.
	Explain segment	<p>Ajoute un nouveau segment textuel au document avec une relation rhétorique de type satellite-à-noyau.</p> <ul style="list-style-type: none"> - Le type spécifique de la relation rhétorique à créer est à choisir par l'utilisateur parmi : <i>Justify</i>, <i>Elaboration</i>, <i>Enablement</i>, <i>Solutionhood</i>, <i>purpose</i>, <i>Background</i>, <i>Evaluation</i>, <i>Interpretation</i>, <i>Summary</i>, <i>Introduction</i>. - Le segment créé est de type (<i>adSatelite</i>) et son contenu est à saisir par l'utilisateur. - Le nouveau segment est lié au segment (du document) choisi par l'utilisateur avec la nouvelle relation rhétorique créée.
Organisationnelle	Delete segment	<p>Supprime un segment du document</p> <ul style="list-style-type: none"> - Le segment à supprimer est rendu invisible (propriété <i>visible=false</i>) - Si le segment à supprimer est la racine du document alors c'est le segment relié à ce segment par une relation rhétorique de type <i>Sequence</i> qui devient racine. - Les relations existantes entre le segment à supprimer et d'autres segments du document sont mises à jour (cas des relations de type <i>Sequence</i>) ou supprimées (cas du reste des relations).
	Replace segment	<p>Remplace le contenu d'un segment existant avec un nouveau texte</p> <ul style="list-style-type: none"> - Le nouveau texte est à saisir par l'utilisateur.
	Reorder segments	<p>Déplace un segment (1) du document par rapport à un autre segment (2)</p> <ul style="list-style-type: none"> - L'utilisateur peut choisir une possibilité parmi : placer le segment (2) avant le segment (1) ou après le segment (1), placer le segment (1) avant le segment (2) ou après le segment (2). - Les relations de type <i>Sequence</i> qui concernent les deux segments à déplacer sont mises à jour.
	Merge segments	<p>Fusionne les contenus de segments consécutifs (reliés par une relations de type <i>Sequence</i>) dans le document</p> <ul style="list-style-type: none"> - Le segment créé est de type (<i>composed</i>) ; son contenu textuel est la concaténation des contenus textuels des segments que l'utilisateur a choisis pour les fusionner. - Si l'un des segments choisis est la racine du document alors le nouveau segment sera la nouvelle racine. - Les relations qui concernent les segments fusionnés sont supprimées ou mises à jour pour concerner le nouveau segment.

Tableau 5.2. Description de l'ensemble des opérations supportées par le module de transformation interactive de l'outil de redocumentation ActRedoc.

Lors de l'application d'une opération rhétorique par l'utilisateur (*Add segment* ou *Explain segment*), le module de transformation interactive lui permet de choisir (dans une liste) une expression textuelle qui correspond à la nouvelle relation rhétorique à créer. Le tableau 5.3 présente les différentes expressions proposées par le module de redocumentation interactive lors de la création d'une nouvelle relation rhétorique par l'utilisateur. Par exemple, si l'utilisateur applique l'opération *Explain segment* sur un segment du document et choisit *Evaluation* comme type de relation rhétorique à créer ; alors le module de redocumentation interactive lui propose de faire un choix dans une liste d'expressions textuelles telle que : {« *Therefore* », « *So* », *etc*}. Le but est que ce module soit capable d'exprimer automatiquement cette relation rhétorique par du texte au moment de la présentation du document produit (*preview*). En effet, le module de transformation interactive permet à l'utilisateur de visualiser à tout moment le document intermédiaire produit des transformations appliquées dans une forme textuelle simple (un document en HTML). Pour l'exemple de la relation rhétorique de type *Evaluation*, l'expression choisie par l'utilisateur (e.g. « *Therefore* ») sera placée entre le contenu textuel du segment choisi par l'utilisateur (segment cible de la relation) et celui du segment ajouté par l'utilisateur (segment fournissant l'information de l'évaluation). Ainsi, les contenus des segments du document fragmenté manipulé par l'utilisateur seront placés comme une suite de textes, en fonction des relations existantes entre ces segments et des expressions choisies par l'utilisateur pour ces différentes relations.

Relation	Expression dans le document affiché (→ : suivi de)
<i>Sequence</i> (séquence)	Texte du segment cible (de la relation) → texte du segment source.
<i>Contrast</i> (contraste)	Texte du segment cible → « <i>Contrary to that</i> » → texte du segment source.
<i>Joint</i> (jonction)	Texte du segment cible → « <i>And</i> » → texte du segment source.
<i>Justify</i> (justification)	Texte du segment cible → « <i>The reason is that</i> » ou « <i>that is because</i> » → texte du segment source.
<i>Elaboration</i> (élaboration)	Texte du segment cible → « <i>Moreover</i> » → texte du segment source.
<i>Background</i> (arrière-plan)	Texte du segment cible → « <i>Notice that</i> » → texte du segment source.
<i>Enablement</i> (facilitation)	Texte du segment cible → « <i>To do that</i> » → texte du segment source.
<i>Evaluation</i> (évaluation)	Texte du segment cible → « <i>Therefore</i> » ou « <i>So</i> » → texte du segment source.
<i>Interpretation</i> (interprétation)	Texte du segment cible → « <i>This means that</i> » → texte du segment source.
<i>Introduction</i> (introduction)	« <i>Introduction:</i> » → texte du segment source → texte du segment cible (ou le contenu du document si c'est tout le document en entier qui est introduit).
<i>Purpose</i> (but)	Texte du segment cible → « <i>The purpose is that</i> » → texte du segment source.
<i>Summary</i> (résumé)	Texte du segment cible (ou le contenu du document en entier si c'est tout le document qui est résumé) → « <i>Summary:</i> » → texte du segment source.
<i>Solutionhood</i> (solution)	Texte du segment cible → « <i>This was a solution for the case</i> » → texte du segment source.

Tableau 5.3. Expression des relations rhétoriques contenues dans le document pour la présentation de celui-ci comme un texte.

Le module de redocumentation interactive utilise un modèle logique et un modèle physique prédéfinis simples pour la présentation du document manipulé. Le modèle logique consiste en un titre du document et une suite de paragraphes. Le titre du document est demandé à l'utilisateur lors de la première demande de visualisation du document (*preview*) ; alors que chaque paragraphe correspond à un segment principal du document avec tous les segments qui lui sont reliés par une relation rhétorique autre que celle de type *Sequence* (un segment principal est un segment source ou cible d'une relation rhétorique de type *Sequence*). Le contenu du paragraphe sera ainsi constitué du contenu textuel du segment principal, de ceux des segments qui lui sont reliés et des expressions textuelles de ces relations ; quant à la disposition des paragraphes les uns à la suite des autres dans le document affiché, elle correspond aux relations rhétoriques de type *Sequence* entre les segments principaux décrits par ces paragraphes. Le modèle physique du document est une feuille de style qui attribut les mêmes propriétés visuelles aux paragraphes du document et qui met en évidence (par des attributs différents) le titre du document et les URLs que celui-ci peut comporter.

5.3.6 Le module d'export

Le module d'export de notre outil de redocumentation ActRedoc permet à l'utilisateur, une fois satisfait du document intermédiaire (D_j), d'exporter ce document fragmenté comme un document final (D_F) dans une forme hypertexte enrichie avec des métadonnées. En plus des métadonnées ajoutées explicitement par l'utilisateur (titre, date et auteur) et qui sont incorporées automatiquement dans l'entête du document, des métadonnées sont ajoutées automatiquement au document pour décrire son contenu et sa structure en utilisant RDFa⁶⁵ (Adida and Birbeck, 2008).

En effet, dans le cadre du Web Sémantique, l'ajout de contenu sémantique aux documents Web sous forme de métadonnées se fait souvent à l'aide d'ontologies et d'une technique d'annotation. Cependant, lorsque ces métadonnées font leur apparition sur le Web, elles sont typiquement distribuées dans un fichier séparé du document auquel elles sont rattachées, avec un format séparé (souvent du RDF) et une correspondance très limitée entre les deux. Ainsi, les navigateurs Web ne peuvent fournir qu'une aide minimale aux humains pour l'analyse et le traitement des documents web. Pour surmonter cette limite, RDFa a été proposé comme une nouvelle recommandation du W3C pour embarquer des métadonnées (en RDF) décrivant les documents Web (en XHTML) dans le niveau expression d'attributs de ceux-ci. L'objectif est de rendre les documents Web exploitables, à la fois, par des humains et par la machine (navigateurs, programmes d'interprétation, *etc.*). La syntaxe de RDFa utilise un nombre d'attributs déjà existants tels que : « *rel* » ou « *rev* » pour définir une relation ou une relation inverse entre deux ressources, « *content* » pour définir une chaîne de caractère comme contenu d'un prédicat et « *href* » et « *src* » pour exprimer l'URI d'une ressource dans une relation. Mais cette syntaxe rajoute de nouveaux attributs tels que : « *about* » pour décrire le sujet dans une relation, « *property* » pour décrire la relation entre un sujet et un texte, « *resource* » pour décrire l'objet d'une relation et « *typeof* » pour indiquer le type RDF à associer au sujet d'une relation). Elle introduit également la notion de « *CURIEs* » qui désigne des URIs compactes. Pour plus de détail sur la syntaxe de RDFa et son utilisation concrète, on peut consulter (Pemberton, 2009).

Le contenu du document final produit par le module d'export de l'outil ActRedoc est représenté par la figure 5.9. Dans ce document, les données exploitables par les humains

⁶⁵ RDFa : Resource Description Framework in Attributes

représentent le texte de ce document. Le module d'export forme ce texte à partir des contenus des segments et des expressions des relations rhétoriques qui constituent le document fragmenté (D_j) exporté (ceci de la même façon que nous avons expliqué auparavant pour le module de transformation interactive lors de la visualisation d'un document intermédiaire comme un document texte). Ces segments et relations sont à la base des instances de l'ontologie de document ; alors que certains segments (ceux issus de la trace et dont la propriété *uri-source* est renseignée) peuvent référencer des instances de l'ontologie de trace (une instance de type *Trace* ou *Action*). Le module d'export annote ainsi le texte du document final avec des indicateurs faisant référence aux éléments de l'ontologie de document (référéncée par *docOnt*) et de celle de la trace (référéncée par *traceOnt*) en utilisant la syntaxe RDFa. Par exemple, sur la figure 5.9, le premier paragraphe du document final est annoté comme étant le contenu de l'instance *Seg1* de la classe *Segment* de l'ontologie de document (*seg1.content*), tout en gardant le lien (s'il existe) avec l'instance *trace* ou *action* de l'ontologie de la trace décrite par ce segment (*rel="docOnt:uri-source" href=(Seg1.uri-source)*). Le deuxième paragraphe du document est annoté de la même façon mais pour l'instance *Seg2*. Puis la relation rhétorique *rell* qui existe entre les deux segments est exprimée sous forme de métadonnées qui décrivent le type de cette relation rhétorique (*docOnt:Sequence*), son segment noyau (*docOnt:hasNucleous*), etc.

Le format hypertexte enrichi avec des métadonnées (XHTML+RDFa) pour le document final permet ainsi de garder, à l'intérieur des documents produits de la redocumentation des traces d'activité, des liens vers ces traces. Il est alors possible de trouver les documents qui décrivent la même trace ou la même activité ou des traces d'un même utilisateur, etc. En outre, le fait de pouvoir garder dans le document produit des liens avec les éléments de l'ontologie de document (segments et relations rhétoriques) permet d'interroger sémantiquement ce contenu pour analyser les pratiques de redocumentation des utilisateurs (e.g. pour trouver les différentes expressions textuelles exprimant un type particulier de relations tel que *Contraste* ou *évaluation*) et il est également possible d'appliquer des traitements automatiques sur ce document.

<pre> <?xml version="1.0"?> <!DOCTYPE html PUBLIC "-//W3C//DTD XHTML+RDFa 1.0//EN" "http://www.w3.org/MarkUp/DTD/xhtml-rdfa-1.dtd"> <html xmlns="http://www.w3.org/1999/xhtml" xml:lang="en" xmlns:traceOnt= http://www.owl-ontologies.com/Ontology1206542235.owl# " xmlns:docOnt="http://www.owl-ontologies.com/Ontology1251460419.owl# " <body> ... <div about= "#seg1" typeof= "docOnt:Segement" < p property="docOnt:content" rel="docOnt:uri-source" href=(seg1.uri-source)> (seg1.content) </p> </div> <div about= "#seg2" typeof= "docOnt:Segment" < p property="docOnt:content" rel="docOnt:uri-source" href=(seg2.uri-source)> (seg2.content) </p> </div> ... <div about= "#seg1" <span rev="docOnt:hasNucleous" href= "# rel1" ... </body> </html </pre>	<p>Références des ontologies de Trace et de Document</p> <p>Annotations du 1er paragraphe du document</p> <p>1er paragraphe du document</p> <p>Annotations du 2ème paragraphe du document (contenu de seg2)</p> <p>2ème paragraphe du document</p> <p>métadonnées pour décrire une relation de seg2 vers seg1</p>
--	---

Figure 5.9. Vue du contenu du document final exporté (XHTML+RDFa).

Nous supposons que le module d'export utilise un gabarit prédéfini (en XML) pour la structure logique du document, ainsi qu'une feuille de style prédéfinie pour la structure physique du document. Ce choix est fait pour des raisons de simplicité ; mais ces modèles peuvent être paramétrés pour supporter les choix de l'utilisateur dans la mise en forme du document final (choix des couleurs, de la police, etc.). Ainsi, le module d'export procède de la même façon que le module de redocumentation interactive lors de la présentation (visualisation) d'un document intermédiaire comme un document hypertexte puisque les métadonnées contenu dans le document final ne seront pas visualisées pour l'utilisateur.

5.3.7 L'interface de l'outil ActRedoc

L'interface de l'outil ActRedoc permet à l'utilisateur, dans un premier temps, de choisir (dans une liste) une trace d'activité à redocumenter. Le choix d'une trace particulière entraîne l'invocation du module de transformation automatique pour produire un document initial (D₀). Alors l'interface principale de l'outil ActRedoc, représenté par la figure 5.10 s'affiche ; elle est composée de trois panneaux. Le panneau de droite permet l'accès aux opérations de transformation supportées par le module de transformation interactive ; il comporte également une zone d'aide sur l'utilisation de ces opérations. Le panneau central affiche les segments textuels du document manipulé (D_j) ; la couleur de contour de chaque segment renseigne sur son type (e.g noir pour un segment original issu de la trace, bleu pour un segment composé, etc.) et une bulle contextuelle d'informations permet d'afficher les autres propriétés du segment (sa position et ses relations rhétoriques avec d'autres segments du document). Le panneau de gauche affiche le document intermédiaire dans une forme hypertexte. Nous décrivons dans la section qui suit le contenu de cette interface de façon plus détaillée à travers un exemple d'utilisation concrète de l'outil de redocumentation ActRedoc.

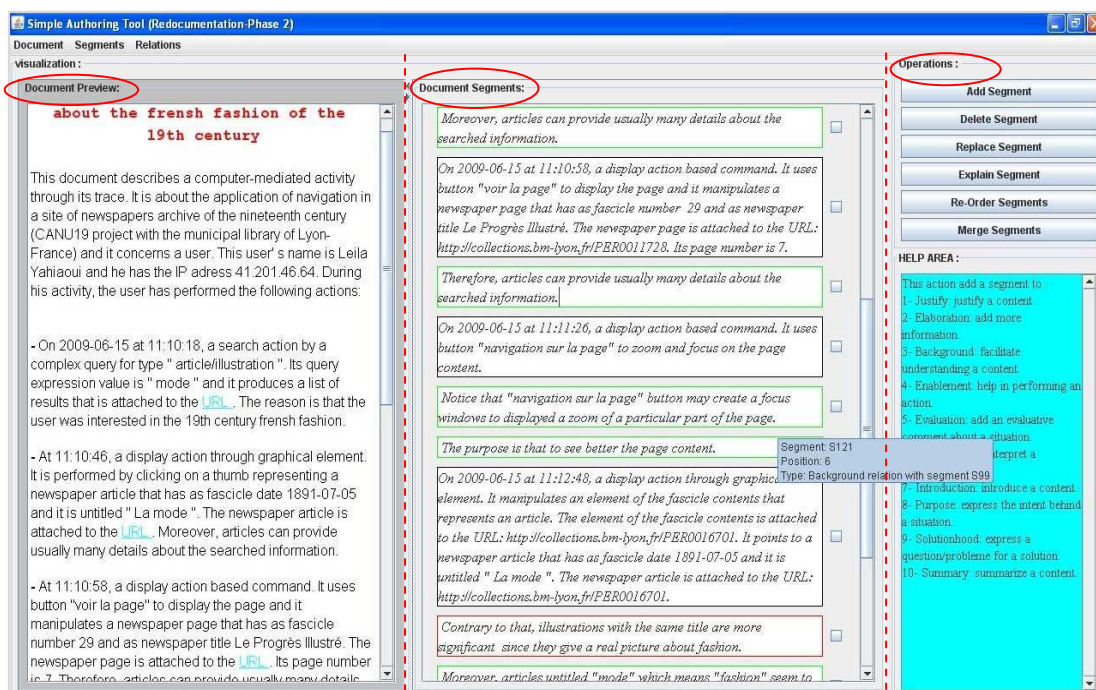


Figure 5.10. Interface de l'outil de redocumentation ActRedoc.

5.4 Un exemple d'utilisation de ActRedoc pour la redocumentation de l'activité « Presse Illustrée »

Après avoir décrit les différents composants de l'outil de redocumentation en texte ActRedoc, nous pouvons ici préciser le rôle de chacun de ces composants lors de l'application du processus de redocumentation sur une trace d'activité particulière. Il s'agit de l'activité de navigation dans la « Presse Illustrée » que nous avons décrite auparavant (section 5.2) et dont l'ontologie de trace est représentée par la figure 5.5. Un test en groupe visant à réaliser cette activité par un groupe d'utilisateurs nous a permis de récupérer un fichier log (figure 5.4) qui décrit les traces de bases de l'activité en question. Nous avons modélisé par la suite ces traces de base en utilisant l'ontologie de trace afin d'aboutir à des traces d'activité plus significatives sur le plan sémantique. Cependant, avant de pouvoir appliquer le processus de redocumentation sur une trace de celles-ci via notre outil ActRedoc, il est indispensable de fournir à celui-ci les annotations linguistiques de l'ontologie de trace qui permettront le fonctionnement du moteur NaturalOWL. Ainsi, nous commençons par décrire la procédure d'annotation linguistique de l'ontologie de trace de navigation dans la « Presse Illustrée » bien qu'elle ne fasse pas partie du processus de redocumentation en lui-même.

5.4.1 L'annotation linguistique de l'ontologie de trace

Nous avons réalisé la procédure d'annotation de l'ontologie de trace de l'activité de navigation dans la « Presse Illustrée », qui est une ontologie en OWL, en utilisant le module d'annotation de l'outil NaturalOWL qui s'intègre dans l'éditeur d'ontologie Protégé. Nous avons expliqué que cette annotation se fait à trois niveaux (le niveau lexical, le niveau micro-plans et le niveau préférences) et qu'elle permet de produire trois fichiers de métadonnées (en RDF) correspondants à ces niveaux. Ces fichiers seront exploités par la suite par le moteur Natural pour générer des descriptions textuelles (en anglais) à partir des éléments de l'ontologie annotées. Toutefois, nous tenons à préciser que nous avons réalisé cette annotation une seule fois et en tant que concepteur de l'ontologie de trace.

5.4.1.1 Annotation du niveau lexical

Au niveau lexical, l'annotation linguistique de l'ontologie consiste à exprimer le genre et le nombre des classes (et des instances) de celle-ci. La figure 5.11 représente l'interface d'annotation linguistique de NaturalOWL pour ce niveau dans l'éditeur d'ontologies Protégé. L'exemple affiché concerne l'annotation de la classe *SearchByEquation* ; une sous-classe de *Action* dans l'ontologie de trace. L'expression des instances de cette classe au singulier est « *search action by a complex query* », qui donne au pluriel « *search actions by complex queries* » ; elles sont de genre *neutre* et *comptable*. La figure 5.12 représente un extrait du fichier (RDF) de métadonnées généré pour le niveau lexical de l'ontologie.



Figure 5.11. L'interface d'annotation de NaturalOWL au niveau lexical de l'ontologie (de trace de l'activité de navigation dans la « Presse Illustrée »).


```

- <owl:Lexicon>
- <owl:NPList rdf:parseType="Collection">
- <owl:NP rdf:ID="SearchByEquation-NP">
- <owl:LanguagesNP rdf:parseType="Collection">
+ <owl:GreekNP></owl:GreekNP>
- <owl:EnglishNP>
  <owl:countable>true</owl:countable>
  <owl:num>singular</owl:num>
  <owl:gender>nonpersonal</owl:gender>
  <owl:singular>search action by a complex query</owl:singular>
  <owl:plural>search actions by complex queries</owl:plural>
</owl:EnglishNP>
</owl:LanguagesNP>
</owl:NP>
+ <owl:NP rdf:ID="DisplayByUrl-NP"></owl:NP>

```

Figure 5.12. Un extrait du fichier RDF des annotations du niveau lexical de l'ontologie (de trace de l'activité de navigation « Presse Illustrée »).

5.4.1.2 Annotation du niveau micro-plans

Au niveau micro-plans, l'annotation linguistique de l'ontologie concerne l'expression des propriétés de ses classes et des relations entre celles-ci selon des modèles (*templates*). Par exemple, pour la relation *composeTrace* qui existe entre les classes *Action* et *Trace* de l'ontologie de trace de l'activité de navigation dans la « Presse Illustrée », nous avons choisi d'exprimer cette relation selon le modèle représenté par la figure 5.13. Ce modèle est composé de quatre parties (*Slots*) qui seront utilisées et remplacées par le moteur NaturalOWL : la première indique à ce moteur qu'il faut commencer la description de la relation par un pronom nominatif qui réfère l'instance source de la relation, la deuxième indique le verbe à utiliser pour exprimer la relation (*belong*) ainsi que le temps et la voix de sa conjugaison (*belongs* au singulier, *belong* au pluriel et la voix active), la troisième indique qu'il faut utiliser une préposition (*to*) et la quatrième partie est une simple chaîne de caractères qui complète à description de la relation. Ainsi, le moteur NaturalOWL peut produire une phrase pour décrire une relation ou une propriété.

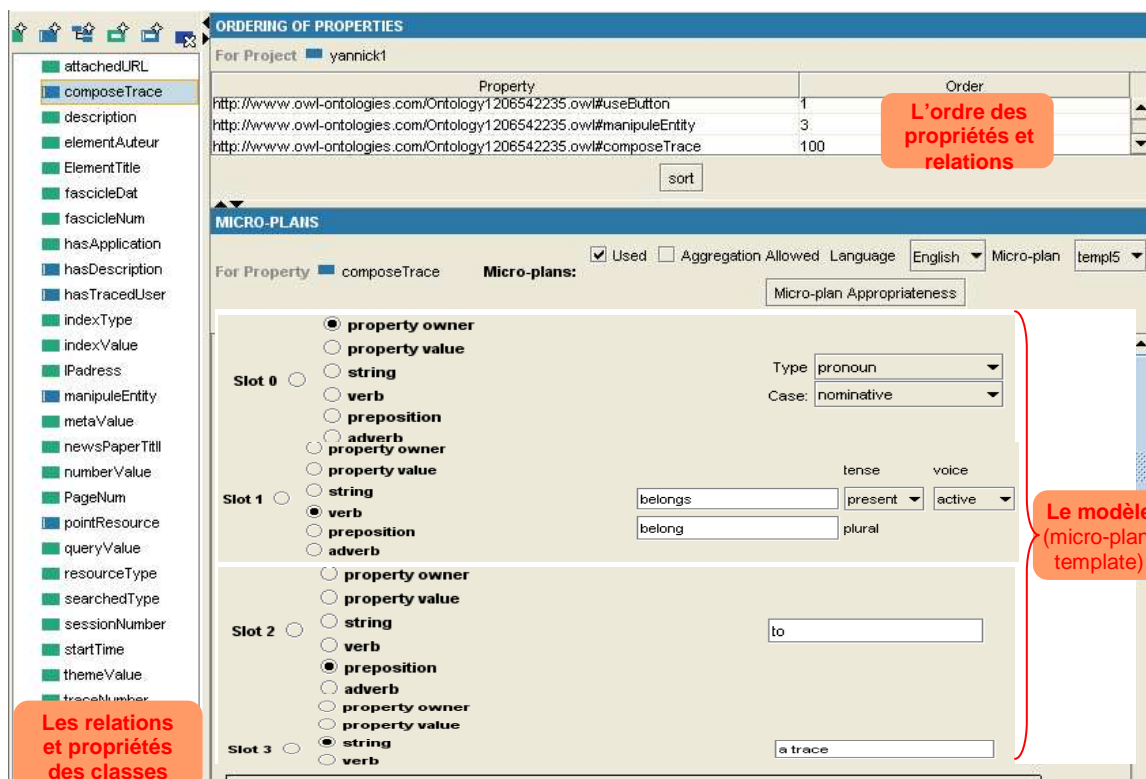


Figure 5.13. L'interface d'annotation de NaturalOWL au niveau micro-plans de l'ontologie (de trace de l'activité de navigation dans la « Presse Illustrée »).

Nous pouvons également indiquer au moteur NaturalOWL de ne pas utiliser un micro-plan (*used*), d'agréger l'expression d'une relation/propriété avec celles d'autres propriétés/rerelations pour former des phrases plus longues (*Aggregation allowed*) ou de l'utiliser dans des comparaisons (*property is used for comparaison*). De plus, à chacune des propriétés et relations de l'ontologie, nous avons assigné une priorité que le moteur NaturalOWL va utiliser pour ordonner les descriptions des différentes propriétés et relations d'une même instance (de l'ontologie) dans la description globale de celle-ci. Par exemple, nous avons choisi d'attribuer à la propriété *startTime* de la classe *Action* la priorité d'ordre la plus forte (*ordre=1*), à la relation *composeTrace* la priorité la plus faible (*ordre=100*) et à la relation *manipuleEntity* une priorité intermédiaire (*ordre=3*). Lorsque NaturalOWL est invoqué pour décrire une instance de type *Action*, il décrit la classe de l'instance puis les propriétés et les relations de celle-ci dans l'ordre indiqué. La figure 5.14 représente un extrait du fichier (rdf) de métadonnées généré pour le niveau micro-plans de l'ontologie.

```

<owl:MicroplansAndOrdering>
  <owl:Properties rdf:parseType="Collection">
    <owl:Property rdf:about="http://www.owl-ontologies.com/Ontology1206542235.owl#composeTrace"> ← Relation à exprimer
      <owl:Order>100</owl:Order> <owl:UsedForComparisons>false</owl:UsedForComparisons>
      <owl:EnglishMicroplans rdf:parseType="Collection">
        <owl:Microplan rdf:about="http://www.owl-ontologies.com/Ontology1206542235.owl#composeTrace-templ5-en">
          <owl:MicroplanName>templ5</owl:MicroplanName> <owl:Used>true</owl:Used> <owl:AggrAllowed>false</owl:AggrAllowed>
          <owl:Slots rdf:parseType="Collection">
            <owl:Owner> <owl:case>nominative</owl:case> <owl:RETYPE>RE_PRONOUN</owl:RETYPE> </owl:Owner>
            <owl:Verb>
              <owl:voice>active</owl:voice>
              <owl:tense>present</owl:tense>
              <owl:Val xml:lang="en">belongs</owl:Val> <owl:pluralVal xml:lang="en">belong</owl:pluralVal>
            </owl:Verb>
            <owl:Prep> <owl:Val xml:lang="en">to</owl:Val> </owl:Prep>
            <owl:Text> <owl:Val xml:lang="en">a trace</owl:Val> </owl:Text>
          </owl:Slots>
        </owl:Microplan>
      </owl:EnglishMicroplans>
    </owl:Property>
    <owl:Property rdf:about="http://www.owl-ontologies.com/Ontology1206542235.owl#useButton">

```

Figure 5.14. Un extrait du fichier RDF des annotations du niveau micro-plans de l'ontologie (de trace de l'activité de navigation dans la « Presse Illustrée »).

5.4.1.3 Annotation du niveau préférences

Au niveau préférences, l'annotation linguistique consiste à préciser des paramètres qui influencent directement le processus de génération des descriptions textuelles du moteur NaturalOWL tels que la *langue* à utiliser, la profondeur des inférences (*la distance d'inférence*) dans la description des instances, le nombre maximum de propriétés et/ou relations à exprimer par phrase générée (nombre max de faits par phrase) et le nombre maximum de relations et/ou propriétés à exprimer par page de texte. Bien que NaturalOWL permette de créer des modèles utilisateur à partir de ces paramètres, nous avons supposé l'utilisation d'un seul modèle utilisateur par défaut. Dans ce modèle, nous avons fixé la langue à *anglais*, le nombre maximum de faits par phrase à quatre et le nombre maximum de phrases par page à 34. Ces données sont sauvegardées dans un fichier RDF qui comporte les annotations linguistiques du niveau préférences (ou modélisation de l'utilisateur) ; quant à la *distance d'inférence*, elle est communiquée au moteur NaturalOWL au moment de son invocation.

5.4.2 La redocumentation d'une trace d'activité via ActRedoc

L'outil de redocumentation ActRedoc permet à l'utilisateur de choisir graphiquement une trace particulière de l'activité à redocumenter comme donnée d'entrée. Le processus de redocumentation supporté par cet outil est caractérisé par deux phases : une phase de redocumentation automatique (supportée par le module de transformation automatique) et une phase de redocumentation interactive (supportée par le module de transformation interactive) Il permet de produire un document texte fragmenté modélisé par l'ontologie de document (figure 5.8) ; qui peut être visualisé à tout moment (comme document hypertexte) ou exporté (par le module d'export) comme un document final (hypertexte enrichi avec des métadonnées). Nous décrivons, ci-dessous en détail toutes les étapes du processus de redocumentation ainsi que les produits de chacune de celles-ci.

5.4.2.1 Choix de la trace à redocumenter

Lors du lancement de l'application ActRedoc, qui correspond à notre outil de redocumentation, il est demandé à l'utilisateur de choisir une trace particulière dans une liste de traces de l'activité à redocumenter. Dans notre cas, nous avons configuré l'outil pour que cette liste de choix (figure 5.15) comporte les identifiants de toutes traces décrites par notre ontologie de trace de l'activité de navigation dans la « Presse Illustrée »⁶⁶. Nous supposons que l'utilisateur a choisi une trace (*trace_5*) par exemple ; alors à travers l'ontologie de trace, il est possible de récupérer toutes les données concernant cette trace (les informations sur l'utilisateur tracé, les actions composant la trace ainsi que les entités qu'elles manipules). La figure 5.16 est une représentation graphique de la composition de la trace choisie (*trace_5*) comme une suite d'actions positionnées sur une ligne de temps (en fonction des valeurs de la propriété *startTime* de ces actions).



Figure 5.15. Fenêtre de choix de la trace à redocumenter dans l'interface de ActRedoc.

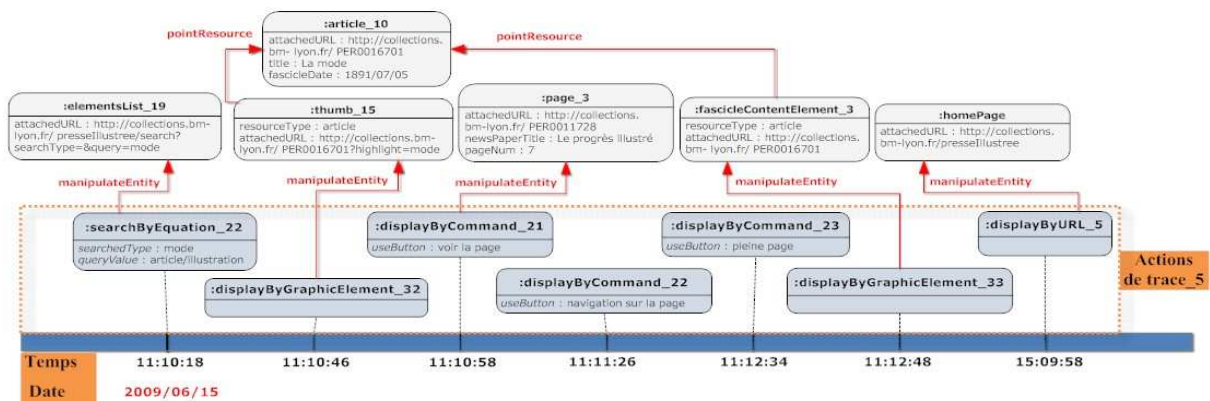


Figure 5.16. Représentation des actions (*obsels*) de la trace choisie (*trace_5*) sur une ligne de temps.

⁶⁶ Pour redocumenter d'autres activités en utilisant ActRedoc, il est nécessaire de fournir à cet outil, à chaque fois, l'ontologie de trace de l'activité à redocumenter (qui doit correspondre à notre modèle de trace) et les fichiers d'annotations linguistiques de cette ontologie.

5.4.2.2 Transformation automatique de la trace en un document initial

Le choix d'une trace d'activité particulière déclenche la phase de redocumentation automatique dans l'outil ActRedoc. Le module de transformation automatique procède à une invocation récursive du moteur NaturalOWL pour générer des descriptions textuelles (en anglais) de la trace choisie (en tant qu'instance de l'ontologie de trace) et de chacune des actions (instances) composant cette trace.

La génération de la description textuelle d'une instance par le moteur NaturalOWL. Dans notre outil de redocumentation ActRedoc, le moteur NaturalOWL est à invoquer par deux paramètres : le premier est l'*url* de l'instance de l'ontologie de trace à décrire et le deuxième est la *distance d'inférence* à utiliser. Nous avons expliqué auparavant que ce moteur dispose des trois fichiers d'annotations linguistiques préparés au préalable (que nous avons décrits ci-dessus) ; alors il exploite ces fichiers de métadonnées et l'ontologie de trace pour produire une description textuelle de l'instance concernée et qui peut être de type *Trace* ou *Action*. La figure 5.17 représente l'exemple d'une instance de type *Action* (*searchByEquation_22*) pour laquelle le moteur NaturalOWL est invoqué avec une distance d'inférence de deux (La langue=*anglais* et le nombre max de faits/phrase=*4*). Les numéros affichés à côté des relations et des propriétés de l'ontologie de trace sont les valeurs des *priorités d'ordre* de celles-ci ; ces données sont disponibles dans le fichier d'annotation du niveau micro-plans de l'ontologie.

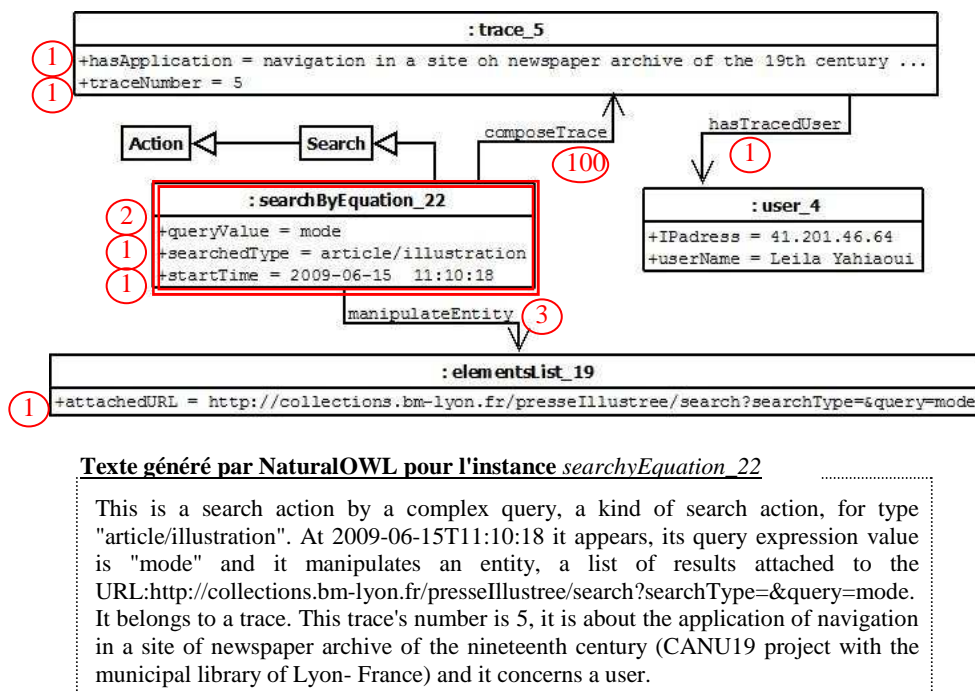


Figure 5.17. Un exemple de description textuelle générée par NaturalOWL pour une instance de l'ontologie de trace de l'activité de navigation dans la « Presse Illustrée ».

Le moteur NaturalOWL procède comme suit :

1. Il commence la description de l'action (*searchByEquation_22*) par la description de sa classe (*SearchByEquation*) en exploitant le fichier des annotations linguistiques du niveau lexical de l'ontologie de trace. Dans notre exemple, il décrit également la superclasse puisque la *distance d'inférence* = 2.

2. Il décrit la propriété *searchedType* de l'instance en utilisant le micro-plan de celle-ci décrit dans le fichier des annotations linguistiques du niveau micro-plans. Cette propriété est décrite en premier puisque elle a la priorité la plus forte (*ordre=1*) par rapport aux autres propriétés et relations de l'instance.
3. Il décrit la propriété *StartTime* de l'instance. Cette propriété a également la priorité la plus forte (*ordre=1*) par rapport aux autres propriétés et relations de l'instance et le moteur peut décrire celle-ci avant la propriété *searchedType* (choix aléatoire).
4. Il décrit la propriété *queryValue* de l'instance et qui a une priorité inférieure (*ordre=2*).
5. Il décrit la relation *manipulateEntity* de l'instance (*searchByEquation_22*) et qui a une priorité encore inférieure (*ordre=3*) ; puis il décrit l'instance de type *ElementsList* (*elementsList_19*) à laquelle cette action est liée par la relation en utilisant les annotations du niveau lexical. Il décrit également la propriété *attachedURL* de la deuxième instance (*elementsList_19*) puisque la *distance d'inférence = 2*.
6. Il décrit la relation *composeTrace* de l'instance (*searchByEquation_22*) qui a la priorité la plus faible (*ordre=100*) en utilisant le micro-plan de cette relation. Puis il décrit l'instance de type *Trace* (*trace_5*) concernée par cette relation ainsi que les propriétés et les relations de cette instance (*hasApplication*, *traceNumber* et *hasTracedUser*) qui ont les mêmes priorités d'ordre (*ordre=1*). Si la distance d'inférence avait été de 3, le moteur d'inférence aurait décrit l'instance de type *User* (*user_4*) liée à l'instance (*trace_5*) et les propriétés de cette instance puisque c'est cette distance qui précise la profondeur des parcours du moteur NaturalOWL dans le graphe des instances en partant de l'instance à décrire.

La composition du document initial (D_0) à partir des descriptions textuelles générées.

Nous avons déterminé que le module de transformation automatique doit invoquer le moteur NaturalOWL avec une distance d'inférence maximale (3) afin de récupérer le maximum d'informations dans la description textuelle de chacune des actions de la trace à redocumenter. Toutefois, nous procédons ensuite à une amélioration de ces descriptions textuelles sur le plan linguistique (e.g. supprimer les expressions du genre « *this is a* » que le moteur NaturalOWL utilise automatiquement pour débiter la description d'une instance, régler les problèmes de ponctuation dans les descriptions générées, *etc.*) et sur le plan sémantique (e.g. éviter la répétition de la description de la trace dans chacune des descriptions textuelles des actions composant celle-ci, ajouter une phrase à la fin du texte du segment décrivant la trace pour introduire le reste du document, *etc.*).

Le module de transformation automatique crée un nouveau document (instance) dans l'ontologie de document (document D_0) et relie celui-ci à la trace redocumentée via la propriété (*uriTrace*). Puis il crée un premier segment (racine du document) dont le contenu correspond à la description textuelle de la trace choisie. Il crée ensuite un segment pour chacune des descriptions textuelles des actions de la trace (le contenu du segment est la description textuelle). Finalement, il relie les segments du document entre eux par des relations rhétoriques de type *Séquence* en fonction de la relation d'ordre temporelle entre les actions décrites par les segments comme cela est illustré par la figure 5.18. Ainsi, le document initial généré de la trace est un document texte fragmenté composé d'une séquence de segments textuels issus de la trace choisie (i.e. *typeSegment= original*). Le module de

transformation automatique génère également un document texte (*documentTrace.txt* et *documentTrace.html*) à partir de ce document.

5.4.2.3 Transformation interactive du document initial

Une fois que le document initial (D_0) est généré, il est affiché comme une suite de segments textuels dans l'interface de l'outil de redocumentation ActRedoc (figure 5.9, panneau central) pour qu'il puisse être manipulé par l'utilisateur durant la phase de redocumentation interactive. Durant cette phase, supportée par le module de transformation interactive, l'utilisateur peut appliquer au document (D_0) des opérations organisationnelles ou rhétoriques (décrites dans le tableau 5.2) de façon itérative et aboutir à un document intermédiaire (D_J) après chaque itération (J). Pour décrire la suite de notre exemple de redocumentation, nous supposons que l'utilisateur applique les opérations suivantes (dans l'ordre) sur le document initial (D_0) produit par le module de transformation automatique (figure 5.18) :

Le document initial (D_0) comme un ensemble de segments et de relations :



Le document initial (D_0) comme un document texte (en html):

Document trace	
This document describes a computer-mediated activity through its trace. Its number is 5, it is about the application navigation in a site of newspaper archive of the nineteenth century (CANU19 project with the municipal library of Lyon- France) and it concerns a user. This user's name is Leila Yahiaoui and he has the IP adress 41.201.46.64 and session number 0dee13f97aede85c236032d9022abeac. During his activity, the user has performed the following actions:	
1.	On 2009-06-15 at 11:10:18, a search action by a complex query for type " article/illustration ". Its query expression value is " mode " and it produces a list of results that is attached to an URL .
2.	On 2009-06-15 at 11:10:46, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper article that has as fascicle date 1891-07-05 and it is untitled " La mode ". The newspaper article is attached to an URL .
3.	On 2009-06-15 at 11:10:58, a display action based command. It uses button "voir la page" to display the page and it manipulates a newspaper page that has as fascicle number 29 and as newspaper title Le Progrès Illustré. The newspaper page is attached to an URL . Its page number is 7.
4.	On 2009-06-15 at 11:11:26, a display action based command. It uses button "navigation sur la page" to zoom and focus on the page content.
5.	On 2009-06-15 at 11:12:34, a display action based command. It uses button "pleine page" to display the page.
6.	On 2009-06-15 at 11:12:48, a display action through graphical element. It manipulates an element of the fascicle contents that represents an article. The element of the fascicle contents is attached to an URL . It points to a newspaper article that has as fascicle date 1891-07-05 and it is untitled " La mode ". The newspaper article is attached to the URL: http://collections.bm-lyon.fr/PER0016701 .
7.	On 2009-06-15 at 15:09:58, a display action using an URL .

Figure 5.18. Représentation du document initial fragmenté (D_0) produit de la transformation (redocumentation) automatique de la trace (*trace_5*).

1. Une opération organisationnelle « *Replace Segment* » appliquée au premier segment du document D_0 (décrivant la trace) pour reformuler son contenu (suppression du numéro de session).
2. Une opération rhétorique « *Explain Segment* » appliquée au deuxième segment du document D_0 (décrivant la 1ère action de la trace) avec une relation rhétorique de type « *Justify* ». Le nouveau segment dont le contenu est saisi par l'utilisateur comporte le texte qui justifie l'action décrite par ce segment ; il est lié à ce dernier par une relation rhétorique de type *Justification* dont l'expression textuelle (*The reason is that*) est choisi par l'utilisateur dans la liste des expressions proposées (figure 5.19).
3. Une opération rhétorique « *Explain Segment* » appliquée au troisième segment du document D_0 (décrivant la 2ème action de la trace) avec une relation rhétorique de type « *Elaboration* ». L'expression textuelle (*Moreover*) est choisie pour cette relation d'élaboration dont le but est de donner plus de détails sur l'action décrite.

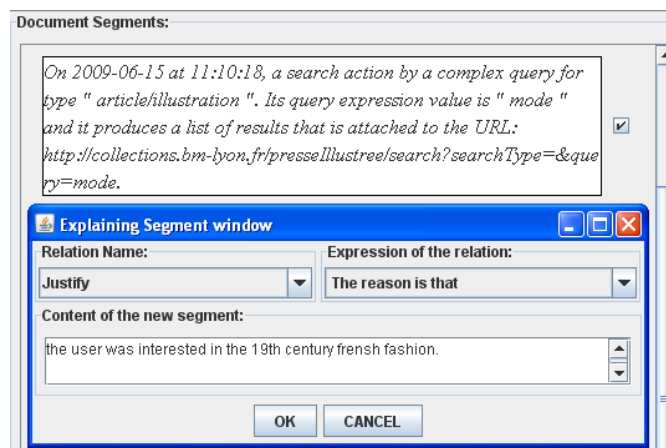


Figure 5.19. Interface d'application d'une opération « Explain Segment » à un segment du document D_0 dans l'outil ActRedoc (avec une relation de justification).

4. Une opération rhétorique « *Explain Segment* » appliquée au troisième segment du document D_0 (décrivant la 2ème action de la trace) avec une relation rhétorique de type « *Elaboration* ». L'expression textuelle (*Moreover*) est choisie pour cette relation d'élaboration dont le but est de donner plus de détails sur l'action décrite.
5. Une opération rhétorique « *Explain Segment* » appliquée au quatrième segment du document D_0 (décrivant la 3ème action de la trace) avec une relation rhétorique de type « *Evaluation* ». L'expression textuelle (*Therefore*) est choisie pour cette relation d'évaluation.
6. Une opération rhétorique « *Explain Segment* » appliquée au cinquième segment du document D_0 (décrivant la 4ème action de la trace) avec une relation rhétorique de type « *Background* ». L'expression textuelle (*Notice that*) est choisie pour cette relation d'arrière-plan.

7. Une opération rhétorique « *Explain Segment* » appliquée au même segment (cinquième segment du document D_0) avec une relation rhétorique de type « *Purpose* ». L'expression textuelle (*The purpose is that*) est choisie pour cette relation de but.
8. Une opération organisationnelle « *Delete Segment* » appliquée au sixième segment du document D_0 (décrivant la décrivant la 5ème action de la trace). L'utilisateur a jugé que le contenu de ce segment n'est pas important puisque l'action décrite consiste simplement à annuler le zoom de la page affichée.
9. Une opération rhétorique « *Add Segment* » appliquée au septième segment du document D_0 (décrivant la 6ème action de la trace) avec une relation rhétorique de type « *Contrast* ». L'expression textuelle (*Contrary to that*) est choisie pour cette relation de contraste.
10. Une opération rhétorique « *Explain Segment* » appliquée au même segment (septième segment du document D_0) avec une relation rhétorique de type « *Elaboration* ». L'expression textuelle (*Moreover*) est choisie pour cette relation d'élaboration.
11. Une opération organisationnelle « *Delete Segment* » appliquée au huitième segment du document D_0 (décrivant la 7ème action de la trace).
12. Une opération rhétorique « *Add Segment* » appliquée au septième segment du document D_0 (décrivant la 6ème action de la trace) avec une relation rhétorique de type « *Séquence* ». Ce segment est ajouté par l'utilisateur pour décrire la 7ème action de la trace dont le segment descriptif a été supprimé.
13. Une opération rhétorique « *Explain Segment* » appliquée dernier segment ajouté avec une relation rhétorique de type « *Interpretation* ». L'expression textuelle (*More clearly*) est choisie pour cette relation.
14. Une opération rhétorique « *Explain Segment* » appliquée au document avec une relation rhétorique de type « *Summary* ». L'expression textuelle (*Summary :*) est choisie pour cette relation dont le but est de résumer le contenu du document.

Le produit de l'application de cette suite d'opérations sur le document initial D_0 permet de produire le document texte intermédiaire, représenté par la figure 5.20. Ce document est composé d'un ensemble de segments textuels inter-liés par des relations rhétoriques issues de la trace ou ajoutées par l'utilisateur.

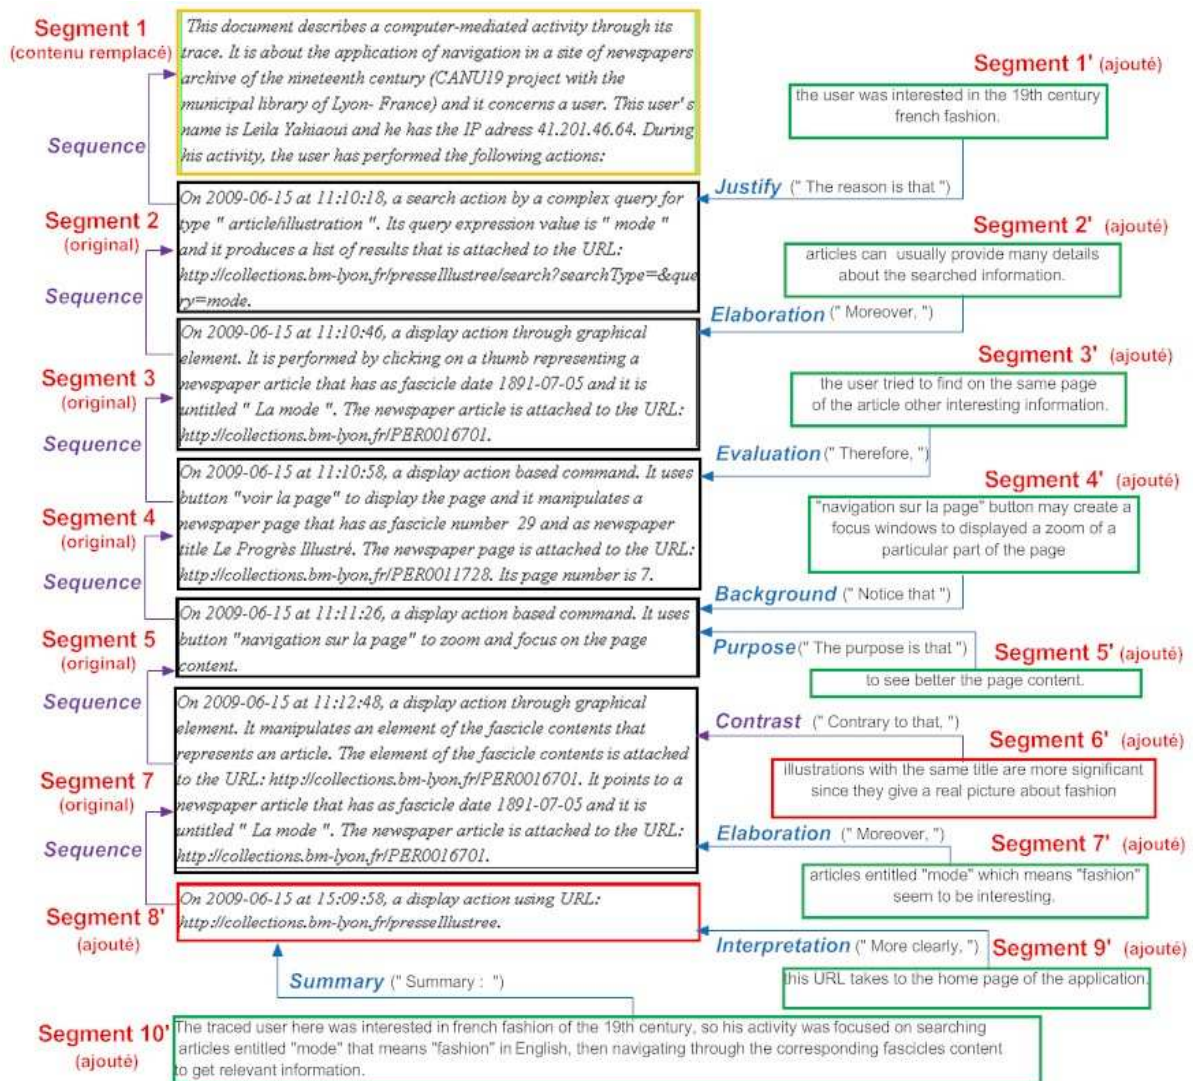


Figure 5.20. Représentation du document intermédiaire (D_j) produit de la redocumentation (transformation) interactive du document initial (D_0).

5.4.2.4 Visualisation et export du document final (D_F)

La demande de visualisation du document intermédiaire sous une forme hypertexte peut se faire par l'utilisateur à tout moment (par la commande *preview* du menu de ActRedoc) durant la phase de redocumentation interactive. Mais lors de la première demande de visualisation, il est demandé à l'utilisateur de saisir le nom de l'auteur du document et le titre de celui-ci. La figure 5.21 représente le panneau de gauche de l'interface de ActRedoc qui affiche le document intermédiaire sous une forme textuelle. Nous avons expliqué le principe de construction de ce document lorsque nous avons décrit le module de transformation interactive comme un composant de l'architecture de l'outil ActRedoc. L'export du document intermédiaire comme un document final permet de générer un document HTML pour lequel l'utilisateur spécifie le nom (document pérenne) ; il est représenté par la figure 5.22.

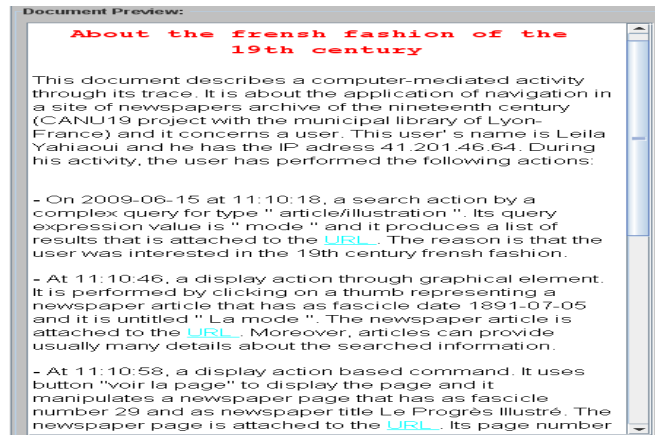


Figure 5.21. Visualisation du document intermédiaire (D_J) comme un document texte dans l'interface de l'outil ActRedoc.

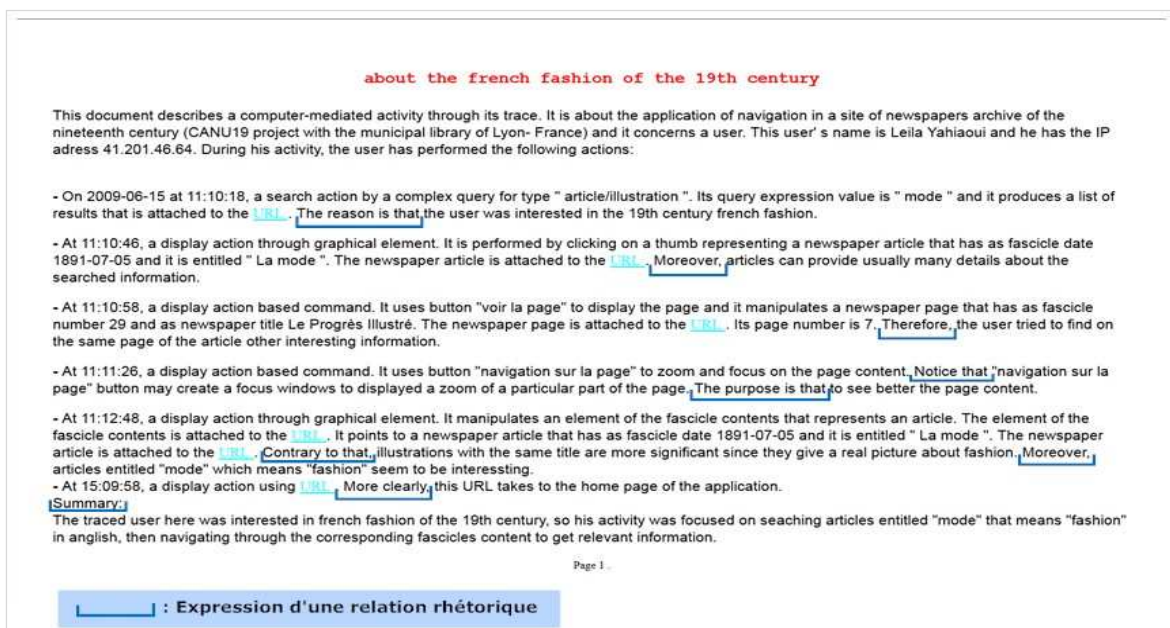


Figure 5.22. Visualisation du document final (D_F) exporté comme un document HTML dans le navigateur Firefox.

5.5 Une première évaluation de l'outil ActRedoc

Nous avons testé la première version de notre prototype ActRedoc dans le cadre d'une étude préliminaire visant l'évaluation de son utilisabilité⁶⁷ et de son utilité⁶⁸ (Yahiaoui et al., 2011). Cette étude visait également à fournir une analyse du processus de redocumentation de l'activité informatique et à étudier comment ce processus est réalisé en utilisant notre outil

⁶⁷. L'*utilisabilité* d'un outil est définie en termes de cinq mesures concernant la facilité de son utilisation : l'*apprenabilité* (facilité de la première utilisation de l'outil), l'*efficacité* (vitesse d'utilisation), la *mémorabilité* (facilité de se rappeler de l'utilisation de l'outil après une période de non utilisation), les *erreurs* (nombre d'erreurs commises par les utilisateurs, gravité de ces erreurs et facilité de recouvrement) et la *satisfaction des utilisateurs*.

⁶⁸. L'*utilité* d'un outil réfère sa fonctionnalité et s'il répond aux besoins des utilisateurs.

auteur. La collecte des mesures d'utilisabilité et d'utilité d'un système informatique nécessite souvent un nombre important d'utilisateurs afin de surmonter les variations de la performance entre individus, ce qui peut rendre l'évaluation coûteuse et parfois trompeuse. Cependant, une étude de Nielsen a montré qu'un nombre restreint d'utilisateurs (typiquement 5) était suffisant pour une première évaluation d'un système (Nielsen and Loranger, 2006) ; la révision de la conception étant suivie d'autres évaluations similaires afin d'améliorer le système de façon progressive et peu coûteuse. C'est l'idée que nous avons adoptée dans l'évaluation de notre outil de redocumentation. Avant de décrire les participants et leur expérience de redocumentation, nous commençons par décrire les traces d'activité utilisées comme des données d'entrée pour le processus de redocumentation.

5.5.1 Les traces d'activité

L'activité informatique tracée étant celle de navigation dans la « Presse Illustrée », un ensemble d'utilisateurs a été sollicité pour mettre en œuvre des scénarios de navigation pertinents. Tout d'abord, des traces de base ont été extraites du fichier log produit, chaque trace concernant un utilisateur particulier (l'adresse IP et le numéro de session de l'utilisateur nous ont permis de distinguer les traces des différents utilisateurs). Ces traces de base ont été modélisées sémantiquement selon l'ontologie de trace (figure 5.5). Dans notre expérimentation, en plus de l'évaluation de l'outil ActRedoc, nous tenions à montrer différents effets à travers un ensemble minimal de traces choisies :

1. L'effet de la longueur des traces (en nombre d'action) sur le processus de redocumentation.
2. L'effet de la durée de temps entre le traçage de l'activité et sa redocumentation sur le processus.
3. La variation possible dans le processus de redocumentation induite par le fait qu'un utilisateur redocumente la trace de son activité ou de celle d'une autre personne.

Par conséquent, nous avons sélectionné dans l'ensemble seulement six traces ayant les caractéristiques suivantes :

1. Des traces de longueurs différentes (en nombre d'actions) dont quatre traces ont une longueur similaire, une trace de longueur maximale (T4) et une autre de longueur minimale (T5).
2. Deux traces concernent un même utilisateur, celle d'une activité ancienne (T4) et celle d'une activité récente (T5).
3. Dans la plupart des cas, une trace d'activité est redocumentée par l'utilisateur tracé (dont l'activité est tracée) et par un autre participant à l'expérimentation.

5.5.2 Les participants

Nous avons demandé à dix participants (3 femmes et 7 hommes ; tranche d'âge : 26-36 ans) de redocumenter les traces d'activité choisies en utilisant notre outil de redocumentation. Parmi ceux-ci, seuls cinq participants avaient déjà effectué l'activité informatique tracée (utilisateurs tracés : participants 4,5,6,7,9), c'est pourquoi nous avons demandé au reste de consulter rapidement l'application « Presse illustrée » (participants 1,2,3,8,10). Chaque participant devait utiliser une ou deux traces via l'outil de redocumentation ActRedoc dans le but de générer un document textuel décrivant l'activité tracée. L'attribution des traces aux participants n'a pas été faite de façon purement arbitraire puisque :

- Chaque utilisateur tracé devait redocumenter sa propre activité tracée en utilisant la trace de celle-ci ; un participant particulier (participant 1) devait redocumenter deux activités le concernant en utilisant la trace d'une activité ancienne et celle d'une activité récente.
- Un utilisateur tracé (participant 8) devait redocumenter l'activité d'un autre utilisateur tracé (participant 1).
- Chacune des traces d'activité devait être exploitée par au moins deux participants ; ainsi, chaque activité tracée devait être redocumentée par au moins un participant différent de l'utilisateur tracé.
- Un même participant (participant 1) devait redocumenter la trace la plus longue et la plus courte.

Avant l'expérimentation de la redocumentation, nous avons demandé aux participants de décrire oralement les activités qu'ils devaient redocumenter à partir des traces de base (fichier log). A ce niveau, nous avons constaté que ces participants avaient des difficultés à interpréter le contenu des traces, en particulier lorsque la trace d'activité n'était pas la leur. Par la suite, nous avons initié les participants à l'utilisation de notre outil ActRedoc (pour 20 mn) en utilisant les différentes opérations supportées par celui-ci. Pour cela, nous avons utilisé, comme donnée d'entrée pour l'outil la trace d'activité de l'exemple de redocumentation présenté dans la section précédente ; l'activité à redocumenter était ainsi la recherche des articles et des illustrations de la « Presse Illustrée » qui concernent la mode française du 19^{ème} siècle. Durant cette initiation à l'utilisation de ActRedoc, nous avons insisté sur l'utilisation des opérations rhétoriques ; nous avons constaté que les participants n'étaient pas familiers avec ce type d'opérations bien qu'ils les emploient implicitement lors de la description (écrite ou orale) de leurs expériences.

5.5.3 L'expérimentation

Les participants ont procédé à des tests séparés de l'outil ActReedoc pour redocumenter les traces qui leurs avaient été attribuées, sans pour autant leur imposer des contraintes à propos de l'objectif du processus de redocumentation. Ainsi, chacun des participants avait son propre objectif de redocumentation. Durant ces tests, nous avons observé chacun des participants et nous avons pris des notes à propos de ses attitudes. Nous nous sommes intéressée en particulier :

- aux types d'opérations utilisées plus ou moins que d'autres ;
- à la façon de combiner les opérations ;
- au temps qu'il passait pour l'utilisation de chaque type d'opérations ;
- à la durée du processus de redocumentation ;
- au recours à l'aide sur le principe des opérations supportées par l'outil ;
- aux difficultés rencontrées lors de l'utilisation de l'outil ;
- aux erreurs commises et aux réactions pour surmonter ces erreurs ;
- à la maîtrise de l'utilisation des différentes fonctions supportées par l'outil ;
- au genre du document produit.

Durant cette expérimentation, nous avons veillé à ne pas intervenir pour aider les participants à résoudre les problèmes rencontrés lors de l'utilisation de ActRedoc, sauf en cas de nécessité. Une fois l'expérimentation achevée, nous avons demandé à chacun des participants de décrire l'objectif de sa redocumentation et d'évaluer l'outil utilisé selon différents critères : la facilité d'utilisation ainsi que la satisfaction de l'ergonomie de l'interface, de la fonctionnalité de l'outil et des produits de la redocumentation (le document initial D0 et le document final DF). Nous avons également demandé à chacun des participants s'il lui plaisait d'utiliser l'outil et quels étaient leurs besoins non satisfaits.

5.5.4 Résultats

Les interviews avec les participants ont révélé une certaine facilité de l'utilisation de l'outil ActRedoc ainsi que la relative satisfaction de ses utilisateurs. Nous avons résumé nos observations et les réponses des participants dans le tableau 5.4. Dans ce tableau, les traces manipulées et les participants sont identifiés par leurs numéros alors que les colonnes décrivent les informations suivantes :

- La première colonne affiche le numéro du participant, le numéro de la trace qu'il a redocumentée et le numéro de l'utilisateur tracé.
- La deuxième colonne affiche la durée du processus de redocumentation (mn).
- La troisième colonne décrit le genre du document produit que nous qualifions soit de rapport d'analyse (R-ana), soit de rapport de synthèse (R-syn), soit rapport annoté (R-ano). Le document produit peut par ailleurs être personnel (P) ou destiné à d'autres personnes (A) et long (L) ou court (C). Cette classification est basée sur notre analyse des contenus et des formes des documents produits, ainsi que les objectifs des participants. Dans un rapport annoté (figure 5.22), le participant tente de préserver le contenu du document initial et se concentre sur l'explication de ses différentes parties en utilisant des opérations rhétoriques selon une pratique d'annotation. Dans un rapport de synthèse, le participant extrait du document initial (D₀) décrivant la trace les informations qui lui semblent importantes afin de constituer une sorte de résumé, puis s'approprie ce contenu selon un style personnel. Dans un rapport d'analyse, le participant se concentre plutôt sur le raisonnement de l'utilisateur tracé et son comportement au moment où il a effectué l'activité tracée ; il reformule et enrichi ce contenu selon son propre style. Toutefois, il est possible que le document produit ait des caractéristiques d'un rapport annoté et d'un rapport d'analyse au même temps ; ou encore d'un rapport de synthèse et d'un rapport d'analyse. Un exemple de chacun de ces types de rapports est présenté dans Annexe A.
- La quatrième colonne présente une évaluation de l'utilité de l'outil (B : bon, M : moyen, F : faible) à travers l'évaluation des participants du document produit automatiquement (D0) et de l'aptitude de l'outil à répondre à leurs besoins, ainsi que des informations sur l'utilisation des opérations supportées en distinguant celles utilisées (U), celles fréquemment utilisées (F) et celles non utilisées (NU). Nous distinguons également les opérations rhétoriques (RS : Add Segment et Explain Segment) de celles organisationnelles (OR : Replace Segment, Réorder Segments et Merge Segments).
- La cinquième colonne présente une évaluation de l'utilisabilité de l'outil (B, M ou F) à travers la mesure de la facilité de sa première utilisation (*Apprenabilité*), de la facilité à reprendre son utilisation après une période de non utilisation (*Mémorabilité*), de l'*efficacité* de son utilisation et de la *satisfaction* des participants à propos de cette utilisation.

Participant, Trace, utilisateur tracé	Durée du processus	Document produit (genre, destinataire, taille)	Utilité de l'outil			Utilisabilité			
			Evaluation de D ₀	Utilisation des opérations utilisées (U) / non utilisées (NU) / fréquemment utilisées (F)	Evaluation des besoins	Apprenabilité	Efficacité	Mémorabilité	Satisfaction
1,4,1	40	R-ano, P, L	B	NU : delete, explain (<i>Solutionhood</i>), add (<i>joint, contrast</i>) F : RS	B	B	B		B
1,5,1	15	R-ano, P, C	B	NU : explain (<i>justify, enablement, evaluation, interpretation, introduction</i>), reorder, merge F : explain (<i>Elaboration, justify</i>)	B	B	B	B	B
2,2,2	20	R-syn, P,L	M	U : OR, explain (<i>Justify, Introduction, interpretation, summary</i>) F : replace, merge, explain (<i>Justify</i>)	M	M	B		B
3,3,3	30	R-syn, A, C	B	U : OR, explain (<i>Elaboration</i>), Add (<i>Sequence</i>) F : replace, merge, explain (<i>Elaboration</i>)	B	B	B		B
4,5,1	25	R-ana A,C	M	U : OR, explain (<i>purpose, summary, Justify</i>) F : replace, explain (<i>Justify</i>)	M	B	B		M
5,1,8	90	R-ana, A, L	B	U : replace, delete, explain (<i>Introduction, Elaboration, Enablement, Background, summary</i>). F : replace, explain (<i>Enablement</i>)	B	M	M		B
6,4,1	35	R-ano, A,L	B	U : replace, explain (<i>Justify, Introduction, interpretation, purpose</i>), Add (<i>Sequence</i>) F : RS, replace	B	B	B		B
7,3,3	20	R-ana, A, C	B	U : replace, explain (<i>Evaluation, Solutionhood</i>) F : replace, explain (<i>Evaluation</i>).	B	M	B		M
8,1,8	35	R-syn, A,C	B	NU : RN, explain (<i>Solutionhood</i>) F : merge, delete, replace, explain (<i>Justify</i>)	B	B	M		B
8,4,1	50	R-ano, A, L	B	NU : delete, reorder, RN, explain (<i>Solutionhood</i>) F : explain (<i>Justify, Background, Elaboration</i>)	B	B	M	B	B
9,6,10	20	R-syn, A,C	B	U : merge, replace, explain (<i>Introduction, Summary</i>) F : merge, replace	B	B	B		B
9,2,2	15	R-ana, A, C	B	U : Replace, delete, merge F : replace, delete	B	B	B	B	B
10,6,10	40	R-ano, A, C	B	NU : RN, reorder F : merge, replace, explain (<i>Justify, Purpose, Background</i>)	B	B	M		B

Tableau 5.4. Synthèse de l'expérimentation de redocumentation et de ses résultats.

OR : *Organizational* operation (delete, replace, reorder or merge segments); *Rhetorical* operation (add segment with *Rhetorical-NN* or explain segment with *Rhetorical-SN*); RS : *Rhetorical-SN* (justify, elaboration, background, enablement, evaluation, interpretation, introduction, summary, purpose, solutionhood); RN : *Rhetorical-NN* (sequence, joint, contrast); (G: good, A: average, and L: low).

5.5.5 Discussion

Notre discussion à propos des résultats de cette expérimentation porte sur trois points : l'évaluation de l'outil ActRedoc, l'étude des facteurs qui peuvent influencer la durée du processus de redocumentation et de l'utilisation des opérations supportées par l'outil de redocumentation ActRedoc.

5.5.5.1 L'évaluation de l'outil

A travers cette expérimentation, nous avons constaté que la majorité des participants étaient satisfaits de l'utilité de l'utilisabilité et des produits de l'outil ActRedoc. Ils ont apprécié le document (D_0), produit automatiquement par l'outil ActRedoc, et l'ont trouvé plus compréhensible que la trace d'activité dont il est issu (fichier log). Ce document a été considéré comme un bon support pour la phase de redocumentation interactive puisque il forme une description détaillée et cohérente de l'activité réalisée. Par ailleurs, deux participants (2 et 4) ont demandé de réduire et d'améliorer le contenu du document initial (e.g. éviter la répétition du même style d'expression, ce qui est un inconvénient du générateur NaturalOWL que nous avons utilisé).

Sept participants (sur dix) ont considéré qu'il était facile d'utiliser l'outil ActRedoc (*apprenabilité*) et que celui-ci leur permettait rapidement d'accomplir leurs tâches (*efficacité*). Quant à la facilité de mémoriser les fonctions de cet outil (*mémorabilité*), l'évaluation de cette mesure était satisfaisante pour les participants qui ont pu utiliser l'outil plus qu'une fois pour réaliser le processus de redocumentation (participants 1, 8 et 9). Huit participants ont considéré que l'outil répondait vraiment à leurs besoins ; alors que sept participants ont apprécié l'interface de l'outil. Cependant, deux participants (2 et 7) ont proposé d'améliorer l'interface de l'outil en remplaçant le panneau central affichant les segments du document par un graphe de segments et de relations ; cela pour éviter à l'utilisateur de déduire ces relations à partir des positions des segments, de leurs couleurs et des données contextuelles affichées pour chacun des segments. Des participants (4 et 7) ont également mis en évidence de nouveaux besoins, en particulier la possibilité d'enrichir le contenu du document texte produit avec des données d'autres formes (vidéos, illustrations, etc.). Par conséquent, nous prévoyons de prendre en considération ces améliorations dans notre futur travail.

Finalement, trois participants (5, 2, 10) avaient eu des difficultés à appliquer quelques opérations car ils n'avaient pas bien compris les principes des relations rhétoriques. Par exemple, le participant-9 a essayé de fusionner un segment ajouté via une relation rhétorique de type *Justify* avec un segment original (issu de la trace) ; alors que le participant-2 a essayé de réordonner le premier segment du document initial (D_0) avec un segment ajouté via une relation rhétorique avec le quatrième segment du document. Nous avons déduit que les utilisateurs de l'outil ActRedoc avaient besoin de plus de temps et de pratique pour comprendre le principe et maîtriser l'utilisation des différentes relations rhétoriques utilisables via l'outil. Nous prévoyons également l'amélioration de l'interface de l'outil afin de faciliter, au maximum, le travail de l'utilisateur. Nous prévoyons éventuellement de réduire l'ensemble des relations rhétoriques utilisé par notre outil auteur en supprimant celles qui sont rarement utilisées (telles que *Solutionhood*, *Joint* et *Contrast*).

5.5.5.2 L'étude de la durée du processus de redocumentation

La durée du processus de redocumentation s'est révélée variable. Elle dépendait notamment de la longueur de la trace d'activité redocumentée (en nombre d'actions) ; ceci est le cas du participant-8 qui a pris le maximum du temps à redocumenter la trace la plus longue (T4). Cependant, il ne s'agissait pas du seul facteur puisque le participant-5 a pris

beaucoup de temps à redocumenter une trace de longueur moyenne (T1). Cette durée dépendait également de l'objectif du participant et/ou des performances de celui-ci. Pour illustrer le premier cas, nous donnons l'exemple des participants 8 et 5 qui ont redocumenté la même trace (T1) ; alors que la différence entre les durées des deux processus de redocumentation (35mn et 90mn) était importante. Nous pouvons expliquer cela par le fait que l'objectif du participant-8 était de décrire son activité personnelle pour d'autres personnes via un rapport de synthèse (comment il avait fait des recherches à propos de Napoléon Bonaparte et ce qu'il avait trouvé intéressant) ; alors que celui du participant-5 était de produire un rapport d'analyse détaillé de l'activité tracée et du comportement du participant-8 (par exemple, il a supposé que l'utilisateur tracé avait probablement confondu *Napoléon Bonaparte* avec *Napoléon II* ou *Napoléon III*). En effet, le participant-5 nous a confirmé qu'il lui fallait beaucoup de temps pour analyser la trace d'activité qui ne durait que quelques minutes. Mais nous pouvons également justifier cette différence dans les durées de la redocumentation par le fait que l'utilisateur tracé (Participant 8) comprenait mieux et rapidement le contenu de la trace à redocumenter puisque cette trace concernait son activité, ce qui lui a rendu le processus de redocumentation plus facile (rapide) par rapport à d'autres personnes. Pour illustrer le deuxième cas, nous donnons l'exemple des participants 8 et 6 qui ont redocumenté la même trace (T4) selon des objectifs similaires (produire un rapport annoté) mais qui n'ont pas pris le même temps pour effectuer cette redocumentation.

Nous avons constaté que l'utilisateur tracé prenait moins de temps à redocumenter sa trace d'activité que d'autres participants ; ceci via l'exemple du participant-3 qui a redocumenté sa trace d'activité (T3) durant un temps record par rapport au participant-7 qui a redocumenté la même trace. En revanche, cela ne peut être généralisé du fait que le degré d'engagement dans le processus de redocumentation peut varier d'un participant à l'autre. Par exemple, le participant-2 a pris plus de temps à redocumenter la trace de son activité (T2) par rapport au participant-9 ; pourtant, le document produit par le participant-2 était un rapport de synthèse alors que celui produit par le participant-9 était un rapport d'analyse. Nous avons également constaté que le temps de la redocumentation de la trace d'une activité récente était plus court que celui de la trace d'une activité ancienne pour l'utilisateur tracé ; ceci est le cas du participant-1 qui a redocumenté une trace ancienne (T4) et une autre plus récente (T5). Nous justifions cela par l'effet de la mémoire du participant (pour se rappeler du contexte de l'activité réalisée) sur la durée du processus de redocumentation.

5.5.5.3 L'étude de l'utilisation des opérations supportées par l'outil

Les utilisateurs tracés nous ont paru plus engagés dans le processus de redocumentation de leurs traces que les autres participants. Leur consultation des documents produits initialement (D₀) a montré qu'ils considéraient ces documents comme des supports mémoriels pertinents. Durant le processus de redocumentation, ces participants ont utilisé différentes opérations (rhétoriques et organisationnelles) qu'ils avaient choisies avec soin (cas des participants 1, 2 et 8) malgré la longueur de la trace à redocumenter parfois (cas de la trace T4). En général, les participants étaient plus familiarisés avec les opérations organisationnelles qu'avec les opérations rhétoriques. Pour cela, certains d'entre eux (cas des participants 2,5 et 6) ont consulté l'aide sur ces opérations à plusieurs reprises, alors que d'autres (cas des participants 3,7 et 9) n'en ont utilisé que quelques-unes (particulièrement *explain* avec *Justify*, *Introduction* et *Summary*) en combinaison avec l'opération *replace*.

L'un des participant (participant 4) a proposé que l'ensemble des opérations rhétoriques soit réduit, mais d'autres (cas des participants 1 et 10) ont considéré que toutes les opérations supportées étaient utiles pour la redocumentation de leurs activités. Les opérations

organisationnelles *replace* et *merge* ont été utilisées par la majorité des participants ; contrairement à *delete* et *reorder*, en particulier pour les participants qui ont redocumenté les traces des autres et qui ont hésité à falsifier leurs contenus (cas des participants 4, 6 et 7). De plus, l'objectif de la redocumentation a influencé l'utilisation des opérations supportées par notre outil. Pour produire des rapports de synthèse, les opérations les plus utilisées étaient *merge*, *replace* et *explain* (avec *justify*) ; pour des rapports d'analyse, les opérations les plus utilisées étaient *explain* (avec *Purpose*, *Justify*, *Background*, *Evaluation*, *Elaboration*) ; alors que pour des rapports annotés, des opérations rhétoriques plus variées ont été utilisées.

5.6 Conclusion

Dans le chapitre précédent, nous avons proposé une approche de redocumentation interactive de l'activité médiée informatiquement à partir de sa trace et nous avons spécifié cette approche pour le cas particulier de la redocumentation en texte. Pour rendre cette approche concrètement utilisable, nous avons développé un outil auteur de redocumentation, appelé ActRedoc, comme une première implémentation de cette approche. Cet outil permet d'exploiter des traces d'activité modélisées sémantiquement (par une ontologie en OWL) pour produire un document texte qui décrit l'activité de façon personnalisée par l'utilisateur. L'architecture de l'outil ActRedoc est centrée autour de deux modules : un module de transformation automatique qui génère un document texte fragmenté initial à partir d'une trace choisie en faisant appel à un générateur du langage naturel (NaturalOWL) et un module de transformation interactive qui permet à l'utilisateur de manipuler le document initial, modélisée par une ontologie, en lui appliquant des opérations basées sur des règles rhétoriques assurant le maintien de la cohérence du document. Finalement, lorsque l'utilisateur est satisfait du document produit, il peut exporter celui-ci dans une forme exploitable aussi bien par des humains que par des machines (texte enrichi de métadonnées).

Nous avons exploité différentes technologies du web sémantique pour implémenter l'outil ActRedoc : des ontologies en OWL pour modéliser les traces et les documents produits, un outil de génération du langage naturel (NaturalOWL) à partir de l'ontologie de la trace, et RDFa pour enrichir le contenu du document final avec des métadonnées sur la structure rhétorique du document et sur les éléments de la trace d'activité qu'il décrit. Le choix de la théorie de la structure rhétorique (RST) pour modéliser le contenu du document produit et les opérations applicables à celui-ci est dû à sa simplicité et à la diversité de ses applications pour contrôler la cohérence des documents. Ainsi, nous pouvons maintenir, tout au long du processus de redocumentation, suffisamment d'informations exploitables automatiquement pour pouvoir supporter ce processus et assister l'utilisateur à construire de façon naturelle une histoire de l'activité tracée. Pour illustrer le fonctionnement de l'outil ActRedoc, nous avons choisi une activité informatique à redocumenter en utilisant cet outil. Il s'agit d'une activité de navigation dans un site d'archive de journaux du XIX^{ème} dont l'objectif est de mettre en ligne des fonds patrimoniaux de la presse illustrée régionale du XIX^{ème} siècle, disponibles au département Documentation Lyon et Rhône-Alpes de la Bibliothèque Municipale de Lyon. Via l'instrumentation de l'application, nous avons procédé au traçage de l'activité en question dans le cadre d'un test en groupe et nous avons modélisé sémantiquement les traces produites (fichier log). Alors, l'une des traces résultantes nous a servi d'exemple pour décrire le déroulement du processus de redocumentation supporté par ActRedoc et le document produit d'un tel processus. En outre, nous avons réalisé une première évaluation de l'outil auprès d'un groupe d'utilisateurs, centrée sur l'étude de l'utilisabilité et de l'utilité de celui-ci. Cependant, des besoins ont été signalés, particulièrement pour faciliter l'utilisation des opérations rhétoriques et enrichir le document texte produit avec d'autres médias (photos, vidéos...).

Conclusion et perspectives

Conclusion

La documentation de l'activité médiée informatiquement est un processus qui nécessite la collecte de données décrivant cette activité. Une bonne partie de ces données résulte de l'enregistrement automatique de l'interaction de l'utilisateur avec le système informatique utilisé (traces d'activité), alors que l'autre partie est souvent fournie via une intervention humaine pour décrire le contexte de l'activité et expliciter la logique et les intentions de l'utilisateur tracé. En effet, collecter des données à propos de l'activité tracée n'est pas suffisant pour décrire celle-ci ; un processus interprétatif et organisationnel est notamment requis pour exprimer seulement ce qui est important dans une forme compréhensible, cohérente et facilement échangeable. Dans ce travail de thèse, nous avons proposé d'appliquer un processus de *redocumentation* de l'activité informatique à base de ses traces. Nous avons proposé une étude théorique fouillée de ce processus et nous avons proposé un cadre général d'application. Pour sa mise en place effective, nous avons proposé une approche semi-automatique de *Storytelling* basée sur la théorie de la structure rhétorique (RST). Cette approche utilise des modèles formels pour les données d'entrée (trace d'activité) et de sortie (document produits) du processus et le supporte à travers la construction d'une narration considérée comme moyen naturel que les êtres humains utilisent pour décrire leurs expériences. Dans notre cas, une telle construction est caractérisée par deux phases : une première phase automatique qui génère un document initial fragmenté à partir de la trace d'activité et une seconde phase interactive qui permet à l'utilisateur de s'approprier le contenu et la forme du document initial selon ses besoins et ses choix tout en maintenant la cohérence de celui-ci, afin d'aboutir à un document final personnalisé et facilement échangeable.

Nous avons également proposé une spécification de cette approche pour le cas particulier de la redocumentation par le texte ; ainsi, le document produit est doté d'une forme textuelle familière. Comme première implémentation de cette approche, nous avons développé un outil de redocumentation, appelé *ActRedoc*, en utilisant différentes technologies du Web sémantique. Cet outil auteur exploite des traces d'activité modélisées sémantiquement (par une ontologie) et un outil de génération du langage naturel (NaturalOWL) pour générer automatiquement un document texte fragmenté initial. Par ailleurs, la modélisation sémantique de ce document et la spécification d'opérations à base de règles rhétoriques qui peuvent lui être appliquées permettent d'en préserver la cohérence durant sa manipulation par l'utilisateur, ainsi que son export dans une forme exploitable aussi bien par des humains que par des machines (texte enrichi de métadonnées).

Nous avons choisi un terrain applicatif pour notre approche de redocumentation en texte via l'utilisation de l'outil ActRedoc. Il s'agit de la redocumentation de l'activité de navigation dans un site public d'archive de journaux qui met en ligne des fonds patrimoniaux de la presse illustrée régionale du XIX^{ème} siècle disponibles au département Documentation Lyon et Rhône-Alpes de la Bibliothèque Municipale de Lyon. Nous avons procédé au traçage de l'activité en question via l'instrumentation de l'application ; puis nous avons récupéré des traces de base (fichier log) lors d'un test de l'application de l'activité que nous avons modélisées sémantiquement. De façon à illustrer et à tester notre approche avec un exemple complet du processus de redocumentation d'une trace particulière, nous avons ensuite proposé

à différents utilisateurs de redocumenter (en texte) les traces collectées en utilisant *ActRedoc*, nous les avons observés et avons mené des entretiens avec eux. Cette étude a montré la satisfaction de la majorité de ces utilisateurs à propos de l'utilisabilité, de l'utilité et des produits de l'outil. Cependant, différents besoins ont été signalés, particulièrement pour faciliter l'utilisation des opérations rhétoriques et l'enrichissement du document texte produit avec d'autres médias (photos, vidéos...).

Par conséquent, les principales **contributions** de ce travail concernent :

1. La proposition d'un nouveau concept de « *Redocumentation* » que nous avons défini et positionné théoriquement par rapport aux concepts associés de « *Documentation* », « *Documentarisation* » et « *Redocumentarisation* ».
2. La proposition d'un processus de redocumentation de l'activité informatique dont le principe est de transformer la (les) trace(s) de celle-ci en un document numérique décrivant l'activité de façon personnalisée par un individu et la justification de l'intérêt d'un tel processus.
3. La proposition de modèles génériques pour la trace d'activité et le document numérique (produit de la redocumentation), qui peuvent être implémentés sous forme de modèles formels (ontologies).
4. La proposition d'une approche générique, naturelle et interactive pour le processus de redocumentation de l'activité informatique, qui utilisent les modèles proposés et des principes de la théorie de la structure rhétorique (RST), pour générer un document cohérent, personnalisé et facilement échangeable.
5. La spécification de l'approche proposée pour le cas particulier de la redocumentation par le texte.
6. L'implémentation de l'approche de redocumentation par le texte via le développement d'un outil auteur en utilisant différentes technologies du Web Sémantique.
7. Le test de l'approche proposé pour une activité informatique concrète (terrain applicatif) et l'évaluation de l'outil développé auprès de ses utilisateurs.

Discussion

Dans ce travail de thèse, nous avons fait certains choix que nous avons justifiés au long de ce mémoire. Notre objectif était de fournir, pour l'activité médiée informatiquement, une description lisible, compréhensible, facilement échangeable et personnalisable par un individu ; ceci en exploitant les données enregistrées automatiquement à propos de celle-ci sous forme de traces numériques.

Sur le plan théorique, nous avons supposé que les traces d'activité forment le produit d'une première documentation (automatique) de l'activité ; mais que ce produit doit être amélioré afin d'acquies le statut d'un document (lisibilité, intelligibilité et échange sur le plan social) et atteindre ainsi notre objectif. Nous avons alors étudié les deux processus qui permettent de renforcer le statut documentaire des traces. Tout d'abord, la *documentarisation* des traces qui se base sur l'exploitation de leurs supports afin d'en faciliter l'accès au contenu selon une dimension interne et externe (catalogage, indexation, mise en forme, *etc.*). Ensuite la *redocumentarisation*, qui offre plus de liberté pour réarticuler le contenu des traces selon leur interprétation et leurs usages, sans pour autant produire de nouveaux documents. Cela

n'était pas suffisant pour nos besoins c'est pourquoi nous avons proposé le concept de *redocumentation* des traces que nous avons exposé dans le cadre théorique des transactions communicationnelles afin de pouvoir comparer ce concept aux concepts sous-jacents (*Documentation*, *documentarisation* et *redocumentarisation*). Nous avons supposé qu'au cours du processus de redocumentation, un individu peut interpréter et réécrire les traces d'une activité dans un nouveau document afin de décrire l'activité dans toute sa richesse (décrire le contexte de sa réalisation, le raisonnement de l'utilisateur tracé, etc.). Ainsi, nous avons renforcé le statut documentaire du résultat et le document produit peut être utilisé dans des échanges avec soi-même ou avec d'autres personnes.

Sur le plan pratique, nous avons proposé une approche de redocumentation semi-automatique et assistée par un outil auteur, basée modèles, narrative, qui utilise les principes de RST et qui produit un document doté d'une forme universelle. Nous avons justifié chacun de ces choix comme suit :

- *Approche semi-automatique (interactive) et assistée par un outil auteur* : d'un côté, nous pensons qu'une approche manuelle préserve la liberté de l'utilisateur de s'approprier la description de l'activité tracée et facilite l'expression des informations relatives à son contexte ; cependant, ce type d'approche est souvent coûteux en temps et en effort pour les utilisateurs. De l'autre, nous pensons qu'une approche automatique économise le temps et l'effort de l'utilisateur ; mais qu'elle est trop contraignante pour sa liberté et ne peut pas fournir une description de qualité pour l'activité d'autant plus qu'il est impossible de modéliser formellement tout ce qui peut être impliqué dans une activité. Par conséquent, nous avons opté pour une approche semi-automatique qui permet à l'utilisateur de décider concrètement du contenu et de la forme du document produit, une fois que celui-ci est généré automatiquement à partir de la trace d'activité. Toutefois, pour minimiser l'effort cognitif de l'utilisateur et rendre plus facile son travail de produire un document décrivant l'activité tracée tout en assurant la cohérence de celui-ci, nous avons choisi à ce que le processus de redocumentation soit assisté par une outil auteur.

- *Approche basée modèles* (pour les traces et les documents produits) : nous pensons qu'une approche de modélisation sémantique pour les traces d'activité permet de réduire le contenu de celles-ci à des unités abstraites pouvant être agrégées dans des unités sémantiques de haut-niveau qui soient significatives pour un être-humain et manipulables par la machine. Le but est de rendre plus facile l'intervention de l'utilisateur pour la visualisation, la sélection et la transformation automatique des traces durant le processus de redocumentation. Quant à la modélisation sémantique du document produit, nous pensons qu'elle permet de mettre en place une assistance automatique pour la construction de ce document, sa manipulation et le maintien de sa cohérence. De plus, nous pouvons garder dans ce document des liens vers la trace d'activité redocumentée et différentes possibilités de présentation peuvent être appliquées au document.

- *Approche narrative (basée sur le storytelling)* : les narrations sont les formes les plus naturelles que les êtres humains utilisent pour décrire et partager leurs expériences et connaissances. Ainsi, nous pensons qu'une approche narrative est bien adaptée au processus de redocumentation de l'activité informatique puisqu'elle rend facile le rôle de l'utilisateur à décrire l'activité tracée via la construction d'une histoire. Nous avons adopté la vision de Bal (Bal, 1997) pour la modélisation de la narration car elle fournit le modèle le plus connu et le plus complet pour celle-ci (trois couches : le *fabula*, l'*histoire*, et la *narration*). Pour que la machine puisse produire des narrations, nous supposons qu'il est essentiel de lui fournir une compréhension de la narration à travers des représentations sémantiques pour les différentes

couches de celle-ci. Dans notre cas, nous avons modélisé le *fabula* via la modélisation sémantique des traces d'activité et l'histoire et la narration via la modélisation sémantique du document produit et sa présentation.

- *Approche utilisant les principes de RST* : ce choix est dû à la simplicité de cette théorie et la diversité de ses applications (la génération et l'analyse de textes, la génération de documentaires vidéos, l'aide à l'écriture, etc.). Mais, ce qui nous a intéressée le plus, c'est que RST est également utilisée pour le maintien de la cohérence des documents produits. Par ailleurs, nous avons choisi d'utiliser un sous-ensemble des relations rhétoriques définies par RST, et nous avons pris les relations que nous avons jugées intéressantes pour la description d'une activité modélisée principalement comme l'ensemble de ses actions. Ces relations sont : *Sequence* pour exprimer l'ordre temporel des actions composant l'activité, *Justify* et *Interpretation* pour justifier ou interpréter une action, *Evaluation*, *Purpose* et *solutionhood* pour analyser une situation, *Elaboration*, *Background* et *Enablement* pour ajouter de nouvelles idées, *Summary* et *Introduction* pour fournir une introduction ou une synthèse du contenu, *Contrast* et *joint* pour exprimer des possibilités combinées ou alternatives. Nous estimons que l'utilisation d'un grand nombre de types de relations aurait risqué de créer des confusions pour l'utilisateur de celles-ci durant la phase de redocumentation interactive.

- *Approche dont le produit a une forme universelle (hypermédia)* : Pour notre approche générale de redocumentation, nous n'avons imposé aucune contrainte sur la forme du document produit ; au contraire, nous avons supposé une forme universelle (hypermédia).

Le modèle de trace d'activité que nous avons proposé est un modèle simple et générique qui peut être spécifié pour des activités concrètes. Dans ce modèle, nous avons mis l'accent sur les éléments qui caractérisent (le plus) l'activité en se référant aux travaux de modélisation de celle-ci et au méta-modèle de la trace d'activité du SBT. Ainsi, nous avons modélisé la trace d'activité comme un ensemble d'actions (éléments observés) caractérisées par leur temporalité (un intervalle de temps ou un instant caractérisant l'occurrence de l'action) ; celles-ci manipulent des entités (objets ou ressources) et concernant un utilisateur particulier. Bien que cette modélisation puisse être appliquée à une bonne partie des activités informatiques ; nous tenons à préciser qu'elle a tout de même ses limites. Par exemple, elle ne peut pas être appliquée à une activité collective (menée par plusieurs utilisateurs) tel le cas *des activités collaboratives*. Quant au **modèle de document proposé**, c'est un modèle générique qui prend en considération la multi-structuralité du document numérique. Nous avons focalisé cette modélisation sur la structure sémantique (rhétorique) du document, sans pour autant négliger les deux autres structures (logique et physique). Ce choix est dû à notre besoin principal de produire et de manipuler un document tout en préservant sa cohérence, car c'est la structure rhétorique du document qui permet de transmettre le sens du contenu du document en attribuant une fonction particulière à chacune des parties de ce contenu. Cette structure peut être facilement implémentée comme un modèle formel et ceci facilite la création de documents cohérents en se basant sur des règles rhétoriques à implémenter et à respecter. Pour les structures logique et physique du document permettant la présentation de celui-ci, nous avons proposé l'utilisation de modèles prédéfinis pour des raisons de simplicité ; mais nous avons également supposé une possibilité d'intervention de l'utilisateur pour le choix de certaines propriétés de ces modèles (couleur, font, etc.).

L'originalité de l'approche de redocumentation que nous avons proposée ne se limite pas à l'abstraction et à la modélisation sémantique des données manipulées (traces et documents) ; elle réside également dans la façon de maintenir, tout au long du processus de

redocumentation, suffisamment d'informations exploitables automatiquement afin de pouvoir supporter ce processus et assister l'utilisateur à construire de façon naturelle une histoire de l'activité tracée. Cette approche peut être utilisée pour la redocumentation de toute activité informatique à condition que les traces de celles-ci soient modélisées selon le modèle de trace que nous avons proposé. Pour une première spécification de l'approche proposée nous sommes intéressée au cas particulier de la redocumentation par le texte. Nous avons choisi une forme textuelle pour le produit documentaire final car il s'agit d'une forme familière et facilement échangeable pour les utilisateurs. Toutefois, cette spécification a ajouté une nouvelle contrainte sur le type d'activités informatiques à redocumenter : en plus du fait que l'on ne peut redocumenter que les activités tracées dont le modèle de traces correspond au modèle de trace proposé ; les actions de l'activité à redocumenter ne doivent alors pas se chevaucher dans le temps. Avec une activité composée d'actions qui durent dans le temps et qui se chevauchent, les segments textuels générés automatiquement à partir de ces actions (durant la phase de redocumentation automatique) ne peuvent pas être présentés comme un texte linéaire (par la relation séquence).

L'outil auteur ActRedoc que nous avons développé comme une implémentation de cette approche spécifique utilise différentes technologies du Web Sémantique : les ontologies pour modéliser les traces et les documents produits, un outil de génération du langage naturel (NaturalOWL) et une spécification (RDFa) pour enrichir les données visuelles des documents produits avec des métadonnées. Nous avons choisi les ontologies car elles offrent un mécanisme de conceptualisation et de formalisation de données, à la fois naturel et puissant, mais également parce que plusieurs outils sont disponibles pour la création et la manipulation de ces ontologies (éditeurs, raisonneurs, APIs, *etc.*). Nous avons choisi le générateur NaturalOWL en particulier parce qu'il permet de générer des descriptions textuelles à partir des instances d'une ontologie en OWL (l'ontologie de trace dans notre cas) et qu'il s'intègre facilement dans notre outil auteur. Quant au format hypertexte enrichi de métadonnées (XHTML+RDFa) que nous avons proposé pour le document final exporté, il permet de garder, à l'intérieur des documents produits de la redocumentation des traces d'activité, des liens vers ces traces ainsi que des liens avec les éléments de l'ontologie de document (segments et relations rhétoriques) ; ce qui rend possible l'interrogation sémantique du contenu de ces documents.

L'utilisation de l'outil ActRedoc pour la redocumentation d'une activité concrète nécessite le traçage de l'activité, la modélisation de ses traces par une ontologie (en OWL) qui spécialise notre modèle générique de trace et la préparation des fichiers des annotations linguistiques indispensables pour le fonctionnement de NaturalOWL. L'activité de navigation dans le site de la « Presse Illustrée » a été choisie comme **terrain applicatif** pour plusieurs raisons. Tout d'abord, cette application supportant l'activité à redocumenter est accessible à tous (site public) ; ainsi, nous avons pu tester cette application et faire réaliser l'activité sous-jacente par plusieurs utilisateurs. Nous avons également pu instrumenter l'application (en collaboration avec le développeur de celle-ci) avec un module de traçage pour tracer l'activité en question et modéliser les traces de celle-ci selon notre modèle générique. Ensuite, l'objectif de l'application était d'offrir aux lecteurs du corpus numérique (de journaux) une reconstitution du contexte spatial et temporel dans lequel ces fonds ont été produits ; nous avons alors choisi d'offrir à ces lecteurs la possibilité de construire leurs propres documents à partir de ces sources et de la façon dont ils exploitent celles-ci afin de partager leurs expériences de navigation, leurs évaluations de ces sources, *etc.* Ainsi, les documents produits peuvent être regroupés dans une base documentaire dotée de services d'accès par contenu

sémantique. Le choix du protocole de l'étude préliminaire de l'ergonomie de l'outil ActRedoc visait l'évaluation de l'utilisabilité et de l'utilité de l'outil tout en minimisant le coût des tests ; cela en utilisant un nombre minimal mais bien choisi de traces et d'utilisateurs.

Perspectives

Notre travail futur se focalisera sur l'amélioration de nos propositions théoriques et pratiques afin de pouvoir aller plus loin dans la mise en place du processus de redocumentation de l'activité informatique. Ces améliorations vont concerner :

- **Le modèle de trace** : le modèle de trace que nous avons proposé est un modèle simple qui peut être amélioré pour rendre l'approche de redocumentation proposée applicable à d'autres types d'activités informatiques. En premier lieu pour les activités collectives (réalisées par plusieurs utilisateurs), nous pourrions modifier le modèle de trace de telle sorte que l'utilisateur (la classe *Utilisateur*) soit lié à l'action au lieu de concerner la trace en entier. Ainsi, la trace d'une même activité pourra comporter les actions de différents utilisateurs, ce qui est nécessaire dans le cas d'une activité collaborative par exemple. Le concept d'élément observé (*obsel*) figurant dans le modèle de trace peut également être étendu pour désigner autres choses que les actions : nous pouvons considérer les ressources (entités) manipulées par ces actions comme des éléments observés. En effet, lorsqu'un utilisateur réalise une activité qui produit des documents par exemple, ces documents avec l'ordre temporel de leur production peut former une trace de l'activité réalisée. Ainsi, nous souhaitons combiner dans le modèle de trace proposé deux visions : une vision centrée sur les actions et une autre centrée sur les données manipulées et produites par ces actions. Par la suite, et durant le processus de redocumentation, nous pensons qu'il sera utile de combiner les deux visions dans la description de l'activité ou de laisser le choix à l'utilisateur de focaliser le processus sur la construction de l'histoire du déroulement des actions de l'activité ou plutôt sur la construction de l'histoire des ressources exploitées (leur création, leur modification, leur échange, *etc.*). Nous pouvons également monter d'un niveau d'abstraction dans la modélisation de la trace d'activité en considérant des sous-activités ; cependant, plus le modèle de trace est compliqué et plus la mise en place du processus de redocumentation devient difficile.

- **Le modèle de document** : nous avons proposé un modèle générique de document qui prend en considération les trois niveaux sémantique, logique et physique. Cependant, du point de vue modélisation, nous n'avons décrit en détail que la structure sémantique sous la forme de structure rhétorique. Nous pensons qu'il sera intéressant de pouvoir modéliser les deux autres structures et de prendre en charge leur manipulation durant le processus même de redocumentation de l'activité informatique. Ainsi, l'utilisateur pourra choisir les différents aspects de présentation du document produit sans être contraint par des modèles prédéfinis. Nous pensons également que chacune de ces structures (physique et logique) du document pourrait être modélisée comme un ensemble de segments et de relations, sans pour autant confondre ceux-ci avec les segments de contenu et leurs relations rhétoriques. Par exemple, au niveau logique, un segment peut correspondre à l'organisation d'un ensemble de segments du contenu et d'un sous ensemble des relations rhétoriques existantes entre ces segments. Cela, correspond à ce que nous avons expliqué dans l'approche de redocumentation en texte, à savoir que les contenus de plusieurs segments textuels consécutifs et les relations rhétoriques menées par ces segments peuvent être exprimés dans un seul paragraphe (segment du niveau logique). Similairement, un segment du niveau physique peut attribuer un ensemble de propriétés visuelles à un (ou à plusieurs) segment(s) du niveau logique (e.g. police, couleur, *etc.*).

- **L'implémentation de l'approche générale de redocumentation** : nous avons pu implémenter l'approche de redocumentation de l'activité informatique par le texte ; mais les modalités de redocumentation présentées dans ce cas sont relativement simples et contraignantes en ce qui concerne la forme du document produit (du texte). Nous souhaitons ainsi implémenter l'approche générale de redocumentation de façon à produire d'autres types de rendus. Par exemple, nous souhaitons pouvoir produire une animation mettant en scène la trace d'activité ; ceci ressemblera à un processus de montage au sens cinématographique du terme. Pour atteindre un tel objectif, nous pensons que nous devrions utiliser ou développer un outil similaire à NaturalOWL mais capable de produire des animations (vidéos) à partir des éléments observés de la trace (e.g. les actions) qui sont décrits par un modèle formel (l'ontologie de trace). Ces animations, en tant que segments documentaires, peuvent alors être exploitées de façon à constituer un document fragmenté ; celui-ci pourra être manipulé par l'utilisateur (via des opérations rhétoriques et organisationnelles) puis exporté comme une vidéo annotée décrivant l'activité tracée. Durant la phase de redocumentation interactive, le rôle des opérations rhétoriques relèvera plus de l'annotation des segments du document manipulé, tandis que l'ensemble des opérations organisationnelles pourra être enrichi avec de nouvelles opérations adaptées à la forme du document (vidéo).

- **L'outil de redocumentation en texte *ActRedoc*** : via notre étude préliminaire de l'utilisation de l'outil *ActRedoc*, nous avons identifié les aspects pouvant être améliorés dans celui-ci. Tout d'abord, dans l'interface de l'outil, nous pensons qu'il sera intéressant de représenter les segments et les relations du document manipulé sous forme de graphe interactif. Nous tenons également à améliorer les expressions textuelles générées par NaturalOWL (ou utiliser un autre outil) et à produire un document initial plus pertinent que celui produit actuellement en utilisant des principes supplémentaires de génération automatique de texte (e.g. éviter la répétition des mêmes expressions dans des segments consécutifs du document initial). Nous pensons étudier l'intérêt de chacune des relations rhétoriques utilisables via les opérations supportées par *ActRedoc* afin de réduire cet ensemble (supprimer les relations *SolutionHood*, *Joint* et *contrast* par exemple car nous avons constaté qu'elles étaient peu utilisées) ; ceci dans le but de faciliter le travail de l'utilisateur qui nous semble avoir des difficultés à maîtriser l'utilisation de toutes ces relations. Nous voudrions également offrir plus de liberté à l'utilisateur pour personnaliser la présentation du document final (via la manipulation de sa structure logique et physique) et enrichir sa forme avec d'autres médias (hypermédia). Par exemple, pour le terrain applicatif choisi, il est possible d'incorporer dans le document produit des photos des articles et des illustrations manipulées durant l'activité de navigation dans la « Presse Illustrée ». En outre, nous tenons à tester l'outil *ActRedoc* dans la redocumentation d'autres activités informatiques, éventuellement collaboratives. Le contexte applicatif auquel nous pensons actuellement est la redocumentation des traces d'utilisation d'un outil bibliographique (Zotero) ayant une dimension collaborative. Toutefois, nous veillerons à faire les tests auprès d'utilisateurs engagés dans le processus afin d'évaluer au mieux l'utilité de notre outil de redocumentation.

Bibliographie

- Abascal, R., Beigbeder, M., Bénel, A., Calabretto, S., Chabbat, B., Champin, P., Jouve, D., Prié, Y., Rumpler, B., Thivant, E., 2004. Documents à structures multiples. In Proceedings of SETIT 2004, Susa, Tunisia.
- Adam, J.-M., 2001. Types de textes ou genres de discours ? Comment classer les textes qui disent de faire quelque chose et comment faire?. *Langages journal* (141), pp. 10–27.
- Adida, B., Birbeck, M., 2008. RDFa primer: Bridging the Human and Data Webs. W3C Working Group Note 14 October 2008. Lien : <http://www.w3.org/TR/xhtml-rdfa-primer/>
- Ahmed, M., Hoang, H.H., Karim, M.S., Khusro, S., Lanzenberger, M., Latif, K., Michlmayr, E., Mustofa, K., Nguyen, H.T., Rauber, A., others, 2004. Semanticlife-a framework for managing information of a human lifetime. In Proceedings of the 6th International Conference on Information Integration and Web-based Applications and Services.
- Androutopoulos, I., Oberlander, J., Karkaletsis, V., 2006. Source authoring for multilingual generation of personalised object descriptions. *Natural Language Engineering* 13(3), pp. 191–233.
- Anjewierden, A., Efimova, L., 2006. Understanding weblog communities through digital traces: a framework, a tool and an example. In Proceedings of OTM Confederated International Workshops, Springer LNCS 4278, Montpellier, France, pp. 279–289.
- Anon, 1937. La terminologie de la documentation. *Coopération Intellectuelle* 77, pp. 228–240.
- Antipolis, S., 1990. A debugging environment for functional programming in CENTAUR. Rapport de recherche de l'INRIA/CENTAUR (n° 1265).
- Appan, P., Sundaram, H., Birchfield, D., 2004. Communicating everyday experiences. In Proceedings of the 1st ACM Workshop on Story Representation, Mechanism and Context, pp. 17–24.
- Araszkiewicz, J., 2003. Notes sur la théorie du genre. In Colloque sur le genre journalistique. Lien : http://archivesic.ccsd.cnrs.fr/sic_00000855/en/
- Aussenac-Gilles, N., Condamines, A., 2004. Documents électroniques Et Constitution De Ressources Terminologiques Ou Ontologiques. *Information-Interaction-Intelligence* 4(1), pp. 75–93.
- Avouris, N., Margaritis, M., Komis, V., 2004. Modelling interaction during small-group synchronous problem-solving activities : The Synergo approach. In Proceedings of 7th International Conference on Intelligent Tutoring Systems (ITS 2004), Maceio, Brasil, pp. 13–18.
- Azouaou, F., 2003. Formalisme pour une mémoire de formation à base d'annotations : articule sémantique implicite et explicite. In Actes de la conférence Environnements Informatiques Pour l'Apprentissage Humain (EIAH 2003), pp. 43–54.

- Bachimont, B., 1999. Bibliothèques numériques audiovisuelles : des enjeux scientifiques et techniques. *Document Numérique* 2(3-4), pp. 219–242.
- Bachimont, B., 2004. Pourquoi n’y a-t-il pas d’expérience en ingénierie des connaissances ?. In Actes des Journées francophones d’ingénierie des connaissances (IC’04), Lyon, France, pp. 53–64.
- Badre, A., Santos, P., 1991. A knowledge based system for capturing humancomputer interaction events: CHIME. Rapport technique (GIT-GVU-91-21).
- Bailey, P., 1999. Searching for storiness: Story-generation from a reader’s perspective. In Working Notes of the Narrative Intelligence Symposium, pp. 157–164.
- Baker, M., Lund, K., 1997. Promoting reflective interactions in a computer supported collaborative learning environment. *Journal of Computer Assisted Learning* 13(1), pp. 175–193.
- Baker, M., Quignard, M., Lund, K., Séjourné, A., 2003. Computer-supported collaborative learning in the space of debate. In Proceedings of the International Conference on Computer Support for Collaborative Learning, pp. 11–20.
- Bakhtine, M., 1984. *Esthétique de la création verbale*. Gallimard (Eds).
- Bal, M., 1997. *Narratology: introduction to the theory of narrative*. University of Toronto Press.
- Balasubramanian, V., 1994. State of the Art Review on Hypermedia Issues And Applications. Rapport, Graduate school of management, Rutgers University, Newark, NJ.
- Barbier, F., 2002. Chez les Levrault : un éditeur et ses auteurs, années 1820-1870. *Revue française d’histoire du livre*.
- Barrutieta, G., Abaitua, J., Diaz, J., 2002. An XML/RST-based approach to multilingual document generation for the web. In Proceedings of the Natural Language (n° 29), Italy, pp. 247–253.
- Barthes, R., 1984. *La mort de l’auteur*. Paris, Le Seuil (Eds). Repris dans *Le Bruissement de la langue*.
- Bates, P.C., 1995. Debugging heterogeneous distributed systems using event-based models of behavior. *ACM Trans on Computer Systems*.
- Beauvisage, T., 2004. Sémantique des parcours des utilisateurs sur le Web. Thèse de doctorat en Sciences du langage, Université Paris X, France, 361 p.
- Bertrand, R., 2005. Documents Multi-structurés, Du point de vue de l’usage. Mémoire de Master Recherche, INSA, EDIIS (Ecole Doctorale Informatique et Information pour la Société). Université Lyon 1, France.
- Bétrancourt, M., Guichon, N., Prié, Y., 2011. Assessing the use of a trace-based synchronous tool for distant language tutoring. In Proceedings of the 9th International Conference on Computer Supported Collaborative Learning, Hong Kong, pp. 486–493.
- Bocconi, S., Nack, F., Hardman, L., 2005. Using rhetorical annotations for generating video documentaries. In Proceedings of Multimedia and Expo 2005, pp. 16–19.
- Bourgeois, D., 2002. le statut du document numérique et sa diffusion. In Communication à la journée d’étude du CERC: “Métamorphoses du lecteur et de l’auteur”, Nantes, France.

- Branigan, E., 1992. *Narrative Comprehension and Film*. 1st edition, Routledge (Eds).
- Bratitsis, T., Dimitracopoulou, A., 2006. Indicators for measuring quality in asynchronous discussion forums. In Proceedings of the International Conference on Cognition and Exploratory Learning in Digital Era (CELDA2006), Barcelona.
- Briet, S., 1951. *Qu'est ce que la documentation ?*. Editions Documentaires Industrielles et Techniques - EDIT, Paris.
- Brinkman, W., Gray, P., Renaud, K., 2006a. Pre-Processing and Analysis of User Interaction Data. In Proceedings of Human-Computer Interaction Conference, Londres.
- Brinkman, W., Gray, P., Renaud, K., 2006b. Computer-Assisted Recording, Pre-Processing and Analysis of User Interaction Data. In Proceedings of Human-Computer Interaction Conference, Londres.
- Brooks, K.M., 1997. Do story agents use rocking chairs? The theory and implementation of one model for computational narrative. In Proceedings of the 4th ACM International Conference on Multimedia, pp. 317–328.
- Bruner, J., 1973. L'organisation des premiers savoir-faire. *Le développement de l'enfant, savoir dire, savoir faire*, Paris, PUF.
- Brusilovsky, P., Kobsa, A., Vassileva, J., 1998. *Adaptive hypertext and hypermedia*. Springer (Eds), 274 p.
- Buckland, M.K., 1997. What is a “document”?. *Journal of the American Society for Information Science* 48(9), pp. 804–809.
- Bush, V., 1945. As We May Think. *The Atlantic Monthly* 176(1), pp. 101–108.
- Byrne, D., Jones, G.J., 2009a. Digital life stories: narrating personal experience from SenseCam collections. Lien : http://doras.dcu.ie/15122/1/SenseCam_WS__Poster_DByrne_1.7.pdf
- Byrne, D., Jones, G.J.F., 2009b. Creating stories for reflection from multimodal lifelog content: an initial investigation. In the Designing for Reflection on Experience, Workshop at CHI 2009, Boston, USA, pp. 09–14.
- Catledge, L., Pitkow, J., 1995. Characterizing browsing strategies in the World-Wide Web. *Computer Networks and ISDN Systems* 27(6), pp. 1065–1073.
- Champin, P.A., Prié, Y., Mille, A., 2004. MUSERTE: a Framework for Knowledge Capture from Experience. In Proceedings of WS5, From Structured Cases to Unstructured Problem Solving Episodes For Experience-Based Assistance (at ICCBR'03), Trondheim, Norway, pp. 279–294.
- Charbonnaud, C., Mercier, R., 2005. LogManager: manage your security logs. Lien : <http://web.ossir.org/resist/supports/cr/20050926/LogManager.pdf>
- Chatterjee, P., Hoffman, D.L., Novak, T.P., 2003. Modeling the clickstream: Implications for web-based advertising efforts. *Marketing Science* 22(4), pp.520–541.
- Chen, J., Sun, L., Zaiane, O., Goebel, R., 2004. Visualizing and discovering web navigational patterns. In Proceedings of the 7th International Workshop on the Web and Databases : Colocated with ACM SIGMOD/PODS, Paris, France, pp. 13–18.
- Chi, E., 2002. Improving web usability through visualization. *IEEE Internet Computing archive* 6(2), pp.64–71.

- Choquet, C., Iksal, S., 2007. Modeling Tracks for the Model Driven Re-engineering of a TEL System. *Journal of Interactive Learning Research* 18(2), pp.161–184.
- Christophides, V., 1998. Document Management Systems. Lien : <http://www.ics.forth.gr/~christop/>
- Cockburn, A., McKenzie, B., JasonSmith, M., 2002. Pushing Back: Evaluating a New Behavior for the Back and Forward Buttons in Web Browsers. *International Journal of Human-Computer Studies* 57(5), pp. 397–414.
- Compagon, A., 1998. *Le démon de la théorie: Littérature et sens commun*. Paris, Le Seuil (Eds), 51 p.
- Cram, D., 2007. Visualisation de Traces : Application aux Traces Réflexives d'eLycée. Rapport de stage, laboratoire LIRIS, Lyon, France.
- Daubert, J., Eliot, J., 2010. L'histoire au coeur de la société numérique. *Actionmiroir.com, Le reflet des numériques*. Lien : <http://www.actionmiroir.com/2010/05/lhistoire-au-coeur-de-la-societe-numerique/>
- De Silva, N., Henderson, P., 2005. Narrative support for technical documents: Formalising rhetorical structure theory. In Proceedings of Enterprise Information Systems (In Press), pp. 10–16.
- Demaiziere, F., 1996. Multimédia et enseignement des langues : rêves, craintes et réalités nouvelles. *Les Langues modernes* 90(1), pp.19–27.
- Derrida, J., 1972. *La différence, Marges de la philosophie*. Paris, Minuit (Eds).
- Després, C., Coffinet, T., 2004. Reflet, un miroir sur la formation. In Actes de la Conférence Internationale Sur Les Technologies De l'Information Et De La Connaissance Dans l'Enseignement Supérieur Et l'Industrie, Compiègne, France, pp. 19–24.
- Després, C., Leroux, P., 2003. Le tutorat synchrone en formation à distance : un modèle pour le suivi pédagogique synchrone d'activités d'apprentissage à distance. In Actes de la conférence Environnements Informatiques pour l'Apprentissage Humain, Strasbourg, France.
- Djemaï, K., Soulé-Dupuy, C., Vallès-Parlangeau, N., 2009. Multistructured documents: from modelling to multidimensional analyses. *SciWatch Journal* 2(4), pp. 12–24.
- Dubois, J., Dao-Duy, J., Eldika, S., 2000. L'analyse des traces informatiques des usages : un outil pour valider la conception d'un site web. In Actes Des Rencontres des Jeunes Chercheurs En Interaction Homme- Machine, Ile de Berder, pp. 85–89.
- Ducasse, S., Gîrba, T., Wuyts, R., 2006. Object-Oriented Legacy System Trace-based Logic Testing. In Proceedings of the 10th European Conference on Software Maintenance and Reengineering (CSMR 2006), IEEE Computer Society Press, pp. 35–44.
- Etiévant, H., 2004. Journalisation des événements avec l'API Logging de Java. Lien : <ftp://ftp-developpez.com/cyberzoide/java/logging.pdf>
- Ferraris, C., Martel, M., Vignollet, L., 2007. Helping teachers in designing CSCL Scenarios: a methodology based on the LDL Language. In Proceedings of the 8th International Conference on Computer Support for Collaborative Learning (CSCL'07), New Brunswick, New Jersey, USA, pp. 193–195.

- Ferrer, D., 1997. *Le matériel et le virtuel : du paradigme indiciaire à la logique des mondes possibles*. CNRS (Eds), Pourquoi la critique génétique ? Méthodes, théories, Paris.
- Fisher, W.R., Arnold, C.C., 1989. *Human Communication as Narration: Toward a Philosophy of Reason, Value, and Action*. University of South Carolina Press, 201 p.
- Foucault, M., 1969. Qu'est-ce qu'un auteur ?. *Bulletin de la Société française de philosophie*, 63ème année 3(1), pp. 73–104.
- Frenzel, K., Müller, M., Sottong, H., 2004. *Storytelling*. Das Harun-al-Raschid-Prinzip, München: Hanser (Eds), 319 p.
- Galan, G., 2002. L'analyse des fichiers log pour étudier l'impact de la musique sur le comportement des visiteurs d'un site Web culturel. In Actes Du 18ème Congrès International De l'Association Française De Marketing, Lille, France.
- Galanis, D., Androutsopoulos, I., 2007. Generating multilingual descriptions from linguistically annotated OWL ontologies: the NaturalOWL system. In Proceedings of the 11th European Workshop on Natural Language Generation, pp. 143–146.
- Gallezot, G., 2000. Normes et standards dans le processus de traitement du document numérique en biologie moléculaire. *Revue SOLARIS*, dossier n° 6.
- Gandhe, S., Whitman, N., Traum, D., Artstein, R., 2009. An integrated authoring tool for tactical questioning dialogue systems. In Proceedings of the 6th Workshop on Knowledge and Reasoning in Practical Dialogue Systems, Pasadena, California, USA.
- Gemmell, J., Aris, A., Lueder, R., 2005. Telling stories with MyLifeBits. In Proceedings of IEEE International Conference on Multimedia & Expo, pp. 1536–1539.
- Georgeon, O., 2008. Analyse de traces d'activité pour la modélisation cognitive : Application à la conduite automobile. Thèse de doctorat en informatique, Université de Lyon, France.
- Georgeon, O., Mille, A., Bellet, T., 2006. Abstract: un outil et une méthodologie pour analyser une activité humaine médiée par un artefact technique complexe. In: Actes Des Journées Francophones De l'Ingénierie Des Connaissances (IC 2006), Nantes.
- Ginzburg, C., 1989. Traces : Racines d'un paradigme indiciaire. In Mythes, Emblèmes, Traces, - Morphologie Et Histoire, Paris, pp. 139–180.
- Goodman, B.A., Linton, F.N., Gaimari, R.D., Hitzeman, J.M., Ross, H.J., Zarrella, G., 2005. Using Dialogue Features to Predict Trouble During Collaborative Learning. *User Modeling and User-Adapted Interaction* 15(1-2), 85–134.
- Gray, P., McLeod, I., Draper, S., Crease, M., Thomas, R., 2004. A Distributed Usage Monitoring System. In Proceedings of Computer-Aided Design of User Interfaces IV (CADUI 2004), Madeira, Portugal, pp. 121–132.
- Guillot, M., 1973. Pourquoi un service de documentation d'entreprise. *Paris Management France*.
- Guimbretière, F., Dixon, M., Hinckley, K., 2007. ExperiScope: an analysis tool for interaction data. In Proceedings of Computer Human Interaction (CHI'07), San Jose, California, pp. 1333–1342.
- Halvey, M., Keane, M., Smyth, B., 2005. Time based segmentation of log data for user navigation prediction in personalization. *Web Intelligence IEEE Computer Society*,

- Skowron A., Agrawal R., Luck M., Yamaguchi T., Morizet- Mahoudeaux P., Liu J., Zhong N. (Eds), pp. 636–640.
- Hanoune, M., Benabbou, F., 2006. Traitement et exploration du fichier Log du Serveur Web, pour l'extraction des connaissances: Web Usage Mining. *Afrique Science* 2(3).
- Harper, R., Randall, D., Smythe, N., Evans, C., Heledd, L., Moore, R., 2007. Thanks for the memory. In Proceedings of the 21st British HCI Group Annual Conference on People and Computers: HCI...but Not as We Know It - Volume 2, BCS-HCI '07. British Computer Society, Swinton, UK, UK, pp. 39–42.
- Hauser, J.R., Urban, G.L., Liberali, G., Braun, M., 2009. Website morphing. *Marketing Science* 28(2), pp. 202–223.
- Hawkey, K., Inkpen, K., 2005. Privacy gradients: exploring ways to manage incidental information during co-located collaboration. In Proceedings of CHI 2005, Portland, pp. 1431–1434.
- Heraud, J., France, L., Mille, A., 2004. Pixed: an its that guides students with the help of learners' interaction log. In Proceedings of the 7th International Conference on Intelligent Tutoring Systems (Workshop Analyzing Student-Tutor Interaction Logs to Improve Educational Outcomes), Maceio, pp. 57–64.
- Hightower, R., Ring, L., Helfman, J., Bederson, B., Hollan, J., 1998. Graphical Multiscale Web Histories: A Study of PadPrints. In Proceedings of the ACM Conference on Hypertext, ACM Press, pp. 58–65.
- Hilbert, D.M., Redmiles, D.F., 2000. Extracting Usability information from User Interface Events. *ACM Computing Surveys* 32(4), pp. 384–421.
- Hill, W., Hollan, J., Wroblewski, D., McCandless, T., 1992. Edit wear and read wear. In Proceedings of the SIGCHI Conference on Human Factors in Computing Systems, ACM, Monterey, California, United States, pp. 3–9.
- Iksal, S., Garlatti, S., 2002. Spécification déclarative pour des documents virtuels personnalisables. In Actes du congrès Documents virtuels personnalisables (DVP 2002), Brest, pp. 127–140.
- Ioannides, D., 2007. A study of information fragment association in information management and retrieval applications. Phd thesis in Philosophy, University of Pittsburgh.
- Jansen, B., Pooch, U., 2000. A Review of Web Searching Studies and a Framework for Future Research. *American Journal of Society of Information Science* 52(3), pp. 235–246.
- K. Achilleos, 2010. Evolution of lifelogging. In Proceedings of Multimedia Systems Conference 2010, University of Southampton, UK, pp. 20–25.
- Kaptelinin, V., 1996. Activity theory: implications for human-computer interaction. *Context and consciousness: Activity theory and human-computer interaction*, pp. 103–116.
- Kaptelinin, V., 2003. UMEA: translating interaction histories into project contexts. In Proceedings of the SIGCHI Conference on Human Factors in Computing Systems, ACM Press, pp. 353–360.
- Kelliher, A., Davenport, G., 2007. Everyday Storytelling: supporting the mediated expression of online personal testimony. *Humain Computer Interaction* 4(1), pp. 926–933.

- Kevin, K., 2007. Lifelogging, An Inevitability. Lien : http://www.kk.org/thetechnium/archives/2007/02/lifelogging_an.php
- Khademi, M., Haghshenas, M., Kabir, H., 2011. A review on Authoring Tools. In Proceedings of the International Conference on Distance Learning and Education (ICDLE 2011), pp. 16–18.
- Kim, S., Alani, H., Hall, W., Lewis, P., Millard, D., Shadbolt, N., Weal, M., 2002. Artequakt: Generating tailored biographies from automatically annotated fragments from the web. In Proceedings of Workshop on Semantic Authoring, Annotation & Knowledge Markup (SAAKM'02), Lyon, France, pp. 1–6.
- Koper, R., Olivier, B., Anderson, T., 2003. IMS Learning Design Information Model. Presented at the IMS Global Consortium.
- Kurlander, D., Feiner, S., 1992. A history-based macro by example system. In Proceedings of the 5th Annual ACM Symposium on User Interface Software and Technology (UIST'92), ACM, New York, NY, USA, pp. 99–106.
- Laflaquière, J., 2009. Conception de système à base de traces numériques dans les environnements informatiques documentaires. Thèse de doctorat en informatique, Université de technologie de Troyes, France, 241 p.
- Laflaquière, J., Champin, P., Prié, Y., Mille, A., 2005. Approche de modélisation de l'expérience d'utilisation de systèmes complexes pour l'assistance aux tâches de veille informatiquement médiées. In Actes de ISKO-France'2005, INIST/CNRS Nancy, France, pp. 209–230.
- Laflaquière, J., Settouti, L.S., Prié, Y., Mille, A., 2007. Traces et inscriptions de connaissances. In Actes des journées francophones De Ingénierie Des Connaissances (IC'07), pp. 329–331.
- Lalanne, D., Ingold, R., Vonrotz, D., 2005. Intégration de documents dans des archives multimédias de réunions. *IM2. DI*.
- Laperrousaz, C., 2006. Le suivi individuel d'apprenants engagés dans une activité collective à distance, TACSI: un Environnement informatique support aux activités du tuteur. Thèse de doctorat en informatique, Université de Maine.
- Latour, B., 2007. Beware, your imagination leaves digital traces. *Times (Higher Literary Supplement)* n° 129.
- Lee, B., 1996. Remote diagnostics and product lifecycle monitoring for high-end appliances: a new Internet-based approach utilizing intelligent software agents. In Proceedings of the Appliance Manufacturer Conference.
- Lemoine, P., 2005. Traces actives et sécurité: les libertés à l'épreuve des traces. Lien : <http://www.cnil.fr/index.php?id=2080>
- Lesgold, Lajoie, S., Bunzo, M., Eggan, G., 1992. SHERLOCK: A coached practice environment for an electronics troubleshooting job. *Computer Assisted Instruction and Intelligent Tutoring Systems Shared Goals and Complementary Approaches*, pp. 201–238.
- Lettkeman, T., Stumpf, S., Irvine, J., Herlocker, J., 2006. Predicting Task-Specific Webpages for Revisiting. In Proceedings of the National Conference on Artificial Intelligence (AAAI-06), Boston, USA.

- Lieberman, H., 2001. Interfaces that give and take advice. In *Human– Computer Interaction in the New Millennium*, J.M. Carroll (Eds), The ACM Press, pp. 475–484.
- Linard, M., 2001. Concevoir des environnements pour apprendre. *Sciences et techniques éducatives* 8(3-4).
- Linard, M., 2002. Conception de dispositifs et changement de paradigme en formation. *Éducation permanente* 152(1), pp. 143–155.
- Lindley, S.E., Randall, D., Sharrock, W., Glancy, M., Smyth, N., Harper, R., 2009. Narrative, memory and practice: tensions and choices in the use of a digital artefact. In *Proceedings of the 23rd British HCI Group Annual Conference on People and Computers: Celebrating People and Technology*, pp. 11–19.
- Lund, N.W., Skare, R., 2010. Document Theory. *Encyclopedia of Library and Information Sciences, 3ème édition* 1(1), pp. 1632–1639.
- Luria, A.R., 1982. *Language and cognition*. James V. Wertsch (Eds), New York, Wiley.
- Maes, P., 1990. Situated agents can have goals. *Robotics and autonomous systems* 6(1-2), pp. 49–70.
- Mahmud, R., 2003. Possible Attributes For Identifying Discourse Relations For A Reflective Learning Tool. *Computational Linguistics*, UK.
- Mann, W., Thompson, S., 1988. Rhetorical structure theory: Toward a functional theory of text organization. *Text* 8(3), pp. 243–281.
- Martin, P., Alpay, L., 1996. Conceptual Structures and Structured Documents. In *Proceedings of the 4th International Conference on Conceptual Structures (ICCS'96)*, Volume 1115 of *Lecture Notes in Artificial Intelligence*, Springer-Verlag, pp. 145–159.
- Marty, J., Heraud, J., Carron, T., France, L., 2004. A quality approach for collaborative learning scenarios. *Learning Technology Newsletter of IEEE Computer Society* 6(4), pp. 46–48.
- Marty, J., Heraud, J., France, L., Carron, T., 2007. Matching the Performed Activity on an Educational Platform with a Recommended Pedagogical Scenario: a Multi Source Approach. *Journal of Interactive Learning Research* 18(2), pp. 267–283.
- Mayer, M., George, S., Prévôt, P., 2008. A Closer Look at Tracking Human & Computer Interactions in Web-Based Communications. *International Journal of Interactive Technology and Smart Education* 5(3), 170–188.
- Mazza, R., Dimitrova, V., 2003. CourseVis: Externalising Student Information to Facilitate Instructors in Distance Learning. In *Proceedings of the International Conference on Artificial Intelligence in Education (AIED 2003)*, Sydney, Australia, pp. 279–286.
- Mille, A., 2006a. From case-based reasoning to traces-based reasoning. *Journal of IFAC* 30(2), pp. 223–232.
- Mille, A., 2006b. Raisonner à Partir de l'Expérience Tracée. In *Le Storytelling : Concepts, Outils Et Applications*, *Traité IC2, Série Informatique Et SI*, Hermes Science (Eds).
- Mille, A., Prié, Y., 2006. Une théorie de la trace informatique pour faciliter l'adaptation dans la confrontation logique d'utilisation/logique de conception. In *the 13eme Journées de Rochebrune - Traces, Enigmes, Problèmes : Emergence et construction du sens -*

- Rencontres interdisciplinaires sur les systèmes complexes naturels et artificiels, Rochebrune, pp. 1–12.
- Mobasher, B., Cooley, R., Srivastava, J., 2000. Automatic Personalization Based On Web Usage Mining. *Communication of ACM* 43(8), pp. 142–151.
- Moran, T.P., 2005. Unified activity management: explicitly representing activity in work-support systems. In Proceedings of the European Conference on Computer-Supported Cooperative Work (ECSCW 2005), Workshop on Activity: From Theoretical to a Computational Construct.
- Morse, E., Steves, M., 2000. CollabLogger: A Tool for Visualizing Groups at Work. In Proceedings of WETICE2000, Workshops on Enabling Technologies: Infrastructure for Collaborative Enterprises, IEEE Computer Society. pp. 104–109.
- Naja-Jazzar, H., Desilva, N., Skaf-Molli, H., Rahhal, C., Molli, P., 2009. OntoRest: A RST-based Ontology for Enhancing Documents Content Quality in Collaborative Writing. *Journal of Computer Science INFOCOMP* 8(3), pp. 03–13.
- Nakamura, T., 2008. An application-independent system for visualizing user operation history. In Proceedings of the 21st Annual ACM Symposium on User Interface Software and Technology (UIST'08), pp. 23–32.
- Nakasone, A., Ishizuka, M., 2006. SRST: A storytelling model using rhetorical relations. *Technologies for Interactive Digital Storytelling and Entertainment*, pp. 127–138.
- Nanard, M., Nanard, J., 1989. MacWeb: un outil pour élaborer des documents. In the Workshop on Object Oriented Document Manipulation (WOODMAN'89), Rennes.
- Neal, A., Simons, R.M., 1983. PLAYBACK: A method for evaluating the usability of software and its documentation. In Proceedings of SIGCHI Conference on Human Factors in Computing Systems (CHI'83), ACM, Boston, USA, pp. 78–82.
- Nielsen, J., 1994. *Usability engineering*. Morgan Kaufmann (Eds), 380 p.
- Nielsen, J., Loranger, H., 2006. *Prioritizing Web Usability*, New Riders Press (Eds).
- O'donnell, M., Mellish, C., Oberlander, J., Knott, A., 2001. ILEX: an architecture for a dynamic hypertext generation system. *Natural Language Engineering* 7(3), pp. 225–250.
- O'Hara, K., Tuffield, M.M., Shadbolt, N., 2008. Lifelogging: Privacy and empowerment with memories for life. *Identity in the Information Society* 1(1), pp. 155–172.
- Ollagnier-Beldame, M., 2006. Traces d'interactions et processus cognitifs en activité conjointe: Le cas d'une co-rédaction médiée par un artefact numérique. Thèse de Doctorat en informatique, Université Lumière Lyon2, France, 256 p.
- Olsen, O., Halversen, B., 1988. Interface usage measurements in a user interface management system. In Proceedings of UIST'88.
- Otlet, P., 1934. *Traité de documentation*. Brussels: Editiones Mundaneum. (Reprinted 1989, Liège: Centre de Lecture Publique de la Communauté Française).
- Ottogalli, F.G., Vincent, J.M., 1999. Mise en cohérence et analyse de traces multiniveaux. Presented at the CFSE, Rennes.
- Patarin, S., 1999. Pandora: un système de collecte de traces du trafic Web de communautés d'utilisateurs réparties. Rapport de Recherche (n° RR-3743), INRIA.

- Payne, S., Green, T., 1986. Task-action grammars: A model of the mental representation of task languages. *Human-Computer Interaction* 2(1).
- Pédauque, R., 2005. Auctorialité : production, réception et publication de documents numériques. Lien : <http://archivesic.ccsd.cnrs.fr/docs/00/12/06/99/RTF/08PSI-auteur-V3.rtf>
- Pédauque, R.T., 2006. *Le document à la lumière du numérique : forme, texte, médium : comprendre le rôle du document numérique dans l'émergence d'une nouvelle modernité*. C&F (Eds), 218 p.
- Pédauque, R.T., 2007. *La redocumentarisation du monde*. Cépaduès (Eds). 213 p.
- Pemberton, S.P., 2009. RDFa for HTML Authors. Lien : <http://www.w3.org/MarkUp/2009/rdfa-for-html-authors>
- Pirolli, P., Fu, W., Reeder, R., Card, S., 2002. A user-tracing architecture for modeling interaction with the World Wide Web. In Proceedings of Advanced Visual Interfaces 2002, ACM, Trento, Italy, pp. 75–83.
- Plaisant, C., Milash, B., Rose, A., Wido, S., Shneiderman, B., 1996. Lifelines : visualizing personal histories. In Proceeding of the International Conference on Human Factors in Computing Systems, ACM Press, New York, NY, USA, pp. 221–227.
- Plaisant, C., Rose, A., Rubloff, G., Salter, R., Shneiderman, B., 1999. The design of history mechanisms and their use in collaborative educational simulations. In Proceedings of Computer Support for Collaborative Learning Conference (CSCL'99), Palo Alto, CA, Stanford University, pp. 348–359.
- Poullet, L., 1997. Formaliser la sémantique des documents - un modèle unificateur. In Actes Du Congrès INFORSID'97, Toulouse, pp. 339–352.
- Prié, Y., 2000. Sur la piste de l'indexation conceptuelle de documents. Une approche par l'annotation. *Document Numérique* 4(162), numéro spécial "L'indexation", pp. 11–35.
- Prié, Y., 2011. Vers une phénoménologie des inscriptions numériques. Dynamique de l'activité et des structures informationnelles dans les systèmes d'interprétation. Mémoire d'Habilitation à Diriger des Recherches, Université Lyon 1, France, 247 p.
- Ranganathan, S.R., 1963. *Documentation and its facets: being a symposium of seventy papers by thirty-two authors*. Asia Pub House (Eds), 648 p.
- Ranwez, S., Crampes, M., 1999. Conceptual Documents and Hypertext Documents are two Different Forms of Virtual Documents. In Proceedings of the www8 workshop on Virtual Documents.
- Rauterberg, M., Fjeld, M., 1998. Task analysis in human-computer interaction - supporting action regulation theory by simulation. *Zeitschrift fuer Arbeitswissenschaft* 3(98), pp. 152–161.
- René, D., 2000. Apport d'une trace informatique dans l'analyse du processus d'apprentissage d'une langue seconde ou étrangère. In Apprendre Une Langue Dans Un Environnement Multimédia, Outremont, Canada, pp. 281–301.
- Rézeau, J., 2001. Concordances in the classroom: The evidence of the data. *Chambers & Davies, ICT and Language Learning: A European Perspective*, pp. 147–166.
- Rhéaume, J., 1993. Les hypertextes et les hypermédias. *Revue EducaTechnologie* 2(1).

- Rich, C., Sidner, C.L., 1997. Segmented interaction history in a collaborative interface agent. In Proceedings of the 2nd International Conference on Intelligent User Interfaces (IUI '97), ACM, New York, NY, USA, pp. 23–30.
- Rizzo, P., Shaw, E., Johnson, W., 2002. An agent that helps children to author rhetorically-structured digital puppet presentations. In Proceedings of the 6th International Conference on Intelligent Tutoring Systems, pp. 903–912.
- Rossi, F., Lechevallier, Y., El Golli, A., 2005. Visualisation de la perception d'un site web par ses utilisateurs. In Actes des 5ème journées Extraction et Gestion des Connaissances (EGC 2005), *Revue des Nouvelles Technologies de l'Information (RNTI-E-3)*, Pinson S., Vincent N. (Eds), pp. 563–574.
- Salaun, J.-M., 2012. *Vu lu su*. Fnac.com, La découverte (Eds).
- Salaün, J.M., 2010. Web et théorie du document : Utopie des ingénieurs et appétit des entrepreneurs. In Proceedings of the 3ème Conférence Document numérique et Société, IEP d'Aix en Provence, pp. 1–8.
- Salaün, J.M., 2007. La redocumentarisation, un défi pour les sciences de l'information. *Études de Communication n° 30*, Entre information et communication, Les nouveaux espaces du document, Université de Lille 3.
- Salaün, J.M., 2008. Le défi du numérique : redonner sa place à la fonction documentaire. *Documentaliste Sciences de l'Information* 45(1), pp. 36–39.
- Sanderson, P., Fisher, C., 1994. Exploratory sequential data analysis: foundations. *Human Computer Interaction* 9(3), pp. 251–317.
- Sanderson, P., Scott, J., Mainzer, J., Watanabe, L., James, J., 1994. MacSHAPA and the enterprise of exploratory sequential data analysis (ESDA). *International Journal of Human-Computer Studies* 41(1), pp. 633–681.
- Schneider, M., Bauer, M., Kröner, A., 2005. Building a Personal Memory for Situated User Support. In Proceedings of the 1st International Workshop on Exploiting Context Histories in Smart Environments (ECHISE'05).
- Serres, A., 2002. Quelle(s) problématique(s) de la trace. In Communication Du Séminaire Du CERCOR, Traces Et Corpus Dans Les Recherches En SIC, Sciences De l'Information Et De La Communication.
- Settoui, L.S., 2010. Systèmes à Base de Traces Modélisées : Modèles et Langages pour l'exploitation des traces d'Interactions. Thèse de doctorat en informatique, Université Lyon1, France.
- Settoui, L.S., 2006. Un cadre théorique pour l'exploitation des traces : Systèmes à Base de Traces, état de l'art et proposition. Rapport de recherche, laboratoire LIRIS, équipe SILEX.
- Sharma, V., 2005. Content Authoring Tools and Standards –A Self-Reliant Mechanism for Content Development. Lien : <http://elearn.cdac.in/eSikshak/eleltechIndia05/PDF/09-Content%20authoring%20Tools%20and%20standards-VK%20Sharma-09.pdf>
- Shirai, Y., Yamamoto, Y., Nakakoji, K., 2006. A history-centric approach for enhancing web browsing experiences. In Proceedings of Extended Abstracts on Human Factors in Computing Systems (CHI EA'06), ACM, New York, NY, USA, pp. 1319–1324.

- Siochi, A., Roger, E., 1991. Computer Analysis of User interfaces Based on Repetition in Transcripts of User Sessions. *ACM Transactions on Information Systems* 9(4), pp. 309–335.
- Spierling, U., Szilas, N., 2009. Authoring Issues beyond Tools. In Proceedings of the 2nd Joint International Conference on Interactive Digital Storytelling (ICIDS'09), Portugal, pp. 50–61.
- Srivastava, J., Cooley, R., Deshpande, M., Tan, P., 2000. Web usage mining : Discovery and applications of usage patterns from web data. In Proceedings of SIGKDD Explorations, ACM, pp. 12–23.
- Strahovnik, V., Mecava, B., 2009. Storytelling and Web 2.0 Services: A synthesis of old and new ways of learning. *eLearning Papers* 3. Lien : <http://65.54.113.26/Publication/5994925/storytelling-and-web-2-0-services-a-synthesis-of-old-and-new-ways-of-learning>
- Stumpf, S., Bao, X., Dragunov, A., Dietterich, T.G., Herlockel, J., Johnsrude, K., Li, L., Shen, J., 2005. The TaskTracer system. In Proceedings of the 20th National Conference on Artificial Intelligence (AAAI'05), pp. 1712–1713.
- Szilas, N., 2002. Structural Models for Interactive Drama. In Proceedings of The 2nd International Conference on Computational Semiotics for Games and New Media, Augsburg.
- Taboada, M., Mann, W., 2006a. Introduction to Rhetorical Structure Theory. RST Website : <http://www.sfu.ca/rst/05bibliographies/report.html>.
- Taboada, M., Mann, W.C., 2006b. Applications of rhetorical structure theory. *Discourse studies* 8(4), pp. 567–588.
- Tauscher, L., Greenberg, S., 1997. How People Revisit Web Pages : Empirical Findings and Implications for the Design of History Systems. *International Journal of Human Computer Studies* 47(1), Special issue on World Wide Web Usability, pp. 97–138.
- Terveen, L., McMackin, J., Amento, B., Hill, W., 2002. Specifying preferences based on user history. In Proceedings of the SIGCHI Conference on Human Factors in Computing Systems: Changing Our World, Changing Ourselves, pp. 315–322.
- Thomas, R., Kennedy, G., Draper, S., Mancy, R., Crease, M., Evans, H., Gray, P., 2003. Generic usage monitoring of programming students. In Proceedings of Ascilite 2003 Conference, Adelaide, pp. 715–719.
- Touch, S., 2006. Système d'Exploitation intégrant des Traces. Rapport de Master Recherche en Informatique, Université Claude Bernard Lyon 1, France.
- Toulmin, S., Rieke, R., Janik, A., 1979. *An Introduction to Reasoning*. 1st edition, MacMillan Publishing Company (Eds), 343 p.
- Trevarianus, J., 2008. Authoring Tools. In *Web Accessibility: A Foundation for Research*, Hamburg (Eds).
- Tuffield, M.M., Millard, D.E., Shadbolt, N.R., 2006. Ontological approaches to modelling narrative. In Proceedings of 2nd AKT DTA Symposium, Aberdeen University, UK.
- Tuffield, M.M., Chakravarthy, M.A., Duplaw, M.D.P., Brewster, M.C., Hara, M.K.O., Ciravegna, P.F., Shadbolt, P.N.R., Wilks, P.Y., 2006. Image annotation with

- Photocopain. In Proceedings of the First International Workshop on Semantic Web Annotations for Multimedia (SWAMM'06), Edinburgh, UK.
- Vortac, O., Edwards, M., Manning, C., 1994. Sequences of actions for individual and teams of air traffic controllers. *Human-Computer Interaction* 9(3-4), pp. 319–343.
- Weinreich, H., Obendorf, H., Herder, E., Mayer, M., 2006. Off the Beaten Tracks : Exploring Three Aspects of Web Navigation. In Proceedings of the World Wide Web Conference 2006, Edinburgh, UK, pp. 133–142.
- Wexelblat, A., Maes, P., 1999. Footprints: history-rich tools for information foraging. In Proceedings of the SIGCHI Conference on Human Factors in Computing Systems: The CHI Is the Limit (CHI '99), ACM, New York, NY, USA, pp. 270–277.
- Yahiaoui, L., Prié, Y., Boufaïda, Z., 2008. Redocumentation des traces d'activité médiée informatiquement dans le cadre des transactions communicationnelles. In Actes des 19ème Journées Francophones d'Ingénierie Des Connaissances, France, pp. 197–209.
- Yahiaoui, L., Prié, Y., Boufaïda, Z., 2009. The redocumentation process of computer mediated activity traces: a general framework. In Proceedings of the 20th ACM Conference on Hypertext and Hypermedia (HT'09), Italy, pp. 363–364.
- Yahiaoui, L., Prié, Y., Boufaïda, Z., Champin, P.A., 2011. Redocumenting computer-mediated activity from its traces: a model-based approach for narrative construction. *Journal of Digital Information* 12(3).
- Yahiaoui, L., Prié, Y., Boufaïda, Z., 2012. Du traçage de l'activité informatique à sa redocumentation en texte : Une approche narrative et un outil auteur. *Technique et science informatique* 31(n° courant, à paraître).
- Zacklad, M., 2004a. Processus de documentation dans les Documents pour l'Action (DopA) : statut des annotations et technologies de la coopération associées. In Actes Du Colloque «Le Numérique : Impact Sur Le Cycle De Vie Du Document Pour Une Analyse Interdisciplinaire », l'ENSSIB, Montréal.
- Zacklad, M., 2004b. Transactions communicationnelles symboliques et communauté d'action : une approche de la création de valeur dans les processus coopératifs. In Actes Du Colloque De Cerisy : Connaissance, Activité, Organisation.
- Zacklad, M., 2006. Documentarisation processes in Documents for Action (DofA): the status of annotations and associated cooperation technologies. *Computer Supported Cooperative Work* 15(2-3), pp. 205–228.
- Zacklad, M., 2007. Réseaux et communautés d'imaginaire documédiatisées. Skare, R., Lund, W. L., Varheim, A., *A Document (Re)turn*, Peter Lang, Frankfurt am Main, pp. 279–297.

Annexe A

Ci-dessous sont des exemples de documents produits par le processus de redocumentation en texte des traces de l'activité de navigation dans la « presse illustrée » en utilisant l'outil ActRedoc ; ceci dans le cadre de l'expérimentation décrite dans la section 5.5.

1. Documents produits de la redocumentation de la trace (T1) :

1.1 Document initial (D0) produit de la phase de redocumentation automatique

This document describes a computer-mediated activity through its trace. It concerns a user. This user's name is Adla Bentellis and he has the IP address 41.209.136.42 and session number 1dc47f76998cfe66c2ca5b84e2325cfa. This trace is about the application navigation in a site of newspaper archive of the nineteenth century (CANU19 project with the municipal library of Lyon- France) and its number is 1.

During his activity, the user has performed the following actions:

1-On 2008-12-01 at 19:23:44, a display action using URL: <http://collections.bm-lyon.fr/presseIllustrée>.

2-On 2008-12-01 at 19:25:54, a search action by indexed name. Its index type is personne and Napoléon Ier and it produces a list of results that is attached to the URL: http://collections.bm-lyon.fr/presseIllustrée/search/tag_personne:Napol%C3%A9on%20Ier,%201769-1821.

3-On 2008-12-01 at 19:26:34, a search action by a complex query for type " article/illustration ". Its query expression value is " Napoléon " and it produces a list of results that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustrée/search?searchType=&query=Napol%E9on>.

4-On 2008-12-01 at 19:28:50, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper illustration that has as fascicle date 1891-03-22 and it is untitled " Le prince Napoléon ". The newspaper illustration is attached to the URL: <http://collections.bm-lyon.fr/PER0016722>.

5-On 2008-12-01 at 19:29:41, a display action based command and it uses button "PDF" to show the article in pdf format.

6-On 2008-12-01 at 19:31:14, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper illustration that has as fascicle date 1891-03-22 and it is untitled " Le prince Napoléon ". The newspaper illustration is attached to the URL: <http://collections.bm-lyon.fr/PER0016722>.

7-On 2008-12-01 at 19:31:22, a search action by a complex query for type " article/illustration ". Its query expression value is " Napoléon " and it produces a list of results that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustrée/search?searchType=&query=Napol%E9on>.

8-On 2008-12-01 at 19:32:20, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper article that has as fascicle date 1896-12-27 and it is untitled " Causerie ". The newspaper article is attached to the URL: <http://collections.bm-lyon.fr/PER00179008>.

9-On 2008-12-01 at 19:35:46, a display action through a meta data and it manipulates an entity, which value is Napoléon Ier.

10-On 2008-12-01 at 19:37:43, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper article that has as fascicle date 1896-12-27 and it is untitled " Causerie ". The newspaper article is attached to the URL: <http://collections.bm-lyon.fr/PER00179008>.

11-On 2008-12-01 at 19:37:49, a display action through a meta data and it manipulates an entity, which value is Napoléon III.

12-On 2008-12-01 at 19:40:24, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper article that has as fascicle date 1896-12-27 and it is untitled " Causerie ". The newspaper article is attached to the URL: <http://collections.bm-lyon.fr/PER00179008>.

13-On 2008-12-01 at 19:40:32, a print action. It uses button "imprimer" to print the article .

1.2 Document final (D_F) produit de la phase de redocumentation interactive

- **Exemple de rapport d'analyse** : ce document est le produit de la redocumentation de la trace (T1) par un participant (Participant-5) qui n'est pas l'utilisateur tracé.

Opérations utilisées (et nombre de fois) : Explain segment (*Introduction*(4), *Summary*, *Elaboration*, *Enablement*(2), *Background*), Replace segment (4), Delete segment.

Main aspect of a research about Napoleon

- Introduction:

Napoleon is an important person so it seems to be a good thing if we describe a research procedure about him in the site of the "presse illustré". We suggest at the end of the procedure another research about his family to go further.

STEP 1 : If you want to know well Napoleon I suggest that you begin by a research by query on "article/illustration" as the following user

- On 2008-12-01 at 19:23:44, a display action using [URL](#).

- At 19:26:34, a search action by a complex query for type " article/illustration ". Its query expression value is " Napoléon " and it produces a list of results that is attached to the [URL](#). To do that, don't forget that the query place is on the top right of the screen !

- At 19:25:54, a search action by indexed name. Its index type is personne and Napoléon Ier and it produces a list of results that is attached to the [URL](#). Be careful !

If you want to search information by indexed names (bottom left on the screen) you could be disappointed by the result which are not so accurate (see the previous action)

STEP 2 : to obtain more information you can always display pictures

- At 19:28:50, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper illustration that has as fascicle date 1891-03-22 and it is untitled " Le prince Napoléon ". The newspaper illustration is attached to the [URL](#). then the user has displayed the pdf of the picture. display action based command and it uses button "PDF" to show the article in pdf format.

- At 19:31:14, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper illustration that has as fascicle date 1891-03-22 and it is untitled " Le prince Napoléon ". The newspaper illustration is attached to the [URL](#).

STEP 3 : Pictures are great, but sometimes it is better to read articles

- At 19:31:22, a search action by a complex query for type " article/illustration ". Its query expression value is " Napoléon " and it produces a list of results that is attached to the [URL](#). Notice that if you are lost in the informations space you can always reload a research as follow

- At 19:32:20, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper article that has as fascicle date 1896-12-27 and it is untitled " Causerie ". The newspaper article is attached to the [URL](#).

- At 19:35:46, a display action through a meta data and it manipulates an entity, which value is Napoléon Ier. Then he returns to the application IDEA : you can travel through "Meta Data"

- At 19:37:49, a display action through a meta data and it manipulates an entity, which value is Napoléon III. Then return to the application

STEP 4 : don't forget to print the result of your search !!

- At 19:40:32, a print action. It uses button "imprimer" to print the article .

Summary :

In this document, we have tried to guide you navigate through the old history of France.

For this, we re-used real interaction traces of real users in order to create a credible guiding documents.

2. Documents produits de la redocumentation de la trace (T3) :

2.1 Document initial (D0) produit de la phase de redocumentation automatique

This document describes a computer-mediated activity through its trace. It is about the application navigation in a site of newspaper archive of the nineteenth century (CANU19 project with the municipal library of Lyon- France), its number is 3 and it concerns a user. This user's name is Yannick Prié and he has the IP address 134.214.142.207 and session number 2e1ab5a0f437ca986ab539f4e065e6e9.

During his activity, the user has performed the following actions:

- 1-On 2008-12-01 at 19:12:34, a display action using URL: <http://collections.bm-lyon.fr/presseIllustrree>.
- 2-On 2008-12-01 at 19:13:23, a search action by a complex query for type " article/illustration ". Its query expression value is " algérie " and it produces a list of results that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustrree/search?searchType=&query=alg%E9rie>.
- 3-On 2008-12-01 at 19:13:51, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper illustration that has as fascicle date 1891-01-25 and it is untitled " Un convoi militaire bloqué par la neige en Algérie ". The newspaper illustration is attached to the URL: <http://collections.bm-lyon.fr/PER0011106>.
- 4-On 2008-12-01 at 19:14:35, a search action by a complex query for type " article/illustration ". Its query expression value is " algérie " and it produces a list of results that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustrree/search?searchType=&query=alg%E9rie>.
- 5-On 2008-12-01 at 19:15:10, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper article that is untitled " L'Inauguration " and it has as fascicle date 1894-04-29. The newspaper article is attached to the URL: <http://collections.bm-lyon.fr/PER00179199>.
- 6-On 2008-12-01 at 19:16:17, a search action by a complex query for type " article/illustration ". Its query expression value is " palais de l'algérie " and it produces a list of results that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustrree/search?searchType=&query=palais+de+l%27alg%E9rie>.
- 7-On 2008-12-01 at 19:16:40, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper article that is untitled " Causerie " and it has as fascicle date 1894-05-06. The newspaper article is attached to the URL: <http://collections.bm-lyon.fr/PER00110466>.
- 8-On 2008-12-01 at 19:17:57, a search action by a complex query for type " article/illustration ". Its query expression value is " exposition de lyon " and it produces a list of results that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustrree/search?searchType=&query=exposition+de+lyon>.
- 9-On 2008-12-01 at 19:18:17, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper illustration that has as fascicle date 1892-01-31 and it is untitled " Lyon sous la neige ". The newspaper illustration is attached to the URL: <http://collections.bm-lyon.fr/PER00110213>.
- 10-On 2008-12-01 at 19:18:20, a search action by a complex query for type " article/illustration ". Its query expression value is " exposition de lyon " and it produces a list of results that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustrree/search?searchType=&query=exposition+de+lyon>.
- 11-On 2008-12-01 at 19:19:45, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper article that is untitled " Causerie " and it has as fascicle date 1894-07-15. The newspaper article is attached to the URL: <http://collections.bm-lyon.fr/PER00110484>.
- 12-On 2008-12-01 at 19:21:36, a search action by a complex query for type " article/illustration ". Its query expression value is " 24 juin " and it produces a list of results that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustrree/search?searchType=&query=24+juin>.
- 13-On 2008-12-01 at 19:22:03, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper article that has as fascicle date 1894-08-12 and it is untitled " Causerie ". The newspaper article is attached to the URL: <http://collections.bm-lyon.fr/PER00110496>.
- 14-On 2008-12-01 at 19:23:40, a search action by a complex query for type " article/illustration ". Its query expression value is " algerie " and it produces a list of results that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustrree/search?searchType=&query=algerie>.
- 15-On 2008-12-01 at 19:24:05, a search action by a complex query for type " article/illustration ". Its query expression value is " algérie " and it produces a list of results that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustrree/search?searchType=&query=alg%E9rie>.
- 16-On 2008-12-01 at 19:24:42, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper article that is untitled " Causerie " and it has as fascicle date 1894-06-03. The newspaper article is attached to the URL: <http://collections.bm-lyon.fr/PER00110474>.
- 17-On 2008-12-01 at 19:27:54, a search action by a complex query for type " article/illustration ". Its query expression value is " Biskra " and it produces a list of results that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustrree/search?searchType=&query=Biskra>.
- 18-On 2008-12-01 at 19:28:25, a search action by a complex query for type " article/illustration ". Its query expression value is " Algérie " and it produces a list of results that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustrree/search?searchType=&query=Alg%E9rie>.
- 19-On 2008-12-01 at 19:29:03, a display action based command. It uses button next list of résultats "Next" and it produces a list of results that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustrree/search?query=Alg%E9rie&searchType=&hitPageStart=2&hitPageSize=12>.
- 20-On 2008-12-01 at 19:29:33, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper article that is untitled " Causerie " and it has as fascicle date 1892-11-27. The newspaper article is attached to the URL: <http://collections.bm-lyon.fr/PER00110221>.

2.2 Documents finaux (D_f) produits de la phase de redocumentation interactive

- **Exemple de rapport de synthèse** : ce document est le produit de la redocumentation de la trace (T3) par l'utilisateur tracé lui-même (Participant-3).

Opérations utilisées (et nombre de fois) : Delete segment, Replace segment (5), Merge segments (4), Explain segment (*Elabortion*(2)), Add segment (*Sequence*).

About Algeria in Lyon during the 19th century

Hello Leila

This is a description of a exploration of a website I did several months ago. The general idea was to look at algeria related content on the "Progrès Illustré".

on this web [URL](#).

I began with the query "algérie"

I examined an illustration "Un convoi militaire bloqué par la neige en Algérie [URL](#)."

Then I read an article entitled " L'Inauguration " published in 1894 about a king of Universal Exposition at "Parc de la tête d'or" which featured a sub-exposition about Alge [URL](#).

The " palais de l'algerie " as they called it was the occasion to present... (sorry I forgot the exact content of the article)

Then I performed various queries related to that exposition.

At some moment, I was interested by an illustration entitler " Lyon sous la neige " (Lyon under the snow - [URL](#)).

At some moment, I looked for " 24 juin " and I do not remember why (maybe the exposition was on june the 24th).(it was the same for "Biskra")

And that's all, I was rather deceived no to find more documents about Algeria in the collection.

Bye

- **Exemple de rapport d'analyse** : ce document est le produit de la redocumentation de la trace (T3) par un participant (Participant-7) qui n'est pas l'utilisateur tracé.

Opérations utilisées : Replace segment(6), Explain (*Evaluation, Solutionhood*)

document trace

This document describes the computer-mediated activity of Yannick Prié in the site of newspaper archive of the nineteenth century (CANU19 project with the municipal library of Lyon- France).

During his activity, the user has performed the following actions:

- On 2008-12-01 at 19:12:34, he visualized this [URL](#).

At 19:13:23, he searched illustrations about " algérie " and got a list of results available at that [URL](#).

About a minute later, he clicked on a thumbnail of a newspaper illustration from 1891-01-25 : " Un convoi militaire bloqué par la neige en Algérie ", available at [URL](#). but it was no good, so at 19:14:35, he went back to the search results.

At 19:15:10, he clicked on a thumbnail of a newspaper article from 1894-04-29 : " L'Inauguration ", available at [URL](#).

Then, he searched illustrations about " palais de l'algerie " and got a list of results available at that [URL](#).

- At 19:16:40, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper article that is untitled " Causerie " and it has as fascicle date 1894-05-06. The newspaper article is attached to the [URL](#).

- At 19:17:57, a search action by a complex query for type " article/illustration ". Its query expression value is " exposition de lyon " and it produces a list of results that is attached to the [URL](#).

- At 19:18:17, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper illustration that has as fascicle date 1892-01-31 and it is untitled " Lyon sous la neige ". The newspaper illustration is attached to the [URL](#).

- At 19:18:20, a search action by a complex query for type " article/illustration ". Its query expression value is " exposition de lyon " and it produces a list of results that is attached to the [URL](#).

- At 19:19:45, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper article that is untitled " Causerie " and it has as fascicle date 1894-07-15. The newspaper article is attached to the [URL](#).

- At 19:21:36, a search action by a complex query for type " article/illustration ". Its query expression value is " 24 juin " and it produces a list of results that is attached to the [URL](#).

- At 19:22:03, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper article that has as fascicle date 1894-08-12 and it is untitled " Causerie ". The newspaper article is attached to the [URL](#).

- At 19:23:40, a search action by a complex query for type " article/illustration ". Its query expression value is " algerie " and it produces a list of results that is attached to the [URL](#).

- At 19:24:05, a search action by a complex query for type " article/illustration ". Its query expression value is " algérie " and it produces a list of results that is attached to the [URL](#).

- At 19:24:42, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper article that is untitled " Causerie " and it has as fascicle date 1894-06-03. The newspaper article is attached to the [URL](#).

- At 19:27:54, a search action by a complex query for type " article/illustration ". Its query expression value is " Biskra " and it produces a list of results that is attached to the [URL](#).

- At 19:28:25, a search action by a complex query for type " article/illustration ". Its query expression value is " Algérie " and it produces a list of results that is attached to the [URL](#).

- At 19:29:03, a display action based command. It uses button next list of résultats "Next" and it produces a list of results that is attached to the [URL](#).

- At 19:29:33, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper article that is untitled " Causerie " and it has as fascicle date 1892-11-27. The newspaper article is attached to the [URL](#).

3. Documents produits de la redocumentation de la trace (T5) :

3.1 Document initial (D0) produit de la phase de redocumentation automatique

This document describes a computer-mediated activity through its trace. Its number is 5, it is about the application navigation in a site of newspaper archive of the nineteenth century (CANU19 project with the municipal library of Lyon- France) and it concerns a user. This user's name is Leila Yahiaoui and he has the IP address 41.201.46.64 and session number 0dee13f97aede85c236032d9022abeac.

During his activity, the user has performed the following actions:

1-On 2009-06-15 at 11:10:18, a search action by a complex query for type " article/illustration ". Its query expression value is " mode " and it produces a list of results that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustree/search?searchType=&query=mode>.

2-On 2009-06-15 at 11:10:46, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper article that has as fascicle date 1891-07-05 and it is untitled " La mode ". The newspaper article is attached to the URL: <http://collections.bm-lyon.fr/PER0016701>.

3-On 2009-06-15 at 11:10:58, a display action based command. It uses button "voir la page" to display the page and it manipulates a newspaper page that has as fascicle number 29 and as newspaper title Le Progrès Illustré. The newspaper page is attached to the URL: <http://collections.bm-lyon.fr/PER0011728>. Its page number is 7.

4-On 2009-06-15 at 11:11:26, a display action based command. It uses button "navigation sur la page" to zoom and focus on the page content.

5-On 2009-06-15 at 11:12:34, a display action based command. It uses button "pleine page" to display the page .

6-On 2009-06-15 at 11:12:48, a display action through graphical element. It manipulates an element of the fascicle contents that represents an article. The element of the fascicle contents is attached to the URL: <http://collections.bm-lyon.fr/PER0016701>. It points to a newspaper article that has as fascicle date 1891-07-05 and it is untitled " La mode ". The newspaper article is attached to the URL: <http://collections.bm-lyon.fr/PER0016701>.

7-On 2009-06-15 at 15:09:58, a display action using URL: <http://collections.bm-lyon.fr/presseIllustree>.

3.2 Document final (D_F) produits de la phase de redocumentation interactive

➤ **Exemple de rapport annoté** : ce document est le produit de la redocumentation de la trace (T5) par l'utilisateur tracé lui-même (Participant-1).

Opérations utilisées : Delete segment (2), Replace segment, Explain segment (*Justify*, *Elaboration*(3), *Evaluation*, *Background*, *Purpose*, *Interpretation*, *Summary*). Add segment (*Contrast*, *Sequence*).

About french fashion of the 19th century

This document describes a computer-mediated activity through its trace. It is about the application of navigation in a site of newspapers archive of the nineteenth century (CANU19 project with the municipal library of Lyon- France) and it concerns a user. This user's name is Leila Yahiaoui and he has the IP address 41.201.46.64. During his activity, the user has performed the following actions:

- On 2009-06-15 at 11:10:18, a search action by a complex query for type " article/illustration ". Its query expression value is " mode " and it produces a list of results that is attached to the [URL](#). The reason is that the user was interested in the 19th century french fashion.

- At 11:10:46, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper article that has as fascicle date 1891-07-05 and it is untitled " La mode ". The newspaper article is attached to the [URL](#). Moreover, articles can provide usually many details about the searched information.

- At 11:10:58, a display action based command. It uses button "voir la page" to display the page and it manipulates a newspaper page that has as fascicle number 29 and as newspaper title Le Progrès Illustré. The newspaper page is attached to the [URL](#). Its page number is 7. Therefore, articles can provide usually many details about the searched information.

- At 11:11:26, a display action based command. It uses button "navigation sur la page" to zoom and focus on the page content. Notice that "navigation sur la page" button may create a focus windows to displayed a zoom of a particular part of the page. The purpose is that to see better the page content.

- At 11:12:48, a display action through graphical element. It manipulates an element of the fascicle contents that represents an article. The element of the fascicle contents is attached to the [URL](#). It points to a newspaper article that has as fascicle date 1891-07-05 and it is untitled " La mode ". The newspaper article is attached to the [URL](#). Contrary to that, illustrations with the same title are more significant since they give a real picture about fashion. Moreover, articles untitled "mode" which means "fashion" seem to be interesting.

- At 15:09:58, a display action using [URL](#). More clearly, this URL takes to the home page of the application.

Summary:

The traced user here was interested in french fashion of the 19th century, so his activity was focused on searching articles untitled "mode" that means "fashion" in english, then navigating through the corresponding fascicles content to get relevant information.

4. Documents produits de la redocumentation de la trace (T4) :

4.1 Document initial (D0) produit de la phase de redocumentation automatique

This document describes a computer-mediated activity through its trace. It concerns a user. This user's name is Leila Yahiaoui and he has the IP address 41.201.46.64 and session number 0dee13f97aede85c236032d9022abeac. This trace is about the application navigation in a site of newspaper archive of the nineteenth century (CANU19 project with the municipal library of Lyon- France) and its number is 4

During his activity, the user has performed the following actions:

- 1-On 2009-05-29 at 15:20:14, a display action using URL: <http://collections.bm-lyon.fr/presseIllustrree>.
- 2-On 2009-05-29 at 15:25:52, a search action by a complex query for type " article/illustration ". Its query expression value is " mode " and it produces a list of results that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustrree/search?searchType=&query=mode>.
- 3-On 2009-05-29 at 15:26:16, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper article that has as fascicle date 1891-07-05 and it is untitled " La mode ". The newspaper article is attached to the URL: <http://collections.bm-lyon.fr/PER0016701>.
- 4-On 2009-05-29 at 15:34:00, a display action based command. It uses button "voir la page" to display the page and it manipulates a newspaper page that has as fascicle number 29 and as newspaper title Le Progrès Illustré. The newspaper page is attached to the URL: <http://collections.bm-lyon.fr/PER0011728>. Its page number is 7.
- 5-On 2009-05-29 at 15:35:11, a display action based command. It uses button "navigation sur la page" to zoom and focus on the page content.
- 6-On 2009-05-29 at 15:36:50, a display action based command and it uses button "pleine page" to display the page .
- 7-On 2009-05-29 at 15:37:58, a search action by a complex query for type " illustration ". Its query expression value is " mode " and it produces a list of results that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustrree/search?searchType= item%2Fillustration&query=mode>.
- 8-On 2009-05-29 at 15:38:09, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper illustration that is untitled " Jupe froncée à la basque : la mode " and it has as fascicle date 1891-01-04. The newspaper illustration is attached to the URL: <http://collections.bm-lyon.fr/PER001777>.
- 9-a search action by a complex query for type " illustration ". At 2009-05-29T15:40:46 it appears, its query expression value is " mode " and it produces a list of results that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustrree/search?searchType= item%2Fillustration&query=mode>.
- 10-On 2009-05-29 at 15:41:03, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper illustration that has as fascicle date 1891-03-01 and it is untitled " Manteau de demi-saison en drap amazone gris fer : la mode ". The newspaper illustration is attached to the URL: <http://collections.bm-lyon.fr/PER0016102>.
- 11-On 2009-05-29 at 15:42:25, a search action by a complex query for type " illustration ". Its query expression value is " mode " and it produces a list of results that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustrree/search?searchType= item%2Fillustration&query=mode>.
- 12-On 2009-05-29 at 15:42:43, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper illustration that is untitled " La mode " and it has as fascicle date 1891-06-14. The newspaper illustration is attached to the URL: <http://collections.bm-lyon.fr/PER0016388>.
- 13-On 2009-05-29 at 15:43:29, a search action by a complex query for type " illustration ". Its query expression value is " mode " and it produces a list of results that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustrree/search?searchType= item%2Fillustration&query=mode>.
- 14-On 2009-05-29 at 15:44:38, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper illustration that is untitled " La mode " and it has as fascicle date 1891-11-15. The newspaper illustration is attached to the URL: <http://collections.bm-lyon.fr/PER00178958>.
- 15-On 2009-05-29 at 15:46:24, a display action based command. It uses button search "recherche" and it manipulates a search page that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustrree/search>.
- 16-On 2009-05-29 at 15:48:46, a search action by a complex query for type " tout ". Its query expression value is " DARLAUD " and it produces a list of results that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustrree/search?searchType= page&query=DARLAUD>.
- 17-On 2009-05-29 at 15:49:31, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper page that has as newspaper title Le Progrès Illustré and as fascicle number 48 and its page number is 7. The newspaper page is attached to the URL: <http://collections.bm-lyon.fr/PER0011908>.
- 18-On 2009-05-29 at 15:53:11, a display action based command and it uses button "navigation sur la page" to zoom and focus on the page content.
- 19-On 2009-05-29 at 15:54:03, a search action by a complex query for type " tout ". Its query expression value is " DARLAUD " and it produces a list of results that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustrree/search?searchType= page&query=DARLAUD>.
- 20-On 2009-05-29 at 15:54:10, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper page that has as fascicle number 204 and as newspaper title Le Progrès Illustré and its page number is 4. The newspaper page is attached to the URL: <http://collections.bm-lyon.fr/PER0013486>.
- 21-On 2009-05-29 at 15:55:32, a display action based command and it uses button "navigation sur la page" to zoom and focus on the page content.
- 22-On 2009-05-29 at 15:55:46, a display action based command and it uses button "PDF" to show the article in pdf format.
- 23-On 2009-05-29 at 15:57:33, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper page that has as fascicle number 204 and as newspaper title Le Progrès Illustré and its page number is 4. The newspaper page is attached to the URL: <http://collections.bm-lyon.fr/PER0013486>.
- 24-On 2009-05-29 at 15:57:48, a search action by a complex query for type " tout ". Its query expression value is " DARLAUD " and it produces a list of results that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustrree/search?searchType= page&query=DARLAUD>.
- 25-On 2009-05-29 at 15:58:06, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper page that has as fascicle number 204 and as newspaper title Le Progrès Illustré and its page number is 4. The newspaper page is attached to the URL: <http://collections.bm-lyon.fr/PER0013486>.
- 26-On 2009-05-29 at 15:58:38, a display action based command. It uses button search "recherche" and it manipulates a search page that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustrree/search>.
- 27-On 2009-05-29 at 15:59:16, a search action by a theme. Its parameter value is " société/mode " and it produces a list of results that is attached to the URL: http://collections.bm-lyon.fr/presseIllustrree/search?query=fullname_subject%3A%22soci% E9% E9%2Fmode%22.
- 28-On 2009-05-29 at 16:00:55, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper illustration that is untitled " Toilette de ville : la mode " and it has as fascicle date 1891-03-08. The newspaper illustration is attached to the URL: <http://collections.bm-lyon.fr/PER0016122>.
- 29-On 2009-05-29 at 16:04:13, a display action through graphical element. It is performed by clicking on a thumb representing a news paper fascicle that has as fascicle date 1891-03-08 as fascicle number 12 and as newspaper title Le Progrès Illustré. The news paper fascicle is attached to the URL: <http://collections.bm-lyon.fr/PER0011345>.
- 30-On 2009-05-29 at 16:09:41, a compress action. It uses button "ZIP" to compress the fascicle.

4.2 Document final (D_F) produits de la phase de redocumentation interactive

- **Exemple de rapport annoté** : ce document est le produit de la redocumentation de la trace (T4) par un participant (Participant-8) qui n'est pas l'utilisateur tracé.

Opérations utilisées : Replace segment (3), Explain segment (*Introduction, Purpose, Interpretation, Justify*), Add segment (*Sequence(2)*).

a redocumentation test about leila'S trace

Introduction:

This document represents the activity of an user interested by the french fashion. In the first time, the user has done a searching by the key word "Mode". After many operating of researchs, the user have choosen another way of searching "By theme" of the name.

This document describes a computer-mediated activity through its trace. It concerns a user. This user's name is Leila Yahiaoui and he has the IP adress 41.201.46.64 and session number 0dee13f97aede85c236032d9022abeac. This trace is about the application navigation in a site of newspaper archive of the nineteenth century (CANU19 project with the municipal library of Lyon- France) and its number is 4.

During his activity, the user has performed the following actions:

- On 2009-05-29 at 15:20:14, a display action using [URL](#). The purpose is that to visit the Web site of the application
 - At 15:25:52, a search action by a complex query for type " article/illustration ". Its query expression value is " mode " and it produces a list of results that is attached to the [URL](#).
 - At 15:26:16, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper article that has as fascicle date 1891-07-05 and it is untitled " La mode ". The newspaper article is attached to the [URL](#).
 - At 15:34:00, a display action based command. It uses button "voir la page" to display the page and it manipulates a newspaper page that has as fascicle number 29 and as newspaper title Le Progrès Illustré. The newspaper page is attached to the [URL](#). Its page number is 7.
 - At 15:35:11, a display action based command. It uses button "navigation sur la page" to zoom and focus on the page content. This means that the user has scroled the vertical bar or has used the zoom tool, ... ?
 - At 15:36:50, a display action based command and it uses button "pleine page" to display the page .
 - At 15:37:58, a search action by a complex query for type " illustration ". Its query expression value is " mode " and it produces a list of results that is attached to the [URL](#).
 - At 15:38:09, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper illustration that is untitled " Jupe froncée à la basque : la mode " and it has as fascicle date 1891-01-04. The newspaper illustration is attached to the [URL](#).
- Then the user returned to the previous searching list
- At 15:41:03, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper illustration that has as fascicle date 1891-03-01 and it is untitled " Manteau de demi-saison en drap amazone gris fer : la mode ". The newspaper illustration is attached to the [URL](#).
- Then the user returned to the previous searching list
- At 15:42:43, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper illustration that is untitled " La mode " and it has as fascicle date 1891-06-14. The newspaper illustration is attached to the [URL](#).
- Then the user returned to the previous searching list
- At 15:44:38, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper illustration that is untitled " La mode " and it has as fascicle date 1891-11-15. The newspaper illustration is attached to the [URL](#).
 - At 15:46:24, a display action based command. It uses button search "recherche" and it manipulates a search page that is attached to the [URL](#).
 - At 15:48:46, a search action by a complex query for type " tout ". Its query expression value is " DARLAUD " and it produces a list of results that is attached to the [URL](#). The reason is that the used has found this name "Darlaud" previous results about "Mode"
 - At 15:49:31, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper page that has as newspaper title Le Progrès Illustré and as fascicle number 48 and its page number is 7. The newspaper page is attached to the [URL](#).
 - At 15:53:11, a display action based command and it uses button "navigation sur la page" to zoom and focus on the page content. Then the user returned to the previous searching list
 - At 15:54:10, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper page that has as fascicle number 204 and as newspaper title Le Progrès Illustré and its page number is 4. The newspaper page is attached to the [URL](#).
 - At 15:55:32, a display action based command and it uses button "navigation sur la page" to zoom and focus on the page content.
 - At 15:55:46, a display action based command and it uses button "PDF" to show the article in pdf format. Then the user returned to the previous searching list two times
 - At 15:58:38, a display action based command. It uses button search "recherche" and it manipulates a search page that is attached to the [URL](#).
 - At 15:59:16, a search action by a theme. Its parameter value is " société/mode " and it produces a list of results that is attached to the [URL](#).
 - At 16:00:55, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper illustration that is untitled " Toilette de ville : la mode " and it has as fascicle date 1891-03-08. The newspaper illustration is attached to the [URL](#).
 - At 16:04:13, a display action through graphical element. It is performed by clicking on a thumb representing a news paper fascicle that has as fascicle date 1891-03-08 as fascicle number 12 and as newspaper title Le Progrès Illustré. The news paper fascicle is attached to the [URL](#).
 - At 16:09:41, a compress action. It uses button "ZIP" to compress the fascicle.

5. Documents produits de la redocumentation de la trace (T2) :

5.1 Document initial (D0) produit de la phase de redocumentation automatique

This document describes a computer-mediated activity through its trace. It is about the application navigation in a site of newspaper archive of the nineteenth century (CANU19 project with the municipal library of Lyon- France), its number is 2 and it concerns a user. This user's name is Damien Cram and he has the IP address 83.205.159.206 and session number 21bfaa599a360daf59239acc9daa3806.

During his activity, the user has performed the following actions:

- 1-On 2008-12-01 at 19:01:33, a display action using URL: <http://collections.bm-lyon.fr/presseIllustrree>.
- 2-On 2008-12-01 at 19:01:50, a display action based command. It uses button search "recherche" and it manipulates a search page that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustrree/search>.
- 3-On 2008-12-01 at 19:02:44, a search action by fascicle year. Its parameter value is 1890, it has as newspaper title Le progrès illustré and it produces a list of results that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustrree/search/journal:%22Le+Progr%E8s+Illustr%E9%22%20type:page%20numPage:1%20date:1890?display=thumb>.
- 4-On 2008-12-01 at 19:03:00, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper page that has as newspaper title Le Progrès Illustré and as fascicle number 1. The newspaper page is attached to the URL: <http://collections.bm-lyon.fr/PER001592>. Its page number is 1.
- 5-On 2008-12-01 at 19:03:09, a display action based command. It uses button "navigation sur la page" to zoom and focus on the page content.
- 6-On 2008-12-01 at 19:04:17, a display action based command and it uses button "pleine page" to display the page .
- 7-On 2008-12-01 at 19:04:29, a display action through graphical element. It manipulates an element of the fascicle contents that represents an article. The element of the fascicle contents is attached to the URL: <http://collections.bm-lyon.fr/PER001636>. It points to a newspaper article that has as fascicle date 1890-12-21 and it is untitled " La mode ". The newspaper article is attached to the URL: <http://collections.bm-lyon.fr/PER001636>.
- 8-On 2008-12-01 at 19:06:56, a search action by a complex query for type " article ". Its query expression value is " mode " and it produces a list of results that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustrree/search?searchType=item%2Farticle&query=mode>.
- 9-On 2008-12-01 at 19:07:31, a display action based command. It uses button next list of résultats "Next" and it produces a list of results that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustrree/search?query=mode&searchType=item/article&hitPageStart=2&hitPageSize=12>.
- 10-On 2008-12-01 at 19:07:53, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper article that has as fascicle date 1891-06-28 and it is untitled " La mode ". The newspaper article is attached to the URL: <http://collections.bm-lyon.fr/PER00110400>.
- 11-On 2008-12-01 at 19:08:16, a display action based command. It uses button "voir la page" to display the page and it manipulates a newspaper page that has as newspaper title Le Progrès Illustré and as fascicle number 28 and its page number is 8. The newspaper page is attached to the URL: <http://collections.bm-lyon.fr/PER0011721>.
- 12-On nd at 200 at -12-01T19:08:44, a display action based command. It uses button "PDF" to show the article in pdf format.
- 13-On 2008-12-01 at 19:08:44, a display action through graphical element. It manipulates an element of the fascicle contents that represents an illustration. The element of the fascicle contents is attached to the URL: <http://collections.bm-lyon.fr/PER0016692>. It points to a newspaper illustration that has as fascicle date 1891-03-28 and it is untitled " L'Arbresle : aux environs de Lyon ". The newspaper illustration is attached to the URL: <http://collections.bm-lyon.fr/PER0016692>.
- 14-On 2008-12-01 at 19:09:23, a display action through graphical element. It manipulates an element of the fascicle contents that represents an illustration. The element of the fascicle contents is attached to the URL: <http://collections.bm-lyon.fr/PER0016692>. It points to a newspaper illustration that has as fascicle date 1891-03-28 and it is untitled " L'Arbresle : aux environs de Lyon ". The newspaper illustration is attached to the URL: <http://collections.bm-lyon.fr/PER0016692>.
- 15-On 2008-12-01 at 19:09:46, a display action based command. It uses button search "recherche" and it manipulates a search page that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustrree/search>.
- 16-On 2008-12-01 at 19:10:04, a search action by a theme. Its parameter value is " société/mode " and it produces a list of results that is attached to the URL: http://collections.bm-lyon.fr/presseIllustrree/search?query=fullname_subject%3A%22soci%E9t%E9%2Fmode%22.
- 17-On 2008-12-01 at 19:10:23, a display action based command. It uses button next list of résultats "Next" and it produces a list of results that is attached to the URL: http://collections.bm-lyon.fr/presseIllustrree/search?query=fullname_subject:%22soci%E9t%E9/mode%22&searchType=sx&hitPageStart=2&hitPageSize=12.
- 18-On 2008-12-01 at 19:10:48, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper illustration that has as fascicle date 1891-03-29 and it is untitled " Chapeau de campagne : la mode ". The newspaper illustration is attached to the URL: <http://collections.bm-lyon.fr/PER0016148>.
- 19-On 2008-12-01 at 19:11:19, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper fascicle that has as fascicle number 15 as fascicle date 1891-03-29 and as newspaper title Le Progrès Illustré. The newspaper fascicle is attached to the URL: <http://collections.bm-lyon.fr/PER0011390>.
- 20-On 2008-12-01 at 19:11:31, a display action based command. It uses button "ZIP" to compress the fascicle.
- 21-On 2008-12-01 at 19:13:26, a display action based command. It uses button next fascicle "arrow" and it manipulates a newspaper fascicle that has as fascicle date 1891-04-05 as newspaper title Le Progrès Illustré and as fascicle number 16. The newspaper fascicle is attached to the URL: <http://collections.bm-lyon.fr/PER0011410>.
- 22-On 2008-12-01 at 19:13:41, a display action based command. It uses button search "recherche" and it manipulates a search page that is attached to the URL: <http://collections.bm-lyon.fr/presseIllustrree/search>.

5.2 Document final (D_F) produits de la phase de redocumentation interactive

- **Exemple de rapport de synthèse (ou d'analyse réflexive)** : ce document est le produit de la redocumentation de la trace (T2) par l'utilisateur tracé lui-même (Participant-2).

Opérations utilisées : Delete segment, Replace segment (7), Merge segments (2), Explain segment (*Introduction, Interpretation, Justify, Summary*).

searching information about fashion of the 19th century

Introduction: The idea was to find articles and illustrations showing some features of the old french fashion, published during the nineteenth century.

To do that, I have performed the following actions:

- On 2008-12-01 at 19:01:33, I displayed the [URL](#). (This means the link to the home page of the online library)
 - At 19:01:50, I clicked on the button search "recherche" to get the result page ([URL](#)). Then, I searched by fascicle year (1890) and title (Le progrès illustré). It gave the following result list ([URL](#)).
 - At 19:03:00, I clicked on the thumb of the first fascicule representing a newspaper page entitled Le Progrès Illustré ([URL](#)). In order to check if the returned results contain the info I needed. I clicked after that on the button "pleine page" to display the page.
 - At 19:04:29, I have done a display action through graphical element. It manipulates an element of the fascicule contents that represents an article. The element of the fascicule contents is attached to the [URL](#). It points to a newspaper article that has as fascicule date 1890-12-21 and it is entitled "La mode". The newspaper article is attached to the [URL](#).
 - At 19:07:53, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper article that has as fascicule date 1891-06-28 and it is entitled "La mode". The newspaper article is attached to the [URL](#). It uses button "voir la page" to display the page and it manipulates a newspaper page that has as newspaper title Le Progrès Illustré and as fascicule number 28 and its page number is 8. The newspaper page is attached to the [URL](#). It uses button "PDF" to show the article in pdf.
 - At 19:09:23, a display action through graphical element. It manipulates an element of the fascicule contents that represents an illustration. The element of the fascicule contents is attached to the [URL](#). It points to a newspaper illustration that has as fascicule date 1891-03-28 and it is entitled "L'Arbresle : aux environs de Lyon". The newspaper illustration is attached to the [URL](#).
 - At 19:09:46, a display action based command. It uses button search "recherche" and it manipulates a search page that is attached to the [URL](#).
 - At 19:10:04, a search action by a theme. Its parameter value is "société/mode" and it produces a list of results that is attached to the [URL](#).
 - At 19:10:23, a display action based command. It uses button next list of résultats "Next" and it produces a list of results that is attached to the [URL](#).
 - At 19:10:48, a display action through graphical element. It is performed by clicking on a thumb representing a newspaper illustration that has as fascicule date 1891-03-29 and it is entitled "Chapeau de campagne : la mode". The newspaper illustration is attached to the [URL](#).
 - At 19:11:19, a display action through graphical element. It is performed by clicking on a thumb representing a news paper fascicule that has as fascicule number 15 as fascicule date 1891-03-29 and as newspaper title Le Progrès Illustré. The news paper fascicule is attached to the [URL](#).
 - At 19:11:31, a display action based command. It uses button "ZIP" to compress the fascicule.
 - At 19:13:26, a display action based command. It uses button next fascicule "arrow" and it manipulates a news paper fascicule that has as fascicule date 1891-04-05 as newspaper title Le Progrès Illustré and as fascicule number 16. The news paper fascicule is attached to the [URL](#).
 - At 19:13:41, a display action based command. It uses button search "recherche" and it manipulates a search page that is attached to the [URL](#).
- Summary: Thanks to new interactive features on old digitalized newspapers, we can easily see that social behaviors about fashion have not changed.