



HAL
open science

Méthode de classification multicritère, incrémentale et périodique appliquée à la recommandation pour l'aide au transfert des savoirs dans les MOOCs

Sarra Bouzayane

► To cite this version:

Sarra Bouzayane. Méthode de classification multicritère, incrémentale et périodique appliquée à la recommandation pour l'aide au transfert des savoirs dans les MOOCs. Autre [cs.OH]. Université de Picardie Jules Verne; Université de Sfax (Tunisie), 2017. Français. NNT : 2017AMIE0029 . tel-03650459

HAL Id: tel-03650459

<https://theses.hal.science/tel-03650459>

Submitted on 25 Apr 2022

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

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

Thèse de Doctorat

*Mention Informatique
Sans spécialité*

présentée à *l'Ecole Doctorale en Sciences Technologie et Santé (ED 585)*

de l'Université de Picardie Jules Verne

par

Sarra Bouzayane

pour obtenir le grade de Docteur de l'Université de Picardie Jules Verne

*Méthode de classification multicritère, incrémentale et
périodique appliquée à la recommandation pour l'aide au
transfert des savoirs dans les MOOCs*

Soutenue le 05 octobre 2017, après avis des rapporteurs, devant le jury d'examen :

M^{me} Marie-Hélène Abel, Professeur

Rapporteur

M^{me} Henda Hajjami Ben Ghézala, Professeur

Rapporteur

M. Ahmed Hadj Kacem, Professeur

Examineur

M^{me} Marilyn Rosselle, Maître de conférences

Examinatrice

M^{me} Inès Saad, Enseignant-Chercheur

Co-encadrante

M. Gilles Kassel, Professeur

Directeur de Thèse

M. Faiez Gargouri, Professeur

Directeur de Thèse

Résumé

La thèse aborde la problématique de transfert de connaissances dans les environnements médiatisés à l'ère de la massification de données.

Nous proposons une méthode d'aide à la décision multicritère *MAI2P* (*Multicriteria Approach for the Incremental Periodic Prediction*) pour la prédiction périodique et incrémentale de la classe de décision à laquelle une action est susceptible d'appartenir. La méthode *MAI2P* repose sur trois phases. La première phase est composée de trois étapes : la construction d'une famille de critères pour la caractérisation des actions ; la construction d'un ensemble des "Actions de référence" représentatif pour chacune des classes de décision ; et la construction d'une table de décision. La deuxième phase s'appuie sur l'algorithme *DRSA-Incremental* que nous proposons pour l'inférence et la mise à jour de l'ensemble de règles de décision suite à l'incrémental séquentielle de l'ensemble des "actions de référence". La troisième phase permet de classer les "Actions potentielles" dans l'une des classes de décision en utilisant l'ensemble de règles de décision inféré.

La méthode *MAI2P* est validée sur un contexte des MOOCs (*Massive Open Online Courses*) qui sont des formations en ligne caractérisées par une masse importante de données échangées entre un nombre massif d'apprenants. Elle a permis la prédiction hebdomadaire des trois classes de décision : Cl_1 des "Apprenants en risque" d'abandonner le MOOC ; Cl_2 des "Apprenants en difficulté" mais n'ayant pas l'intention d'abandon ; et Cl_3 des "Apprenants leaders" susceptibles de soutenir les deux autres classes d'apprenants en leur transmettant l'information dont ils ont besoin. La prédiction est basée sur les données de toutes les semaines précédentes du MOOC afin de prédire le profil de l'apprenant pour la semaine suivante.

Un système de recommandation *KTI-MOOC* (*Recommender system for the Knowledge Transfer Improvement within a MOOC*) est développé pour recommander à chaque "Apprenant en risque" ou "Apprenant en difficulté" une liste personnalisée des "Apprenants leaders". Le système *KTI-MOOC* est basé sur la technique de filtrage démographique et a l'objectif de favoriser l'appropriation individuelle, des informations échangées, auprès de chaque apprenant.

Mots-clés : Savoir factuel, Savoir-faire, Transfert des connaissances, Aide multicritère à la décision, DRSA-incrémentale, Prédiction périodique, Taux d'abandon, Apprentissage incrémental, MOOCs, Système de recommandation.

Abstract

The thesis deals with the problem of knowledge transfer in mediated environments in the era of massive data.

We propose a Multicriteria Approach for the Incremental Periodic Prediction (*MAI2P*) of the decision class to which an action is likely to belong. The *MAI2P* method is based on three phases. The first consists of three steps : the construction of a family of criteria for the characterization of actions ; the construction of a representative set of “Reference actions” for each of the decision classes ; and the construction of a decision table. The second phase is based on the *DRSA-Incremental* algorithm that we propose for the inference and the updating of the set of decision rules following the sequential increment of the “Reference actions” set. The third phase is meant to classify the “Potential Actions” in one of the predefined decision classes using the set of inferred decision rules.

The *MAI2P* method is validated especially in the context of the Massive Open Online Courses (MOOCs), which are e-courses characterized by a huge amount of data exchanged between a massive number of learners. It allows the weekly prediction of the three decision classes : Cl_1 of the “At risk learners”, those who intend to give up the MOOC ; Cl_2 of the “Struggling learners”, those who have pedagogical difficulties but have no plan to abandon it ; and Cl_3 of the “Leader learners”, those who can support the other two classes of learners by providing them with all the information they need. The prediction is based on data from all the previous weeks of the MOOC in order to predict the learner profile for the following week.

A recommender system *KTI-MOOC (Recommender system for Knowledge Transfer Improvement within a MOOC)* is developed to recommend to each “At risk learner” or “Struggling learner” a personalized list of “Leader learners”. This system is based on the demographic filtering technique and aims to promote the individual appropriation, of the exchanged information, for each learner.

Keywords : Knowing-that, Knowing-how, Knowledge Transfer, Multi-criteria decision making, DRSA-incremental, Periodic prediction, Dropout rate, Incremental learning, MOOCs, Recommender system.

Dédicaces

A mon père,

Mon premier encadrant et formateur depuis ma naissance, l'homme le plus digne de mon respect, aucun dédicace ne peut suffire pour te remercier pour ton extrême tendresse, ton permanent soutien et tes encouragements que tu m'as offerts tout au long de ma vie. Que dieu te garde.

A ma mère,

Tu m'as donné la vie, le grand amour et les infinis sacrifices pour réussir et arriver jusqu'au bout. Rien ne peut exprimer l'immense amour que je te porte et la profonde gratitude que je te témoigne pour tous les efforts et le dévouement que tu n'as jamais cessé de consentir pour mon instruction et mon bien être. Que dieu te procure la santé.

A ma chère grand-mère,

Je te dédie aujourd'hui ma réussite tout en espérant qu'elle soit l'expression des vœux que tu n'as jamais cessé de formuler dans tes prières. Je t'adore Mamie. Que Dieu te préserve une longue vie.

A mes chers frères et adorables soeurs

Votre affection et votre soutien m'ont été d'un grand secours tout au long de ma vie professionnelle et personnelle. Je vous dédie ce travail avec tous mes vœux de bonheur, de santé et de réussite.

A toute ma famille

A tous mes enseignants

A mes chers amis

A tous ceux que j'aime et qui m'aiment de retour

Je dédie le couronnement de mes années d'études

Remerciements

En premier lieu, j'exprime ma profonde reconnaissance à Madame **Inès Saad** pour m'avoir permis de cette opportunité et pour avoir suivi l'évolution de ce travail avec tous ses détails. C'est grâce à ses conseils et à son aide constante que j'ai pu mener à bien ce travail. Tous les beaux mots du monde ne suffisent pas pour exprimer ma reconnaissance et mon respect à son égard.

Je tiens également à remercier Monsieur **Faiez Gargouri** qui a toujours su motiver et diriger mon travail. Je ne saurais assez le remercier pour l'intérêt qu'il n'a cessé de me témoigner et pour les encouragements constants qu'il m'a prodigué durant ces années de thèse.

J'exprime aussi mes vifs remerciements et ma profonde gratitude à Monsieur **Gilles Kassel** pour sa disponibilité et sa compétence scientifique. Je le remercie pour les nombreuses remarques et réflexions discutées, particulièrement, lors de la rédaction du premier chapitre.

Outre la qualité de l'encadrement dont ils m'ont fait tous trois bénéficier, je souhaite les remercier pour la confiance qu'ils m'ont accordée, et celle qu'ils m'ont aidée à acquérir. J'ai beaucoup appris grâce à eux, et je leur en remercie profondément.

Je remercie les professeurs Mme. **Marie-Hélène Abel** et Mme. **Henda Hajjaji Ben Ghzala** d'avoir accepté de rapporter sur ce travail, ainsi que les professeurs Mme. **Marilyne Rosselle** et M. **Ahmed Hadj Kacem** d'avoir bien voulu l'examiner.

J'adresse mes sincères remerciements à Mme **Marion Flautre** pour m'avoir fournie toutes les informations nécessaires pour réaliser la partie applicative de cette thèse et pour le temps qu'elle a investi durant toutes les réunions à Amiens.

Je tiens à témoigner de ma profonde reconnaissance aux membres de l'équipe SIGECAD de l'Université Paris Dauphine : **M. Grundstein, Mme. Rosenthal-Sabroux, Lynda, Zahra, Pierre-Emmanuel, Elsa, Brice, Maude, Kathia** ; pour leur sympathie, leur désir de partage et leurs conseils assez valorisants.

Enfin un grand merci, à tous mes collègues au laboratoire MIRACL et au laboratoire MIS et à toutes les personnes nombreuses qui ont de près ou de loin contribué à la finalisation de cette thèse.

Table des matières

Dédicaces	i
Remerciements	ii
Introduction générale	1
1 Transfert des connaissances	11
1.1 Notions de connaissance	12
1.1.1 Donnée-Information	12
1.1.2 Connaissance	14
1.1.3 Catégorisation de la connaissance	16
1.2 Transfert et partage des connaissances	20
1.2.1 Transfert des connaissances	20
1.2.2 Partage des connaissances	22
1.2.3 Discussion	22
1.3 Concepts de base : nos définitions	24
1.4 Apprentissage	28
1.4.1 Définition de l'apprentissage	28
1.4.2 Théories de l'apprentissage	29
1.4.3 Types de l'apprentissage	31
1.5 Les systèmes de connaissance	32
1.6 Modèles de transfert des connaissances	35
1.7 Conclusion	38
2 Massive Open Online Courses (MOOCs)	40
2.1 Les Massive Open Online Courses	41
2.1.1 Définition d'un MOOC	42
2.1.2 Les hébergeurs et les producteurs des MOOCs	44
2.1.3 Description	45
2.1.4 Transfert d'informations source des savoirs	46
2.2 Le problème d'abandon	48
2.2.1 Positionnement du problème d'abandon	49
2.2.2 Les motifs d'abandon	50

2.2.3	Indicateurs d'abandon et de performance	51
2.3	Les modèles de prédiction	53
2.3.1	Prédiction des apprenants en risque d'abandon	53
2.3.2	Prédiction d'une solution pour la minimisation du taux d'abandon	55
2.3.3	Analyse récapitulative	56
2.4	Conclusion	59
3	Algorithme de mise à jour incrémentale	60
3.1	Préliminaires	62
3.1.1	Aide multicritère à la décision	63
3.1.2	Dominance-based Rough Set Approach (DRSA)	64
3.1.3	Théorème de la décision P-généralisée	67
3.1.4	Modèle de préférences	68
3.2	Apprentissage incrémental	69
3.3	Travaux antérieurs	71
3.4	Algorithme de mise à jour incrémentale	72
3.4.1	Algorithme et notations	72
3.4.2	Etape 1 : Application du théorème de la décision P-généralisée des actions insérées	74
3.4.3	Etape 2 : Mise à jour de l'union supérieure et inférieure des classes de décision	76
3.4.4	Etape 3 : Mise à jour de l'ensemble P-dominé et P-dominant des actions initiales	77
3.4.5	Etape 4 : Mise à jour des approximations inférieures et supérieures	78
3.5	Conclusion	81
4	Méthode de prédiction périodique	82
4.1	Travaux antérieurs	84
4.1.1	Méthode basée sur l'approche DRSA pour la prédiction de la faillite des entreprises	85
4.1.2	Méthode basée sur l'approche DRSA pour la prédiction de la performance financière des banques	86
4.2	La méthode <i>MAI2P</i>	87
4.2.1	Phase 1 : Construction de la table de décision de la période P_i	88
4.2.2	Phase 2 : Mise à jour incrémentale des approximations de DRSA pour la construction d'un modèle de préférence . . .	94
4.2.3	Phase 3 : Classification périodique des "Actions potentielles" de la période P_{i+1}	95
4.3	Conclusion	96

5	Expérimentation et évaluation	98
5.1	Contexte applicatif	99
5.1.1	Présentation du MOOC “Pensée Design”	100
5.1.2	Problème d’abandon dans le MOOC “Pensée Design”	103
5.2	Application de notre méthode <i>MAI2P</i>	104
5.2.1	Phase1 : Construction de la table de décision	105
5.2.2	Phase 2 : Mise à jour incrémentale des approximations de DRSA pour la construction d’un modèle de préférence	108
5.2.3	Phase 3 : Classification périodique des “Apprenants potentiels”	108
5.3	Evaluation	108
5.3.1	L’algorithme <i>DRSA-Incremental</i> vs. l’algorithme non-incrémental	109
5.3.2	Evaluation de la qualité de prédiction	110
5.4	Conclusion	115
6	Système de recommandation <i>KTI-MOOC</i>	117
6.1	Travaux antérieurs	119
6.1.1	Systèmes de recommandation pré-engagement à un MOOC	119
6.1.2	Systèmes de recommandation post-engagement à un MOOC	121
6.2	Système de recommandation <i>KTI-MOOC</i>	124
6.2.1	Définition du contexte de la recommandation	124
6.2.2	Processus de recommandation des “Apprenants leaders”	125
6.3	Architecture du système <i>KTI-MOOC</i>	130
6.4	Expérimentations et résultats	133
6.4.1	Quelques interfaces	133
6.4.2	Performance de l’algorithme de recommandation sur le temps d’exécution	135
6.4.3	Evaluation sur la couverture de l’espace item	136
6.5	Conclusion	137
	Conclusion générale et perspectives	139
	Publications	148
	A Algorithme incrémental	151
	B Tables de décision	153
	C Modèles de préférences	158
	D Mesures de performances des modèles de prédiction	163
	E Résultats de mesures de performance	165
E.1	Approche optimiste non-cumulative	165
E.2	Approche optimiste cumulative	166
E.3	Approche pessimiste non-cumulative	166

E.4	Approche pessimiste cumulative	167
F	Les systèmes de recommandation	168
F.1	Synthèse sur les techniques de filtrage	168
F.1.1	Filtrage collaboratif	168
F.1.2	Filtrage basé contenu	169
F.1.3	Filtrage basé connaissance	169
F.1.4	Filtrage démographique	170
F.2	Inconvénients et avantages des techniques de filtrage	170
F.3	Modèles hybrides	172

Liste des figures

1	Environnement socio-technique du MOOC	2
1.1	Processus de construction individuelle d'un savoir-faire et savoir factuel	25
2.1	Description- générale d'un MOOC	46
2.2	Environnement socio-technique du MOOC	47
2.3	Module IE&C (Fortier et Kassel, 2004)	48
4.1	Description générale des trois phases de la méthode de classification incrémentale <i>MAI2P</i> pour une période P_i	88
4.2	Application périodique et incrémentale de la méthode <i>MAI2P</i> . . .	89
5.1	Taux de participation dans les forums du MOOC "Pensée Design" .	102
5.2	Taux de participation dans les activités proposées par le MOOC "Pensée Design"	103
5.3	Taux d'abandon hebdomadaire du MOOC "Pensée Design"	104
5.4	Comparaison de la F-mesure globale calculée pour les quatre ap- proches de DRSA pendant la diffusion du MOOC	112
5.5	Les mesures de performance de la prédiction pour chaque classe de décision durant la diffusion du MOOC	112
5.6	La variation de la F-mesure ce chacune des classes de décision pen- dant les quatre semaines du MOOC	114
5.7	Comparaison entre la F-mesure globale et l'exactitude globale des classes de décision durant les quatre semaines du MOOC	115
6.1	Processus de recommandation : cas d'un "Apprenant en risque" ou un "Apprenant en difficulté"	126
6.2	Répartition de n-top "Apprenants leaders" recommandés (les cases hachées représentent les "Apprenants leaders" non appréciés par l'ap- prenant cible)	130
6.3	Architecture du système de recommandation <i>KTI-MOOC</i>	131
6.4	Page d'accueil de l'environnement du MOOC	133
6.5	Processus de recommandation pour un apprenant X	134
6.6	Page personnelle d'un apprenant du MOOC suite à l'intégration du <i>widget KTI-MOOC</i>	134

- 6.7 Temps d'exécution de l'algorithme de recommandation : étude de la sensibilité par rapport au nombre d'apprenants et celui des évaluations 135
- 6.8 Couverture de l'espace item et diversité des recommandations proposées (Axe des abscisses : Identifiant de l'apprenant leader recommandé ; Axe des ordonnées : Nombre de recommandations d'un apprenant leader). 136

Liste des tableaux

1.1	Théories de l'apprentissage (Siemens, 2008)	29
2.1	Etude récapitulative sur les travaux antérieurs	58
3.1	Exemple d'une table de décision dans DRSA	65
3.2	Notations symboliques de DRSA entre la <i>Période_i</i> et la <i>Période_{i+1}</i>	73
4.1	Exemple d'une table décision construite à la <i>Période_j</i>	94
4.2	Exemple d'un modèle de préférence pour une <i>Période_j</i>	95
5.1	Taux d'accès aux ressources pédagogiques proposées durant le MOOC "Pensée Design"	103
5.2	Famille cohérente de critères	106
5.3	Comparaison du temps d'exécution mis par un algorithme non incrémental et l'algorithme <i>DRSA-Incremental</i> pour le calcul des approximations DRSA (nombre de critères = 12, nombre de classes de décision = 3)	109
5.4	Comparaison du temps d'exécution par rapport à l'augmentation du nombre de critères (trois classes de décision)	110
5.5	Comparaison du temps d'exécution par rapport au nombre de classes de décision (12 attributs)	110
6.1	Synthèse sur les travaux antérieurs dans le cas de recommandation post-engagement	123
B.1	Table de décision <i>Semaine_{1,2}</i>	154
B.2	Table de décision <i>Semaine_{2,3}</i>	155
B.3	Table de décision <i>Semaine_{3,4}</i>	156
B.4	Table de décision <i>Semaine_{4,5}</i>	157
C.1	Modèle de préférence <i>MP_{1,2}</i>	159
C.2	Modèle de préférence <i>MP_{2,3}</i>	160
C.3	Modèle de préférence <i>MP_{3,4}</i>	161
C.4	Modèle de préférence <i>MP_{4,5}</i>	162

C.5	Cores : l'ensemble de critères pertinents pour la classification faite par le décideur	162
D.1	Matrice de confusion	163
E.1	Approche optimiste non-cumulative	165
E.2	Approche optimiste cumulative	166
E.3	Approche pessimiste non-cumulative	166
E.4	Approche pessimiste cumulative	167
F.1	Synthèse sur les quatre techniques de filtrage	172

Introduction générale

En raison de la révolution numérique et de la massification des données, le processus de transfert des connaissances est devenu de plus en plus médiatisé et centré utilisateur. L'échange de l'information se fait ainsi à distance via un système d'information numérique qui encourage la participation active des utilisateurs. Ces derniers peuvent enrichir le système en déposant des données numérisées, puis effectuer une recherche autonome de l'information dont ils ont besoin pour atteindre leurs objectifs. Certes, ce qui est important dans le processus de transfert n'est pas uniquement la transmission de données ou d'informations mais plutôt l'appropriation de ces informations transmises auprès des utilisateurs afin de pouvoir en inférer les connaissances nécessaires pour l'aide à une prise de décision ou bien pour effectuer une tâche particulière. Le processus de transmission de données et celui de l'appropriation de l'information se réfèrent, ensemble, au processus de transfert des connaissances auquel nous nous intéressons dans cette thèse.

Le nouvel environnement de transfert des connaissances et de communication -où la distance géographique, temporelle et culturelle entre les acteurs se manifeste considérablement- a fait naître plusieurs défis. Tout d'abord, la source de la connaissance n'y est pas toujours connue ni vérifiable ce qui remet en cause son exactitude et sa véracité, en particulier dans les contextes où les données source de ces connaissances sont massives, hétérogènes (provenant des sources distinctes) et dynamiques (ne sont pas stables au cours du temps). En outre, les données échangées via les outils numériques ne sont pas structurées ou proprement préservées (exp. dans une mémoire d'organisation, dans des livres de bonnes pratiques, dans les bases de données, etc.). Elles sont, néanmoins, disponibles en réseau, sur le WEB dans des emplacements divers généralement informels (exp. les forums, les blogs, les réseaux sociaux, etc.). Ceci rend difficile pour l'utilisateur d'effectuer une recherche afin de trouver l'information appropriée. De même, un autre défi qui nous semble aussi important concerne le transfert des connaissances tacites, qui sont incarnées dans les têtes des utilisateurs et généralement difficiles à transférer. Compte tenu du modèle SECI (Socialisation, Externalisation, Combinaison, Internalisation) de Nonaka et Konno (1998), ces connaissances se transfèrent à travers l'interaction entre les membres d'un groupe via l'observation, l'imitation et la pratique. De ce fait, il est intéressant de révéler à quel point les outils numériques dédiés au transfert des connaissances permettent le transfert de cette catégorie

tacite en respectant son évolution continue dans le temps.

Notre travail lie fortement le transfert des connaissances à la problématique d'innovation et de mise en place de dispositifs physiques ou virtuels en termes de méthodes, de techniques et d'outils pour acquérir et traiter ces données numérisées tout en favorisant les interactions entre les personnes dans l'objectif d'aider au transfert des connaissances.

Contexte de la thèse

Dans cette thèse, nous traitons le cas d'échange et de traitement d'information dans le contexte des MOOCs (*Massive Open Online Courses*). Ce sont des systèmes d'information numérisés dédiés pour l'apprentissage en ligne et ouvert. Un MOOC est un modèle de prestation éducative qui est, à des degrés divers, Massif, avec théoriquement aucune limite d'inscriptions ; Ouvert, permettant à quiconque de participer, généralement sans frais ; Online (en ligne), les activités d'apprentissage se déroulant généralement sur le web ; et un Cours, structuré autour d'un ensemble d'objectifs d'apprentissage dans une zone d'étude définie (Educause, 2013). En tant que produit de la révolution de l'ère numérique, les MOOCs sont devenus une alternative aux cours traditionnels d'enseignement supérieur (Yuan et Powell, 2013).

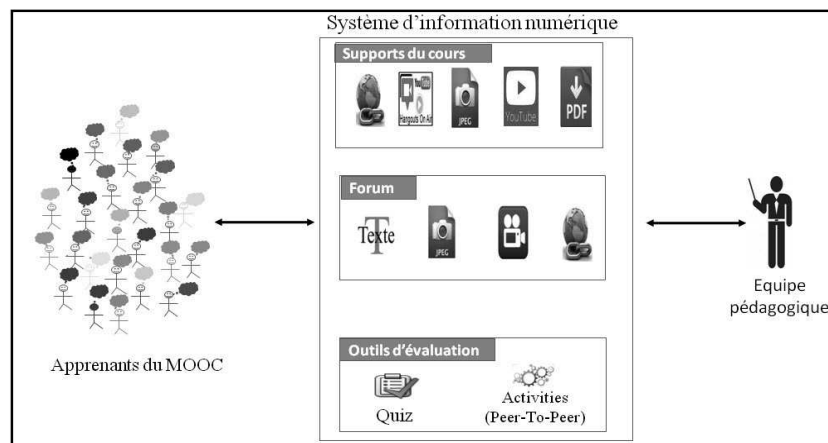


FIGURE 1 – Environnement socio-technique du MOOC

Les MOOCs sont accessibles par un nombre massif d'apprenants de profils hétérogènes (exp. âge, origine, culture, niveau d'études, catégorie socioprofessionnelle, etc.). Une masse énorme de données est déposée sur le système numérique soit par l'équipe pédagogique soit volontairement par les apprenants sous plusieurs formes (exp. pdf, image, vidéo, lien hypertexte). Ces données sont publiques et par suite seront consultées par les apprenants qui fouillent dedans afin de les interpréter en

informations. Ces informations doivent être absorbées afin d'en inférer les connaissances nécessaires. Les apprenants doivent périodiquement fournir un retour sur les connaissances acquises en répondant sur les modalités d'évaluation proposées par l'équipe pédagogique telles que les tests automatisés et les évaluations par les pairs (cf. Figure 1). Dans ce contexte, les apprenants sont, à la fois, processeurs de l'information et porteurs de la connaissance (Grundstein *et al.*, 2014; Arduin, 2013). Le MOOC est toutefois animé par une équipe pédagogique de taille réduite qui se trouve généralement incapable d'accompagner l'intégralité des participants. Ainsi, les apprenants ont recours aux données échangées via le forum dont l'exactitude et la pertinence ne sont pas garanties.

Le MOOC est caractérisé par un système d'information dynamique. En effet, les données sur les apprenants varient au cours du temps en fonction de la nature et de la fréquence de leurs activités sur l'environnement du MOOC. De même, les caractéristiques du MOOC ne sont pas stables vu le matériel du cours qui est fourni périodiquement et les activités d'évaluations qui sont proposées en alternance d'une période à une autre. Par conséquent, dans ce contexte nous ne pouvons pas avoir une visibilité préalable sur l'intégralité des données dès le début du MOOC, mais ces données nous sont fournies en portions d'une manière séquentielle.

Cependant, malgré leur succès et leur prolifération, les MOOCs souffrent d'un problème majeur qui est le taux d'abandon excessif des apprenants qui atteint généralement 90% (Yang *et al.*, 2013; Pomerol *et al.*, 2015). Ce sont les apprenants qui quittent la formation dans une phase prématurée. Plusieurs raisons ont été identifiées, pour expliquer ce comportement d'abandon, y compris l'absence d'accompagnement de la part de l'équipe pédagogique et, donc, l'absence de l'information nécessaire en cas de besoin (Hone et El Said, 2016; Labarthe *et al.*, 2016a; El Said, 2016).

Les environnements d'apprentissage en ligne, tels que les MOOCs, ont remis en cause les méthodes classiques de traitement de l'information qui sont devenues insuffisantes voire inefficaces et conduit à l'innovation d'autres technologies pour faire face à la massification et à l'hétérogénéité des données.

Problématique de recherche et motivations

La problématique centrale dans laquelle se situe cette thèse est l'aide au transfert des connaissances dans les environnements d'apprentissage médiatisés à l'ère de la massification des données en considérant le cas applicatif des MOOCs. L'aide envisagée concerne, à la fois, la transmission des données et des informations via les systèmes d'information numériques et l'appropriation de ces informations auprès de chaque apprenant. Outre que les connaissances explicites qui sont aisément codifiables et transférables, nous nous intéressons au transfert des connaissances tacites qui sont incarnées dans les têtes des individus. Cependant, étant donnée l'hétérogénéité des profils des apprenants dans un contexte des MOOCs, l'aide proposée doit être personnalisée auprès de chaque apprenant en fonction de son profil

afin d'inhiber les obstacles de transfert des connaissances. Relativement à cette problématique, différents points sont traités dans cette thèse, parmi lesquels nous citons :

- ***Comment caractériser les actions dans un système d'information ?*** il s'agit de la construction d'une famille de critères permettant de caractériser l'ensemble des actions. Les problématiques concernent, d'une part, l'identification des indicateurs pouvant caractériser les actions dans un contexte massif; et d'autre part, l'approche à adopter pour la construction et la validation de la famille de critères. La construction doit prendre en considération le point de vue préférentiel du décideur sur chaque critère.
- ***Comment prendre en compte l'évolution des actions ainsi que leurs évaluations sur les critères au cours du temps ?*** dans ce travail nous traitons les systèmes d'information dynamiques où l'ensemble d'apprentissage est généré périodiquement en portions. Ainsi, notre problématique concerne le choix de la méthode permettant l'identification précoce (ou la prédiction) de la classe de décision à laquelle une action est susceptible d'appartenir en fonction de ces ensembles d'apprentissage. En outre, la méthode proposée doit permettre d'incrémenter périodiquement l'ensemble d'apprentissage courant en fonction des ensembles précédents.
- ***Comment appliquer la méthode de prédiction dans le contexte des MOOCs ?*** le système d'information du MOOC est dynamique dans le sens où les données sur les apprenants ne sont pas fournies en une seule fois. Elles sont toutefois générées périodiquement. Pour cela, nous visons la prédiction des profils des apprenants et non pas la simple identification. En effet, le profil d'un apprenant peut évoluer d'une période à autre en fonction de la nature et de la fréquence de son activité sur le site. Il faut, ainsi, identifier les classes de décision aux quelles les apprenants sont susceptibles d'appartenir en considérant leur nombre massif et leurs profils hétérogènes. De même, il faut identifier et construire la famille de critères pouvant caractériser les apprenants selon les classes de décision définies et en fonction des préférences du décideur (dans ce cas l'équipe pédagogique du MOOC). Il est, aussi, important de construire un ensemble d'apprentissage représentatif à chacune des classes de décision qui soit à la fois de haute qualité et de taille raisonnable en respectant la capacité cognitive du décideur humain (Miller, 1956). D'après Hall (1999), la phase d'identification d'un ensemble représentatif de données pour la construction d'un modèle de classification représente le problème central dans l'apprentissage par machine.
- ***Comment personnaliser le transfert des connaissances auprès de chaque apprenant ?*** il s'agit de l'outil (exp. une cartographie, un système de recommandation, etc.) et des techniques (exp. filtrage collaboratif, filtrage démographique, etc.) à mettre en place afin d'aider au processus de transfert

de connaissances auprès de chaque apprenant. Etant donné l'hétérogénéité des apprenants et leur nombre massif, l'aide doit être personnalisée selon le profil de chacun d'entre eux. L'outil proposé doit exploiter le résultat périodique de la méthode de prédiction définie et prendre en compte les facteurs inhibiteurs d'un processus de transfert des connaissances en ligne entre les apprenants.

Contributions apportées

Afin de traiter la problématique d'aide au transfert des connaissances dans les environnements d'apprentissage à distance, nous faisons recours à trois champs de recherche qui sont : (i) le transfert des connaissances (ii) l'aide multicritère à la décision pour la construction d'un ensemble de critères nécessaires pour la caractérisation et la prédiction des profils apprenants, et (iii) les systèmes de recommandation afin de personnaliser l'aide auprès de chaque apprenant du MOOC. Afin d'atteindre cet objectif, plusieurs autres contributions ont été mises en oeuvre.

- **Algorithme pour la mise à jour incrémentale des approximations de DRSA** : nous avons proposé un algorithme *DRSA-Incremental* pour la mise à jour incrémentale des approximations inférieures et supérieures de l'approche DRSA (*Dominance-based Rough Set Approach*). Cet algorithme est générique et peut être appliqué dans le cas d'un système d'information dynamique où les données d'apprentissage du modèle (de prédiction ou de classification) sont reçues par portion. L'algorithme *DRSA-Incremental* évite le calcul à zéro des approximations de DRSA, à chaque arrivée d'une nouvelle portion de données, qui utilise un temps et un espace mémoire énormes. Les approximations sont les ensembles donnés en entrée à un algorithme d'induction afin d'inférer un ensemble de règles de décision. L'algorithme *DRSA-Incremental* permet de garder un ensemble de règles de décision à jour lors d'un apprentissage incrémental, tout en minimisant la complexité temporelle de l'algorithme conventionnel de DRSA.
- **Une méthode de prédiction basée sur l'approche DRSA** : nous avons proposé une méthode *MAI2P (Multicriteria Approach for the Incremental Periodic Prediction)* pour l'aide à la décision périodique et incrémentale. Elle permet l'identification précoce d'un nombre fini de classes de décision. Cette méthode est composée de trois phases successives : (i) la construction d'une table de décision en prenant en compte les préférences des décideurs ; (ii) l'inférence d'un ensemble de règles de décision en utilisant l'algorithme *DRSA-Incremental* ; et (iii) la classification précoce des actions dans les classes de décision prédéfinies. La première phase repose sur trois étapes : la construction d'une famille de critères pour la caractérisation des actions, la construction d'un ensemble d'apprentissage représentatif (dit "Actions de référence") pour l'ensemble des classes de décision et la classification de chaque "Action

de référence” dans l’une des classes de décision. La méthode *MAI2P* est périodique dont la première et la deuxième phase s’exécutent à une période courante pour prédire une classification pour une période suivante. Elle est générique qui peut être réutilisée dans d’autres domaines d’aide à la décision multicritère dans le cas d’un apprentissage incrémental. L’approche DRSA permet d’extraire les préférences des décideurs sur la base d’un ensemble d’apprentissage ce qui réduit naturellement l’effort cognitif requis par eux dans un contexte de classification d’une masse grandissante de données (Hu *et al.*, 2017). De même, grâce à l’intervention du décideur humain, l’approche DRSA permet de surmonter le problème de données déséquilibrées qui résulte d’une répartition inégale entre les instances des classes utilisées lors de la phase d’apprentissage du modèle. Elle infère également des règles de décision de type “Si condition(s), alors décision”, ce qui permet au décideur de comprendre la raison de sa décision en langage naturel (Błaszczyszński *et al.*, 2012).

- ***Expérimentation et validation de la méthode proposée par son application dans un cas réel des MOOCs*** : nous avons validé la méthode *MAI2P* dans un contexte des MOOCs. Trois classes de décision sont définies : la classe de décision Cl_1 des “Apprenants en risque”, la classe de décision Cl_2 des “Apprenants en difficulté” et la classe de décision Cl_3 des “Apprenants leaders”. La première phase de la méthode est basée sur les préférences de l’équipe pédagogique. Le MOOC avance d’une manière hebdomadaire dans la mesure où chaque semaine nous recevons une nouvelle portion de données qui devrait être considérée pour l’apprentissage. Un prototype a été développé pour expérimenter la méthode sur un cas réel d’un MOOC français. La qualité de la prédiction a prouvé des résultats satisfaisants qui atteignent les valeurs F-mesure= 0.66 et Exactitude = 0.89.
- ***Construction d’une famille cohérente de critères pour la caractérisation des profils apprenants*** : nous avons adopté une approche ascendante pour la construction d’une famille cohérente de critères. Cette approche est basée sur deux étapes : une étude bibliographique approfondie pour l’identification des indicateurs pouvant caractériser un apprenant dans un contexte des MOOCs selon les trois classes de décision prédéfinies. La deuxième étape est la réalisation des réunions avec l’équipe pédagogique du MOOC en question afin d’élucider ses préférences. La famille de onze critères que nous avons construite peut être utilisée comme une liste préliminaire par toute autre équipe pédagogique qui pourra la modifier selon ses préférences lors de l’application de la méthode *MAI2P* dans un autre MOOC.
- ***Développement d’un système de recommandation KTI-MOOC (Recommender system for the Knowledge Transfer Improvement within a MOOC)*** : l’objet de la recommandation dans ce travail est identifié

par l'application périodique de la méthode *MAI2P*. Le système *KTI-MOOC* permet de recommander à chaque "Apprenant en risque" ou un "Apprenant en difficulté" une liste des "Apprenants leaders". Cette liste doit être personnalisée de manière qu'elle minimise la distance entre l'apprenant transmetteur de la connaissance ("Apprenant leader") et l'apprenant récepteur ("Apprenant en risque" ou "Apprenant en difficulté"). La distance est calculée en termes des facteurs inhibant le processus de transfert des connaissances à distance. Le système de recommandation proposé est basé sur la technique de filtrage démographique et la distance euclidienne pour le calcul du voisinage. Il est validé sur des données semi-génériques et testé en termes de temps d'exécution et de la couverture minimale. L'algorithme est, en effet, sensible au nombre d'apprenants participants au MOOC et au nombre d'évaluations enregistrées. La couverture a été très satisfaisante d'une valeur qui a atteint 0.94%.

Ces méthodes et outils développés ont l'objectif d'aide au transfert des connaissances explicites et tacites entre les apprenants du MOOC. L'aide vise à la fois les deux processus de transmission et d'appropriation des connaissances auprès de chaque apprenant. Ceci peut permettre, d'une part, à l'apprenant de profiter d'avantage de la formation qui lui a été proposée et, d'autre part, à l'équipe pédagogique d'attirer le maximum d'apprenants et de faire réussir son MOOC.

Plan du manuscrit

Le plan de cette thèse est structuré en six chapitres.

Chapitre 1. *Etat de l'art sur le processus de transfert des connaissances.* Ce chapitre introduira les concepts fondamentaux liés au processus de transfert des connaissances. Une étude approfondie sera menée dans le but de distinguer entre les concepts de donnée, d'information et de connaissance. Ceci peut nous aider, principalement, à clarifier l'objet de transfert qui demeure ambiguë dans une majorité des travaux antérieurs. Ensuite, nous présenterons les définitions de référence du transfert et du partage des connaissances en menant une discussion afin de clarifier la distinction entre eux. Ces deux sections précédentes, nous permettront de proposer nos propres définitions pour tous les concepts en élucidant toutes les ambiguïtés révélées dans la littérature. Dans ce chapitre, nous introduirons, également, la théorie de l'apprentissage comme étant une finalité pour le transfert des connaissances qui s'intéresse à la manière dont l'individu acquiert les savoirs qui lui sont transmis : les définitions de base, les différentes théories ainsi que les types principaux seront abordés. De même, nous repenserons le processus de transfert de connaissance à l'ère du numérique où l'utilisateur est, à la fois, processeur de l'information et porteur de la connaissance. Par conséquent, nous parlerons plus d'un système d'information mais plutôt d'un système d'information

et de connaissance. Généralement, nous parlons d'un système socio-technique où l'interaction entre les acteurs se produit via le système numérique et permettra l'échange des informations et des connaissances. Finalement, nous présenterons les principaux outils de transfert qui sont mis en place et les facteurs susceptibles de l'inhiber ou de le catalyser en présentant certains modèles de la littérature.

Chapitre 2. *Les Massive Open Online Courses (MOOCs)*. Ce chapitre sera dédié aux MOOCs. Nous présenterons le contexte des MOOCs en abordant la problématique du transfert des connaissances via les outils numériques. Nous considérons les MOOCs comme étant un produit de l'ère numérique dédié pour l'apprentissage en ligne. Ils offrent des cours gratuits et sont caractérisés par la massification et l'hétérogénéité de leurs participants ainsi que les données qu'ils partagent. Cependant, malgré leur prolifération, les MOOCs souffrent d'un taux d'abandon excessif qui peut être causé par l'absence de l'accompagnement de la part de l'équipe pédagogique et aussi par l'absence d'un processus de transfert personnalisé entre les apprenants. Dans ce chapitre, nous présenterons la problématique d'abandon dans les MOOCs. Dans un premier temps, nous positionnerons la problématique d'abandon et nous mènerons une étude bibliographique approfondie afin d'identifier les motifs et les indicateurs principaux pour un comportement d'abandon. Ensuite, nous présenterons les modèles de prédiction et les solutions proposées par les chercheurs afin de minimiser le taux d'abandon excessif qui caractérise les MOOCs.

Chapitre 3. *DRSA-Incremental : Algorithme de mise à jour incrémentale des approximations de l'approche DRSA*. Dans ce chapitre nous introduirons, dans un premier temps, l'approche DRSA (*Dominance-based Rough Set Approach*) proposée par Greco *et al.* (2001a). DRSA est une technique pour l'apprentissage supervisé, dédiée à l'aide multicritère à la décision et basée sur la théorie des ensembles approximatifs. Ensuite, nous définirons l'apprentissage incrémental qui se produit lorsque l'échantillon d'apprentissage est fourni au modèle prédictif en portions d'une manière séquentielle. Dans un deuxième temps, nous utiliserons l'algorithme de DRSA conventionnelle et le théorème de décision généralisé (Kotlowski *et al.*, 2008) afin de proposer un algorithme *DRSA-Incremental*. Contrairement à l'algorithme conventionnel de DRSA, l'algorithme que nous proposerons s'adapte à l'apprentissage incrémental et permettra de mettre à jour les approximations de DRSA suite à l'incrémental de l'échantillon d'apprentissage. L'algorithme est composé de trois étapes : la mise à jour des unions inférieures et supérieures des classes de décision, la mise à jour des ensembles P-dominés et P-dominant des unions inférieures et supérieures de classes de décision, et la mise à jour des approximations inférieures et supérieures des unions inférieures et supérieures des classes de décision. Cet algorithme est générique et permettra de minimiser le temps de calcul consommé par l'algorithme conventionnel. Toutes les étapes de l'algorithme seront accompagnées par un exemple illustratif.

Chapitre 4. MAI2P : Méthode basée-DRSA pour la prédiction périodique et incrémentale dans un système d'information dynamique.

Ce chapitre présente une méthode MAI2P (*Multicriteria Approach for the Incremental Periodic Prediction*) basée sur l'algorithme DRSA- *incremental* pour un objectif de prédiction dans un système d'information dynamique. Elle doit permettre de prédire, pour chaque action dans le système d'information, la classe de décision à laquelle elle est susceptible d'appartenir. La prédiction se fait pour une période P_{i+1} en fonction des données de toutes les périodes précédentes $\sum_{t=1}^i P_t$. Sauf que ces données ne sont pas fournies dans une seule portion, mais plutôt reçues d'une manière séquentielle. La méthode MAI2P prend en compte les préférences des décideurs humains dans le processus de prise de décision et se compose de trois phases. La première phase vise à construire une table de décision et repose sur trois étapes : la construction d'une famille cohérente de critères pour la caractérisation des actions ; puis, l'identification d'un échantillon d'apprentissage représentatif pour les n classes de décision prédéfinies en amont ; et enfin, la classification de chaque action dans l'échantillon dans l'une des classes de décision. La deuxième phase concerne l'inférence d'un modèle de préférence qui aboutit à un ensemble de règles de décision. Elle est basée sur l'algorithme DRSA-*Incremental* proposé dans le Chapitre 3 pour la mise à jour incrémentale des approximations inférieures et supérieures des unions des classes de décision dans DRSA. La troisième phase consiste à la classification précoce des "Actions potentiels", en utilisant le modèle de préférence précédemment inféré.

Chapitre 5. Expérimentation et évaluation de la méthode MAI2P.

Dans ce chapitre, nous validerons la méthode MAI2P dans un contexte applicatif d'un MOOC français proposé par un établissement d'enseignement supérieur en France. Une description détaillée du MOOC et du problème d'abandon seront présentés. L'objectif de la méthode est de prédire d'une manière périodique et incrémentale les trois classes de décision : la classe de décision Cl_1 des "Apprenants en risque", la classe de décision Cl_2 des "Apprenants en difficulté" et la classe de décision Cl_3 des "Apprenants leaders". Comme indiqué dans le Chapitre 4, la méthode repose sur trois phases : la première concerne la construction d'une table de décision, la deuxième infère un modèle de préférence en appliquant l'algorithme DRSA-*Incremental*, la troisième vise la classification des "Apprenants potentiels" dans l'une des trois classes de décision suscitées en exploitant le modèle de préférence précédemment inféré. Etant donnée la nature dynamique du contexte du MOOC, la méthode s'exécute d'une manière périodique : la première et la deuxième phase s'exécutent à la fin de chaque semaine du MOOC et la troisième au début de chaque semaine du même MOOC. Le décideur dans ce contexte est l'équipe pédagogique du MOOC. La méthode sera testée en fonction des quatre mesures : rappel, précision, F-mesure et exactitude. En outre, une étude comparative entre l'algorithme conventionnel de DRSA et l'algorithme DRSA-*Incremental* sur le temps d'exécution sera menée.

Chapitre 6. KTI-MOOC : Un système de recommandation pour l'aide au transfert des connaissances. Dans ce chapitre, nous impliquerons les systèmes de recommandation dans le domaine d'apprentissage médiatisé afin d'améliorer le processus de transfert de savoirs entre les apprenants d'un MOOC. Le système de recommandation devrait aider les apprenants à trouver l'information pertinente qu'ils cherchent quand ils se trouvent face à une masse grandissante de données numérisées produites par un nombre massif d'acteurs distants et de profils hétérogènes. Ainsi, nous proposerons de recommander à chacun d'entre eux, une liste personnalisée d'"Apprenants leaders" susceptibles de l'accompagner durant son processus d'apprentissage médiatisé sur le MOOC. L'approche de recommandation repose sur deux phases : la première concerne la prédiction périodique et incrémentale des trois classes de décision : Cl_1 des "Apprenants en risque", Cl_2 des "Apprenants en difficulté" et Cl_3 des "Apprenants leaders" (cf. Chapitre 5). La deuxième phase exploite le résultat de la première afin de recommander pour chaque "Apprenant en risque" ou "Apprenant en difficulté" une liste d'"Apprenants leaders" appropriée à son profil. Le système doit personnaliser le processus de transfert des connaissances (transmission et appropriation) auprès de chaque "Apprenants en risque" ou "Apprenants en difficulté". La recommandation combine le filtrage démographique et la distance euclidienne afin de minimiser les facteurs inhibant le transfert de connaissances. Elle sera évaluée sur le temps d'exécution et sur la couverture minimale.

Annexes. Cette partie présente les annexes décrivant quelques informations complémentaires à certaines sections des chapitres mentionnés ci-dessus.

Chapitre 1

Etat de l'art sur le processus de transfert des connaissances

Sommaire

1.1	Notions de connaissance	12
1.1.1	Donnée-Information	12
1.1.2	Connaissance	14
1.1.3	Catégorisation de la connaissance	16
1.2	Transfert et partage des connaissances	20
1.2.1	Transfert des connaissances	20
1.2.2	Partage des connaissances	22
1.2.3	Discussion	22
1.3	Concepts de base : nos définitions	24
1.4	Apprentissage	28
1.4.1	Définition de l'apprentissage	28
1.4.2	Théories de l'apprentissage	29
1.4.3	Types de l'apprentissage	31
1.5	Les systèmes de connaissance	32
1.6	Modèles de transfert des connaissances	35
1.7	Conclusion	38

Ce chapitre a pour objectif d'explicitier les notions fondamentales de transfert des connaissances. Nous présentons, tout d'abord, une revue de littérature que nous avons établie afin de définir les concepts de donnée, information, connaissance, savoir factuel et savoir-faire. Nous nous intéressons, par la suite, aux deux concepts du

transfert et du partage en discutant la différence entre eux. Enfin, nous proposons nos propres définitions pour ces différents concepts afin d'éclaircir les ambiguïtés révélées dans la littérature. Ces trois premières sections du chapitre doivent, ainsi, nous apporter des éléments de réponse rigoureux sur la confusion majeure qui entoure le concept du transfert des connaissances : Qu'est-ce qu'on est en train de transférer exactement ? Est-ce que ce sont des données, des informations, ou -tel que le concept "transfert des connaissances" l'indique-, des connaissances ? Comment peut-on partager une connaissance alors qu'elle est, en partie, incarnée dans l'esprit des individus ? Peut-on parler de transfert d'une connaissance tacite alors que cette connaissance, une fois externalisée, n'est plus tacite ? Les deux notions du transfert et du partage sont-elles synonymes ? etc.

Dans une deuxième partie, nous focalisons sur l'apprentissage en définissant ses différentes théories et catégories. Cette section vise à positionner le processus de transfert des connaissances dans les environnements d'apprentissage collaboratifs où s'inscrit le contexte applicatif de cette thèse. Ce nouveau contexte nous a conduits à aborder la problématique de transfert des connaissances à l'ère du numérique où la distance géographique entre les acteurs s'impose. Ces acteurs jouent, dès lors, un rôle très important durant le processus de transfert des connaissances, puisqu'ils sont devenus à la fois processeurs de l'information et porteurs de la connaissance. De ce fait, nous introduisons les systèmes d'information et de connaissances où l'aspect humain a été considéré en plaçant l'individu au coeur des systèmes d'information.

Finalement, nous présentons les outils et les modèles du transfert des connaissances afin d'identifier ses facteurs inhibiteurs et catalyseurs, particulièrement, dans les contextes de transfert en ligne. Ces facteurs doivent être pris en compte quand proposer notre outil d'aide au transfert des connaissances.

Ce chapitre présente le cadre introductif de la thèse. Tous les concepts et les notions présentés seront utilisés au fur et à mesure tout au long du manuscrit.

1.1 Notions de connaissance

Nous focalisons dans cette section sur les concepts de base du transfert de connaissances, en particulier la donnée, l'information, le savoir et la connaissance. En effet, étant donné leur utilisation dans des disciplines différentes (philosophie de l'information, ontologie, science de l'information, gestion des connaissances, etc.), les définitions accordées à ces concepts sont nombreuses et divergentes ce qui rend difficile d'atteindre une compréhension unanime. Ces notions nous permettront par la suite d'une meilleure compréhension du processus de transfert des connaissances.

1.1.1 Donnée-Information

Puisque la définition de l'information dépend généralement de celle de la donnée, nous proposons, pour une meilleure compréhension, de regrouper les notions

de donnée et d'information dans une même section et de consacrer une deuxième section à la connaissance.

Les notions de donnée et d'information ont toujours eu des explications diverses. Cette polysémie dépend de plusieurs facteurs tels que le niveau d'abstraction (Floridi, 2008), le niveau d'analyse (analyse technique, sémantique ou influentielle) (Shannon et Weaver, 2002) et la diversité des applications (Shannon, 1993). Pour cela, nous proposons de présenter des points de vue différents issus des domaines de la philosophie, de l'ontologie et de la gestion des connaissances.

D'un point de vue philosophique, Floridi (2011) a considéré la donnée comme un fait putatif relatif à une différence ou un manque d'uniformité dans un certain contexte. Toutefois, l'information est une chaîne de données "bien formée" et "significative", c'est-à-dire "syntaxiquement" et "sémantiquement" appropriée. Ainsi, une "information sans données" ou bien une "information sans sens" ne peut pas exister. L'information doit impérativement être composée de données et porteuse de sens. Le sens, appelé aussi "contenu sémantique", peut être factuel ou correspondre à des instructions. L'information sémantique, dans ce cas, n'est pas nécessairement linguistique (exp. dans le cas du manuel d'utilisation d'une machine, les illustrations sont susceptibles d'être visuellement présentées pour le lecteur sous forme des images successives). L'information factuelle décrit une situation, un fait ou un état. En revanche, l'information exposant des instructions indique ce qui doit être fait pour arriver à une situation, un fait ou un état. Sur cette même base, les philosophes ont aussi soulevé la question de la valeur véridique de l'information, en rapport avec la pertinence et la véracité de son contenu sémantique. Un grand débat est encore ouvert entre ceux qui négligent l'importance de la valeur véridique en jugent l'information uniquement sur sa syntaxe et sa sémantique (Fetzer, 2004 ; Dodig-Crnkovic, 2005) et ceux qui considèrent que le contenu sémantique, s'il n'est pas vrai, ne permet pas de parler d'une information et on reste au niveau d'une donnée (Grice, 1991 ; Barwise et Seligman, 1997 ; Graham, 1999 ; Floridi, 2004). Donc, une information incomplète ou une information erronée n'est pas un sous type d'information mais tout simplement elle n'est pas une information. Cette idée est justifiée par le fameux exemple d'un faux ami qui ne peut pas être considéré comme un sous type d'un ami mais plutôt comme "n'est pas un ami".

D'un point de vue ontologique, Gibaud et Kassel (2013) ont défini la donnée comme étant *des enregistrements publics possédant un contenu informationnel. Ces enregistrements, jouissant d'une certaine stabilité dans le temps, demeurent exploitables pour des traitements, notamment leur interprétation en des informations.* Certaines données sont élémentaires. L'ensemble des données élémentaires peut former des collections (spatiales ou temporelles)¹ ou composer des données struc-

1. L'ontologie fondatrice DOLCE-CORE définit deux catégories disjointes d'entités observables qui sont les "Objects" et les "Events". Leur nature différente tient à la façon dont ces entités sont localisées dans l'espace-temps : les Objects, notamment les objets physiques, sont principalement reliés à l'espace tandis que les Events sont principalement reliés au temps ; d'où les deux types spatiales et temporelles des collections.

turées auxquelles correspondent des contenus informationnels complexes. Considérons leur nature ontologique, les données peuvent être caractérisées par leur matérialité (les données sont des enregistrements physiques matériels), leur artefactualité (elles sont, pour la plupart, intentionnellement produites) et leur fonctionnement sémiotique (elles sont porteuses de sens pour un être humain). Cette caractérisation permet de préciser à quel point la donnée est susceptible de porter de l'information. Basés sur cette analyse, Gibaud et Kassel ont évoqué deux classes de données : les données d'observation qui sont des données exploitées et produites à l'occasion d'observations, de mesures ou d'études scientifiques reposant sur des expérimentations (par exemple, la température d'un patient) et les métadonnées qui représentent des propriétés attachées à la donnée pour lui conférer un sens en augmentant son intelligibilité (par exemple, l'indication sur la localité d'une donnée).

Dans le domaine de la gestion des connaissances, Boisbouvier (2011) a défini les données comme étant des éléments factuels, a priori fondamentaux et objectifs. Elles sont le résultat d'un processus de recherche, de collecte, de création ou de découverte. Celui-ci s'effectue par l'intermédiaire d'une observation ou d'une mesure instrumentale de la réalité, souvent en vue de valider ou d'infirmer une hypothèse. Les données se situent au plus bas en termes de contexte et de compréhension, dans le sens où elles ne sont pas en soi directement et immédiatement significatives. L'information est, par conséquent, un ensemble de données auxquelles on a ajouté du contexte et donné du sens en les reliant entre elles selon un arrangement et/ou une présentation spécifique (textuelle, auditive, visuelle). Les informations se situent donc à un niveau de contexte qui correspond à la compréhension des relations entre données. Autrement, Doody (2003) a défini la donnée comme étant une matière première à partir de laquelle l'information est produite. L'information est une collection de données pertinentes à un endroit et à un temps donnés. L'information est ainsi une donnée dans un contexte : elle a une signification, une pertinence et un objectif. Dans une analyse proche, Balmisse (2002) considère la donnée comme étant un élément brut livré en dehors de tout contexte et l'information est le résultat de la compréhension des relations qui peuvent exister entre plusieurs données.

Les définitions des deux concepts de donnée et d'information sont toujours suivies par celle de connaissance.

1.1.2 Connaissance

La connaissance est souvent définie en continuum avec la donnée et l'information. Dans la littérature, il n'est pas surprenant de trouver les deux concepts "Information" et "Connaissance" utilisés d'une manière interchangeable, sous le prétexte que la différence, même si elle existe, n'est pas assez importante et donc qu'il est inutile de la traiter (Bartol et Srivastava, 2002 ; Makhija et Ganesh, 1997). Cela a été pourtant réfuté par d'autres chercheurs dans la science de l'information comme

Hey (2004) qui a clairement indiqué que la connaissance est une “entité” tout à fait différente des informations ou des données. Elle est généralement personnelle, subjective et intrinsèquement locale. Elle se trouve dans la tête des individus plutôt qu’objectivement dehors. Elle est intériorisée par le connaisseur et, en tant que tel, formée par les perceptions et les expériences existantes. Cependant, entre ces deux visions extrémistes, il y a une majorité qui a une vision modérée définissant la connaissance sur la base de l’information. Selon Tsuchiya (1993), l’information devient connaissance seulement quand elle est lue par le cadre interprétatif du récepteur. Toute information incompatible avec son cadre interprétatif n’est pas perçue dans la plupart des cas. Par conséquent, pour partager les connaissances individuelles, les cadres interprétatifs des membres doivent être commensurables. En effet, quand une donnée est dotée de sens au travers d’un schéma d’interprétation, elle devient une information et quand le sens d’une information est lu au travers d’un schéma d’interprétation, elle devient une connaissance (Tsuchiya, 1993 ; Arduin, 2013). Kogut et Zander (1992) pensent que toutes les informations sont considérées comme des connaissances, sauf que la connaissance n’inclut pas uniquement l’information mais aussi le savoir-faire. L’information représente ainsi une partie mais pas la totalité de la connaissance (Machlup, 1982). Davenport et Prusak (1998) ont mis le point sur le système cognitif du récepteur et sa capacité d’absorption en considérant la connaissance comme étant un mélange d’expertise, de valeurs, d’information contextuelle et de perspicacité experte articulées offrant un cadre pour évaluer et incorporer de nouvelles expériences et de l’information. Elle provient de, et est utilisée dans, les têtes des “connaisseurs”. Dans les organisations, elle est souvent stabilisée non seulement dans les documents ou les dépôts, mais aussi dans les routines, les processus, les pratiques et les normes organisationnels.

Floridi (2011) a encore insisté sur l’importance du contenu sémantique vrai de l’information et l’a considéré comme une condition nécessaire pour pouvoir parler d’une connaissance. Une fois que l’information est disponible, la connaissance peut être construite en termes d’une information sémantique justifiable ou explicable. Cette condition a été précédemment mentionnée par Dretske (1981) qui a considéré la connaissance comme un terme beaucoup plus global intégrant la notion de croyances basées sur l’information.

Dans une autre perspective, le concept de connaissance a été lié à l’interaction et à la socialisation. En effet, la connaissance, d’après Berger et Luckmann (1967), dépend de l’engagement et de la compréhension de la personne qui occupe ces croyances, qui sont touchées par l’interaction entre les personnes et aussi le développement du jugement, du comportement et de l’attitude. Elle a été considérée par la suite comme un processus dynamique créé à travers une interaction sociale entre individus et organisations et est spécifique à un contexte (Nonaka *et al.*, 2000).

Dans une acception large, la connaissance est liée à l’action. Selon Zeleny (1987), la connaissance se réfère à la distinction d’objets d’un observateur à travers lesquels éclot du background de l’expérience un ensemble cohérent et auto-cohérent d’actions coordonnées. Grâce au processus de distinction, les données et les in-

formations individuelles deviennent reliées entre elles dans un réseau de relations. Aussi, Chyi Lee et Yang (2000) ont considéré les informations comme des données organisées en modèles significatifs. Une information est transformée en connaissances quand une personne lit, comprend, interprète et applique les informations à une fonction de travail spécifique. La connaissance devient visible lorsque des personnes expérimentées mettent en pratique les leçons apprises au fil du temps. Selon Lin (1999), une fois que l'information est transférée, c'est la capacité d'agir sur elle qui est appelée connaissance.

Cette analyse nous a permis de constater un accord considérable sur le fait que (1) les deux concepts de donnée et d'information sont distincts mais fortement liés, (2) l'information est l'interprétation d'une donnée, et (3) que par rapport à une information, la donnée manque un contexte et un sens. En ce qui concerne la notion de la connaissance, les chercheurs sont allés vers la catégorisation afin de mener une analyse et une compréhension plus profondes.

1.1.3 Catégorisation de la connaissance

Un autre axe de recherche sur la connaissance concerne la typologie. La connaissance peut être analysée et catégorisée selon deux dimensions : la dimension épistémologique et la dimension individuelle/collective.

Dimension épistémologique

La catégorie épistémologique concerne plusieurs facettes de la connaissance telles que la codifiabilité, les mécanismes de transfert, d'accumulation et d'acquisition, le potentiel pour l'agrégation et les modes d'appropriation (Lam *et al.*, 1998).

Des catégories diverses ont été proposées dont la plus citée concerne la connaissance tacite et explicite (Polanyi, 1962). La connaissance tacite est une connaissance qui ne peut pas être complètement explicitée par un expert et qui ne peut être transférée d'une personne à une autre que par un long processus d'apprentissage. Nonaka et Takeuchi (1995) définissent la connaissance tacite par une connaissance difficilement communicable et fortement liée à son possesseur. En revanche, la connaissance explicite est une connaissance objective, exprimable dans un langage formel, facile à codifier et indépendante de son possesseur. Un autre point de vue (Kogut et Zander, 1992 ; Grant, 1996 ; Ryle, 1945) considère que la connaissance explicite ou explicitée revient finalement à une information. L'information est, en effet, définie comme une connaissance aisément codifiable qui peut, une fois les règles syntaxiques requises pour la déchiffrer connues, être transmise "sans perte". Dans quelques travaux, nous trouvons un autre type de connaissance intermédiaire entre la connaissance explicite et la connaissance tacite et qui est la connaissance implicite. Alonderiene *et al.* (2006) ont défini la connaissance tacite par la connaissance qui ne peut pas être articulée alors que la connaissance implicite est une connaissance qui peut être articulée mais juste qui n'a pas encore été articulée. La connaissance explicite est donc la connaissance qui a été articulée et, le plus

souvent, perçue sous forme de texte, de tableaux, de diagrammes, de spécifications de produits, etc.

Une autre catégorisation épistémologique a aussi été fréquemment utilisée dans la littérature qui est le savoir factuel ou “*Knowing-that*” et le savoir-faire ou “*Knowing-how*”. Pour différencier un savoir factuel d’un savoir-faire, Ryle (1945 ; 2009) a eu recours à la notion d’intelligence. Un savoir factuel est le fait de connaître un fait ou une vérité. Le savoir-faire est le savoir exécuter une règle d’inférence (*i.e.* une opération intelligente permettant de passer de la reconnaissance de certains faits à la reconnaissance des autres). En effet, savoir une règle d’inférence ne signifie pas la possession d’un peu plus d’information, mais plutôt d’être en mesure d’effectuer une opération intelligente. Savoir une règle est un savoir-faire réalisé sur les prestations (démonstrations et méthodes) qui sont conformes à la règle, et non pas dans les citations de théorique. Un savoir-faire est le résultat des exercices appropriés, inspirés d’exemples et de préceptes et corrigés par des critiques. Il ne peut pas être défini en termes de savoirs factuels étant donné qu’il en est logiquement antérieur. En effet, pour connaître un savoir factuel, il faut l’avoir découvert ou établi. Mais la découverte et l’établissement sont des règles d’inférence. Un savant ne peut découvrir un savoir factuel particulier s’il ne sait pas le découvrir. Pour cela, le savoir-faire ne peut pas être construit uniquement par l’accumulation de morceaux de savoirs factuels mais surtout par la maîtrise cumulée des méthodes. De surcroît, contrairement à un savoir factuel, le savoir-faire ne peut pas être communiqué mais seulement inculqué. Autrement, nous pouvons être instruits dans les faits, alors que nous ne pouvons pas être disciplinés dans les méthodes. En effet, une formation ne produit pas des habitudes aveugles mais des processus intelligents. En inculquant une compétence, nous ne formons pas un individu pour faire une action aveuglément, mais pour faire une action d’intelligemment. L’individu, dans ce cas, n’acquiert pas une habitude mais une habileté contenant naturellement des habitudes. Lim *et al.* (1999) ont établi une relation entre les deux catégorisations épistémologiques. En effet, une connaissance explicite est la connaissance qui peut être facilement et artificiellement capturée à travers, par exemple, des manuels et des opérations standard, puis partagée avec les autres soit par des cours de pensée soit par des livres pour l’auto-lecture. Les connaissances tacites sont les compétences et le “savoir-faire” que nous avons en chacun de nous et qui ne peuvent pas être facilement partagés. Par comparaison, le savoir-faire implique des connaissances tacites, complexes et difficiles à codifier. Hawley (2003) se demandait sur la position du succès par rapport à la réalisation d’un savoir-faire, si une pratique qui se conclue par un échec peut être considérée comme un savoir-faire. L’analyse effectuée revenait à dire que le succès est une condition nécessaire mais pas suffisante pour pouvoir parler d’un savoir-faire. En effet, le succès d’une pratique peut parfois exister à la suite d’une action accidentelle dont la causalité demeure ambiguë (par exemple, préparer un gâteau délicieux alors que les ingrédients n’étaient pas tous disponibles). Dans ce cas, le savoir-faire (par exemple, savoir préparer un gâteau) ne s’est pas réalisé bien que le succès se soit manifesté (par exemple,

le gâteau préparé est délicieux). Le succès peut être inférieur à un savoir-faire de deux façons : par l'incapacité d'un sujet à comprendre sa situation ou par l'absence d'un lien approprié entre la bonté de la méthode et l'utilisation de cette méthode par le sujet. Pour cela, le succès doit être accompagné d'une justification ou bien effectué par une action intentionnelle afin d'aboutir à un savoir-faire lié à certaines circonstances contrefactuelles. Cependant, dans certains cas, le savoir-faire en échec occasionnel peut aussi se produire ; si les circonstances sont fixées de façon que le succès soit toujours obtenu, ou bien que le savoir-faire exige un succès fiable, mais pas exceptionnel. L'auteur a aussi évoqué la différence entre savoir-faire une action et être capable de faire une action. En effet, savoir-faire une action signifie que l'action mène obligatoirement à un succès dans les circonstances normales. Alors que, pouvoir-faire une action signifie que l'action peut, à la suite de certains essais, conduire à un succès dans des circonstances similaires ou proches. De sa part, Fantl (2012) a distingué la connaissance pratique de la connaissance théorique basé soit sur l'objet de la connaissance soit sur la manière dont elle a été apprise. Considérons son objet, la connaissance pratique est une proposition sur ce qu'il faut faire (par exemple quel langage utiliser pour implémenter un site web) ou comment faire une action (comment implémenter un site web). La connaissance théorique est une toute autre proposition (par exemple la racine carrée d'un nombre). Considérons la manière d'apprentissage, la connaissance pratique est apprise par ce que l'on apprend de la pratique et la connaissance théorique par l'étant dit. En effet, une personne qui a consulté un manuel sur l'implémentation d'un site web n'aura pas la même connaissance qu'une personne qui a testé la création du même site web avec l'aide d'un formateur.

Dans le cadre des travaux menés par notre équipe de recherche, Ghrab (2016) a eu recours aux notions de disposition et d'état de croyance afin de définir les concepts de savoir-faire et du savoir factuel. Une disposition réfère à la manifestation possible du comportement d'un objet sous certaines conditions. Ainsi, un savoir-faire est une disposition à réaliser un type d'action. Il est considéré comme synonyme de la capacité et donc susceptible d'être acquis, perdu ou bloqué pour un certain temps. Le savoir-faire peut être composé d'autres savoir-faire et savoir factuels. Il peut être explicite et formulé dans des phrases, représenté dans des dessins et stocké sur un support physique ou tacite enraciné dans l'action, les procédures, les routines, l'engagement, les idées et les émotions. Un savoir factuel est un état de croyance qui concerne une description et qui affecte une valeur de vérité à une description pouvant être factuelle ou instructionnelle. Une description factuelle est une affirmation d'une situation donnée. Une description instructionnelle représente un contenu sémantique montrant une certaine démarche ou un ensemble d'instructions à suivre.

Connaissance individuelle- Connaissance collective

Cette dimension décrit la transformation des connaissances individuelles en connaissances de groupe, puis, la transformation de la connaissance de groupe en

connaissances organisationnelles, avec de possibles actions inverses de l'organisation vers le groupe et l'individu.

D'après Reix (1995a); Tarondeau (1998), la connaissance individuelle est une connaissance détenue par l'individu et la connaissance organisationnelle est un ensemble de croyances partagées par l'organisation. D'après Lam *et al.* (1998), la connaissance individuelle est la partie de la connaissance de l'organisation qui se trouve dans le cerveau et les aptitudes physiques de l'individu. Elle est acquise par l'éducation formelle et l'expérience pratique. La connaissance individuelle est discrète et autonome. Il s'agit d'un répertoire de connaissances appartenant à la personne qui peut être appliqué indépendamment à des types spécifiques de tâches ou de problèmes. L'autonomie en application est sa caractéristique clé. Étant données les limites cognitives de l'individu dans le stockage et le traitement des informations, la connaissance individuelle est inévitablement spécialisée et spécifique à un domaine. Elle est également transférable, se déplaçant avec la personne, ce qui donne lieu à des problèmes potentiels de rétention et d'accumulation (Lam *et al.*, 1998).

Spender (1996) a identifié les connaissances individuelles et les connaissances sociales. Les connaissances d'un individu sont intrinsèquement transférables, en se déplaçant avec la personne, alors que les connaissances sociales sont publiques ou collectives et intégrées aux routines, aux normes et à la culture de l'entreprise. Chacun des deux types peut être soit explicite soit tacite. Une connaissance individuelle explicite est une connaissance consciente telle que les faits. Une connaissance individuelle tacite est une connaissance automatique telle qu'une compétence artistique. Une connaissance sociale explicite est une connaissance objectivée comme les idées partagées d'une solution existante. Une connaissance sociale tacite est une connaissance collective telle qu'une connaissance issue d'une expérience collective.

D'après Ghrab (2016), un savoir-faire individuel est un savoir-faire détenu par un individu et un savoir-faire collectif est celui détenu par un collectif et nécessitant la collaboration entre ses différents membres. D'autre part, un savoir factuel collectif est un savoir factuel détenu par un collectif et connu par tous ses membres. Le savoir-faire de l'organisation est détenu par une organisation et a pour thème des actions propres à l'organisation et non plus aux individus ou aux collectifs affiliés à l'organisation.

En conclusion, nous constatons que la littérature définissant les concepts de donnée, information et connaissance est très riche et a été traité selon des points de vue distincts. Une majorité des travaux a été unanime sur la dépendance et l'enchaînement des définitions de ces trois concepts. En outre, dans une acception large, l'information a été considérée comme une donnée mise en contexte en lui attribuant un sens. La connaissance est l'interprétation de l'information. La catégorisation nous a permis une compréhension plus rigoureuse et approfondie de la connaissance, particulièrement en abordant la dimension tacite et explicite. Cette dimension insiste sur l'intérêt de la connaissance tacite, ce qui a mis en exergue l'importance de l'individu qui la détient.

Dans la section suivante, nous présentons une revue de littérature sur les deux notions du transfert et du partage des connaissances tel que définies selon des points de vue différents.

1.2 Processus de transfert ou de partage des connaissances

Les deux processus de transfert et de partage des connaissances ont été fréquemment définis dans des contextes divers et pour des objectifs différents (gestion des connaissances (Davenport et Prusak, 1998 ; Cohen et Levinthal, 1990), psychologie cognitive (Singley et Anderson, 1989), psychologie organisationnelle et industrielle (Goldstein, 1980), apprentissage (Argote et Ingram, 2000), etc.). Néanmoins, malgré la richesse de la littérature, la conceptualisation affronte encore une ambiguïté sérieuse. En effet, les deux concepts de “transfert” et “partage” sont, d’une part, considérés distincts et indépendants et, d’autre part, utilisés d’une manière interchangeable sans en faire une distinction précise.

1.2.1 Transfert des connaissances

Davenport et Prusak (1998) ont défini le transfert de connaissance comme un processus combinant à la fois la transmission de la connaissance par un individu transmetteur et l’absorption et l’utilisation de cette même connaissance par un individu récepteur (*Transfer = Transmission + Absorption (and use)*). Une connaissance est ainsi transférée quand l’information est transmise par un transmetteur ; laquelle information est ensuite absorbée et interprétée en une connaissance tacite dans l’esprit de son récepteur et enfin utilisée. Ainsi, un simple accès à la connaissance est nécessaire mais non suffisant pour parler d’un processus de transfert. Une connaissance ne peut être transférée que si elle est absorbée. Cette définition dépend fortement de la capacité absorptive de l’individu qui reflète sa capacité à reconnaître la valeur de l’information, l’assimiler et l’appliquer (Cohen et Levinthal, 1990). Argote et Ingram (2000) ont défini le transfert des connaissances comme le processus par lequel une unité organisationnelle (*e.g.* groupe, département ou division) est affectée par l’expérience d’une autre. Le processus peut se produire explicitement lorsque, par exemple, une unité communique avec une autre unité sur une pratique à appliquer ou bien implicitement, *i.e.* sans que l’unité destinataire soit capable d’articuler les connaissances qu’elle a acquises. L’affectation dans ce cas se traduit par des changements de la connaissance ou de la performance des unités bénéficiaires (*recipient units*). Cette définition généralise celle donnée par Singley et Anderson (1989) dans un contexte d’analyse de la psychologie cognitive où le transfert de connaissance est décrit comme la manière selon laquelle les connaissances acquises dans une situation s’appliquent (ou ne parviennent pas à s’appliquer) à une autre situation. La définition de Singley et Anderson (1989) concerne le niveau

individuel, alors que pour Argote et Ingram (2000) le problème du transfert des connaissances dans les organisations doit inclure des niveaux d'analyse plus élevés, tels que le groupe, le service ou la division. Les "réservoirs"² où les connaissances sont intégrées dans les organisations jouent un rôle double dans le transfert des connaissances. Ils sont d'une part modifiés lorsque le transfert des connaissances se produit et en sont d'autre part le résultat. De ce fait, l'état des "réservoirs" affecte les processus et les résultats du transfert des connaissances. De la même façon que la volonté d'un individu et ses connaissances antérieures affectent sa capacité à acquérir de nouvelles connaissances (Goldstein, 1980), les connaissances actuelles de l'organisation affectent sa capacité à assimiler de nouvelles connaissances (Cohen et Levinthal, 1990). Gilbert et Cordey-Hayes (1996) ont défini le processus de transfert des connaissances comme un processus dynamique faisant partie d'un processus d'apprentissage continu. Il est, en fait, décrit en cinq étapes pré-ordonnées. Il est d'abord initié par l'acquisition basée principalement sur la recherche de la nouvelle connaissance, en apprenant du passé ou en s'informant auprès d'individus porteurs de cette nouvelle connaissance. Ensuite, il s'agit de la communication verbale ou écrite de la connaissance acquise. La troisième étape concerne l'application de la connaissance acquise et diffusée pour qu'elle puisse être retenue. L'application est une étape critique dans le processus de transfert puisque l'organisation apprend quand elle applique la connaissance et non quand elle la reçoit. La quatrième étape est l'acceptation. En effet, l'action humaine résulte d'une adoption raisonnable et cohérente de dispositions comportementales pertinentes (Ajzen, 2005). Ainsi, une fois la connaissance appliquée et avant qu'elle ne puisse être assimilée dans les routines de base, elle doit être jugée acceptable par les individus. La cinquième étape est l'assimilation des résultats et des effets de l'application de la connaissance. Elle implique la notion de changement chez les individus, les groupes et les organisations qui se manifestent par des modifications de leurs cognition, attitude et comportement comme conséquence directe de l'utilisation des connaissances acquises.

Sur la base de ces définitions, nous remarquons un consensus sur le fait que le transfert des connaissances dépasse la simple transmission des données ou des connaissances entre les acteurs. En revanche, le transfert s'assure de l'appropriation de la connaissance transmise auprès des récepteurs (Davenport et Prusak, 1998). En effet, c'est grâce à la phase d'appropriation que l'unité réceptrice s'affecte par une nouvelle connaissance (Argote et Ingram, 2000), ou bien que la connaissance puisse s'appliquer dans des situations diverses du monde réel (Singley et Anderson, 1989). Le transmetteur et le récepteur de la connaissance sont tous les deux indispensables durant le processus de transfert.

2. Le terme "réservoir" utilisé dans le papier de Argote et Ingram (2000) est dérivé du verbe français "réserver" qui signifie "garder pour une utilisation future" parce que ce terme évoque que la connaissance peut être utilisée à nouveau.

1.2.2 Partage des connaissances

Contrairement aux définitions de transfert qui convergent généralement vers des compréhensions rapprochées, les chercheurs ont échoué à faire l'unanimité concernant la définition de "partage des connaissances". Les définitions proposées ont chacune conditionné le processus de partage des connaissances à un facteur spécifique tel que la réciprocité, le collectivisme, l'enjeu, etc. Le partage des connaissances, d'après Van den Hooff et Hendrix (2005), est un processus où les individus échangent mutuellement leurs connaissances (tacites et explicites) et créent conjointement de nouvelles connaissances. Cette définition implique que tous les processus de partage des connaissances consistent à la fois à apporter (ou donner) des connaissances et à en obtenir (ou collecter) d'autres. Autrement dit, le partage de connaissance exige l'échange de connaissances dans les deux sens.

Dorsey (2003) ; Cummings (2004) ; Wang et Noe (2010) définissent le partage des connaissances par la communication d'informations et de savoir-faire pour aider ou bien collaborer avec les autres afin de résoudre des problèmes, développer de nouvelles idées, ou mettre en œuvre des politiques ou des procédures. Le partage se fait par l'intermédiaire de la correspondance écrite ou à travers des communications de face-à-face, ou en réseau, avec d'autres experts. La communication peut être formelle ou informelle.

Lee (2001) a défini le processus de partage de connaissance comme un ensemble d'activités de transfert et de diffusion des connaissances tacites ou explicites d'une personne, d'un groupe ou d'une organisation à une autre. Quelques travaux, tels que ceux Cabrera *et al.* (2006), ont utilisé le concept de "partage des connaissances" de manière interchangeable avec le concept d'"échange des connaissances". Cependant, l'échange des connaissances, selon Wang et Noe (2010), comprend à la fois la recherche de la connaissance auprès des autres personnes et ensuite le partage des connaissances avec d'autres.

En conséquence, nous constatons que les définitions du partage sont distinctes et parfois rapprochées de celles du transfert. Cependant, ces points de vue ont pratiquement négligé la phase d'appropriation. Dans la section suivante nous discutons la différence entre ces deux concepts.

1.2.3 Discussion

Les deux concepts de transfert et de partage des connaissances ont été parfois considérés comme synonymes et utilisés d'une manière interchangeable (Jonsson, 2008 ; Liyanage *et al.*, 2009) et, dans d'autres cas (Szulanski *et al.*, 2004 ; Paulin et Suneson, 2012), utilisés différemment, ce qui a fait naître un débat entre les chercheurs et les experts du domaine concernant la distinction entre eux. Szulanski *et al.* (2004) ont fait la distinction par rapport à la phase d'appropriation. Ils considèrent ainsi, le transfert des connaissances comme à la fois, la transmission des connaissances par une source et l'acquisition et l'application des connaissances par le destinataire. Argote et Ingram (2000) ont distingué les deux concepts par

rapport au niveau individuel ou collectif des parties prenantes. En effet, le partage des connaissances dans les organisations implique essentiellement l'échange des connaissances au niveau individuel ; en revanche, le transfert des connaissances concerne des niveaux plus élevés tels que le groupe, le service ou la division. Cette distinction a été aussi soutenue par Wei Choo et Correa Neto (2010). D'après Paulin et Suneson (2012) la différence entre le transfert et le partage des connaissances est liée à la nature de la connaissance à partager ou à transférer selon la typologie de Sveiby (1997). Si la connaissance est un objet traité indépendamment de la personne qui le manipule, par exemple connaissance préservée dans un guide de bonnes pratiques, il existe un biais vers l'utilisation du concept transfert. De même, si la connaissance est une construction contextuelle subjective, demeurant liée au contexte et à la personne qui la construit, le concept "partage" sera plus approprié. Une autre distinction a porté sur la réciprocité dans l'échange d'informations entre les individus. En effet, le transfert des connaissances est la communication unidirectionnelle des connaissances entre les agents de sorte que le destinataire ait une compréhension cognitive et une capacité d'appliquer les connaissances (King, 2008). Le partage des connaissances est, plutôt, l'échange mutuel de connaissances entre les individus (Truch *et al.*, 2002). Cette distinction est soutenue par Van den Hooff et Hendrix (2005).

À travers cette étude, nous constatons que le processus de partage de connaissances a toujours été considéré comme un simple échange d'informations basé particulièrement sur le transmetteur de la connaissance, d'où la négligence de la phase de l'appropriation qui demeure à notre avis une phase primordiale. L'appropriation des connaissances par l'individu est un processus socialement médiatisé, interprétatif et contesté (Billett, 1998). En effet, il est probable que les apprenants contestent les connaissances dérivées de l'extérieur, car ils tentent d'établir l'équilibre entre leurs connaissances actuelles et ce qu'ils éprouvent. Pourtant, bien que l'appropriation soit collaborative, il s'agit d'un processus de négociation dans lequel les individus procèdent et contestent leurs connaissances avec d'autres (Piaget et Inhelder, 1973 ; Billett, 1998). L'appropriation est, ainsi, basée sur la construction individuelle des connaissances socialement dérivées à travers la résolution des problèmes routiniers et non-routiniers qui transforme et co-construit des connaissances (Scribner, 1985). Ces connaissances concernent les phénomènes sociaux et se produisent lorsque les individus génèrent une compréhension du monde social, en faisant des inférences et en formant des théories sur les événements sociaux expérimentés. Elles sont le résultat de l'analyse et de l'interprétation, par les systèmes conceptuels des individus, des éléments variés de leurs expériences sociales. L'appropriation va alors au-delà d'une simple intériorisation des stimuli dérivés de l'extérieur. En effet, dans le modèle de l'internalisation, l'individu est soit un récepteur passif d'une influence sociale ou culturelle externe soit un chercheur actif de connaissances et de compétences sociales et culturelles passives externes. Alors que dans la perspective de l'appropriation participative, les processus personnels, interpersonnels et culturels se constituent mutuellement à mesure qu'ils transforment l'activité socio-

culturelle (Rogoff, 2008). C’est ainsi le fait d’interprétation et de transformation de la connaissance externe qui doivent accompagner le processus d’internalisation afin de pouvoir parler d’une appropriation. Ces définitions nous permettent de souligner l’importance de la phase de l’appropriation auprès du récepteur lors d’un processus de transfert des savoirs ou des connaissances. Par conséquent, contrairement à Paulin et Suneson (2012), nous pensons que le processus de transfert ne se limite pas aux connaissances de type objet qui sont d’une manière ou autre stockées et préservées, mais s’intéresse aussi aux connaissances tacites incarnées dans l’esprit des individus auxquels elles sont fortement liées.

Malgré leur richesse et leur diversité, ces études n’ont pas permis de clarifier l’ambiguïté liée à l’objet de transfert et ont ainsi échoué à identifier ce que nous sommes en train de transférer exactement : des données, des informations ou des connaissances. En effet, les définitions présentées dans la littérature ont été proposées particulièrement pour comprendre les concepts en tant que concepts sans enchaîner avec leur finalité de transfert. Pour cela, dans la section suivante, nous nous basons sur l’analyse précédente (cf. Sections 1.1 et 1.2) afin de définir, avec plus de rigueur, les notions de base du processus de transfert des connaissances.

1.3 Définitions des notions de base pour le transfert des connaissances

Dans cette section, nous définissons les concepts de base liés au processus de transfert des connaissances afin de résoudre l’ambiguïté que nous avons relevée dans la littérature. Nous allons ainsi définir les concepts d’une donnée, d’une information et d’une connaissance ainsi que les interactions entre eux (cf. Figure 1.1). Ensuite, nous définissons le processus de transfert des connaissances tel qu’il sera utilisé tout au long de ce manuscrit. Les définitions seront accompagnées par des exemples issus du domaine éducatif et d’enseignement où s’implique le cadre applicatif de cette thèse. Notre contribution repose sur les travaux antérieurs présentés dans les Sections 1.1 et 1.2.

Nous définissons une donnée par *une entité matérielle située dans le monde physique et perçue par un agent cognitif. La perception est liée à un ensemble de signaux détectés par le système perceptif de l’agent cognitif.* Parmi les données existantes, l’agent cognitif sélectionne et acquiert celles dont il a besoin afin de construire ce que nous appelons une “donnée de sens”.

D’un point de vue philosophique, les “données de sens” sont les objets supposés dépendants de l’esprit auxquels nous sommes directement ou indirectement conscients à travers la perception. Elles existent à chaque fois qu’une personne perçoit une entité, par l’un de ses sens et aussi à chaque fois qu’une personne a une expérience qualitativement égale à une perception, comme une hallucination ou une illusion. Le rôle de la perception dans ce contexte est de nous faire prendre conscience des objets extérieurs qui ne peuvent pas être réels mais plutôt

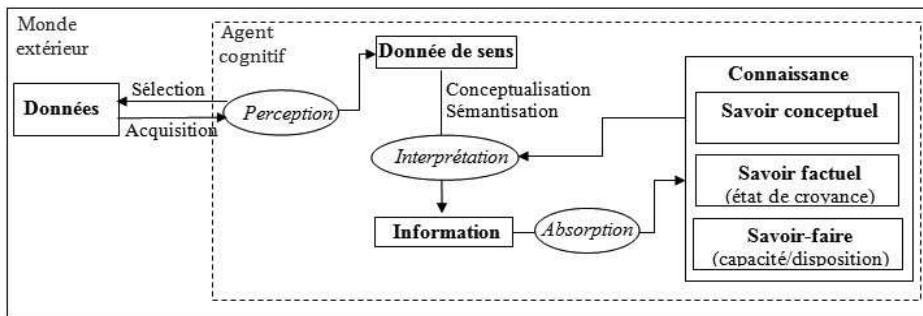


FIGURE 1.1 – Processus de construction individuelle d’un savoir-faire et savoir factuel

des images dans l’esprit, appelées “images mentales” ou “données de sens” (Huemer, 2010). L’écart entre les objets extérieurs et les images mentales peut être le résultat de plusieurs phénomènes tels que la variation de la perspective (exp. la taille d’un objet varie en fonction de la distance qui le sépare de l’agent. Plus l’agent est loin, plus la taille est petite et non réelle), l’illusion (exp. un bâton droit semi-immérgé dans l’eau peut nous sembler penché), l’hallucination (exp. une grande dose d’hallucinogène pourrait nous permettre d’avoir une expérience de sembler voir un rat sur une table, où il n’y a en réalité rien de semblable à un rat), etc. Ces phénomènes sont détaillés dans (Huemer, 2010).

Exemple 1.1 : Prenons l’exemple d’une personne française assise devant son ordinateur en train de consulter quelques documents. Ces documents peuvent être de nature audio, textuelle, visuelle, audio-visuelle ou échographique. Le site consulté propose des documents rédigés en langue française et d’autres en langue chinoise. Par analogie à nos définitions, l’ordinateur, les documents, la table, etc., sont tous des “entités” existantes dans le monde extérieur de cette personne. L’agent cognitif sélectionne, par l’un ou plusieurs de ses sens, les entités dont il a besoin parmi toutes les entités existantes. Seules les données acquises sont dites “données de sens”.

Nous définissons une information comme *le résultat d’une interprétation d’une donnée de sens. L’interprétation est un processus complexe composé d’une conceptualisation et d’une sémantisation. Elle mobilise un ensemble de connaissances notamment de nature conceptuelle afin d’établir une relation sémantique entre les différents concepts. L’interprétation dépend de l’agent cognitif.*

Contrairement à la donnée qui est externe à l’agent cognitif, l’information est interne, et donc subjective, du fait de l’interprétation.

Revenons à l’Exemple 1.1 et considérons que les deux données acquises par l’agent cognitif sont relatives à deux documents dont l’un est rédigé en français et l’autre en chinois. L’agent cognitif français a échoué à identifier les concepts du document chinois et à leur donner un sens. Ce document ne peut pas être interprété, ce qui le limite à “une donnée”. Cependant, chaque phrase dans le document français

peut mener à une information.

L'information est aussi susceptible de s'étendre à une connaissance sous l'effet de l'absorption. D'après Davenport et Prusak (1998), une information est absorbée quand elle est transformée en une connaissance tacite dans l'esprit de son récepteur. Dans ce travail, nous suivons la perspective présentée par (Ghrab, 2016; Ghrab et Saad, 2016; Ghrab *et al.*, 2017) et nous considérons que parler d'un "savoir factuel" et de "savoir-faire" est plus significatif que de parler d'une connaissance en général. *Nous considérons, en effet, que la notion de connaissance englobe la donnée, l'information, le savoir factuel et le savoir-faire.*

Comme noté dans la Section 1.1.3, un savoir factuel est un état de croyance qui concerne une description et qui affecte une valeur de vérité à une description qui peut être factuelle ou instructionnelle (Ghrab, 2016).

Cependant, concernant la définition d'un savoir-faire, nous combinons les deux définitions proposées par Ghrab (2016) et Hawley (2003) pour le définir comme *une disposition à réaliser avec succès un type d'action*. Donc la capacité est une condition nécessaire à un savoir-faire et non un synonyme. Un savoir-faire est avoir la capacité de réaliser une action et la réussir.

Par exemple, tout étudiant en informatique possède la capacité d'implémenter un site web dynamique. En revanche, tout étudiant ne saura pas l'implémenter. En effet, un étudiant peut avoir la capacité de l'implémenter puisqu'il a tous les éléments nécessaires pour le faire, mais il a néanmoins besoin d'effectuer d'une recherche approfondie sur google pour réussir son site web. L'étudiant peut implémenter un site web mais qui ne soit pas proprement fonctionnel. Donc, dans ce cas, l'étudiant possède la capacité mais pas le savoir-faire.

Nous considérons aussi qu'un savoir-faire explicité revient à un savoir factuel concernant une description instructionnelle. Un savoir-faire ne peut qu'être tacite enraciné dans l'action, les procédures, les routines, l'engagement, les idées et les émotions. Il est transférable par l'accompagnement. Par conséquent, contrairement à un savoir factuel qui peut être transféré facilement en utilisant tout moyen de communication (texte, image, etc.), le savoir-faire n'est transférable qu'à travers les communications en face-à-face ou via les vidéos. Un savoir-faire est composé de savoirs factuels et peut être de savoir-faire. Le savoir factuel est le résultat factuel d'un savoir-faire.

Le savoir-faire et le savoir factuel sont tous les deux fortement liés à l'agent cognitif. Ainsi, d'une même information, deux agents cognitifs peuvent inférer deux savoirs distincts. En effet, le processus d'absorption fait appel au schéma d'interprétation de l'agent cognitif qui résulte principalement de sa culture et de son background. Les agents qui ne possèdent pas forcément des schémas d'interprétation proches ou identiques atteignent généralement des savoirs factuels et des savoir-faire différents. Cela dépend de la complexité du savoir.

Revenons sur l'Exemple 1.1 de l'agent cognitif ayant interprété le document en français et donc construit des informations. Il peut dès lors absorber ces informations afin d'en inférer, en mobilisant d'autres connaissances, un nouveau savoir qui

peut être dans ce cas uniquement factuel. En effet, considérons que cette personne cherche à savoir faire le nœud de sa cravate, dans ce cas, contrairement à une vidéo, un document textuel, même si rédigé en français, n'est pas susceptible de faire passer ce savoir-faire. De même, cet agent, après avoir regardé la vidéo, a acquis la capacité de réaliser ce savoir-faire mais nous ne pouvons pas dire qu'il sait le faire. C'est après quelques essais et au moment où le nœud de la cravate de cet agent est bien fait que nous pouvons dire que cette personne sait faire un nœud de cravate.

A ce niveau, nous pouvons clarifier l'ambiguïté concernant les deux concepts de partage et de transfert et identifier l'objet concerné par chacun d'eux. Nous considérons d'abord que le partage concerne les données et le transfert concerne les informations. Autrement dit, "*nous partageons des données pour le transfert des informations sources des savoirs factuels et des savoir-faire*". Ainsi, puisque le terme connaissance englobe la donnée, l'information, le savoir factuel et le savoir-faire, nous considérons dans ce travail que *le concept transfert des connaissances désigne le transfert des informations source des savoirs factuels et des savoir-faire*.

Nous définissons le partage de données comme "*la mise à disposition, par un groupe d'agents cognitifs, d'un ensemble de données*". Ainsi, nous considérons que le concept de partage s'intéresse exclusivement à la phase de transmission et de diffusion des "entités physiques" que nous avons appelées données. L'objectif d'un partage de données est de faire véhiculer une information.

Pour définir le concept de transfert, nous adoptons la définition de Davenport et Prusak (1998) mais nous considérons que l'objet de transfert est plutôt l'information et non pas la connaissance. Cependant, l'information transférée a certainement l'objectif de transférer un savoir factuel ou un savoir-faire. De ce fait, dans ce travail nous parlons d'*un transfert d'informations source de savoirs (savoir factuels ou savoir-faire) défini par un processus combinant à la fois la transmission de l'information par un individu transmetteur et ensuite l'absorption et l'utilisation de cette même information par un individu récepteur afin d'en inférer ses propres savoirs*. Une information est ainsi transférée quand elle est transmise par un transmetteur, ensuite absorbée et interprétée en savoirs factuels ou en savoir-faire par le récepteur.

Nous continuons sur le même exemple pour distinguer entre les différents concepts. Le site consulté par l'agent cognitif a été d'abord enrichi par des documents qui ont été partagés par l'administrateur. Ainsi, ce dernier a mis à la disposition des visiteurs de son site des données afin de leur transférer des informations ou des savoirs. Ce sont ces données qui ont été par la suite perçues, interprétées et absorbées par les agents cognitifs.

Finalement, dans ce travail nous n'allons pas traiter la dimension collective d'un savoir factuel ou d'un savoir-faire. Nous nous contentons de traiter la dimension individuelle. Nous définissons ainsi un savoir factuel individuel par un état de croyance inféré, à un instant t , par un agent cognitif en appliquant une interprétation individuelle basée sur son état de connaissances individuel par rapport à un sujet spécifique, sur un ensemble d'informations reçues. De même, un savoir-faire

individuel est une capacité acquise, à un instant t , par un agent cognitif en appliquant une appropriation individuelle basée sur son état de connaissances individuel par rapport à un sujet spécifique, d'un ensemble d'informations reçues. Généralement, les informations sources de cette connaissance sont incarnées dans les actions et les routines reçues par l'observation. Cette capacité doit mener à un succès.

Le sujet d'interprétation est un contexte bien précis qui doit être maîtrisé par l'agent cognitif récepteur afin de pouvoir interpréter les informations. L'état de connaissance est l'ensemble d'informations et de connaissances mobilisées par l'agent cognitif récepteur pour interpréter et absorber l'information reçue afin d'en faire ressortir les savoirs. Elle englobe le background et les compétences acquis au cours du temps et les savoirs innés.

Ces différents concepts, tel que définis, seront utilisés tout au long de cette thèse et en particulier dans le chapitre 2 où ils seront validés dans un contexte d'apprentissage collaboratif qui est celui des MOOCs (*Massive open Online Courses*). Dans la section suivante, nous focalisons sur l'apprentissage et nous expliquons comment le transfert de connaissances se produit lors de ses différentes théories.

1.4 Apprentissage

Les deux concepts de transfert de savoirs et d'apprentissage sont fortement dépendants. Le transfert se réfère soit à l'application de la connaissance apprise, ou bien à la façon dont l'apprentissage antérieur affecte le nouvel apprentissage (Ertmer et Newby, 1993).

1.4.1 Définition de l'apprentissage

Dans l'organisation, Argyris et Schön (2002) ont lié l'apprentissage à l'action. L'apprentissage organisationnel se produit lorsque les individus de l'organisation se trouvent confrontés à une situation problématique et qu'ils entament une investigation au nom de l'organisation. Ils constatent une erreur et répondent par un processus de réflexion et d'action qui les conduit à modifier leurs représentations de l'organisation ou bien leur compréhension des phénomènes organisationnels et à restructurer leurs activités. Nous apprenons ainsi quand nous détectons une erreur et nous la corrigeons ou bien quand nous obtenons pour la première fois une concordance entre l'intention et le résultat. Dans un contexte de résolution des problèmes, l'apprentissage de nouvelles connaissances, du point de vue d'Anderson (1993), est la transformation du savoir existant via son déploiement dans d'autres situations similaires, ou non similaires, associées ainsi au développement cognitif. L'apprentissage ne peut avoir lieu que par la tentative de résoudre un problème et ne se fait donc que pendant l'activité (Arrow, 1971).

Dans un contexte éducationnel, l'apprentissage est défini par le changement durable de comportement, ou dans la capacité de se comporter d'une manière donnée, qui résulte de la pratique ou d'autres formes d'expérience (Schunk, 1991). Il

doit ainsi impliquer un changement, c'est-à-dire les apprenants deviennent capables de faire quelque chose différemment ; durer au fil du temps, c'est-à-dire qui exclut le changement temporaire et se produire à travers l'expérience, c'est-à-dire par la pratique, l'observation ou autre mais qui exclut le comportement héréditaire ou inné (par exemple les changements de croissance chez l'enfant). D'après Schunk (1991), l'apprentissage est évalué par ce que les gens disent, écrivent et font ; et pour cela il doit impliquer une capacité aussi modifiée pour démonter, d'une manière donnée, les compétences, les connaissances, les croyances ou les comportements qu'ils ont appris.

Le transfert et l'apprentissage sont, ainsi, deux termes fortement liés. Le transfert des savoirs, en particulier le savoir-faire, est réalisé via un processus d'apprentissage. De même, la finalité de l'apprentissage est de transférer les savoirs. Par conséquent, la transformation progressive des méthodes et des outils des transferts des savoirs dans le temps a fait naître quatre théories d'apprentissage.

1.4.2 Théories de l'apprentissage

La combinaison de la psychologie cognitive et de l'apprentissage social a fait apparaître quatre courants principaux, évolués au fil du temps, dont l'objectif de chacun est d'expliquer ce qui se passe lors d'un processus de transfert de connaissances (cf. Table 1.1). Cette évolution porte à la fois sur les finalités de l'apprentissage, le rôle de l'apprenant, le rôle de l'enseignant et sur le rôle du processus cognitif interne du cerveau (Villiot-Leclercq, 2007).

TABLE 1.1 – Théories de l'apprentissage (Siemens, 2008)

Propriété	Behaviourisme	Cognitivism	Constructivisme	Connectivisme
Comment l'apprentissage se produit ?	Boite noire, Comportement observable	Structuré, Computationnel	Social, Sens personnel créé par chaque apprenant	Distribué dans un réseau, social, technologique
Comment le transfert se produit ?	Stimulus-Réponse	Dupliquer les connaissances des connaisseurs	Socialisation	Connexion aux (ajouter des) nœuds et faire croître le réseau (social et conceptuel)
Types d'apprentissage mieux expliqués	L'apprentissage basé sur les tâches	Raisonnement, Objectifs claires, Résolution des problèmes	Apprentissage social	Apprentissage complexe, Plusieurs sources de connaissances

- *Théorie du behaviorisme* : la théorie du behaviorisme est une approche psychologique se focalisant sur le comportement observable déterminé par l'en-

vironnement d'une part et l'histoire des interactions de l'individu avec son milieu d'autre part, sans faire appel aux processus mentaux non directement observables (Legendre, 2008). Cette école de pensée est qualifiée de "physicalisme de la boîte noire" puisqu'elle néglige délibérément les activités du cerveau pour ne prendre en compte que le comportement humain ou animal. Elle limite l'apprentissage à l'association stimulus-réponse. L'apprentissage y est ainsi décrit comme une modification du comportement observable, due à la modification de la force avec laquelle une réponse est associée à des stimuli extérieurs (environnement externe) ou à des stimuli intérieurs (environnement interne) sur l'organisme (Legendre, 2008).

- *Théorie du cognitivisme* : la théorie du cognitivisme est née en prolongation du behaviorisme, endossant l'hypothèse selon laquelle la pensée est un processus de traitement de l'information. La notion de cognition y est centrale. L'état mental a l'objectif d'entretenir un ensemble de relations avec les autres états mentaux, ainsi qu'avec les stimuli et les comportements, en interaction avec l'environnement. Le courant cognitiviste considère la connaissance comme des constructions mentales symboliques dans l'esprit de l'apprenant, et le processus d'apprentissage comme étant le moyen par lequel ces représentations symboliques sont commises à la mémoire (Siemens, 2014).
- *Théorie du constructivisme* : le constructivisme assimile l'apprentissage à la création d'un sens à partir de l'expérience. Un concept essentiel dans la conception constructiviste est que l'apprentissage se déroule toujours dans un contexte et que le contexte forme un lien inexorable avec les connaissances qui s'y trouvent (Bednar *et al.*, 1992). Ainsi, bien que le behaviorisme et le cognitivisme considèrent la connaissance comme externe à l'apprenant et le processus d'apprentissage comme l'acte d'internaliser la connaissance, le constructivisme suppose que les apprenants doivent essayer activement de créer un sens (Siemens, 2014). La position constructiviste suppose que le transfert peut être facilité par l'implication dans des tâches authentiques ancrées dans des contextes significatifs. Puisque la compréhension est "indexée" par l'expérience, l'authenticité de l'expérience devient critique pour la capacité de l'individu à utiliser des idées (Brown *et al.*, 1989).
- *Théorie de connectivisme* : le connectivisme est l'apprentissage en réseau. Il a été inventé par Siemens en 2008 afin de répondre à la faiblesse des théories précédentes concernant la création et l'expansion de la connaissance. En effet, "Si les apprenants construisent leurs propres connaissances, comment leur est-il possible de créer une structure cognitive plus complexe que celle qu'ils possèdent déjà" (Sawyer, 2005). Le connectivisme vise le développement continu des connaissances. Il représente le courant le plus adapté à l'ère du numérique puisqu'il prend en compte l'utilisation de la technologie et la massification d'informations. L'apprentissage est un processus qui se

produit dans les environnements nébuleux, dont les éléments de base sont changeants, donc qui ne sont pas entièrement sous le contrôle de l'individu. Il y est ainsi vital d'avoir la capacité d'établir des distinctions entre des informations importantes et non importantes. L'apprentissage est un processus de connexion de nœuds spécialisés ou de sources d'information qui peut toutefois résider dans des appareils non humains (Siemens, 2012 ; 2014). Notre contexte applicatif des MOOCs s'inscrit dans les méthodes d'enseignement connectivistes.

La table 1.1 récapitule ces quatre théories en précisant la manière dont le transfert des connaissances se produit en chacune d'entre-elles.

1.4.3 Types de l'apprentissage

La catégorisation de l'apprentissage dépend de plusieurs facteurs tels que le domaine, l'acteur, la finalité, etc. Dans cette section nous présentons quelques catégorisations liées au domaine de l'éducation et de l'enseignement.

- *Apprentissage individuel, apprentissage collaboratif* : l'apprentissage individuel est le processus conscient ou inconscient où la connaissance tacite et/ou explicite est créée par une personne à travers l'intuition et l'interprétation de l'information (Bontis *et al.*, 2002 ; Ruiz-Mercader *et al.*, 2006). En conséquence, pour ce niveau d'apprentissage, les compétences et les comportements individuels seront modifiés (Fiol et Lyles, 1985 ; Garvin, 1993). Dans l'environnement d'apprentissage individuel, l'apprenant apprend seul à accomplir l'objectif d'apprentissage sans s'occuper par un autre apprenant. Cependant, l'apprentissage collaboratif implique la construction conjointe de sens par interaction avec d'autres et peut être caractérisé par un engagement commun à un objectif partagé (Curnow *et al.*, 2006). Ainsi, les apprenants travaillent ensemble sur un sujet, échangent leurs opinions et visent une solution commune aux problèmes. La plus grande différence entre l'apprentissage collaboratif et l'apprentissage individuel est l'existence de l'interaction entre les apprenants (Johnson et Johnson, 1994). Ces interactions conduisent les résultats d'apprentissage dans l'environnement collaboratif et offrent aux apprenants la possibilité de réfléchir et d'exprimer leur apprentissage individuel et leur pensée (Puntambekar, 1999).
- *Apprentissage centré-apprenant, apprentissage centré-enseignant* : l'apprentissage centré-apprenant est une approche pédagogique où l'apprenant est l'objectif principal. Il sera, du coup, responsable du contenu, des activités, du matériel et du rythme de l'apprentissage. L'apprenant n'a pas dès lors besoin d'ajuster son niveau de pensée, ou la façon dont il veut comprendre un sujet particulier, aux niveaux des autres apprenants, mais les enseignants doivent descendre au niveau des apprenants pour leur garantir une

meilleure compréhension (Lathika, 2016). En revanche, dans l'apprentissage centré-enseignant l'accent est mis sur les enseignants et la matière d'éducation (Spencer et Jordan, 1999). L'apprenant devient donc un consommateur passif. Harden et Crosby (2000) ont vu que durant l'apprentissage centré-enseignant la connaissance est transmise d'une manière unidirectionnelle de l'expert au novice, alors que pour l'apprentissage centré-apprenant, ce sont les apprenants qui "font" pour parvenir à la connaissance.

- *Apprentissage en présentiel, apprentissage en ligne, apprentissage mixte* : l'apprentissage en présentiel est l'apprentissage classique qui se produit en face à face. Il est généralement critiqué parce qu'il encourage l'apprentissage passif, ignore l'hétérogénéité individuelle et les différents besoins des apprenants (Banathy, 1994; Johnson *et al.*, 2000). Ce type d'apprentissage donne moins d'attention à la résolution de problèmes, à la pensée critique ou à d'autres aptitudes de pensée de haut niveau. L'apprentissage en ligne, dit e-learning, signifie l'utilisation de la technologie électronique pour offrir l'information dans l'objectif de soutenir et améliorer l'enseignement et l'apprentissage (Sun *et al.*, 2008). Il se caractérise par l'interaction libre et ouverte entre les apprenants et les enseignants. L'apprentissage mixte combine les deux afin de faire face aux limitations de chacun d'entre eux.

Les MOOCs sont un produit de l'ère numérique qui s'inscrivent dans la théorie de connectivisme. Ils représentent un environnement d'apprentissage collaboratif, centré-apprenant et médiatisé.

1.5 Transfert des connaissances à l'ère du numérique : vers les systèmes de connaissance

L'expansion géographique des organisations, leur dimension multidisciplinaire, l'aspect dynamique de leurs employés, ainsi que l'importance de la connaissance tacite et explicite dont elles disposent, ont mis le processus de transfert des connaissances face à une complexité évolutive. Les organisations doivent, ainsi, accorder plus d'intérêt à la communication à distance qui est devenue une nécessité et, de même, à l'individu qui y représente à la fois l'utilisateur et le producteur de l'information. Ceci peut justifier le passage d'un système d'information à un système d'information et de connaissance.

Dans une organisation, le système d'information doit garantir que la bonne information soit disponible au bon endroit et au bon moment (Bernus *et al.*, 1996). Dans une acception large, le système d'information est défini comme un ensemble organisé de ressources (matériel, logiciel), employés, données, procédures, permettant d'acquérir, de traiter, de stocker, de diffuser des informations (données, documents, image, sons, etc.) dans l'organisation (Reix, 1995b). Une autre définition

met plutôt l'accent sur son utilité en le définissant comme un système utilisateur-machine intégré qui produit de l'information pour assister les êtres humains dans les fonctions d'exécution, de gestion et de prise de décision (Davis *et al.*, 1986). D'après ces définitions, le système d'information se focalise sur l'information sans forcément la distinguer d'une connaissance. Le rôle de l'individu s'y limite à l'utilisation de l'information disponible. Cependant, le rôle important que joue la connaissance en général, et la connaissance tacite en particulier, dans la réalisation des objectifs des organisations, met en valeur l'importance de l'individu qui la détient. L'information ou la connaissance explicitée stockées dans les supports physiques de l'entreprise ne sont plus avantageuses et un recours à la connaissance tacite incarnée dans la tête des individus est devenu ainsi indispensable.

Nonaka et Konno (1998) ont proposé le concept de *ba* qui est un contexte physique ou virtuel dans lequel la connaissance est partagée, créée et utilisée. Ce contexte doit permettre l'interprétation d'une information à une connaissance. Le processus de création de la connaissance se fait grâce aux interactions entre les individus ou entre les individus et leurs environnements. Les participants de *ba* ne peuvent pas être de simples spectateurs mais ils doivent s'engager à faciliter l'action et l'interaction. En effet, les changements dans un *ba* se déroulent à la fois aux niveaux micro et macro, car les participants changent à la fois eux-mêmes et le *ba*. Il existe quatre types de *ba* qui sont définis pour la gestion de la dynamique de la création de la connaissance selon le modèle SECI (Nonaka et Takeuchi, 1995) (Socialisation, Externalisation, Combinaison, Internalisation) en fonction du type de l'interaction (face à face ou à distance) et des partis prenants (individuel ou collectif). *L'Originating ba* concerne l'interaction individuelle en face à face. Il offre un contexte pour la socialisation où les individus partagent les connaissances tacites à travers les expériences, les émotions et les modèles mentaux. *Le dialoguing ba* concerne l'interaction collective en face à face. Il offre un contexte pour l'externalisation où les modèles mentaux et les compétences des individus sont partagés, convertis en termes communs et articulés comme des concepts à travers les dialogues entre les participants. Ce contexte repose fortement sur la sélection d'un groupe d'individus justifiant une combinaison appropriée de compétences et de capacités spécifiques. *Le systemising ba* définit les interactions collectives et virtuelles. Il offre un contexte pour combiner les connaissances explicites existantes et en construire une nouvelle connaissance explicite facilement partageable, en format écrit, avec un groupe d'individus. Cela est basé sur les technologies de l'information tels que les messages électroniques et les environnements collaboratifs virtuels. *Le exercising ba* est le contexte offert pour l'internalisation et concerne les interactions individuelles virtuelles. Dans ce contexte un individu absorbe les connaissances explicites qui lui sont transmises par les outils médiatisés. *Le exercising ba* synthétise la réflexion à travers l'action, alors qu'en *dialoguing* cela se fait via la pensée. Par conséquent, les actifs de la connaissance d'une entreprise sont mobilisés et partagés en *ba*, où la connaissance tacite détenue par les individus est convertie et amplifiée par la spirale de la connaissance par le modèle SECI.

Dans cette même perspective, Grundstein *et al.* (2014) ont proposé le système d'information et de connaissance (SICO) qui place l'individu au cœur du système comme étant à la fois processeur de l'information et porteur de la connaissance. Le système d'information et de connaissance est “*un ensemble qui repose sur un tissu sociotechnique (individus en interaction entre eux, avec des machines, et avec le système lui-même)*” (Grundstein, 2009). Selon leur point de vue, le système d'information ne distingue pas entre l'information et la connaissance qui sont réellement deux concepts différents où la connaissance représente l'interprétation de l'information. Cette dernière peut être interprétée différemment par des personnes différentes. Les connaissances tacites dans nos têtes résultent du sens que nous donnons, à travers nos cadres interprétatifs, à une donnée que nous percevons dans l'information qui nous a été transmise. En effet, l'auteur d'une information possède une connaissance qu'il a formalisée dans un système d'information en lui attribuant un sens pour qu'elle soit par la suite une information source de connaissance pour quelqu'un qui lui attribuera le même sens. La connaissance n'est donc pas un objet traité indépendamment de la personne qui la traite mais elle est plutôt incarnée dans sa tête. Pour satisfaire cette vision, le SICO est composé de trois sous-systèmes : un système d'information numérique représentant le système artificiel conçu par les technologies de l'information et de la communication, un système d'information constitué par les individus qui sont les processeurs des données auxquelles ils donnent du sens sous la forme d'une information, enfin le système de connaissance représenté par la connaissance tacite détenue par les individus et les connaissances explicites codifiées sous n'importe quelle forme de support (document, vidéo, photo, etc.). Dans un SICO, la dimension explicitée est traitée par l'individu processeur d'informations, alors que la dimension tacite est traitée par l'individu porteur de connaissances (Arduin, 2013).

Dans notre travail, tenant compte de la distinction que nous avons faite entre information et connaissance, nous partageons les mêmes pensées que les auteurs Nonaka et Konno (1998) et Grundstein *et al.* (2014) en considérant l'individu comme étant un composant du système d'information eu égard à l'importance du savoir factuel et du savoir-faire qu'il détient. Cette importance se manifeste clairement dans le domaine d'apprentissage collaboratif médiatisé où l'individu doit à la fois créer, partager et utiliser ces savoirs. Dans ce cas, un système d'information où l'individu est un simple utilisateur, n'est plus pertinent pour le transfert des connaissances à l'ère du numérique.

Afin de permettre le transfert des connaissances à distance, des outils divers ont été proposés et mis en place. De même, des modèles de recherche ont été proposés afin de déterminer les obstacles aux quels le processus de transfert est soumis, en particulier lorsque la communication se déroule à distance. Ces éléments font l'objet de la section suivante.

1.6 Modèles de transfert des connaissances

La communication directe, en face-à-face, n'est plus le seul moyen de transfert des connaissances. Elle est même devenue, dans quelques cas, impossible étant données les contraintes géo-temporelles qui séparent obligatoirement les acteurs. De ce fait, les technologies de l'information et de la communication ainsi que les systèmes à base de connaissances ont été combinés afin de proposer des solutions permettant de remédier à ces contraintes et de garder le partage et le transfert des connaissances possibles même à distance.

Parmi les solutions nous citons les cartographies. Ghrab (2016) a proposé une cartographie basée sur l'aide multicritère à la décision pour la caractérisation et l'évaluation des connaissances médicales. Cette cartographie est conçue comme un outil de repérage, de visualisation et de partage des savoir-faire et des savoirs factuels. Ermine *et al.* (2006) ont proposé une cartographie pour l'identification des connaissances professionnelles cruciales qui méritent d'être transférées entre les acteurs d'une organisation. Sellin (2011) a proposé une cartographie pour l'accompagnement et le transfert de connaissances. Elle doit permettre l'identification et la valorisation d'un patrimoine de connaissances à travers une approche centrée sur l'individu afin de créer un réseau dynamique et collectif d'employés. D'autres solutions sont basées sur les ontologies. Abou-Zeid (2002) a proposé une ontologie culturelle pour l'explication des notions des systèmes impliqués dans, et l'identification des influences culturelles sur, le processus de transfert des connaissances. Le document de spécification de l'ontologie culturelle comprend son domaine, son but, son niveau de formalité, sa portée, ses sources possibles de connaissances, ses questions de compétences et les éventuelles ontologies réutilisables. Savvas et Basiliades (2009) ont proposé une ontologie dans OWL pour représenter la structure d'administration publique et tout type de document qui circule entre les unités administratives, lors de l'exécution des procédures. Elle est basée sur l'interprétation du cadre juridique, en fournissant aux fonctionnaires, aux citoyens et aux entreprises un certain unique pour chaque procédure. En outre, les systèmes de recommandation ont été aussi définis pour cet objectif. Colomo-Palacios *et al.* (2014) a proposé un système de recommandation basé sur le web sémantique afin d'offrir de conseils judicieux aux employés moins expérimentés en fonction de leur profils, compétences et étiquettes (ou tags). Ceci permet de soutenir le mentorat informel et, en conséquence, l'apprentissage informel dans les organisations. Ning (2016) a proposé un système de recommandation de compétences en exploitant diverses traces collaboratives dans l'espace de travail collectif ou collaboratif. La méthode proposée est fondée sur une analyse sémantique de ressources tracées et la technique de régression logistique pour l'apprentissage. Ceci permet de faciliter le travail personnel et collaboratif et aide à la prise de décision. Labarthe *et al.* (2016a) propose un système pour la recommandation d'une liste d'apprenants experts aux apprenants novices dans un contexte des MOOCs afin de favoriser l'interaction médiatisée entre eux.

Selon nos définitions (cf. Section 1.3), les cartographies, les ontologies et les systèmes de recommandation de ressources matérielles (exp. fichiers pdf, images, description, etc), sont tous des outils de partage. En effet, ces outils se limitent à mettre à la disposition des utilisateurs les données jugées cruciales sans accorder une importance à la phase d'appropriation. En revanche, la recommandation d'une ressource humaine (Ning, 2016 ; Labarthe *et al.*, 2016a) peut être considérée comme étant un outil de transfert étant donnée la présence du récepteur qui est sensé communiquer avec la ressource humaine recommandée afin de discuter les informations reçues. Les individus recommandés seront en mesure de déclencher une communication écrite (exp. messages, mail, etc.), auditive (exp. conversation audio) ou bien audiovisuelle (exp. conversation vidéo) où ils peuvent, également, échanger des ressources pédagogiques. La communication permet au sujets d'échanger et de partager des informations pour en arriver à une compréhension réciproque, un accord mutuel ou une action commune (Devirieux, 2007). En d'autres termes, la communication conduit à l'appropriation de l'information transmises auprès des récepteurs et donc au transfert de ces informations source de savoirs.

Cependant, malgré la diversité de ces outils, le processus de transfert des connaissances est toujours soumis à plusieurs obstacles, en particulier quand la distance (géographique, culturelle, linguistique, etc.) entre les acteurs s'impose. Par conséquent, des modèles ont été proposés afin d'identifier les inhibiteurs et les catalyseurs du transfert des connaissances.

Chiu *et al.* (2006) ont étudié les facteurs pouvant directement catalyser la qualité et la quantité des connaissances partagées dans les communautés virtuelles globales de pratique où le comportement de partage est complètement volontaire ce qui engendre généralement la rétention. La quantité de connaissances partagée est calculée en fonction du volume moyen des connaissances transmises par un individu aux membres de la communauté. La qualité des connaissances partagées est évaluée en fonction de la pertinence, de la facilité de compréhension, de l'exactitude, de l'exhaustivité et de la fiabilité. Les auteurs ont démontré que la quantité de connaissances partagées est affectée par les liens d'interaction sociaux et la norme de réciprocité en bénéfice de récompense attendue par l'individu à la suite d'un comportement de partage, ainsi que par l'identification de l'individu qui reflète son sentiment positif par rapport à son appartenance à la communauté. Cependant, la qualité de la connaissance partagée est influencée par la confiance entre les membres de la communauté, la langue partagée entre eux, y compris les codes scientifiques, et la vision commune de leurs objectifs et aspirations collectifs.

Gooderham (2007) a étudié l'influence directe et indirecte des trois dimensions du capital social (Nahapiet et Ghoshal, 1998) sur la volonté de partage des connaissances tacites dans les sociétés multinationales. La théorie de capital social est le réseau de relations individuelles ou sociales et l'ensemble des ressources incorporées dedans qui influencent ensemble la mesure dans laquelle le transfert des connaissances interpersonnel se produit. Nahapiet et Ghoshal (1998) définissent le capital social en trois dimensions distinctes : structurelle (le schéma global de connexions

entre les acteurs), relationnelle (les relations personnelles développées entre les acteurs à travers une histoire d'interactions) et cognitive (les ressources fournissant les représentations, les interprétations et les systèmes de sens partagés entre les parties). Ils ont ainsi montré que le transfert des connaissances est directement influencé par la dimension relationnelle. Cependant, les capitaux sociaux structurels et cognitifs ne stimulent pas directement le comportement de transfert mais stimulent, plutôt, le capital relationnel. Les environnements interne et externe de l'entreprise influencent aussi le processus de transfert. L'environnement externe est représenté par la distance spatiale qui dégrade le degré du capital social structurel et les distances culturelles, économiques et éducationnelles qui affectent le degré du capital social cognitif. De même, l'environnement interne des sociétés multinationales est représenté par les canaux de transmission qui stimulent le degré du capital social structurel et les mécanismes de socialisation qui stimulent à leur tour le capital social cognitif.

Boughzala et Briggs (2012) ont étudié l'effet de la *shareability* de l'individu sur le comportement de partage dans un contexte de collaboration entre les organisations ou les unités d'une même organisation ayant des disciplines différentes. La *shareability* est une attitude liée à l'individu-même en exprimant le degré auquel il se sent prêt à partager ses connaissances avec des personnes qui ne font pas partie de sa propre unité de travail. Elle dépend des caractéristiques de la connaissance partagée (explicité, utilité, réactivité, efficacité, qualité et valeur ajoutée), de l'individu (substantialité, la confidentialité, la réutilisation, la subsidiarité, la *transférabilité* et la fréquence de la valeur) et du groupe (autonomie, vulnérabilité, valeurs partagées, politique d'incitation). La relation de *shareability*-partage doit être modérée par la capacité à partager. Une intention d'agir ne peut être effectuée que si les acteurs sont capables d'exécuter l'action envisagée. Les problèmes d'appétitude, de capacité et d'accès pourraient empêcher le partage des connaissances, même si la *shareability* était positive. La *shareability* de l'individu est liée à l'enjeu social, politique et cognitif attendu à la suite d'un comportement de partage.

Szulanski (1996) a étudié le processus de transfert de bonnes pratiques dans les entreprises. Les barrières de transfert des connaissances sont liées aux caractéristiques des quatre composants du transfert : la connaissance transférée, le récepteur de la connaissance, la source de la connaissance et le contexte de transfert. Quant à la connaissance elle-même, les barrières qu'elle peut engendrer sont : (1) l'ambiguïté causale qui se produit lorsque nous obtenons un résultat d'échec ou de succès dont nous ne comprenons pas la raison à cause d'une compréhension imparfaite du contexte où la connaissance a été appliquée (Winter, 1995) ou bien aussi, si une portion de la connaissance est tacite et incarnée dans les compétences de l'humain (Polanyi, 1962) ou bien encore, si elle est collective et incarnée dans l'esprit de plusieurs personnes (Winter, 1998) ; (2) l'absence de preuve qui intervient lorsque la connaissance n'est pas enregistrée sur un support rend difficile d'inciter les récepteurs potentiels à s'engager dans le transfert (Rogers, 2010) et à légitimer les efforts d'intégration controversés (Nelson et Winter, 2009). Les barrières liées à la source

de la connaissance sont : (1) le manque de la motivation à partager ses propres connaissances et (2) la non fiabilité de la source qui peut être considérée comme non digne de confiance et donc il sera plus difficile d'initier un transfert à partir de cette source et même ses conseils risquent d'être non pris en compte (Walton, 1975). Les barrières liées au récepteur de la connaissance sont : (1) l'absence de motivation révélée par la réticence de certains récepteurs à accepter des connaissances de l'extérieur, (2) l'absence de la capacité absorptive (Cohen et Levinthal, 1990) lorsque les récepteurs s'avèrent incapables d'exploiter des sources extérieures de connaissances, valoriser, assimiler et appliquer les nouvelles connaissances avec succès, et (3) le manque de capacité de rétention qui empêche d'avancer et conduit toujours à mettre fin aux connaissances déjà utilisées et à revenir au point zéro. Enfin, les barrières liées au contexte qui sont : (1) le contexte aride puisque le contexte fertile basé sur les systèmes formels et les sources de coordination affecte le nombre de tentatives de transfert des connaissances ainsi que le résultat de ces tentatives (Ghoshal et Bartlett, 1994) et (2) la relation ardue (laborieuse et éloignée) entre la source et le récepteur pourrait créer des difficultés supplémentaires dans le transfert dépendant, dans une certaine mesure, de la facilité de la communication (Arrow, 1974) et de l'"intimité" de la relation globale entre l'unité source et l'unité réceptrice (Marsden, 1990).

L'outil que nous proposons dans cette thèse, pour l'aide au transfert en ligne des connaissances dans un contexte multi-culturel, doit alors prendre en considération ces barrières afin de trouver des solutions permettant de les minimiser.

1.7 Conclusion

Dans ce chapitre nous nous sommes focalisés sur le processus de transfert des connaissances. Dans un premier temps nous avons défini, sur la base d'une étude bibliographique rigoureuse, les concepts fondamentaux du transfert qui sont la donnée, l'information, le savoir factuel et le savoir-faire. Notamment, *nous avons considéré que la notion de connaissance englobe ces quatre concepts (la donnée, l'information, le savoir factuel et le savoir-faire).*

Nous avons défini une donnée comme *une entité matérielle située dans le monde physique et perçue par un agent cognitif.* La perception est liée à un ensemble de signaux détectés par le système perceptif de l'agent cognitif. Parmi les données existantes, l'agent cognitif sélectionne et acquiert celles dont il a besoin afin de construire ce que nous appelons "données de sens". Nous avons, ensuite, défini l'information comme *le résultat d'une interprétation des données de sens. L'interprétation est un processus complexe composé d'une conceptualisation et d'une sémantisation. Elle mobilise un ensemble de connaissances notamment de nature conceptuelle afin d'établir une relation sémantique entre les différents concepts. L'interprétation dépend de l'agent cognitif.* Contrairement à la donnée qui est externe à l'agent cognitif, l'information est interne, et donc subjective, du fait de l'interprétation.

Pour définir le savoir factuel et le savoir-faire, nous nous sommes basés sur les travaux de notre équipe de recherche, en particulier celui de (Ghrab, 2016). Nous définissons un savoir factuel comme un état de croyance qui concerne une description et qui affecte une valeur de vérité à une description qui peut être factuelle ou instructionnelle. Cependant, concernant la définition d'un savoir-faire, nous avons combiné les deux définitions proposées par Ghrab (2016) et Hawley (2003) pour le définir comme *une disposition à réaliser avec succès un type d'action*. Le savoir-faire et le savoir factuel sont tous les deux fortement liés à l'agent cognitif.

Ces définitions nous ont permis de définir et distinguer les deux processus de transfert et de partage. Nous avons considéré que "*nous partageons des données pour le transfert des informations sources des savoirs factuels et des savoir-faire*".

Nous avons défini le partage de données par "*la mise à disposition par un groupe d'agents cognitifs d'un ensemble de données*". Pour définir le concept de transfert, nous adoptons la définition de Davenport et Prusak (1998) mais nous considérons que l'objet de transfert est plutôt l'information et non pas la connaissance.

Tout au long du manuscrit, nous allons parler d'un transfert des connaissances qui désigne le transfert d'informations source de savoirs (savoir factuels ou savoir-faire) étant donné que la connaissance englobe les données, les informations et les savoirs.

En outre, nous avons établi une revue de littérature sur l'apprentissage en mettant l'accent sur les différentes théories et catégories définies. Cette section nous a permis de distinguer entre les deux notions d'apprentissage et d'appropriation, d'une part, et de comprendre et positionner le processus de transfert des connaissances dans les environnements d'apprentissage collaboratifs tels que les MOOCs, d'autre part. Nous avons, aussi, présenté deux concepts qui prennent en compte l'aspect humain lors du transfert de la connaissance. Le premier est le système d'information et de connaissances où, comparé à un système d'information, l'individu joue un rôle très important. Ce dernier y est à la fois le processeur de l'information et le porteur de la connaissance (Grundstein *et al.*, 2014). Le deuxième est le concept de *ba* (Nonaka et Konno, 1998) qui contextualise la dynamique de la création de la connaissance chez les individus. Finalement, nous avons présenté les outils et les modèles de transfert de connaissances qui ont étudié ce processus dans des contextes où la distance géographique ou culturelle entre les acteurs s'impose. Ceci nous a aidés à identifier les facteurs inhibiteurs et catalyseurs du processus du transfert.

Ces sections définissent le contexte applicatif de notre thèse, qui est les MOOCs qui sera présenté dans le chapitre 2. En effet, le MOOC est caractérisé par une masse très importante de données échangées à distance entre un nombre massif d'apprenants de profils hétérogènes. Il est fortement basé sur le processus de transfert à distance entre les acteurs (apprenants et tuteur) qui déposent leurs données sur un système numérique dans l'intention de transférer leurs savoirs factuels et savoir-faire.

Chapitre 2

Massive Open Online Courses (MOOCs)

Sommaire

2.1	Les Massive Open Online Courses	41
2.1.1	Définition d'un MOOC	42
2.1.2	Les hébergeurs et les producteurs des MOOCs . . .	44
2.1.3	Description	45
2.1.4	Transfert d'informations source des savoirs	46
2.2	Le problème d'abandon	48
2.2.1	Positionnement du problème d'abandon	49
2.2.2	Les motifs d'abandon	50
2.2.3	Indicateurs d'abandon et de performance	51
2.3	Les modèles de prédiction	53
2.3.1	Prédiction des apprenants en risque d'abandon . .	53
2.3.2	Prédiction d'une solution pour la minimisation du taux d'abandon	55
2.3.3	Analyse récapitulative	56
2.4	Conclusion	59

Dans ce travail, nous focalisons sur le MOOC (*Massive Open Online Course*) qui est un environnement d'apprentissage médiatisé basé sur le transfert de savoirs factuels et du savoir-faire. Les MOOCs sont le produit de l'ère numérique et de la massification de données. Il est animé par une équipe pédagogique de taille réduite et accédé par un nombre massif d'apprenants de profils extrêmement hétérogènes.

Les MOOCs fournissent une formation en ligne et gratuite sur un thème prédéfini et pour un nombre illimité d'apprenants (étudiants, employés, retraités, chômeurs, etc.), généralement, sans exiger une connaissance préalable. L'enrichissement du MOOC se fait soit par l'équipe pédagogique soit par les apprenants via les forums proposés. En cas de besoin d'aide, l'équipe pédagogique intervient très rarement en laissant la tâche pour les apprenants pour répondre et échanger entre eux. Par conséquent, deux problèmes se manifestent : d'une part, le partage dans les MOOCs est complètement volontaire d'où le taux de participation dans les forums est très limité, généralement entre 5% et 15% (Kloft *et al.*, 2014 ; Rosé et Siemens, 2014) et, par suite, une majorité des questions demeurent sans réponse. D'autre part, l'expertise et la performance des apprenants ne sont pas éprouvées en amont et donc la pertinence des informations échangées n'est pas garantie. En raison de ces deux problèmes, les MOOCs, malgré leur prolifération, souffrent d'un taux d'abandon excessif qui atteint 90% (Yang *et al.*, 2013 ; Pomerol *et al.*, 2015).

Ainsi, pour faire face à l'abandon et attirer les apprenants pour une durée maximale, plusieurs travaux ont été proposés pour prédire les apprenants dits "en risque d'abandonner le MOOC". Les modèles de prédiction proposés aboutissent à une solution permettant de minimiser le taux d'abandon, ou bien se limitent à l'identification précoce de ces apprenants pour une intervention non précise.

Dans ce chapitre nous abordons tous les aspects du MOOC : leur définition, leur historique, leurs producteurs et leurs types. Ensuite, nous introduisons le processus de transfert des connaissances dans les MOOCs en nous basant sur le travail réalisé dans le chapitre 1. Finalement, nous définissons la problématique d'abandon ainsi que les défis qui lui sont liés. Puis, nous focalisons sur les modèles de prédiction proposés en précisant leurs contributions et leurs limitations. Ceci peut nous aider, dans le reste du manuscrit, à présenter notre méthode de prédiction et la solution que nous proposons pour la minimisation du taux d'abandon à travers l'aide au transfert de connaissances dans les MOOCs, d'une part, et de justifier nos choix des outils et des méthodes, d'autre part.

2.1 Les Massive Open Online Courses

Le MOOC (Massive Open Online Course) est un environnement d'apprentissage collaboratif, centré-apprenant et médiatisé (cf. Section 1.4.3). D'après Shum et Ferguson (2012), le MOOC est une forme d'apprentissage social en ligne qui prend en compte l'évolution des affordances d'un monde dans lequel l'activité sociale se déroule de plus en plus à distance via des formes de médiation. Dans cette section nous présentons tous les éléments permettant de définir et d'expliquer le contexte des MOOCs.

2.1.1 Définition d'un MOOC

Un MOOC est un modèle de prestation éducative qui est, à des degrés divers, Massif, avec théoriquement pas de limite d'inscription ; Ouvert, permettant à quiconque de participer, habituellement sans frais ; En ligne, où les activités d'apprentissage se déroulant intégralement sur le Web ; et un Cours, structuré autour d'un ensemble d'objectifs d'apprentissage dans un domaine d'études défini (Educause, 2013). L'idée derrière le MOOC est d'offrir à un groupe virtuel des personnes géographiquement dispersées et de profils hétérogènes, l'opportunité de participer, idéalement de manière interactive, à l'apprentissage en ligne.

L'acronyme MOOC a été inventé par Cormier et Alexander en 2008 pour définir le cours "*Connectivism and Connective Knowledge*" mené par George Siemens et Stephen Downes, organisé par l'Université de Manitoba à Canada et suivi par 2300 apprenants. C'est le cours qui a déclenché la révolution dans l'éducation en ligne (Siemens, 2012).

- *Massive* : Le succès du MOOC doit être relatif, pas uniquement au nombre massif d'apprenants inscrits, mais plutôt à la conception du MOOC qui doit rendre possible l'éducation de nombreuses personnes (Downes, 2013).
- *Open* : La participation des apprenants n'a pas de conditions préalables autres que l'accès à un ordinateur ou à un appareil mobile et à internet.
- *Online* : La formation est délivrée complètement à distance. Le matériel du cours, la discussion et les évaluations sont accessibles en ligne et aucune interaction en face-à-face n'est envisagée. Dans le MOOC tout se passe via un environnement d'apprentissage virtuel en ligne (Hlosta *et al.*, 2014).
- *Course* : La formation que le MOOC propose doit être plus qu'une simple transmission ou consommation du cours mais plutôt des activités interactives et de développement des compétences (Downes, 2013).

Le MOOC définit une nouvelle théorie de l'apprentissage pour une ère numérique (Downes et Siemens, 2008). Depuis 2008, plusieurs MOOCs ont eu lieu avec un grand nombre de participants. En 2012, le *New York Times* a déclaré l'année 2012 "l'année du MOOC" (Pappano, 2012), puisque le nombre de MOOCs et d'hébergeurs de leurs plateformes a augmenté considérablement dans le monde, en particulier en 2015 et 2016, où le nombre total de MOOCs a atteint respectivement 4200 et 4550 contre 309 en 2013 (Patru et Balaji, 2016). Les MOOCs sont divisés en deux grandes catégories, qui sont :

- cMOOC : ce type est basé sur l'apprentissage distribué et la théorie de connectivisme, d'où vient la lettre "c". D'après Siemens, le cMOOC se concentre sur la création et la génération de connaissances. Ils sont généralement associés aux principes pédagogiques adoptés par Siemens (2005), par lesquels les apprenants sont tenus de s'engager véritablement dans le développement des objectifs d'apprentissage et de la production du contenu du cours.

- xMOOC : ce type est plutôt penché vers la théorie du *behaviorism*. Il utilise des méthodes de livraison plus conventionnelles centrées sur l'instructeur avec une évaluation objective. Ce dernier enregistre les cours et fournit un ensemble complet de ressources, d'exercices et de tests automatisés. D'après Siemens, les xMOOCs se concentrent sur la duplication des connaissances. Ils sont généralement associés à des approches pédagogiques plus traditionnelles, telles que la transmission des connaissances, et sont conçus pour fournir une forme de certification. Par exemple, un SPOC (Small Private Online Course) est un xMOOC avec un nombre restreint d'apprenants ; généralement 50, où les interactions apprenants-enseignants sont inspirées des interactions traditionnelles en classe (Piquer Forcada *et al.*, 2014).

Comme tout nouveau produit, dès leur apparition, les MOOCs ont créé un débat entre ceux qui les défendent et d'autres qui les refusent. Les points de vue partisans sont plusieurs, dont celui de Barber *et al.* (2013) considérant les MOOCs comme des opportunités offertes par la technologie aux dirigeants des universités qui doivent les exploiter en vue de créer de la valeur pour leurs élèves. Hayes (2015) considère que l'élaboration des MOOCs est une innovation avec un grand potentiel pour élargir la participation et promouvoir l'apprentissage, en s'appuyant sur l'expérience des producteurs des opportunités de l'apprentissage en ligne et mixte. Creelman *et al.* (2014) ont décrit les MOOCs comme étant "une étape récente dans l'éducation ouverte". En effet, les MOOCs peuvent être un ajout précieux à la boîte à outils des méthodes que les enseignants utilisent pour aider les étudiants. Il a donc l'avantage distinct d'élargir la portée et l'impact des enseignants, ce qui permet d'accéder à un public beaucoup plus large que les étudiants résidant dans l'université (Karsenti, 2013). Les MOOCs ont aussi plusieurs avantages tels que le coût gratuit de l'éducation (Harder, 2013), le développement du sens de l'autonomie chez les étudiants et la favorisation de la collaboration (Mackness *et al.*, 2010). Yuan et Powell (2013) pensent que les MOOCs vont révolutionner et transformer l'éducation et leur succès social va changer les approches de la formation ouverte basée sur les logiciels libres et les ressources ouvertes. Les opposants du MOOC ont néanmoins une autre opinion. En effet, les limitations que posent les MOOCs telles que le rôle limité de l'enseignant dans ces cours massifs, le taux élevé d'abandon, l'absence physique des participants, la validité limitée des accréditations, leur accordent plutôt un effet perturbateur dans les processus d'enseignement et d'apprentissage. Les MOOCs sont ainsi une mode passagère de l'éducation ou bien un outil de marketing pour les entreprises et les universités (Daniel, 2012 ; Clow, 2013).

Malgré ces deux avis antagonistes, nous restons partisans aux MOOCs qui ont prouvé un succès incontestable témoigné par leur nombre évolutif, la prolifération continue des plateformes qui les hébergent, les universités qui les proposent et surtout les apprenants qu'y participent. En outre, plusieurs universités souhaitent aller plus loin avec les MOOCs en leur accordant un aspect formel leur permettant d'être reconnus par les entreprises recruteuses et donc inclus dans les Curriculum Vitae des apprenants certifiés. Par conséquent, les MOOCs existent et continuent

à réussir pendant presque toute une décennie sans recul, et cette réussite attire de plus en plus d'apprenants du monde entier qui doivent collaborer à distance afin de mener au mieux leur processus d'apprentissage. Dans cette thèse, nous souhaitons intervenir pour l'aide au transfert d'informations sources de savoirs afin d'aider les apprenants du MOOC à recevoir et à approprier l'information qu'ils cherchent.

2.1.2 Les hébergeurs et les producteurs des MOOCs

Les MOOCs sont fournis par des établissements d'enseignement supérieur, souvent en partenariat avec des "organismes" tels que Coursera, edX et Udacity. Le consortium de Coursera comprend actuellement environ plus que soixante-dix institutions membres et celui de EdX comprend des partenaires des institutions diverses telles que les États-Unis, l'Allemagne, l'Australie, Canada, la Chine, la France et la Suède. Coursera possède des droits sur les matériaux, de sorte qu'ils ne peuvent pas être réutilisés sans autorisation. Le matériel peut être retiré lorsque le cours se termine. Coursera décide quelles institutions peuvent accueillir les MOOCs sur sa plateforme, tandis que edX est une plateforme open source. Toute institution qui rejoint edX peut développer ses propres MOOCs et règles concernant les droits sur le matériel (Bates, 2012). En 2014, environ 1000 MOOCs étaient disponibles dans les universités américaines et 800 dans les institutions européennes et dans plusieurs langues en dehors de l'anglais (Bates, 2012).

Les MOOCs ont rapidement dépassé le périmètre des universités afin d'intégrer les entreprises. Selon des statistiques menées par le groupe *Towards Maturity* en 2014, 8% des entreprises dans le monde utilisent déjà les MOOCs et 7% supplémentaires négocient son intégration proche. Les statistiques prévoient une augmentation de 28% en 2016, ce qui rend cette innovation technologique la plus rapide en matière de diffusion de l'apprentissage. Cette adoption des MOOCs varie aussi en fonction des secteurs dans la mesure où la plus forte adoption se trouve dans le secteur public avec 42%, ensuite le secteur privé avec 26% et finalement le secteur à but non lucratif avec 18%.

Plusieurs études qualitatives conduites sur des MOOCs divers (Christensen *et al.*, 2013; Zhenghao *et al.*, 2015; Hamori, 2017) ont montré que plus que la moitié des apprenants participants aux MOOCs sont des employés à plein temps dont la motivation principale est l'acquisition de compétences liées au travail afin de progresser dans leurs emplois. D'après Zhenghao *et al.* (2015), 62% des apprenants employés qui ont terminé un MOOC depuis plus de quatre mois ont indiqué que le MOOC a effectivement réussi à améliorer leurs compétences pour le travail actuel. Une autre étude réalisée par Castano-Munoz *et al.* (2016) a montré que 72% des employés prennent les MOOCs sans la connaissance de leurs employeurs. D'après Hamori (2017), les employeurs sont plus susceptibles de soutenir les MOOCs si le contenu est étroitement lié aux objectifs du travail ou si les apprenants prévoient utiliser le contenu dans leurs emplois actuels. Également, Hamori a constaté que les entreprises de petite taille, celles qui comptent 50 employés ou moins, sont plus sus-

ceptibles de soutenir les MOOCs. Ces résultats montrent que les MOOCs peuvent offrir une alternative de formation aux entreprises qui n'ont pas les ressources nécessaires pour offrir des formations dans leurs locaux ou envoyer leurs employés à des producteurs externes de formation.

Les entreprises peuvent exploiter un contenu d'un MOOC extérieur qui soit pertinent, selon leur point de vue, afin de compléter leur formation formelle existante et profiter de la portée et du volume de l'apprentissage proposé. Elles peuvent, également, développer leurs propres MOOCs pour aider à informer leurs clients/producteurs de nouveaux produits. Dans le cas d'un MOOC interne, les entreprises doivent bien envisager le potentiel d'imiter le modèle MOOC interne à leur chaîne d'approvisionnement et à leurs marchés.

2.1.3 Description

Dans un contexte du MOOC, nous parlons d'acteurs et du matériel (cf. Figure 2.1). Les acteurs sont, généralement, l'équipe pédagogique qui offre et anime le cours, l'équipe technique qui répond particulièrement aux problèmes techniques liés à la plateforme et les apprenants qui participent pour des raisons diverses telles l'approfondissement de leurs savoirs sur une thématique donnée, l'échange avec les participants ou bien tout simplement pour découvrir le concept du MOOC. Les apprenants sont caractérisés par leur nombre massif et leurs profils très hétérogènes (âge, origine, études, culture, compétences, catégorie socioprofessionnelle, etc.). L'équipe pédagogique est, toutefois, d'une taille très réduite ce qui rend difficile le processus d'accompagnement et de soutien auprès des apprenants (Khalil et Ebner, 2013).

Le MOOC est caractérisé par une date de début et une date de clôture ; et dure généralement entre quatre et douze semaines. Un calendrier détaillé est défini en amont précisant les différents axes qui seront traités chaque semaine. Le matériel du cours est composé de trois sections principales (cf. Figure 2.1) : la section des modules où l'équipe pédagogique dépose les ressources matérielles du cours sous plusieurs formats à savoir les vidéos de durée entre cinq et quinze minutes chacune, les fichiers pdf, les images JPEG, etc. Cette section est chargée progressivement en fonction de l'avancement du cours mais elle est généralement regroupée par le thème de chaque semaine indiqué dans le calendrier. Les ressources sont destinées aux apprenants qui doivent y accéder et en sélectionner celles qui sont appropriées à leurs besoins et préférences. La deuxième section est consacrée pour les tâches permettant d'évaluer l'appropriation du contenu des ressources déposées auprès des apprenants. Les deux outils d'évaluation les plus courants dans un MOOC sont les tests à choix multiples évalués par la machine et les activités évaluées par les pairs. Cependant, ces deux outils présentent des problèmes sérieux de gestion et de rigueur. Etant donnée leur massification, les apprenants ne peuvent pas s'attendre à recevoir des commentaires individuels sur leur travail auprès de leur instructeur, et que dans le meilleur des cas, un autre apprenant s'en charge. La troisième section

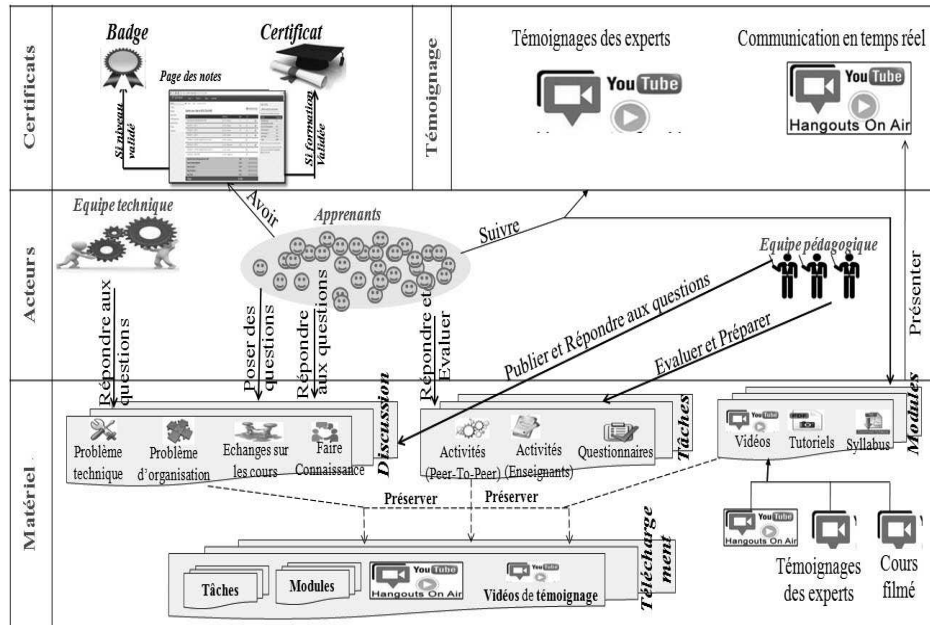


FIGURE 2.1 – Description- générale d'un MOOC

est le forum. Elle représente une section très importante du MOOC dans la mesure où elle est le seul recours des apprenants qui cherchent à trouver une réponse à leurs questions ou bien aussi à faire des connaissances et échanger avec les autres apprenants. A la fin de chaque semaine, tout le matériel est regroupé dans la section Téléchargement pour qu'il soit accessible aux apprenants qui l'ont raté et aussi pour charger la section Modules avec le matériel de la nouvelle semaine. Quelques MOOCs sont aussi enrichis par les témoignages des experts dans la thématique traitée par le MOOC et aussi par les "hangouts" qui sont des vidéos diffusées en direct permettant l'interaction en temps réel entre les apprenants et l'équipe pédagogique.

Certains MOOCs délivrent des certificats d'achèvement et d'autres des badges. Les certificats peuvent, dans quelques cas, être payants mais qui seront reconnus par les universités et les entreprises et serviront donc pour des fins de recrutement.

2.1.4 Transfert d'informations source des savoirs

L'échange de l'information dans les MOOCs se produit via un système d'information numérisé qui encourage la participation active des apprenants (cf. Figure 2.2). Ces derniers peuvent enrichir le système en déposant des données numérisées, puis effectuer une recherche autonome de l'information dont ils ont besoin pour atteindre leurs objectifs d'apprentissage. L'environnement du MOOC remet en cause les méthodes classiques de traitement de l'information qui sont devenues

insuffisantes voire inefficaces et conduit à l'innovation d'autres technologies pour faire face à la massification et à l'hétérogénéité des données.

L'équipe pédagogique dépose les données sous plusieurs formats (exp. vidéo, JPEG, pdf) sur les différentes sections du site du MOOC (exp. Modules, Forums, Evaluations) dans l'intention de transférer des savoirs factuels et du savoir-faire aux apprenants. Cependant, contrairement au transfert d'un savoir factuel qui est formalisable et facilement transférable par le biais de toute forme de données, un savoir-faire ne peut se transférer qu'à travers les modalités spécifiques telles que les vidéos.

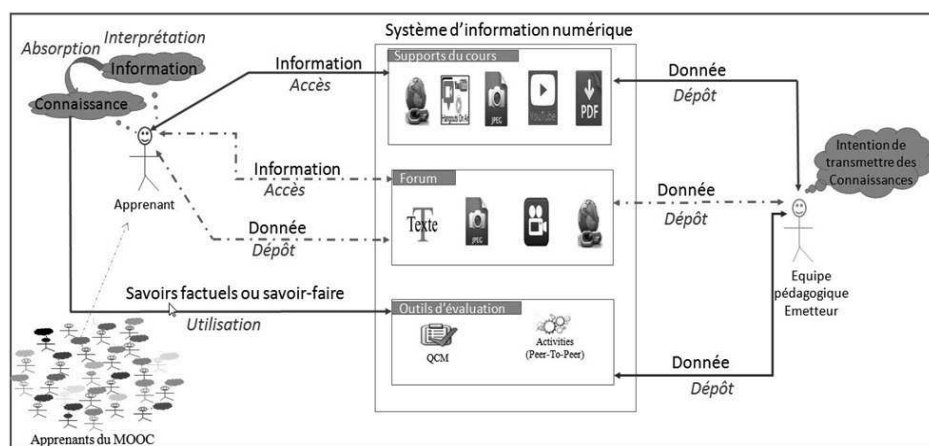


FIGURE 2.2 – Environnement socio-technique du MOOC

Afin de clarifier les données échangées dans un contexte du MOOC, nous nous basons sur le module IE&C (Inscription, Expression and Conceptualization) proposé par Fortier et Kassel (2004) (cf. Figure 2.3). En effet, une donnée déposée par l'équipe pédagogique peut être un objet physique ou non physique. Les objets non physiques sont les expressions des conceptualisations diffusées. La conceptualisation peut être soit des concepts ou bien une description. La description concerne une proposition (exp. une définition du MOOC) ou aussi une description instructionnelle (exp. les étapes pour s'inscrire à un MOOC). Les expressions de ces conceptualisations peuvent ainsi être formalisées sous forme d'image (exp. un apprenant peut déposer une image récapitulative d'une description textuelle inscrite sur un support du cours, afin de faciliter sa compréhension et recenser ses éléments nécessaires) ou bien d'une expression linguistique (exp. l'équipe pédagogique d'un MOOC adapte généralement les vidéos ou bien les fichiers pdf qui sont exprimés en langue naturelle). L'objet physique concerne, par ailleurs, l'inscription d'une information ou bien d'une expression sur un artefact technique tel que l'écran de l'ordinateur que nous utilisons pour accéder aux données du MOOC par exemple ou bien le papier imprimé d'un fichier pdf ou d'une image déposée par l'équipe pédagogique sur le site.

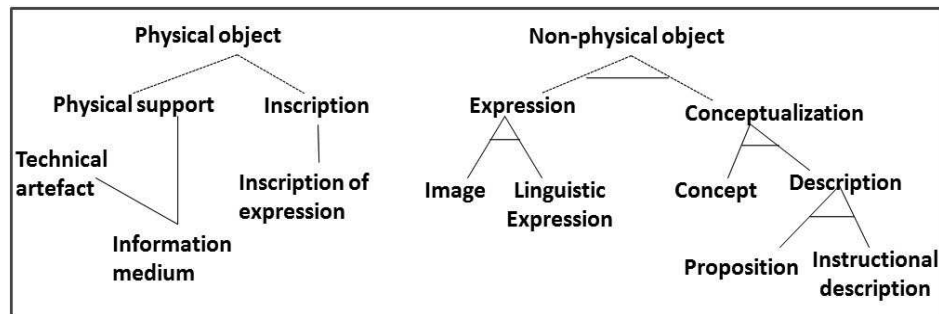


FIGURE 2.3 – Module IE&C (Fortier et Kassel, 2004)

Un apprenant du MOOC accède au site et sélectionne parmi les données déposées celles dont il a besoin afin de les interpréter en information. Comme nous l'avons déjà précisé, un savoir factuel ou un savoir-faire est le résultat du fait de l'absorption d'une information (cf. Section 1.3). Le savoir est lié à l'individu et basé sur son propre bagage culturel ce qui fait que l'information n'est pas interprétée de la même manière par deux apprenants différents. Finalement, puisque le savoir est lié à l'action et doit mener à un succès, le MOOC propose des modalités d'évaluation, questionnaires de choix multiples et évaluations par les paires, permettant à l'apprenant de mettre en œuvre l'information absorbée. Les évaluations par les paires sont le seul moyen permettant l'évaluation d'un savoir-faire. Nous disons qu'un apprenant sait faire une action si et seulement si le résultat de l'application du savoir-faire est correcte. Par exemple, un apprenant sait appliquer le théorème de Pythagore si le résultat de l'application de ce théorème est exact. Evidemment, l'apprenant peut volontairement enrichir le forum du MOOC en déposant des données source de savoirs pour les autres apprenants.

Le MOOC est considéré comme un outil de transfert d'information source de savoirs entre l'équipe pédagogique et les apprenants, ou bien entre les apprenants-mêmes. Cependant, le processus de transfert y est exposé à plusieurs inhibiteurs tels que la distance géographique, culturelle et linguistique séparant ses apprenants ce qui peut causer un problème d'abandon.

2.2 Le problème d'abandon

En dépit de leur popularité croissante et de leur prolifération, les MOOCs sont confrontés à de grandes limitations telles que le taux élevé d'abandon qui atteint généralement 90% (Yang *et al.*, 2013 ; Pomerol *et al.*, 2015). Le problème d'abandon des apprenants représente le premier intérêt des chercheurs et des experts dans le contexte du MOOC. Le problème d'abandon ainsi que ses motifs principaux et ses indicateurs seront présentés dans cette section.

2.2.1 Positionnement du problème d'abandon

Dans la littérature on entend parler de deux concepts : l'abandon et la rétention. Cependant, les deux termes sont complémentaires et représentent les défis principaux dans le contexte des MOOCs. En effet, minimiser l'abandon revient à maximiser la rétention et vice versa. Le taux de rétention des apprenants est communément défini par la fraction des apprenants qui réussissent un cours selon les normes spécifiées par l'instructeur et finissent par obtenir un diplôme signifiant l'achèvement officiel du cours, parmi tous les apprenants qui s'inscrivent initialement (El Said, 2016 ; Koller *et al.*, 2013). Le taux d'abandon représente la problématique majeure pour les concepteurs des MOOCs puisque le nombre des apprenants qui finissent le cours se limite entre 5% et 15% (Daradoumis *et al.*, 2013 ; Dhorne *et al.*, 2017) des participants initiaux et dont la moyenne générale est de 10% (Yang *et al.*, 2013 ; Alraimi *et al.*, 2015). Ce pourcentage n'est pas néanmoins surprenant vu l'accès libre et gratuit à un MOOC.

Le taux d'abandon excessif enregistré a fait naître un nouveau débat qui remet en cause le succès des MOOCs surtout en comparaison avec l'enseignement classique ou l'enseignement mixte. Autrement, le débat tend à déterminer si nous pouvons considérer, ou non, le taux d'abandon comme un critère pour évaluer le succès d'un MOOC. Deux points se sont apparus donnant, ainsi, un premier groupe opposant des chercheurs et des experts qui considèrent qu'une meilleure mesure pour parler de la réussite d'un MOOC est de tenir compte du pourcentage de complétude réalisé par les participants enregistrés (DeBoer *et al.*, 2014 ; Jordan, 2014). Également, Schuman (2013) a considéré le "MOOC comme un mauvais produit" étant donné le taux d'abandon qu'il présente. Le deuxième groupe de partisans, que nous supportons également, considère que le taux d'abandon ne peut pas évaluer le MOOC (Cisel, 2014b). Le succès du MOOC devrait, plutôt, être mesuré à l'aune de ce qui a été appris, compris, intériorisé et donc resté, malgré tout, dépendant de la capacité absorbative (Cohen et Levinthal, 1990) des apprenants. Cependant, étant donnée l'absence d'une évaluation individualisée dans cette formation, il est particulièrement ardu d'évaluer la connaissance absorbée (Cisel, 2014b). Dans ce cas, le succès doit dépendre de l'approche pédagogique suivie où le critère d'évaluation le plus pertinent sera le nombre de vidéos consultées si le MOOC est centré sur les contenus, ou bien le volume des échanges entre participants dans le cas d'un MOOC centré sur l'interaction.

Nous considérons, de même, qu'il y a d'autres motifs externes relatifs aux apprenants et qui sont indépendants de la qualité du MOOC mais conduisent, quand même, l'apprenant à abandonner le cours (cf. Section 2.2.2) ce qui nous empêche d'évaluer le MOOC sur le taux d'abandon.

Pour résumer, nous indiquons que, certes, le taux d'abandon ne permet pas d'évaluer le succès d'un MOOC mais sa minimisation reste quand même un défi majeur pour tous les concepteurs des MOOCs afin de faire transférer leurs savoirs factuels et savoir-faire pour un maximum d'apprenants.

2.2.2 Les motifs d'abandon

Pour faire face au comportement d'abandon, plusieurs chercheurs ont commencé par l'identification des différents motifs susceptibles d'inciter un apprenant à quitter le MOOC. Kizilcec et Halawa (2015) considèrent que le grand écart entre la taille de l'équipe pédagogique et le nombre d'apprenants rend difficile le processus d'accompagnement et d'interaction entre eux ce qui produit un sentiment d'isolement et une volonté d'abandon auprès des apprenants. De même, Guàrdia *et al.* (2013) considèrent que la faible implication des instructeurs lors des différentes étapes du MOOC conduit obligatoirement à une décision d'abandon. Cette implication peut se manifester dans l'interaction entre l'équipe pédagogique et les apprenants pour l'aide à la résolution des problèmes, à la clarification du contenu du matériel et au maintien des relations inter-apprenants via les discussions (Peltier *et al.*, 2003). Basés sur une revue de littérature approfondie, Onah *et al.* (2014) ont identifié des facteurs relatifs à l'apprenant et d'autres qui sont relatifs au cours. Les facteurs liés aux apprenants sont le manque d'une motivation réelle pour finir le MOOC, le manque de temps et donc de disponibilité pour faire le travail et les tâches demandées tout au long de la diffusion du MOOC, le manque des compétences techniques nécessaires pour s'adapter avec les outils technologiques et numériques, les mauvaises expériences d'interaction qui se produisent suite à un comportement inapproprié des pairs dans les forums et le manque de concentration et de coordination dans les forums. Les facteurs relatifs au MOOC sont le niveau de complexité et de difficulté du sujet proposé par rapport au bagage culturel de l'apprenant et le manque de soutien de la part des instructeurs. Hone et El Said (2016) ont utilisé une approche qualitative basée sur un questionnaire rempli par 379 apprenants. Ils ont constaté que l'interaction avec l'instructeur et l'efficacité perçue sont les deux facteurs principaux de l'abandon. L'efficacité est mesurée selon les six critères identifiés par Peltier *et al.* (2007) qui sont : l'interaction apprenant-apprenant, l'interaction apprenant-instructeur, l'accompagnement de l'instructeur, le contenu et la structure du cours proposé, et la technologie de transmission de l'information. Nazir *et al.* (2015) ont établi une étude quantitative basée sur les traces dynamiques des apprenants et ont démontré que le taux d'abandon le plus élevé est atteint au premier jour du MOOC, ce qui est logique et attendu étant donné le caractère ouvert et gratuit du cours. Les apprenants s'y inscrivent, ainsi, afin de vérifier s'ils seront intéressés par le contenu ou non. L'analyse quantitative menée par Morris *et al.* (2015) a montré que les chômeurs ou les demandeurs d'emploi, les apprenants les plus âgés qui ont reçu des niveaux de scolarité plus élevés et les apprenants ayant une expérience antérieure dans l'apprentissage ont tendance à compléter davantage le cours. Labarthe *et al.* (2016b) ont parlé de ce qu'ils ont appelé "Effet de septembre". En effet, suite à une série d'expérimentations sur plusieurs versions d'un MOOC français en entrepreneuriat, ces auteurs ont constaté que le MOOC qui commence en septembre est accédé par des apprenants plus motivés à suivre et à compléter le MOOC. Hlosta *et al.* (2014) ; Wolff *et al.* (2014) ont associé le taux élevé d'abandon à l'absence de l'interaction en présentiel.

Nous remarquons ainsi que les motifs d'abandon et de complétude ne sont pas exclusifs au contenu ou bien à la qualité des MOOCs mais aussi à des conditions purement liées aux apprenants. Ceci confirme notre point de vue partisan concernant le rapport entre le taux d'abandon et le succès d'un MOOC. De même, nous constatons que l'absence de l'accompagnement de la part de l'équipe pédagogique, d'une part, et d'un processus de transfert personnalisé entre les apprenants, d'autre part, représentent les facteurs clés de l'abandon.

2.2.3 Indicateurs d'abandon et de performance dans les MOOCs

D'autres travaux dans la littérature s'intéressent à l'identification des indicateurs susceptibles de prédire si un apprenant a l'intention de quitter la formation ou non. Ces indicateurs peuvent aussi nous indiquer sur la performance des apprenants. Ils peuvent être statiques ou dynamiques. Les indicateurs statiques, dites aussi démographiques, sont généralement obtenus lors du processus d'inscription, ou bien via des enquêtes qui soient publiées à l'avance. Les indicateurs dynamiques sont fournis par les outils de traçabilité proposés par l'environnement des MOOCs permettant de récupérer toutes les activités des apprenants dans des fichiers spécifiques tels que les fichiers *log* ou *CSV* (valeurs séparées par une virgule).

Attributs statiques

Morris *et al.* (2015) ont identifié un lien entre les données démographiques d'un apprenant et la probabilité d'abandon dans le MOOC. Les auteurs ont montré que le niveau d'étude de l'apprenant, son expérience sur l'apprentissage en ligne et sa catégorie professionnelle sont les attributs qui nous permettraient de prédire si les apprenants continueraient ou abandonneraient la formation. Barak (2015) a prouvé que la langue est un indicateur permettant de prédire le comportement d'abandon. En effet, les apprenants qui ne maîtrisent pas la langue du MOOC sont plus susceptibles de l'abandonner. Suriel et Atwater (2012) ont aussi souligné l'importance du bagage culturel de l'apprenant sur la réussite et la complétude de la formation suivie. Alors, un bagage riche aiderait les apprenants à établir une connaissance précise approchée de celle mentionnée par le tuteur du MOOC. Zhang *et al.* (2016) ont montré que l'âge et l'intention préalable de terminer le cours sont fortement liés à la complétude effective. Les personnes à un âge plus avancé avec l'intention de compléter le cours ont tendance à avancer davantage dans la formation. Engle *et al.* (2015) ont constaté que le niveau d'études et la maîtrise de la langue adopté par le MOOC sont aussi des indicateurs forts sur l'abandon. Cisel (2014a) a identifié le statut de l'emploi (emploi à plein temps et à temps partiel) comme un indicateur crucial de la prédiction de la complétude des MOOCs et il a découvert que les apprenants ayant des emplois à temps partiel ont atteint un taux de complétude plus élevé. Ceci en raison de leurs disponibilité qui leur permet

de suivre l'avancement du cours et réaliser les activités proposées. Stein et Allione (2014) ont mis l'accent sur le sexe de l'apprenant, son âge, son niveau d'études et son expérience antérieure avec les environnements en ligne. Il a constaté que les participants plus jeunes (moins de 25 ans), les étudiants et les femmes à temps plein sont plus susceptibles de quitter le cours alors que ceux qui sont âgés (36 à 50 ans) ou ayant une expérience antérieure avec les MOOCs sont moins enclins à abandonner. Kizilcec et Halawa (2015) a prouvé que l'âge de l'apprenant, son niveau et domaine d'études, sa connaissance préalable sur le sujet du MOOC, son niveau d'expérience sur les MOOCs et sa disponibilité hebdomadaire réservée pour le suivi du cours sont tous des indicateurs permettant de prédire le comportement de l'apprenant. Finalement, d'après Fini (2009), la maîtrise de la langue du MOOC, les compétences techniques et la disponibilité sont des indicateurs éminents pour l'abandon.

Attributs dynamiques

Outre que les attributs statiques, les experts et les chercheurs ont également identifié les données dynamiques qui sont tracées en fonction de l'activité de l'apprenant sur l'environnement d'apprentissage.

Wolff *et al.* (2014) ont distingué trois types d'activités qui permettent de prédire l'abandon d'un apprenant. Ces activités sont l'accès à une ressource ou à un matériel de cours ; la publication d'un message sur le forum et l'accès à l'espace d'évaluation. Avec plus de précision, Stein et Allione (2014) ont montré l'effet positif des vidéos consultées, des évaluations essayées et du score obtenu, sur le processus de prédiction des apprenants en risque. Kloft *et al.* (2014) ont également prouvé l'importance du nombre de connexions sur le site du MOOC, du nombre de pages consultées, du nombre de vidéos vues et du nombre d'accès au forum. Ramesh *et al.* (2014) ont défini le nombre de publication dans les forums, le nombre d'affichage du contenu du forum, la période depuis le dernier quiz soumis par l'utilisateur, le nombre de vues des vidéos et le temps passé sur chacune de ces tâches, comme étant des indicateurs forts pour la prédiction d'abandon. Brinton et Chiang (2015) ont identifié neuf indicateurs pouvant informer sur la performance des apprenants qui sont : la fraction du temps dépensée pour la lecture d'une vidéo par rapport à sa longueur, le pourcentage des vidéos lues, le taux de vidéos vues en considérant la répétition, le nombre des pauses où l'apprenant a interrompu la vidéo, la fraction de temps que l'utilisateur a passé en pause sur la vidéo, la moyenne temporelle des taux de lecture des vidéos, l'écart type des taux de lecture sélectionnés dans le temps, le nombre de fois que l'apprenant a revenu en arrière dans la vidéo et le nombre de fois que l'apprenant a raté une vidéo. Dans une hypothèse beaucoup plus simplifiée, Halawa *et al.* (2014) ont défini un apprenant en risque par celui qui a dépassé un mois sans activité ou bien qui a vu moins de 50% des vidéos dans le cours. Kizilcec *et al.* (2013) ont divisé les apprenants selon le taux de complétude de leurs activités (évaluations par les paires et questions à choix multiples) en quatre classes : classe de "Complétude", contenant les apprenants qui ont effectué

la majorité des évaluations offertes, classe des “Audit” rassemblant les apprenants qui font rarement des évaluations mais qui restent engagés, classe de “Désengagement” qui regroupe les apprenants qui répondent aux évaluations seulement au début du cours et disparaissent par la suite et la classe des “Echantillons” qui est faite d’apprenants qui ont regardé la vidéoconférence pour une seule période d’évaluation. D’autres auteurs ont essayé de tester d’autres attributs, autres que ces indicateurs classiques, tel que le score sentimental basé sur la lexique de satisfaction (Chaplot *et al.*, 2015), le niveau social de l’apprenant via ses interactions avec les autres participants (Sunar *et al.*, 2015) et le suivi implicite du rythme cardiaque des apprenants sur leurs téléphones mobiles (Pham et Wang, 2015).

Tous ces indicateurs, statiques et dynamiques, ont été validés en utilisant les modèles de prédiction basés sur les techniques conventionnelles de *machine learning* (Markov, SVM, etc.) sur des MOOCs divers. L’importance de chaque attribut a été prouvé par son impact positif sur la qualité de prédiction obtenue.

2.3 Les modèles de prédiction

La prédiction de l’abandon a pour objectif de délimiter les intentions des apprenants afin de concevoir des interventions permettant de leur augmenter l’engagement et la motivation (Taylor *et al.*, 2014). Les modèles de prédiction proposés pour les MOOCs ont des objectifs divers : prédire les apprenants “en risque” ou bien prédire une solution afin d’aider ces apprenants pour ne pas quitter leur formation.

Cette section présente un état de l’art sur les modèles de prédiction proposés dans le contexte du MOOC qui seront, par la suite, discutés.

2.3.1 Prédiction des apprenants en risque d’abandon

Le principe communément adapté par les chercheurs pour la prédiction des apprenants en risque est d’utiliser l’une des techniques de *machine learning* sur des attributs statiques et dynamiques. Les attributs statiques sont fournis par l’apprenant lors du remplissage du formulaire d’inscription proposé par la plateforme diffusant le MOOC. Les attributs dynamiques sont fournis par le système d’information qui gère l’ensemble du MOOC.

Balakrishnan et Coetzee (2013) ont proposé un modèle pour prédire la rétention des apprenants dans les MOOCs en utilisant deux types de techniques de chaînes de Markov (HMM) ; HMM avec une entrée unique où un seul attribut est considéré et HMM avec entrées multiples qui combine tous les attributs à la fois. La prédiction est basée sur le pourcentage cumulé des vidéos disponibles, le nombre de messages publiés sur le forum, le nombre de discussions consultées et le nombre de fois où les supports du cours ont été consultés. Ce modèle a été validé sur un MOOC de 29882 apprenants de durée de six semaines. Il a pour objectif de prédire l’abandon d’un apprenant pour la semaine prochaine du MOOC sur la base de ses données pour toutes les semaines précédentes. Les expériences ont montré que

le HMM à entrées multiples donne des résultats plus raisonnables que la caractéristique unique. De plus, le pourcentage de vidéos de cours consultées est le plus pertinent lors de l'utilisation de la HMM à entrée unique. Chaplot *et al.* (2015) ont proposé un modèle basé sur les réseaux de neurones pour prédire l'attrition des apprenants dans un MOOC. Outre que les attributs classiques, tels que le nombre de clics effectués par l'apprenant et le nombre hebdomadaire d'accès au forum et au matériel du cours, les auteurs ont intégré un attribut de score sentimental. Ceci est calculé à l'aide d'une analyse du sentiment basée sur le lexique des publications du forum. L'analyse sentimentale est réalisée à l'aide de l'outil SentiWordNet 3.0 (Baccianella *et al.*, 2010) en utilisant un lexique de satisfaction. Les auteurs ont prouvé que l'analyse du sentiment exprimé par les apprenants lors de leur participation aux forums est un indicateur important de l'intention du comportement d'abandon. Ce modèle permet d'estimer si l'élève abandonnera le cours la semaine prochaine du MOOC en fonction de ses données de la semaine précédente. Xing *et al.* (2016) ont proposé une approche de modélisation temporelle pour prédire les apprenants en risque d'abandon en utilisant le réseau bayésien général et l'arbre de décision. Les attributs exploités sont le nombre de messages publiés, le nombre de vues du forum, le nombre de vues de quiz, le nombre de vues des supports du cours et le degré de réseau social. Ce modèle permet de prédire le moment d'abandon de chaque apprenant dans un ordre chronologique. L'apprentissage dans ce modèle se fait sur un MOOC afin de tester sur d'autres MOOCs. L'objectif est de privilégier les apprenants qui tentent abandonner le cours très vivement en leur proposant de l'aide. Le modèle a été validé sur un MOOC hébergé par la plateforme Canvas d'une durée de huit semaines et accédé par 3617 apprenants. Deux cas de figures ont été testés : le premier est de sommer les données de toutes les semaines précédentes, c'est-à-dire d'une semaine à une autre la taille de l'échantillon augmente et la taille de l'ensemble d'attributs reste le même. Le deuxième cas est de sommer les critères, c'est-à-dire d'une semaine à une autre la taille de l'échantillon d'apprentissage reste le même et la taille de l'ensemble de critères augmente. La qualité de prédiction calculée pour ce modèle est très satisfaisante dont la précision atteint 94%. Ren *et al.* (2016) ont développé un modèle de régression linéaire multiple pour prédire la performance des apprenants dans les évaluations futures proposées par le MOOC. La prédiction est basée sur le nombre de cliques effectués par l'apprenant. Les cliques sont catégorisées selon leurs types en six catégories qui sont les cliques liées à une session, à une vidéo, à un quiz, à un devoir, à l'intervalle de temps entre le dernier quiz et un devoir et enfin à l'agrégation des activités entre deux devoirs consécutifs. Deux catégories d'apprenants ont été considérées : ceux qui ont fini toutes les activités et ceux qui les ont partiellement finies. Les expérimentations effectuées sur trois MOOCs dont le nombre de participants est de 13130, 52321 et 3263 respectivement. Elles ont montré que les inputs portant sur toutes les semaines sont plus performants que celles de la dernière semaine uniquement. Aussi, les attributs associés au nombre de connexions, au nombre de visualisations de vidéos et aux questionnaires sont les plus importants. La qualité de prédiction

est satisfaisante d'une précision qui atteint 80%. Sunar *et al.* (2015) ont proposé un modèle permettant de prédire les interactions futures entre les paires en fonction de leur historique d'interaction sur un forum du MOOC. La méthode de prédiction est basée sur un graphe direct où les nœuds sont les apprenants et les arcs sont les interactions entre ces apprenants. Un arc est marqué d'une force qui représente le nombre de commentaires ajoutés par l'apprenant source pour répondre à l'apprenant destinataire. La force prédite entre les paires est basée sur la somme de ces forces existantes. Quatre catégories possibles de relation ont été identifiées : une relation inexistante, une relation persistante, une relation à travers un autre apprenant et une relation isolée où l'apprenant n'a jamais reçu de réponses. La valeur de cette force devrait permettre de prédire si l'apprenant abandonnera ou non le MOOC. La méthode est validée sur un MOOC qui a commencé avec 9855 apprenants et a duré huit semaines. La qualité de prédiction était satisfaisante particulièrement pour les deux classes de relation persistante et indirecte. Amnueypornsakul *et al.* (2014) ont proposé un modèle prédictif pour l'attrition de l'apprenant en utilisant des attributs liés au nombre de tentatives pour répondre à un quiz et les attributs classiques d'interaction avec l'environnement du MOOC. Les activités de l'apprenant sont données au modèle en tant que séquence d'actions enchaînées chronologiquement. Selon la longueur de leur séquence d'action, trois classes d'apprenants sont définies : les apprenants actifs qui sont les apprenants formellement inscrits avec une séquence d'action dont la longueur est supérieure à 2 ; les apprenants inactifs qui sont inscrits mais ayant une séquence d'action inférieure à 2 ; et les apprenants qui ont formellement abandonné. Pour les expériences, deux modes sont considérés : Mod1 où les utilisateurs inactifs sont considérés comme abandonnés et Mod2 où les utilisateurs inactifs sont considérés comme actifs. En outre, deux cas sont considérés : cas spécifique où les utilisateurs inactifs sont exclus et le cas général. La technique de machine à vecteurs de support (SVM) est utilisée. L'expérimentation a montré que le modèle spécifique basé sur le mode Mod1 donne la précision la plus élevée de 91%. Le modèle a par contre donné une F-mesure très faible qui ne dépasse pas 23% dans tous les cas.

La littérature qui propose des modèles de prédiction pour l'identification précoce des apprenants en risque est très riche. Cependant, les travaux qui proposent des solutions pour accompagner ces apprenants ou pour renforcer l'équipe pédagogique sont limités en nombre.

2.3.2 Prédiction d'une solution pour la minimisation du taux d'abandon

Les solutions proposées pour les MOOCs doivent prendre en compte l'hétérogénéité élevée des apprenants, leur niveau varié de maturité et d'expérience et leurs origines pédagogiques et culturelles différentes. Elles doivent garantir une formation adaptable aux profils et aux besoins spécifiques des apprenants en respectant leurs styles d'apprentissage préférés (Daradoumis *et al.*, 2013 ; Reilly, 2013).

Chaturvedi *et al.* (2014) ont proposé un modèle pour prédire la situation où l'instructeur du MOOC doit intervenir dans les discussions du forum. L'objectif est d'aider les apprenants à obtenir l'information dont ils ont besoin de la part de l'instructeur afin de les motiver à ne pas abandonner le MOOC. Ce travail considère les messages d'une discussion en tant qu'une chaîne chronologique d'événements et utilise les deux modèles, linéaire et globale, de la chaîne de Markov. Chacun de ces modèles prend en entrées des informations sur la discussion et sur chaque message qu'elle contient. La structure de la discussion et une analyse lexicale des messages sont également prises en considération. Le modèle a été validé sur deux cours proposés par la plateforme Coursera en utilisant deux échantillons de 3800 et 3900 messages. La chaîne de Markov a donné une qualité de prédiction plus précise que la régression logistique mais d'une valeur relativement faible (F-measure = 35.29%). Moon *et al.* (2014) ont proposé un modèle permettant de prédire ce qu'ils appelaient apprenants leaders. Ce sont les apprenants dont le langage influe sur celui des apprenants en difficulté. Ils ont utilisé la technique SVM ainsi qu'une mesure d'hébergement linguistique. Leur méthode est basée sur l'analyse lexicale des messages du forum afin d'identifier les apprenants leaders dont leurs messages sont réutilisés par d'autres apprenants. Les apprenants leaders seront mobilisés pour répondre aux messages du forum des apprenants en difficulté correspondants. Le modèle a été validé sur deux cours en langage Python et Psychologie proposés par la plateforme Coursera et accédés respectivement par 3509 et 1982 apprenants. Le modèle a donné une qualité de prédiction satisfaisante d'une précision entre 53% et 73%. Chandrasekaran *et al.* (2015) ont proposé un modèle pour prédire exactement à quelle discussion le tuteur doit intervenir tout en respectant sa capacité cognitive. Un classificateur binaire supervisé basé sur une régression logistique régularisée est utilisé. Le processus de classification a incorporé un nouvel attribut qui est le type de forum auquel appartient la discussion. Quatre types de forums ont été considérés qui sont : forum sur le matériel du cours, sur les examens, sur les devoirs et sur les erreurs détectées. Le modèle d'apprentissage est basé sur les discussions précédentes déjà intervenues par le tuteur come étant des échantillons positifs. Le modèle a été validé sur des données issues de 14 cours. Les résultats de la prédiction montrent que le type de forum a entraîné des améliorations significatives de 9.21% par rapport au travail de Chaturvedi *et al.* (2014).

Les modèles de prédiction que nous avons présentés ci-dessus sont soumis à plusieurs limitations qui seront discutées dans la section suivante.

2.3.3 Analyse récapitulative

Dans cette section, nous présentons les obstacles affrontés par les modèles de prédiction quand ils sont appliqués dans le contexte des MOOCs. Ces obstacles impactent la qualité de la prédiction et aussi la pertinence de la solution proposée. Le travail que nous présentons dans cette thèse vise ainsi à proposer des solutions permettant de les surmonter.

- *Problème de données déséquilibrées* : Malgré leur efficacité, les techniques de machine learning sont face au problème d'apprentissage en présence de données déséquilibrées. Ce problème résulte d'une répartition inégale entre les instances des classes utilisées lors de la phase d'apprentissage du modèle. En effet, dans un contexte des MOOCs, nous avons toujours un taux d'abandon excessif qui produit un nombre d'apprenants en risque qui est beaucoup supérieur que le nombre d'apprenants actifs. De même, vu l'intervention rare de l'équipe pédagogique sur les forums, nous obtenons des discussions non intervenues plus que celles qui sont intervenues. Ainsi, nous serons toujours face à une classe majoritaire qui est la classe des "Apprenants en risque" dans le cas de prédiction de l'abandon et la classe des "Discussions non intervenues" dans le cas de proposition d'une solution. Le modèle de prédiction aura ainsi tendance à classer les instances potentielles dans la classe majoritaire ce qui impacte la qualité de la prédiction. Pour remédier à ce problème, des techniques supplémentaires ont été proposées telles que les méthodes d'échantillonnage (Krishna Veni et Sobha Rani, 2011), les méthodes d'apprentissage sensibles aux coûts (Elkan, 2001 ; Ting, 2002) et les méthodes basées sur Kernel (Vapnik, 1995). Dans notre contexte (cf. Table 6.1), Amnueypornsakul *et al.* (2014) ont utilisé la technique de sur-échantillonnage afin d'améliorer la qualité de prédiction en présence de données déséquilibrées. Cependant, cette technique n'avait pas un effet significatif sur le résultat. Chaplot *et al.* (2015) ont fixé un seuil de classification qui représente le ratio entre les points d'abandon et le nombre total de points de données dans l'ensemble d'apprentissage. Cela signifie que si la valeur de sortie du neurone est supérieure à ce ratio, l'apprenant est prédit en risque. Chandrasekaran *et al.* (2015) ont accordé des pondérations plus élevées aux instances de classe minoritaire. Ces poids sont appris en optimisant la mesure de F-maximale en fonction du jeu de formation/validation. Cette solution a amélioré leurs performances à 45,54% contre 35,29% pour Chaturvedi *et al.* (2014). D'autres auteurs choisissent des mesures qui ne sont pas très sensibles au problème de données déséquilibrées telle que la mesure d'exactitude (Ren *et al.*, 2016) ou bien se contentent à déclarer le problème sans lui proposer une solution (Balakrishnan et Coetzee, 2013).
- *Solution basée sur l'intervention du tuteur* : les modèles de prédiction des apprenants en risque se limitent à prédire cette classe d'apprenants. Leur objectif est d'en informer le tuteur afin qu'il intervienne auprès de chaque apprenant en le motivant à ne pas quitter le cours. Cependant, cette solution est difficile voire impossible. En effet, le nombre d'apprenants en risque reste massif si nous considérons le taux élevé qu'ils présentent qui dépasse 90%. Ainsi, le tuteur dans ce cas ne peut pas intervenir ou contacter l'intégralité de ces apprenants et donc nous revenons au problème de massification d'apprenants. Ces travaux doivent donc ramener une solution basée sur le modèle de prédiction qu'ils proposent afin de réaliser leur objectif principal qui est

TABLE 2.1 – Etude récapitulative sur les travaux antérieurs

	Technique	Contribution	Problème d'apprentissage dans des données déséquilibrées	Limites
Prédiction des Apprenants en risque	Chaîne Markov Balakrishnan et Coetzee (2013)	Consultation des vidéos de cours et de la page de cours, Nombre de discussions vues ; Nombre de publications sur le forum		Aucune solution
	Machine à vecteurs du support Amnuey-pornsakul <i>et al.</i> (2014)	Interaction avec l'environnement du MOOC ; Nombre de tentatives de quiz ; Longueur de la séquence d'action		Sur-échantillonnage
	Réseaux de neurones Chaplot <i>et al.</i> (2015)	Interaction avec l'environnement ; Analyse sentimentale des pots du forum		Seuil de classification = points d'abandon/ points dans l'ensemble de formation
Prédiction de l'intervention du tuteur	Régression logistique Chandrasekaran <i>et al.</i> (2015)	Informations sur la discussion ; Type de forum auquel appartient la discussion		Octroyer les instances de la classe minoritaire avec des poids plus élevés

de minimiser le taux d'abandon dans les MOOCs.

- *Solution destinée aux participants du forum* : les modèles qui prédisent l'intervention du tuteur sur le forum construisent leur échantillon d'apprentissage à partir des messages publiés sur le forum. De même, l'aide qu'ils proposent est destinée exclusivement aux participants du forum. Cependant, les études menées sur les MOOCs ont démontré qu'en dépit de leur popularité énorme, la grande majorité des apprenants ne participent pas aux discussions des forums (Kop *et al.*, 2011 ; Manning et Sanders, 2013 ; Breslow *et al.*, 2013). Le taux de participation des apprenants est limitée entre 5% et 10% (Kloft *et al.*, 2014 ; Rosé et Siemens, 2014). Dans ce cas, l'échantillon d'apprentissage ne peut pas être représentatif pour tous les apprenants du MOOC surtout qu'ils sont caractérisés par des profils hétérogènes. Aussi, les apprenants concernés par l'aide représentent une minorité et leur rétention ne pourra pas diminuer le taux d'abandon d'une manière significative.

Dans le reste de ce manuscrit, nous proposerons une méthode basée sur l'aide à la décision multicritère périodique et incrémentale qui permettra d'éviter le problème d'apprentissage en présence des données déséquilibrées sans faire recours à

des techniques supplémentaires. Intégrée dans un système de recommandation que nous développons, notre méthode apportera une solution afin de renforcer l'équipe pédagogique, favoriser l'interaction personnalisée entre les apprenants et aider à l'appropriation individuelle des informations échangées auprès de chaque apprenant du MOOC.

2.4 Conclusion

Dans ce chapitre, nous avons présenté les *Massive Open Online Courses* (ou MOOCs). Ce sont des formations d'apprentissage gratuites diffusées en ligne et accessibles par un nombre massif d'apprenants. Un MOOC est animé par une équipe pédagogique de taille réduite qui se trouve incapable d'accompagner l'intégralité des apprenants durant leur processus d'apprentissage. Le MOOC est un outil de transfert d'informations source de savoirs entre les apprenants entre-eux et avec l'équipe pédagogique. Il est un produit de l'ère numérique soumis à plusieurs contraintes qui inhibent le processus de transfert et, par conséquent, conduisent les apprenants à l'abandonner. Ce chapitre a, ainsi, positionné le problème d'abandon dans les MOOCs ainsi que ses facteurs principaux.

Afin de minimiser le taux d'abandon, plusieurs modèles ont été proposés pour la prédiction des apprenants en risque de quitter le MOOC ou bien afin de proposer une solution permettant d'encourager ces apprenants à continuer leur formation. Cependant, ces modèles sont soumis à plusieurs limitations telles que l'apprentissage en présence des données déséquilibrées.

Ouamani *et al.* (2014) ont défini deux types de défis dans les environnements d'apprentissage collaboratif interculturel. Le premier concerne la gestion (l'identification, la collecte, l'analyse, la construction, le partage et l'application) du savoir socioculturel. Le deuxième concerne l'externalisation de ce savoir en permettant les apprenants, d'une culture différente, de collaborer entre eux et leur donnant les mécanismes nécessaires pour le partage des compréhensions et la résolution des conflits.

Dans le reste du travail nous nous focalisons sur le deuxième défi. En effet, nous présenterons notre méthode de classification multicritère et incrémentale *MAI2P* (*Multicriteria Approach for the Incremental Periodic Prediction*) (cf. Chapitre 4) basée sur notre algorithme *DRSA-Incremental* (cf. Chapitre 3). Appliquée sur le contexte des MOOCs (cf. Chapitre 5) la méthode *MAI2P* nous a permis de prédire les "Apprenants en risque", les "Apprenants en difficulté" et les "Apprenants leaders". La méthode doit répondre aux limitations dévoilées dans les travaux antérieurs liées à la problématique de prédiction. Ensuite, nous proposerons un système de recommandation *KTI-MOOC* (*Recommender system for the Knowledge Transfer Improvement within a MOOC*) (cf. Chapitre 6) basé sur la méthode *MAI2P* pour l'aide au transfert des savoirs entre les apprenants du MOOC.

Chapitre 3

DRSA-Incremental : Algorithme de mise à jour incrémentale des approximations de DRSA

Sommaire

3.1	Préliminaires	62
3.1.1	Aide multicritère à la décision	63
3.1.2	Dominance-based Rough Set Approach (DRSA) . .	64
3.1.3	Théorème de la décision P-généralisée	67
3.1.4	Modèle de préférences	68
3.2	Apprentissage incrémental	69
3.3	Travaux antérieurs	71
3.4	Algorithme de mise à jour incrémentale	72
3.4.1	Algorithme et notations	72
3.4.2	Etape 1 : Application du théorème de la décision P-généralisée des actions insérées	74
3.4.3	Etape 2 : Mise à jour de l'union supérieure et inférieure des classes de décision	76
3.4.4	Etape 3 : Mise à jour de l'ensemble P-dominé et P-dominant des actions initiales	77
3.4.5	Etape 4 : Mise à jour des approximations inférieures et supérieures	78
3.5	Conclusion	81

Dans ce chapitre nous proposons un algorithme basé sur l’approche DRSA (*Dominance-based Rough Set Approach*) (Greco *et al.*, 2001a) et dédié pour l’apprentissage incrémental. D’après Ruping (2001), l’apprentissage incrémental se produit lorsque les données de l’échantillon sont présentées par portions, d’une manière séquentielle, pour un algorithme d’apprentissage. A la réception d’une nouvelle portion de données, toutes les portions précédentes seront compressées. Ensuite, l’apprentissage du modèle se fait en fonction de la nouvelle et des précédentes portions à la fois. L’apprentissage incrémental a deux objectifs. Le premier est de minimiser le coût de calcul lors d’un apprentissage dans une masse grandissante de données. En effet, l’apprentissage non-incrémental reprend tout le calcul à chaque fois qu’une nouvelle portion est fournie ce qui consomme un temps et un espace mémoire énormes (Sutton, 1988). Ceci est indésirable, en particulier, dans le cas où la décision résultante de la phase d’apprentissage doit être prise en temps réel. Le deuxième objectif se révèle lorsque l’ensemble représentatif soit reçu par portions alors que le modèle doit apprendre avant que toutes les informations nécessaires soient disponibles (Michalski, 1988). Dans certains cas il est requis de prendre une décision en fonction de ce que nous avons comme informations, partielles, afin de pouvoir réagir au moment opportun. La décision sera progressivement raffinée lorsque des nouvelles données sont disponibles.

Généralement, l’apprentissage, incrémental ou non-incrémental, est appliqué par les techniques conventionnelles de *machine learning* (exp. les réseaux de neurone, chaîne de Markov, Machine à vecteurs de support, etc.) pour l’élaboration d’un modèle prédictif. Cependant, dans ce travail, nous adoptons l’approche DRSA qui est une technique d’apprentissage supervisé dédiée pour l’aide multicritère à la décision. L’approche DRSA permet d’inférer un ensemble de règles de décision, traduisant les préférences des décideurs humains, à partir d’un ensemble d’apprentissage. Cette approche dispose de plusieurs spécificités qui la caractérisent par rapport aux autres techniques conventionnelles. La première spécificité concerne le choix de l’ensemble d’apprentissage. D’après Hall (1999), la phase d’identification d’un ensemble représentatif de données, pour la construction d’un modèle de classification, représente le problème central dans l’apprentissage par machine. Ainsi, pour définir un ensemble d’apprentissage, à la fois, représentatif et de qualité, l’approche DRSA repose sur les préférences et l’expertise des décideurs humains. L’intervention humaine garantie, également, la répartition égale des instances sur l’ensemble de classes de décision ce qui permet de surmonter le problème de données déséquilibrées (cf. Section 2.3.3) qui caractérise les techniques conventionnelles de prédiction (Bouzayane et Saad, 2017b). Deuxièmement, l’approche DRSA se caractérise par la simplicité des règles de décision qu’elle génère. Ces règles ont la forme de “Si *condition(s)* Alors *décision*” ce qui permet au décideur de comprendre la raison de sa décision en langage naturel (Błaszczyszński *et al.*, 2012). Contrairement aux techniques conventionnelles d’apprentissage, les règles de décision inférées par DRSA sont aisément interprétables.

L'approche DRSA a été fréquemment utilisée pour un objectif de classification (Greco *et al.*, 2000 ; Saad, 2005 ; Saad *et al.*, 2005 ; Deng *et al.*, 2011 ; Turki *et al.*, 2012 ; Stańczyk, 2013 ; Ghrab et Saad, 2016) ou bien de prédiction dans un contexte non-incrémental (Shen *et al.*, 2014 ; Zaras, 2011). En revanche, notre objectif est de l'appliquer pour un objectif de prédiction incrémentale. Dans la littérature, quelques travaux ont proposé des algorithmes pour la mise à jour incrémentale des règles de décision suite à la réception d'une nouvelle portion de données d'apprentissage. Ces algorithmes sont, cependant, non robustes (Greco *et al.*, 2004) ou bien limités à l'ajout d'une seule instance (Li *et al.*, 013b). Dans ce chapitre, nous proposons un algorithme, *DRSA-Incremental*, pour la mise à jour incrémentale des approximations inférieures et supérieures de l'approche DRSA suite à l'insertion simultanée d'un nombre d'échantillons dans l'ensemble d'apprentissage. L'algorithme est composé de trois étapes principales : la mise à jour des unions inférieures et supérieures des classes de décision, la mise à jour des ensembles P-dominé et P-dominant de chaque action de référence, et, finalement, la mise des approximations inférieures et supérieures des unions des classes de décision.

L'algorithme *DRSA-Incremental* sera utilisé dans le Chapitre 4 pour définir notre méthode de classification multicritère et incrémentale permettant de périodiquement prédire la classe de décision à laquelle appartiendra chaque action dans le système d'information. Dans le Chapitre 5 notre méthode de classification basée sur *DRSA-Incremental* sera validée sur le contexte des MOOCs. Dans ce contexte, les exemples d'apprentissage sont fournis périodiquement, en tant qu'une série de traces d'activités décrivant le nouveau comportement des apprenants. Chaque nouvelle série est susceptible de rectifier la décision prise précédemment sur la caractérisation de certains apprenants ce qui nécessite une mise à jour. Cependant, vue la quantité énorme de données disponibles, il est préférable de mettre à jour progressivement les décisions plutôt que de les extraire à partir de zéro.

Le plan de ce chapitre est structuré comme suit : dans la première section nous expliquons l'aide multicritère à la décision, l'approche DRSA et le théorème de décision P-généralisée. La deuxième section définit l'apprentissage incrémental. La troisième section adresse un état de l'art sur quelques algorithmes incrémentaux proposés dans la littérature. Dans la quatrième section, nous détaillons l'algorithme *DRSA-Incremental* que nous avons proposé pour la mise à jour incrémentale des approximations inférieures et supérieures de l'approche DRSA suite à l'insertion d'un ensemble d'actions dans l'échantillon d'apprentissage.

3.1 Préliminaires

Cette section introduit la problématique d'aide à la décision multicritère. Ensuite, elle présente l'approche DRSA et le théorème de décision P-généralisée (Kotowski *et al.*, 2008). Les deux notions seront utilisées pour la mise à jour du résultat d'un modèle prédictif incrémental suite à l'insertion d'un ensemble d'échantillons dans l'ensemble d'apprentissage.

3.1.1 Aide multicritère à la décision

D'après Roy (1985), "l'aide à la décision est l'activité de celui qui, prenant appui sur des modèles clairement explicités mais non nécessairement complètement formalisés, aide à obtenir des éléments de réponse aux questions que se pose un intervenant dans un processus de décision, éléments concourant à éclairer la décision et normalement à recommander, ou simplement à favoriser, un comportement de nature à accroître la cohérence entre l'évolution du processus d'une part, les objectifs et le système de valeurs au service desquels cet intervenant se trouve placé d'autre part". Pour l'aide à la décision, il est préférable de chercher, au moins au départ, à formuler le problème en termes moins restrictifs. Dans cette optique, quatre problématiques de référence doivent être considérées qui sont : la problématique de choix ou de sélection, la problématique de tri ou d'affectation, la problématique de rangement ou de classement et la problématique de description (Roy et Bouyssou, 1993).

Dans le cadre de cette thèse, nous avons choisi d'inscrire notre problème de caractérisation et de classification des profils des apprenants dans une problématique de tri (dit aussi de classification). Cette problématique consiste à éclairer la décision par un tri résultant d'une affectation de chaque action à une catégorie. Les catégories étant définies a priori en fonction de normes ayant trait à la suite à donner aux actions qu'elles sont destinées à recevoir.

Les concepts de base de l'aide multicritère à la décision sont définis comme suit :

- Acteur : un acteur est "tout individu, corps constitué, ou collectivité susceptible de jouer un rôle quelconque, directement ou indirectement, dans le déroulement d'un processus de décision" (Roy, 1985).
- Action : une action désigne "ce qui constitue l'objet de la décision ou ce sur quoi porte l'aide à la décision" (Roy, 1985). Plusieurs termes peuvent remplacer celui de l'action dans la littérature tels que scénario plan, programme, projet, proposition, variante, etc.
- Action potentielle : une action potentielle désigne "une action réelle ou fictive provisoirement jugée réaliste par un acteur au moins ou présumée telle par l'homme d'étude¹ en vue de l'aide à la décision" (Roy, 1985). L'identification des actions potentielles vise à éliminer le champ des solutions potentielles, tout en prenant garde que l'ensemble choisi soit le plus informatif possible.
- Conséquence : chaque action potentielle doit pouvoir être évaluée relativement à chaque conséquence élémentaire et à chaque agrégat de ces connaissances. La conséquence est tout facteur, aspect ou attribut relatif aux actions

1. L'homme d'étude est acteur qui joue le rôle de médiateur pour aider les acteurs de terrain à prendre une décision, mais ne doit en aucun cas influencer leurs décisions (Saad, 2005)

potentielles et susceptible d’influencer, dans un sens ou dans un autre, la décision finale (Roy, 2000). Autrement, une conséquence est une caractéristique permettant de décrire chaque action potentielle.

- Critère : un critère est l’outil permettant l’évaluation et la comparaison des actions potentielles selon un point de vue bien défini (Roy, 2000). Il permet ainsi de mesurer les préférences du décideur vis-à-vis de chaque action. L’évaluation d’une action selon un critère peut faire intervenir des règles de calculs plus ou moins complexes, une enquête plus ou moins lourde ou encore l’opinion d’un ou plusieurs experts. Quelque soit la procédure utilisée, il s’agit de prendre en compte les effets et attributs pertinents selon le point de vue considéré. Pour ce faire, il est commode de passer par l’intermédiaire d’un ou plusieurs indicateurs.
- Echelle de préférence : une échelle de préférence est “un ensemble d’éléments, appelés échelons, rangés selon un ordre complet ; chaque échelon est caractérisé soit par un nombre, soit par un énoncé verbal ; il sert à traduire l’évaluation d’une action en prenant en compte des effets et attributs clairement précisés ; relativement à ceux-ci et toutes autres choses égales par ailleurs, le rangement des échelons reflète le sens de variation de la préférence vis-à-vis des situations qu’ils servent à caractériser” (Roy, 2000). Une échelle peut être soit ordinale, soit quantitative, soit intermédiaire.

3.1.2 Dominance-based Rough Set Approach (DRSA)

L’approche DRSA est une méthode pour l’apprentissage supervisé, proposée par Greco *et al.* (2001a) et basée sur la théorie des ensembles approximatifs (Pawlak, 1992). Elle est dédiée au problème de classification en aide multicritère à la décision et permet de comparer des actions en appliquant une relation de dominance, en tenant compte des préférences du décideur. La comparaison conduit à l’établissement d’un modèle de préférence, sous la forme d’un ensemble de règles de décision, permettant d’affecter les actions à des classes de décision. L’approche DRSA définit une table d’information par un 4-uplets $S = \langle A, F, V, f \rangle$ tels que :

- A : un ensemble fini des actions de référence qui représentent un échantillon suffisamment représentatif pour inférer le modèle de préférence des décideurs.
- F : une famille cohérente de critères.
- $V = \cup_{g \in F} V_g$: un ensemble des valeurs possibles des critères.
- $f : A \times F \rightarrow V$: une fonction d’information telle que $f(x, g) \in V_g, \forall x \in A, \forall g \in F$.

L’ensemble des critères F est divisé en deux sous-ensembles : le sous-ensemble $C \neq \emptyset$ qui désigne les critères-conditions et le sous-ensemble $D \neq \emptyset$ indiquant les

critères-décision tels que $C \cup D = F$ et $C \cap D = \emptyset$. Dans ce cas, S est appelée table de décision (cf. Table 3.1). L'ensemble de critères de décision $D = \{d\}$ est un singleton qui divise l'ensemble A en un nombre fini N de classes de décision $Cl = \{Cl_n, n \in \{1 \dots N\}\}$. Chaque action de référence x est affectée à une seule et unique classe de décision $Cl_n \in Cl$.

TABLE 3.1 – Exemple d'une table de décision dans DRSA

	g_1	g_2	g_3	g_4	D
A_1	2	2	3	3	3
A_2	1	2	2	3	3
A_3	2	1	1	2	1
A_4	1	2	3	1	2
A_5	2	1	3	3	2
A_6	1	2	1	1	1
A_7	2	2	2	3	3
A_8	1	1	1	2	1
A_9	2	1	2	3	3
A_{10}	1	2	2	2	2
A_{11}	1	2	3	3	2

Exemple 1 : La table 3.1 représente un exemple d'une table de décision qui sera utilisée tout au long de ce chapitre pour illustrer les différents concepts et étapes en DRSA. L'ensemble d'actions de référence $A = \{A_i : i = 1, 2, \dots, 11\}$ contient onze actions. Chaque action de référence est caractérisée par quatre critères de condition $P = \{g_1, g_2, g_3, g_4\}$ et un critère de décision $D = \{d\}$. Nous considérons que la table initialement contient les actions $\{A_1, A_2, A_3, A_4, A_5, A_6\}$ uniquement. Alors, pour un premier temps, nous négligeons les actions $\{A_7, A_8, A_9, A_{10}, A_{11}\}$.

Les classes de décision de Cl sont ordonnées selon un ordre croissant de préférence, *i.e.* pour un couple d'actions $(r, s) \in \{1 \dots N\}^2$ tel que $r > s$, les actions contenues dans la classe de décision Cl_r sont plus préférées que celles contenues dans Cl_s . Deux ensembles approximatifs, appelés union inférieure et union supérieure, sont définis pour chaque classe de décision :

- $Cl_n^{\leq} = \cup_{s \leq n} Cl_s$ tel que $n = \{1 \dots N\}$: L'union inférieure de Cl_n signifie que " x appartient au maximum à la classe Cl_n ou bien à une classe au mieux aussi bonne que Cl_n ".
- $Cl_n^{\geq} = \cup_{s \geq n} Cl_s$ tel que $n = \{1 \dots N\}$: L'union supérieure de Cl_n signifie que " x appartient au minimum à la classe Cl_n ou bien à une classe au moins aussi bonne que Cl_n ".

Exemple 2 : Considérons le tableau 3.1, les unions inférieures et supérieures des classes de décision sont calculées comme suit :

- $Cl_1^{\leq} = Cl_1 = \{A_3, A_6\}$, $Cl_2^{\leq} = Cl_1 \cup Cl_2 = \{A_3, A_4, A_5, A_6\}$ et $Cl_3^{\leq} = Cl_1 \cup Cl_2 \cup Cl_3 = \{A_1, A_2, A_3, A_4, A_5, A_6\}$.
- $Cl_1^{\geq} = Cl_1 \cup Cl_2 \cup Cl_3 = \{A_1, A_2, A_3, A_4, A_5, A_6\}$, $Cl_2^{\geq} = Cl_2 \cup Cl_3 = \{A_1, A_2, A_4, A_5\}$ et $Cl_3^{\geq} = Cl_3 = \{A_1, A_2\}$.

Relation de dominance : Soit $P \subseteq F$ un sous ensemble de critères de condition. La relation de dominance D_P associée à P est définie comme suit :

$$\forall (x, y) \in A^2, xD_P y \Leftrightarrow f(x, g_j) \succ f(y, g_j) \forall g_j \in P$$

Pour chaque action $x \in A$, est associé :

- un ensemble, P-dominant, d'actions dominant x noté $D_P^+(x) = \{y \in A : yD_P x\}$;
- un ensemble, P-dominé, d'actions dominées par x noté $D_P^-(x) = \{y \in A : xD_P y\}$.

Exemple 3 : Considérons le tableau 3.1, il est facile de constater que l'action A_1 domine toutes les actions puisque $f(A_1, g_j) \succ f(A_i, g_j) \forall g_j \in P$ et $A_i \in A$. En revanche, aucune relation de dominance n'existe entre les actions A_2 and A_3 , puisque l'évaluation de A_2 est mieux que celle de A_3 sur les critères g_2, g_3 et g_4 alors que l'évaluation de l'action A_3 est mieux que celle de A_2 sur le critère g_1 . Par conséquent :

- Les ensembles P-dominant sont comme suit : $D_P^+(A_1) = \{A_1\}$, $D_P^+(A_2) = \{A_1, A_2\}$, $D_P^+(A_3) = \{A_1, A_3, A_5\}$, $D_P^+(A_4) = \{A_1, A_4\}$, $D_P^+(A_5) = \{A_1, A_5\}$ et $D_P^+(A_6) = \{A_1, A_2, A_4, A_6\}$.
- Les ensembles P-dominé sont calculés comme suit : $D_P^-(A_1) = \{A_1, A_2, A_3, A_4, A_5, A_6\}$, $D_P^-(A_2) = \{A_2, A_6\}$, $D_P^-(A_3) = \{A_3\}$, $D_P^-(A_4) = \{A_4, A_6\}$, $D_P^-(A_5) = \{A_3, A_5\}$ et $D_P^-(A_6) = \{A_6\}$.

Approximation inférieure : Elle regroupe toutes les actions qui ont été classées avec *certitude* dans chaque type d'unions de classes de décision en fonction de $P \subseteq F$.

- $\underline{P}(Cl_n^{\geq}) = \{x \in A : D_P^+(x) \subseteq Cl_n^{\geq}, \forall n \in \{1..N\}\}$: L'approximation inférieure de l'union Cl_n^{\geq} regroupe toutes les actions dont l'ensemble P-dominant est affecté avec *certitude* à des classes au moins aussi bonnes que Cl_n .
- $\underline{P}(Cl_n^{\leq}) = \{x \in A : D_P^-(x) \subseteq Cl_n^{\leq}, \forall n \in \{1..N\}\}$: L'approximation inférieure de l'union Cl_n^{\leq} regroupe toutes les actions dont l'ensemble P-dominé est affecté avec *certitude* à une classe au mieux aussi bonne que Cl_n .

Approximation supérieure : Elle regroupe toutes les actions qui ont été classées d'une manière *possible* dans chaque type d'unions de classes de décision en fonction de $P \subseteq F$.

- $\overline{P}(Cl_n^{\geq}) = \{x \in A : D_P^- \cap Cl_n^{\geq} \neq \emptyset, \forall n \in \{1..N\}\}$: L'approximation supérieure regroupe toutes les actions dont l'ensemble P-dominant est affecté à une classe au moins aussi bonne que Cl_n .
- $\overline{P}(Cl_n^{\leq}) = \{x \in A : D_P^+ \cap Cl_n^{\leq} \neq \emptyset, \forall n \in \{1..N\}\}$: L'approximation supérieure regroupe toutes les actions dont l'ensemble dominé est affecté à une classe au mieux aussi bonne que Cl_n .

Exemple 4 : En utilisant les résultats de l'Exemple 2 et l'Exemple 3, les approximations inférieures et supérieures sont calculées comme suit :

- $\underline{P}(Cl_1^{\leq}) = \{A_3, A_6\}$, $\underline{P}(Cl_2^{\leq}) = \{A_3, A_4, A_5, A_6\}$, $\underline{P}(Cl_3^{\leq}) = \{A_1, A_2, A_3, A_4, A_5, A_6\}$. Par exemple, $D_P^-(A_3) = \{A_3\} \subseteq Cl_1^{\leq} = \{A_3, A_6\}$ alors $A_3 \in \underline{P}(Cl_1^{\leq})$.
- $\underline{P}(Cl_1^{\geq}) = \{A_1, A_2, A_3, A_4, A_5, A_6\}$, $\underline{P}(Cl_2^{\geq}) = \{A_1, A_2, A_4, A_5\}$, $\underline{P}(Cl_3^{\geq}) = \{A_1, A_2\}$.
- $\overline{P}(Cl_1^{\leq}) = \{A_3, A_6\}$, $\overline{P}(Cl_2^{\leq}) = \{A_3, A_4, A_5, A_6\}$, $\overline{P}(Cl_3^{\leq}) = \{A_1, A_2, A_3, A_4, A_5, A_6\}$.
- $\overline{P}(Cl_1^{\geq}) = \{A_1, A_2, A_3, A_4, A_5, A_6\}$, $\overline{P}(Cl_2^{\geq}) = \{A_1, A_2, A_4, A_5\}$, $\overline{P}(Cl_3^{\geq}) = \{A_1, A_2\}$.

Borne : $Bn_P(Cl_n^{\leq}) = \overline{P}(Cl_n^{\leq}) - \underline{P}(Cl_n^{\leq})$ et $Bn_P(Cl_n^{\geq}) = \overline{P}(Cl_n^{\geq}) - \underline{P}(Cl_n^{\geq})$. La borne comprend l'ensemble des actions qui sont affectées à la fois à une classe meilleure et à une ou plusieurs classes inférieures à Cl_n , autrement dit, elle regroupe toutes les actions dont l'ensemble dominant (dominé) ne peut être affecté avec certitude à des classes au moins (plus) aussi bonnes que Cl_n .

Remarque : Dans cet exemple, les approximations supérieures et inférieures sont égales puisque toutes les actions ont été classées avec certitude. Par conséquent, les bornes de toutes les unions de classe de décision sont des ensembles vides.

3.1.3 Théorème de la décision P-généralisée

La "décision P-généralisée" est un théorème proposé par Kotlowski *et al.* (2008) pour calculer, autrement, les approximations inférieures et supérieures des unions de classes de décision. Elle définit un intervalle de classes de décision à laquelle une action peut appartenir. La décision P-généralisée est présentée comme suit :

\forall action $x \in A$, $\exists \delta_p(x) = \langle l_p(x), u_p(x) \rangle$ qui désigne la décision P-généralisée de l'action x , tel que :

- $l_p(x) = \min\{n \in N : D_P^+(x) \cap Cl_n \neq \emptyset\}$
- $u_p(x) = \max\{n \in N : D_P^-(x) \cap Cl_n \neq \emptyset\}$

Cette définition, permet de calculer les approximations inférieures et supérieures des unions de classes de décision de DRSA comme suit :

$$\left\{ \begin{array}{l} \underline{P}(Cl_n^{\geq}) = \{x \in A : l_p(x) \geq n\} \\ \overline{P}(Cl_n^{\geq}) = \{x \in A : u_p(x) \geq n\} \\ \underline{P}(Cl_n^{\leq}) = \{x \in A : u_p(x) \leq n\} \\ \overline{P}(Cl_n^{\leq}) = \{x \in A : l_p(x) \leq n\} \end{array} \right. \quad \begin{array}{l} (3.1) \\ (3.2) \\ (3.3) \\ (3.4) \end{array}$$

Les deux méthodes proposées par Greco *et al.* (2001a) et Kotlowski *et al.* (2008) permettent, chacune, de calculer les approximations inférieures et supérieures de DRSA.

Dans le cas d'un apprentissage incrémental, le théorème de Greco *et al.* (2001a) reprend le calcul des approximations à zéro en appariant la nouvelle table de décision à celle qui existe déjà et les considérant, toutes les deux, comme étant une nouvelle table indépendante. En revanche, le théorème de décision P-généralisée permet la mise à jour des approximations initiales en fonction des approximations calculées pour les nouvelles actions insérées. Ceci permet de minimiser la complexité temporelle de l'algorithme. Les deux théorèmes seront utilisés dans la section 3.4 pour la mise à jour incrémentale des approximations de DRSA.

3.1.4 Modèle de préférences

Une table de décision peut être traduite par un ensemble de règles de décision de la forme “si *Conditions* alors *Décision*”, où la partie de *Conditions* spécifie des valeurs supposées par un ou plusieurs critères et la partie *Décision* spécifie une affectation de l'action à une union de classes de décision. L'approche DRSA propose des algorithmes, tels que *DomLem* (Greco *et al.*, 2001b) et *AllRules* (Stefanowski, 2001), qui prennent en entrée les approximations inférieures et supérieures de toutes les unions des classes de décision et en infèrent un ensemble de règles de décision. Une action $x \in A$ supporte une règle de décision si sa description satisfait, à la fois, les deux parties *Conditions* et *Décision* de la règle. Une règle de décision couvre l'action x si la description de x correspond au moins à la partie *Conditions* de la règle. L'ensemble des règles de décision est appelé modèle de préférences.

Les règles de décision générées à partir des approximations inférieures et supérieures sont comme suit :

- **Si** $f(x, g_1) \leq r_1 \wedge \dots \wedge f(x, g_n) \leq r_n$ **alors** $x \in Cl_t^{\leq}$ tel que $(r_1, \dots, r_n) \in (V_{g_1} \times \dots \times V_{g_n})$.
- **Si** $f(x, g_1) \geq r_1 \wedge \dots \wedge f(x, g_n) \geq r_n$ **alors** $x \in Cl_t^{\geq}$ tel que $(r_1, \dots, r_n) \in (V_{g_1} \times \dots \times V_{g_n})$.

Chaque règle de décision est caractérisée par une force qui représente le ratio de l'ensemble d'actions qui supportent la règle par rapport au nombre total d'actions qui ont été classées d'une manière certaine à une classe donnée.

Dans ce travail, l'approche DRSA et le théorème de décision généralisée seront appliqués dans un contexte d'apprentissage incrémental qui exige la mise à jour des règles de décision. Ceci permettra de garder une vue actualisée sur une situation du monde réel.

3.2 Apprentissage incrémental

L'apprentissage incrémental se réfère à la situation de l'adaptation continue du modèle basée sur un flux de données en arrivée constante (Silver, 2011). Lors d'un apprentissage incrémental, le modèle apprend des descriptions à partir de faits et affine progressivement ces descriptions lorsque des nouveaux faits sont disponibles. L'information nouvellement acquise est plutôt utilisée pour affiner les structures de la description et, rarement entraîne la reformulation de toute la description initialement déduite. Greco *et al.* (2004) ont restreint les cas, où l'apprentissage incrémental s'avère une obligation, à trois :

- Cas d'une source de données à caractère dynamique : lorsque les exemples d'apprentissage sont fournis de manière séquentielle, par exemple en tant qu'une série d'observations ou de mesures, il est souhaitable de mettre à jour la description après avoir appris chaque exemple.
- Cas d'extraction de connaissances d'une base de données massive : compte tenu de la quantité énorme de données dans une base de données, il est préférable de mettre à jour progressivement les résultats de l'exploration de données plutôt que d'extraire à partir de zéro sur chaque mise à jour de la base de données.
- Cas d'apprentissage par portion temporelle : lorsque des exemples sont périodiquement disponibles pour le système d'apprentissage dans certaines parties (sous-ensembles) et il n'est pas acceptable d'induire les connaissances à nouveau à partir de données complètes, par exemple en raison des coûts de calcul ou de l'inaccessibilité des exemples précédemment traités.

L'apprentissage incrémental se présente sous formes diverses dans la littérature et pour des objectifs différents. Nous présentons, ci-dessous, certains cas du monde réel où l'apprentissage incrémental est utilisé.

- Les jeux d'échec : ce jeu fonctionne sur un algorithme établissant à la fois l'état actuel du match et le coup le plus rentable à jouer, en calculant la valeur de chaque pièce par rapport à sa position sur le plateau. Ainsi, pour chaque paire de positions successives, le programme utilise la différence entre les évaluations assignées aux deux positions pour modifier les évaluations de la précédente. Cela nécessite un apprentissage incrémental qui prend en considération l'information sur l'état actuel, les états précédents afin de prédire l'état futur (Samuel, 1959).
- Le suivi visuel : le suivi visuel traite essentiellement des données non stationnaires, liées à la fois à l'objet cible et à l'arrière-plan, qui changent avec le temps (Ross *et al.*, 2008). Il s'agit, donc, de l'apprentissage incrémental pour le suivi des objets par les robots lorsque le flux d'images n'est pas stationnaire. Autrement, ce problème consiste à apprendre l'apparence d'un objet cible tout en surveillant les progrès qui se produisent à l'arrivée des nouvelles observations liées aux changements dans l'apparence de la cible (*exp.* les changements de forme ou bien les conditions d'éclairage spécifique).
- Les prévisions météo : pour ce cas, nous reprenons l'exemple de Sutton (1988). En effet, pour prédire la météo de samedi à partir du lundi, il faut mettre une première prédiction lundi, et l'actualiser chaque jour tout au long de la semaine en fonction de la variation de la météo d'un jour à l'autre. En revanche, une prédiction à une seule étape doit attendre que toutes les données soient disponibles vendredi afin de prédire la météo de samedi. Par conséquent, la prédiction incrémentale permet d'avoir un résultat beaucoup plus en avance sans trop charger l'espace mémoire de la machine ni faire un calcul énorme à la fois.
- Les MOOCs : pour mettre une prédiction concernant les profils apprenants dans un contexte des MOOCs (*i.e* apprenant en risque, apprenant actif, apprenant passif, etc) il faut prendre en considération la variation dans le temps des caractéristiques du MOOC et aussi du comportement et des compétences de l'apprenant. Dans ce contexte, il n'est pas suffisant de mettre une prédiction pour la semaine n du MOOC en fonction de données disponibles au cours de la première semaine uniquement (Balakrishnan et Coetzee, 2013 ; Halawa *et al.*, 2014 ; Ashenafi *et al.*, 2016). Il faut, toutefois, faire apprendre le modèle, au fur et à mesure, à chaque nouvelle observation (*exp.* taux d'accès, score, etc.) susceptible de modifier la prédiction antérieure.

Sutton (1988) a défini trois types d'incrémentation. Le premier est l'incrémentation pour la prédiction d'un résultat cumulatif. Dans ce type, la prédiction ne se limite pas à prédire le résultat final d'une séquence, mais également utilisée pour prédire une quantité qui s'accumule sur une séquence. En effet, le résultat peut se produire à chaque étape d'une séquence, où nous souhaitons prédire le résultat

total prévu. Dans ce cas, le vecteur des résultats est mis à jour après la présentation d'une séquence complète. Par exemple, dans une marche aléatoire bornée on pourrait prédire combien de mesures seront prises avant la fin. Le deuxième type concerne la mise à jour du résultat dans une séquence. Puisque chaque observation d'une séquence génère un incrément au vecteur des résultats, il serait plus simple de mettre à jour le vecteur de résultats immédiatement après chaque observation. Par exemple, dans le cas des MOOCs, chaque semaine nous obtenons de nouvelles observations qui mettent à jour la prédiction précédente sur les profils apprenants. Le troisième type est la prédiction par intervalle fixe. C'est le problème de faire une prédiction pour un certain temps fixe plus tard. Par exemple, supposons que nous souhaitons prédire chaque lundi s'il pleuvra ou non chaque lundi suivant ; chaque mardi, s'il pleuvra ou non le mardi suivant ; et ainsi de suite pour chaque jour de la semaine. Bien que ce problème implique une séquence de prédictions, les prédictions ne peuvent pas être appliquées directement car chaque prédiction est un événement différent et, par conséquent, il n'y a pas de lien clair entre elles.

Dans ce qui suit nous présenterons une méthode de prédiction basée sur l'apprentissage incrémental. Cette méthode doit permettre d'actualiser le résultat de prédiction à chaque fois qu'une nouvelle portion d'information pour l'apprentissage soit disponible.

3.3 Travaux antérieurs

Dans le cas d'un apprentissage incrémental, les algorithmes traditionnels, tels que *Allrules* et *Allrules-extended* (Stefanowski, 2001), sont inefficaces particulièrement dans les problèmes où la contrainte temporelle intervient et une décision doit être prise en temps réel. À cette fin, des approches dynamiques ont été proposées pour la mise à jour incrémentale du système d'information sous la variation de l'ensemble d'actions (Greco *et al.*, 2004 ; Li *et al.*, 013b), l'ensemble des critères (Li *et al.*, 013a ; Zhang *et al.*, 2012) ou bien les valeurs sur les critères (Chen *et al.*, 2010 ; 2012). Dans cette section, nous nous focalisons uniquement sur les approches proposées pour la mise à jour incrémentale sous la variation de l'ensemble d'actions qui représente l'objectif de ce chapitre.

Les auteurs dans (Greco *et al.*, 2004) ont proposé un algorithme appelé *Glance*, pour mettre à jour la base des règles dans le cas d'un apprentissage incrémental. L'algorithme *Glance* considère les actions comme étant des actions négatives. Il crée des règles de décision qui ne couvrent pas l'action x dans toutes les unions des classes aux quelles x n'appartient pas. Par conséquent, chaque règle d'une union donnée doit impérativement ne pas satisfaire x , si x n'appartient pas à cette union, mais elle peut aussi ne satisfaire aucune action x et dans ce cas elle demeure sans supports. Ces règles qui demeurent sans supports sont dites non-robustes et donc l'algorithme est aussi dit non robuste. L'algorithme *Glance* stocke dans la mémoire uniquement les règles de décision et pas les exemples d'apprentissage et donc il est économe par rapport à l'utilisation de l'espace mémoire. La complexité de

l'algorithme est linéaire si on considère le nombre d'actions et elle est exponentielle en considérant le nombre de critères. Cependant, *Glance* peut mener à l'induction d'un nombre élevé des règles de décision qui ne sont pas toutes utiles.

Les auteurs dans (Li *et al.*, 013b) ont proposé un algorithme de mise à jour incrémentale des approximations de l'approche DRSA lors de l'ajout ou la suppression d'une seule action dans ou à partir du système d'information. La méthode est basée sur la décision P-généralisée pour calculer les approximations inférieures et supérieures de chaque union de classes de décision. Elle nécessite : premièrement, la mise à jour des unions inférieures et supérieures des classes de décision, deuxièmement, la mise à jour des ensembles P-dominant et P-dominé de chaque action dans le système d'information et enfin la mise à jour des approximations inférieures et supérieures des unions des classes de décision. L'algorithme proposé minimise le temps de calcul lorsqu'une action entre ou quitte le système d'information. Il est également sensible au nombre d'actions et d'attributs dans le système d'information. Cet algorithme n'affecte pas la qualité des règles de décision. En effet, au lieu de mettre à jour les règles de décision, il met à jour les approximations qui seront entrées par l'algorithme d'induction pour inférer un modèle de préférence actualisé.

Dans ce travail, outre que minimiser le temps de calcul et l'espace mémoire utilisé, nous sommes principalement intéressés par la qualité des règles de décision et nous préférons obtenir des solutions robustes. Pour cette raison, nous choisissons de généraliser l'algorithme présenté dans Li *et al.* (013b) afin de considérer l'entrée simultanée d'un ensemble d'actions au lieu d'une seule.

3.4 Algorithme de mise à jour incrémentale des approximations de DRSA suite à l'insertion simultanée d'un ensemble d'actions

Lorsqu'une action x^+ entre dans un système d'information, i.e. $A' = A \cup \{x^+\}$, cela peut causer des variations dans une classe de décision et dans plusieurs unions de classes de décision. Par conséquent, les ensembles "P-dominant" et "P-dominé" et, par suite, les approximations inférieures et supérieures sont susceptibles d'être modifiées. Pour ce faire, nous proposons un algorithme, *DRSA-Incremental*, pour la mise à jour incrémentale de ces approximations à chaque entrée d'un nouvel ensemble d'actions dans le système d'information. L'algorithme que nous proposons généralise celui proposé par Li *et al.* (013b) en considérant le cas de l'entrée simultanée d'un ensemble d'actions.

3.4.1 Algorithme et notations

Dans ce chapitre, nous allons définir des nouvelles notations pour l'approche DRSA afin de l'adapter à une utilisation dynamique où le système d'information

évolue dans le temps. La table 3.2, présente les différentes notations définies entre deux périodes successives $Période_i$ et $Période_{i+1}$.

TABLE 3.2 – Notations symboliques de DRSA entre la $Période_i$ et la $Période_{i+1}$

	$Période_i$	$Période_{i+1}$
L'ensemble P-dominant de l'action x	$D_i^+ p(x)$	$D_{i+1}^+ p(x)$
L'ensemble P-dominé de l'action x	$D_i^- p(x)$	$D_{i+1}^- p(x)$
Décision P-généralisée de x	$\langle l_i p(x), u_i p(x) \rangle$	$\langle l_{i+1} p(x), u_{i+1} p(x) \rangle$
Union inférieure de la classe Cl_n	$Cl_{i,n}^{\leq}$	$Cl_{i+1,n}^{\leq}$
Union supérieure de la class Cl_n	$Cl_{i,n}^{\geq}$	$Cl_{i+1,n}^{\geq}$
Approximation inférieure de Cl_n^{\geq}	$\underline{P}(Cl_{i,n}^{\geq})$	$\underline{P}(Cl_{i+1,n}^{\geq})$
Approximation supérieure de Cl_n^{\geq}	$\overline{P}(Cl_{i,n}^{\geq})$	$\overline{P}(Cl_{i+1,n}^{\geq})$
Approximation inférieure de Cl_n^{\leq}	$\underline{P}(Cl_{i,n}^{\leq})$	$\underline{P}(Cl_{i+1,n}^{\leq})$
Approximation supérieure de Cl_n^{\leq}	$\overline{P}(Cl_{i,n}^{\leq})$	$\overline{P}(Cl_{i+1,n}^{\leq})$

Notons qu'une action x^+ peut appartenir à une unique classe de décision $Cl_{n'}$. Soient :

- Δ^+ : l'ensemble de k actions à entrer dans le système d'information ;

$$\Delta^+ = \{x^+\} \text{ et } |\Delta^+| = k$$

- $\Delta_{n<}^+$: le sous ensemble de Δ^+ appartenant à des classes de décision moins bonnes que Cl_n ;

$$\Delta_{n<}^+ = \{x^+\} \in (\Delta^+ \cap Cl_{n'}) \text{ tel que } n' < n$$

- $\Delta_{n>}^+$: le sous ensemble de Δ^+ appartenant à des classes de décision aussi bonnes que Cl_n ;

$$\Delta_{n>}^+ = \{x^+\} \in (\Delta^+ \cap Cl_{n'}) \text{ tel que } n' > n$$

- $\Delta_{n=}^+$: le sous ensemble de Δ^+ appartenant à la même classe de décision Cl_n ;

$$\Delta_{n=}^+ = \{x^+\} \in (\Delta^+ \cap Cl_{n'}) \text{ tel que } n' = n$$

Nous pouvons ainsi, en déduire que :

- $A_{i+1} = A_i + \Delta^+$, tels que A_i et A_{i+1} sont respectivement les ensembles d'actions de références de la $Période_i$ et la $Période_{i+1}$.
- $\Delta_{n<}^+ \cup \Delta_{n>}^+ \cup \Delta_{n=}^+ = \Delta^+$ et $\Delta_{n<}^+ \cap \Delta_{n>}^+ \cap \Delta_{n=}^+ = \emptyset$

Exemple 5 : Revenons sur la table 3.1, nous supposons que l'ensemble d'actions $\Delta^+ = \{A_7, A_8, A_9, A_{10}, A_{11}\}$ est inséré dans la table de décision à la *Période*_{*i*+1}. Rappelons que nous traitons trois classes de décision ($N = 3$), les sous ensembles que nous pouvons obtenir de Δ^+ sont comme suit :

- $\Delta_{1<}^+ = \{\emptyset\}$, $\Delta_{2<}^+ = \{A_8\}$, $\Delta_{3<}^+ = \{A_8, A_{10}, A_{11}\}$,
- $\Delta_{1>}^+ = \{A_7, A_8, A_9, A_{10}, A_{11}\}$, $\Delta_{2>}^+ = \{A_7, A_9\}$, $\Delta_{3>}^+ = \{\emptyset\}$,
- $\Delta_{1=}^+ = \{A_8\}$, $\Delta_{2=}^+ = \{A_{10}, A_{11}\}$, $\Delta_{3=}^+ = \{A_7, A_9\}$.

L'algorithme 1 (détaillé dans l'Annexe A) décrit le processus de mise à jour des approximations inférieures et supérieures dans DRSA. Il prend en entrée les ensembles P-dominant $D_i^+ p(x)$ et P-dominé $D_i^- p(x)$ de chaque action dans le système d'information de la *Période*_{*i*}; les approximations inférieures $\underline{P}(Cl_{i,n}^{\leq})$ et $\underline{P}(Cl_{i,n}^{\geq})$ de chaque union de classes de décision; les approximations supérieures $\overline{P}(Cl_{i,n}^{\leq})$ et $\overline{P}(Cl_{i,n}^{\geq})$ de chaque union de classes de décision; et l'ensemble Δ^+ à insérer dans le système d'information. Il produit en résultat les approximations $\underline{P}(Cl_{i+1,n}^{\leq})$, $\underline{P}(Cl_{i+1,n}^{\geq})$, $\overline{P}(Cl_{i+1,n}^{\leq})$ et $\overline{P}(Cl_{i+1,n}^{\geq})$ de chaque union de classes de décision de la *Période*_{*i*+1}. L'algorithme est basé sur quatre étapes : appliquer le théorème de la décision P-généralisée des actions insérées; mettre à jour les unions inférieures et supérieures des classes de décision, mettre à jour les ensemble P-dominant et P-dominé des actions initiales et, finalement, mettre à jour les approximations inférieures et supérieures des actions initiales.

Tout au long du chapitre, nous nous référons aux actions contenues dans le système d'information durant la *Période*_{*i*} par "les actions initiales" (*i.e.* $\{A_1, A_2 \cdots A_6\}$) et à la portion d'actions reçues dans la *Période*_{*i*+1} par "les actions insérées" (*i.e.* $\{A_7, A_8 \cdots A_{11}\}$).

L'algorithme *DRSA-Incremental* de mise à jour incrémentale des approximations inférieures et supérieures, suite à l'insertion d'un ensemble d'actions dans un système d'information de DRSA, sera détaillé et discuté dans le reste de ce chapitre.

3.4.2 Etape 1 : Application du théorème de la décision P-généralisée des actions insérées

La première étape de l'algorithme consiste à appliquer le théorème de la décision P-généralisée, $\delta_p(x) = \langle l_p(x), u_p(x) \rangle$, présenté dans la Section 3.1.3 sur toutes les actions insérées. Ceci nécessite d'abord le calcul des ensembles P-dominant et P-dominé de ces actions. Les décisions $l_p(x)$ et $u_p(x)$ seront utilisées pour la mise à jour des approximations inférieures et supérieures des actions initiales.

Exemple 6 : Suite à l'application du théorème de la décision P-généralisée sur la table 3.1, nous obtenons ces résultats :

Algorithme 1 : Algorithme incrémental pour la mise à jour des approximations de DRSA suite à l'insertion simultanée de plusieurs actions dans le système d'information

Données :
 $\forall x \in A, D_i^+ p(x)$ et $D_i^- p(x)$ de la *Période*_{*i*} et $\forall n \in N, \overline{P}(Cl_{i,n}^{\geq}), \overline{P}(Cl_{i,n}^{\leq}), \underline{P}(Cl_{i,n}^{\leq})$ et $\underline{P}(Cl_{i,n}^{\geq})$ de la *Période*_{*i*} et un ensemble Δ^+ contenant les nouvelles actions

Résultat :
 $\overline{P}(Cl_{i+1,n}^{\geq}), \overline{P}(Cl_{i+1,n}^{\leq}), \underline{P}(Cl_{i+1,n}^{\leq})$ et $\underline{P}(Cl_{i+1,n}^{\geq})$ de la *Période*_{*i+1*}

Begin

pour *i* de 1 à $|\Delta^+|$ **faire**
 Calculer $D_{i+1}^+ p(x_i^+)$ et $D_{i+1}^- p(x_i^+)$;
fin

pour *n* de 1 à *N* **faire**
 Calculer $\Delta_{n<}^+, \Delta_{n>}^+$ et $\Delta_{n=}^+$;
fin

pour *i* de 1 à *A* **faire**
 pour *j* de 1 à $|\Delta^+|$ **faire**
 Mettre à jour $D_{i+1}^- p(x_i)$ et $D_{i+1}^+ p(x_i)$;
 fin
fin

pour *i* de 1 à $|\Delta^+|$ **faire**
 Calculer $l_{i+1} p(x_i^+)$ et $u_{i+1} p(x_i^+)$
fin

pour *n* de 1 à *N* **faire**
 pour *i* de 1 à $|\Delta_{n>}^+|$ **faire**
 Calculer ΔM_n ;
 Mettre à jour $\overline{P}(Cl_{i+1,n}^{\leq}); \overline{P}(Cl_{i+1,n}^{\geq}); \underline{P}(Cl_{i+1,n}^{\geq})$ et $\underline{P}(Cl_{i+1,n}^{\leq})$;
 fin
 pour *i* de 1 à $|\Delta_{n=}^+|$ **faire**
 Mettre à jour $\overline{P}(Cl_{i+1,n}^{\leq}); \overline{P}(Cl_{i+1,n}^{\geq}); \underline{P}(Cl_{i+1,n}^{\geq})$ et $\underline{P}(Cl_{i+1,n}^{\leq})$;
 fin
 pour *i* de 1 à $|\Delta_{n<}^+|$ **faire**
 Calculer ΔX_n ;
 Mettre à jour $\overline{P}(Cl_{i+1,n}^{\leq}); \overline{P}(Cl_{i+1,n}^{\geq}); \underline{P}(Cl_{i+1,n}^{\geq})$ et $\underline{P}(Cl_{i+1,n}^{\leq})$;
 fin
fin

fin
Return $\overline{P}(Cl_{i+1,n}^{\geq}), \overline{P}(Cl_{i+1,n}^{\leq}), \underline{P}(Cl_{i+1,n}^{\leq})$ et $\underline{P}(Cl_{i+1,n}^{\geq})$

- $D_{i+1}^+p(A_7) = \{A_1, A_7\}$, $D_{i+1}^+p(A_8) = \{A_1, A_2, A_3, A_5, A_7, A_8, A_9, A_{10}, A_{11}\}$,
 $D_{i+1}^+p(A_9) = \{A_1, A_5, A_7, A_9\}$, $D_{i+1}^+p(A_{10}) = \{A_1, A_2, A_7, A_{10}, A_{11}\}$ et
 $D_{i+1}^+p(A_{11}) = \{A_1, A_{11}\}$.
- $D_{i+1}^-p(A_7) = \{A_3, A_6, A_7, A_8, A_9, A_{10}\}$, $D_{i+1}^-p(A_8) = \{A_8\}$, $D_{i+1}^-p(A_9) =$
 $\{A_3, A_8, A_9\}$, $D_{i+1}^-p(A_{10}) = \{A_6, A_8, A_{10}\}$ et $D_{i+1}^-p(A_{11}) = \{A_2, A_4, A_6,$
 $A_8, A_{10}, A_{11}\}$.
- $l_{i+1}p(A_7) = \min\{3, 3\} = 3$, $l_{i+1}p(A_8) = \min\{3, 3, 1, 2, 3, 1, 3, 2, 2\} = 1$,
 $l_{i+1}p(A_9) = \min\{3, 2, 3, 3\} = 2$, $l_{i+1}p(A_{10}) = \min\{3, 3, 3, 2, 2\} = 2$,
 $l_{i+1}p(A_{11}) = \min\{3, 2\} = 2$,
- $u_{i+1}p(A_7) = \max\{1, 1, 3, 1, 3, 2\} = 3$, $u_{i+1}p(A_8) = \max\{1\} = 1$, $u_{i+1}p(A_9)$
 $= \max\{1, 1, 3\} = 3$, $u_{i+1}p(A_{10}) = \max\{1, 1, 2\} = 2$, $u_{i+1}p(A_{11}) =$
 $\max\{3, 2, 1, 1, 2, 2\} = 3$.

3.4.3 Etape 2 : Mise à jour de l'union supérieure et inférieure des classes de décision

Chaque action $x_i^+ \in \Delta^+$ appartient à une et une seule classe de décision. Les unions inférieures et supérieures des classes de décision sont mises à jour selon le lemme 1 :

Lemme 1 : Soit $\Delta_{n<}^+ \cup \Delta_{n>}^+ \cup \Delta_{n=}^+ = \Delta^+$ l'ensemble d'actions insérées. Les unions des classes de décision relatives à la *Période* _{$i+1$} sont actualisées comme suit :

$$\begin{cases} Cl_{i+1,n}^{\geq} = Cl_{i,n}^{\geq} \cup \Delta_{n>}^+ \cup \Delta_{n=}^+ & (3.5) \\ Cl_{i+1,n}^{\leq} = Cl_{i,n}^{\leq} \cup \Delta_{n<}^+ \cup \Delta_{n=}^+ & (3.6) \end{cases}$$

Preuve : Supposons que $(\Delta_{n>}^+ \cup \Delta_{n=}^+) = \emptyset$, donc $\forall x_i^+ \in \Delta^+$, $n' < n$, donc $Cl_{i+1,n'} \not\subseteq Cl_{i,n}^{\geq}$. Alors, $Cl_{i+1,n}^{\geq} = Cl_{i,n}^{\geq}$. Sinon, nous avons $\forall x^+ \in (\Delta_{n>}^+ \cup \Delta_{n=}^+)$ tel que $x_i^+ \in \Delta_{n>}^+$ or $x_i^+ \in \Delta_{n=}^+$, $Cl_{i+1,n'} \subseteq Cl_{i,n}^{\geq}$. Par conséquent, $Cl_{i+1,n}^{\geq} = Cl_{i,n}^{\geq} \cup \Delta_{n>}^+ \cup \Delta_{n=}^+$.

Exemple 7 : D'après le lemme 1, les unions inférieures et supérieures des classes de décisions de la table 3.1 sont actualisées comme suit :

- $Cl_{i+1,1}^{\leq} = \{A_3, A_6, A_8\}$, $Cl_{i+1,2}^{\leq} = \{A_3, A_4, A_5, A_6, A_8, A_{10}, A_{11}\}$, $Cl_{i+1,3}^{\leq} =$
 $\{A_1, A_2, A_3, A_4, A_5, A_6, A_7, A_8, A_9, A_{10}, A_{11}\}$.
- $Cl_{i+1,1}^{\geq} = \{A_1, A_2, A_3, A_4, A_5, A_6, A_7, A_8, A_9, A_{10}, A_{11}\}$, $Cl_{i+1,2}^{\geq} = \{A_1, A_2,$
 $A_4, A_5, A_7, A_9, A_{10}, A_{11}\}$, $Cl_{i+1,3}^{\geq} = \{A_1, A_2, A_7, A_9\}$.

3.4.4 Etape 3 : Mise à jour de l'ensemble P-dominé et P-dominant des actions initiales

L'entrée d'une action dans le système d'information nécessite la mise à jour de la relation de dominance Dp. Ainsi, la relation $D_{i+1}p$ peut être présentée comme suit : $D_{i+1}p = D_i p \cup \mathcal{A} \cup \mathcal{B}$, tel que $\mathcal{A} = \{(x_i^+, y) \in \Delta^+ \times A_{i+1} : f_{i+1}(x_i^+, g) \succeq f_{i+1}(y, g), \forall g \in P\}$ et $\mathcal{B} = \{(x_i^+, y) \in \Delta^+ \times A_{i+1} : f_{i+1}(y, g) \succeq f_{i+1}(x_i^+, g), \forall g \in P\}$.

Il est évident que $D_i p \subseteq D_{i+1}p$. Les deux relations $D_{i+1}^+p(x_i^+)$ et $D_{i+1}^-p(x_i^+)$ peuvent être calculées en fonction de \mathcal{A} et \mathcal{B} respectivement. Pour chaque $x \in A_i$, il peut exister $(x_i^+, x) \in \mathcal{A}$ ou $(x, x_i^+) \in \mathcal{B}$. Donc, $D_i^+p(x) \subseteq D_{i+1}^+p(x)$ et $D_i^-p(x) \subseteq D_{i+1}^-p(x)$. Ainsi, les ensembles P-dominé et P-dominant peuvent être actualisés en utilisant le lemme 2.

Lemme 2 : Soit $x_i^+ \in \Delta^+$ une action dans Δ^+ tel que $i \in \{1..k\}$.

$$D_{i+1}^+p(x) = \begin{cases} D_i^+p & \text{si } x \notin \cup_{i=1}^k D_{i+1}^-p(x_i^+) \\ D_i^+p(x) \cup \cup_{i=1}^{k'} \{x_i^+\}, & \forall x_i^+ \in \Delta^+; x \in D_{i+1}^-p(x_i^+) \end{cases} \quad (3.7)$$

k' est le nombre de x_i^+ dans Δ^+ tel que $x \in D_{i+1}^-p(x_i^+)$.

$$D_{i+1}^-p(x) = \begin{cases} D_i^-p & \text{si } x \notin \cup_{i=1}^A D_{i+1}^+p(x_i^+) \\ D_i^-p(x) \cup \cup_{i=1}^{k'} \{x_i^+\}, & \forall x_i^+ \in \Delta^+; x \in D_{i+1}^+p(x_i^+) \end{cases} \quad (3.8)$$

k' est le nombre de x_i^+ dans Δ^+ tel que $x \in D_{i+1}^+p(x_i^+)$.

Preuve : Pour la Période $_{i+1}$, $\forall x \in A_i$, nous avons $D_{i+1}^+p(x) = \{y \in A_i \cup \Delta^+ : y D_{i+1}p x\} = \{y \in A_i : y D_{i+1}p x\} \cup \{y \in \Delta^+ : y D_{i+1}p x\} = D_i^+p(x) \cup \{y \in \Delta^+ : y D_{i+1}p x\} = D_i^+p(x) \cup \{x_i^+ : x_i^+ D_{i+1}p x\}$. Donc, $\forall x_i^+ \in \Delta^+$ tel que $i \in \{1..k\}$, nous avons $\{x_i^+ : x_i^+ D_{i+1}p x\} = \{x_i^+ : x \in D_{i+1}^-p(x_i^+)\} = \cup_{i=1}^{k'} \{x_i^+\}$ tel que $x \in D_{i+1}^-p(x_i^+)$. Sinon, si $x \notin D_{i+1}^-p(x_i^+)$, alors $\{x_i^+ : x \in D_{i+1}^-p(x_i^+)\} = \emptyset$. Donc, $\forall x \in A_i, \forall x_i^+ \in \Delta^+$, si $x \in D_{i+1}^-p(x_i^+)$ alors $D_{i+1}^+p(x) = D_i^+p(x) \cup \cup_{i=1}^{k'} \{x_i^+\}$. Sinon, $D_{i+1}^+p(x) = D_i^+p(x)$. Le même raisonnement est valide pour l'équation 3.8.

Exemple 8 : En appliquant le lemme 2 sur la table 3.1, les ensembles P-dominé et P-dominant sont actualisés comme suit :

- $D_{i+1}^-p(A_1) = \{A_1, A_2, A_3, A_4, A_5, A_6, A_7, A_8, A_9, A_{10}, A_{11}\}$, $D_{i+1}^-p(A_2) = \{A_2, A_6, A_8, A_{10}\}$, $D_{i+1}^-p(A_3) = \{A_3, A_8\}$, $D_{i+1}^-p(A_4) = \{A_4, A_6\}$, $D_{i+1}^-p(A_5) = \{A_3, A_5, A_8, A_9\}$, $D_{i+1}^-p(A_6) = \{A_6\}$.
- $D_{i+1}^+p(A_1) = \{A_1\}$, $D_{i+1}^+p(A_2) = \{A_1, A_2, A_{11}\}$, $D_{i+1}^+p(A_3) = \{A_1, A_3, A_5, A_7, A_9\}$, $D_{i+1}^+p(A_4) = \{A_1, A_4, A_{11}\}$, $D_{i+1}^+p(A_5) = \{A_1, A_5\}$, $D_{i+1}^+p(A_6) = \{A_1, A_2, A_4, A_6, A_7, A_{10}, A_{11}\}$.

3.4.5 Etape 4 : Mise à jour des approximations inférieures et supérieures

Une fois que les ensembles P-dominé et P-dominant sont calculés, nous pouvons mettre à jour les approximations inférieures et supérieures des unions des classes de décision. Pour ce faire, quatre propositions sont proposées :

Proposition 1 : Mise à jour de l'approximation inférieure $\underline{P}(Cl_{i+1,n}^{\geq})$

Soit $x_i^+ \in Cl_{i+1,n'}$ tel que $(n, n') \in N^2$:

$$\underline{P}(Cl_{i+1,n}^{\geq}) = \begin{cases} \underline{P}(Cl_{i,n}^{\geq}), & \text{si } \forall x_i^+ \in \Delta^+, l_{i+1}p(x_i^+) < n \leq n' \\ \underline{P}(Cl_{i,n}^{\geq}) \cup \bigcup_{i=1}^{k'} \{x_i^+\}, & \forall x_i^+ \in (\Delta_{n>}^+ \cup \Delta_{n=}^+); l_{i+1}p(x_i^+) \geq n \\ \underline{P}(Cl_{i,n}^{\geq}) - \Delta_{n<}^{\mathbb{X}}, & \forall x_i^+ \in \Delta_{n<}^+ \end{cases}$$

Où

1. k' est le nombre de $x_i^+ \in (\Delta_{n>}^+ \cup \Delta_{n=}^+)$ tel que $l_{i+1}p(x_i^+) \geq n$
2. $\Delta_{n<}^{\mathbb{X}} = \{x \in \underline{P}(Cl_{i,n}^{\geq}) \cap \bigcup_{i=1}^{k'} D_{i+1}^- p(x_i^+); l_{i+1}p(x) < n, \forall i \in \{1..k\}\}$

Preuve : Nous avons $\underline{P}(Cl_{i+1,n}^{\geq}) = \{x \in A_{i+1} : D_{i+1}^+ p(x) \subseteq Cl_{i+1,n}^{\geq}\} = \{x \in A_i \cup \Delta^+ : D_{i+1}^+ p(x) \subseteq Cl_{i+1,n}^{\geq}\} = \{x \in A_i : D_{i+1}^+ p(x) \subseteq Cl_{i+1,n}^{\geq}\} \cup \{x \in \Delta^+ : D_{i+1}^+ p(x) \subseteq Cl_{i+1,n}^{\geq}\} = \{x \in A_i : D_{i+1}^+ p(x) \subseteq Cl_{i+1,n}^{\geq}\} \cup \{x_i^+ \in \Delta^+ : D_{i+1}^+ p(x_i^+) \subseteq Cl_{i+1,n}^{\geq}\} = \{x \in A_i : D_{i+1}^+ p(x) \subseteq Cl_{i+1,n}^{\geq}\} \cup \{x_i^+ \in \Delta^+ : l_{i+1}p(x_i^+) \geq n\} = \underline{P}(Cl_{i,n}^{\geq}) \cup \{x_i^+ \in \Delta^+ : l_{i+1}p(x_i^+) \geq n\}$. En appliquant la proposition 1, nous obtenons $Cl_{i+1,n}^{\geq} = Cl_{i,n}^{\geq}$, si $(\Delta_{n>}^+ \cup \Delta_{n=}^+) = \emptyset$ et $Cl_{i+1,n}^{\geq} = Cl_{i,n}^{\geq} \cup \Delta_{n>}^+ \cup \Delta_{n=}^+$ si $\Delta_{n>}^+ \cup \Delta_{n=}^+ \neq \emptyset$.

1. Si $\Delta_{n>}^+ \neq \emptyset$ ou $\Delta_{n=}^+ \neq \emptyset$, alors $\exists x_i^+ \in (\Delta_{n>}^+ \cup \Delta_{n=}^+)$ tel que $n \leq n'$. Donc, si $\forall x_i^+ \in (\Delta_{n>}^+ \cup \Delta_{n=}^+)$, $l_{i+1}p(x_i^+) < n \leq n'$, alors $\nexists x_i^+ \in (\Delta_{n>}^+ \cup \Delta_{n=}^+)$ tel que $l_{i+1}p(x_i^+) \geq n$ donc $\underline{P}(Cl_{i+1,n}^{\geq}) = \underline{P}(Cl_{i,n}^{\geq})$. De même, si $l_{i+1}p(x_i^+) \geq n$ alors $\{x \in \Delta_{n>}^+ \cup \Delta_{n=}^+ : l_{i+1}p(x_i^+) \geq n\} = \{\bigcup_{i=1}^{k'} \{x_i^+\} \subseteq (\Delta_{n>}^+ \cup \Delta_{n=}^+) : l_{i+1}p(x_i^+) \geq n\}$. Par conséquent, $\underline{P}(Cl_{i+1,n}^{\geq}) = \underline{P}(Cl_{i,n}^{\geq}) \cup \{\bigcup_{i=1}^{k'} \{x_i^+\} : l_{i+1}p(x_i^+) \geq n\}$.
2. Si $\exists \{x_i^+\} \in \Delta_{n<}^+$, i.e. $\{x_i^+\} \in \Delta^+$ tel que $n' < n$, alors $\{x \in \Delta^+ : l_{i+1}p(x_i^+) \geq n\} = \emptyset$ et $\{x \in A_i : D_{i+1}^+ p(x) \subseteq Cl_{i+1,n}^{\geq}\} = \{x \in A_i : D_{i+1}^+ p(x) \subseteq Cl_{i,n}^{\geq}\} = \{x \in A_i : l_{i+1}p(x) \geq n\} = \{x \in A_i : l_i p(x) \geq n\} - \{x \in \underline{P}(Cl_{i,n}^{\geq}) : l_{i+1}p(x) < n\} = \underline{P}(Cl_{i,n}^{\geq}) - \{x \in \underline{P}(Cl_{i,n}^{\geq}) : l_i p(x) < n\}$. Comme indiqué, $D_i^+ p(x) \subset D_{i+1}^+ p(x)$ et $l_{i+1}p(x) \leq l_i p(x)$. Donc, $\{x \in \underline{P}(Cl_{i,n}^{\geq}) : l_{i+1}p(x) < n\} = \{x \in \underline{P}(Cl_{i,n}^{\geq}) \cap D_i^- p(x_i^+) : l_{i+1}p(x) < n\}$.

Soit $\Delta\mathbb{X}_n = \{x \in \underline{P}(Cl_i^{\leq}) \cap \cup_{i=1}^{k'} D_i^- p(x_i^+) : l_{i+1}p(x) < n, \forall i \in \{1..k\}\}$. Si $n > n'$, alors $\underline{P}(Cl_{i+1,n}^{\geq}) = \underline{P}(Cl_{i,n}^{\geq}) - \Delta\mathbb{X}_n$.

Exemple 9 : D'après la proposition 1 et en utilisant les résultats de l'exemple 6, l'approximation inférieure de $Cl_{i+1,n}^{\geq}$ est calculée comme suit : $\underline{P}(Cl_{i+1,1}^{\geq}) = \{A_1, A_2, A_3, A_4, A_5, A_6\} \cup \{A_8\}$, $\underline{P}(Cl_{i+1,2}^{\geq}) = \{A_1, A_2, A_4, A_5\} \cup \{A_{10}, A_{11}\}$, $\underline{P}(Cl_{i+1,3}^{\geq}) = \{A_1, A_2\} \cup \{A_7\}$.

Proposition 2 : Mise à jour de l'approximation inférieure $\underline{P}(Cl_{i+1,n}^{\leq})$

Soit $x_i^+ \in Cl_{i+1,n'}$ tel que $(n, n') \in N^2$

$$\underline{P}(Cl_{i+1,n}^{\leq}) = \begin{cases} \underline{P}(Cl_{i,n}^{\leq}), & \text{si } \forall x_i^+ \in \Delta^+, u_{i+1}p(x_i^+) > n \geq n' \\ \underline{P}(Cl_{i,n}^{\leq}) \cup \cup_{i=1}^{k'} \{x_i^+\}, & \forall x_i^+ \in (\Delta_{n<}^+ \cup \Delta_{n=}^+); u_{i+1}p(x_i^+) \leq n \\ \underline{P}(Cl_{i,n}^{\leq}) - \Delta\mathbb{M}_n, & \forall x_i^+ \in \Delta_{n>}^+ \end{cases}$$

où

1. k' est le nombre de $x_i^+ \in (\Delta_{n<}^+ \cup \Delta_{n=}^+)$ tel que $u_{i+1}p(x_i^+) \geq n$
2. $\Delta\mathbb{M}_n = \{x \in \underline{P}(Cl_{i,n}^{\leq}) \cap \cup_{i=1}^{k'} D_{i+1}^+ p(x_i^+) : u_{i+1}p(x) > n, \forall i \in \{1..k\}\}$

Preuve : Même raisonnement que la proposition 1.

Exemple 10 : D'après la proposition 2 et en utilisant les résultats de l'exemple 6, l'approximation inférieure de $Cl_{i+1,n}^{\leq}$ est calculée comme suit : $\underline{P}(Cl_{i+1,1}^{\leq}) = \{A_3, A_6\} \cup \{A_8\}$, $\underline{P}(Cl_{i+1,2}^{\leq}) = \{A_3, A_4, A_5, A_6\} \cup \{A_8, A_{10}\} - \{A_5\}$, $\underline{P}(Cl_{i+1,3}^{\leq}) = \{A_1, A_2, A_3, A_4, A_5, A_6\} \cup \{A_7, A_8, A_9, A_{10}, A_{11}\}$. Dans ce cas, on note que l'action A_5 n'est plus classée avec certitude dans $Cl_{i+1,1}^{\leq}$ parce qu'elle domine A_9 alors que $A_9 \in Cl_3$ et $A_5 \in Cl_2$. Cependant, l'action A_5 appartient à $\bar{P}(Cl_{i+1,2}^{\leq})$.

Proposition 3 : Mise à jour de l'approximation supérieure $\bar{P}(Cl_{i+1,n}^{\leq})$

Soit $x_i^+ \in Cl_{i+1,n'}$ tel que $(n, n') \in N^2$:

$$\bar{P}(Cl_{i+1,n}^{\leq}) = \begin{cases} \bar{P}(Cl_{i,n}^{\leq}), & \text{si } \forall x_i^+ \in \Delta^+, l_{i+1}p(x_i^+) > n \\ \bar{P}(Cl_{i,n}^{\leq}) \cup \cup_{i=1}^{k'} \{x_i^+\}, & \forall x_i^+ \in \Delta_{n>}^+; l_{i+1}p(x_i^+) \leq n < n' \\ \bar{P}(Cl_{i,n}^{\leq}) \cup \cup_{i=1}^{k''} D_{i+1}^- p(x_i^+), & \forall x_i^+ \in (\Delta_{n<}^+ \cup \Delta_{n=}^+), \end{cases}$$

où

1. k' est le nombre de $x_i^+ \in \Delta_{n>}^+$ tel que $l_{i+1}p(x_i^+) \leq n$
2. k'' est le nombre de x_i^+ tel que $n' \leq n$; i.e. $k'' = |\Delta_{n<}^+ \cup \Delta_{n=}^+|$

Preuve : Nous avons $\overline{P}(Cl_{i+1,n}^{\leq}) = \{x \in A_{i+1} : D_{i+1}^+p(x) \cap Cl_{i+1,n}^{\leq} \neq \emptyset\} = \{x \in A_i : D_{i+1}^+p(x) \cap Cl_{i+1,n}^{\leq} = Cl_{i,n}^{\leq} \neq \emptyset\} \cup \{x_i^+ \in \Delta^+ : D_{i+1}^+p(x) \cap Cl_{i+1,n}^{\leq} \neq \emptyset\} = \{x \in A_i : D_{i+1}^+p(x) \cap Cl_{i+1,n}^{\leq} \neq \emptyset\} \cup \{x_i^+ \in \Delta^+ : l_{i+1}p(x_i^+) \leq n\}$. D'après l'équation (6), nous avons $Cl_{i+1,n}^{\leq} = Cl_{i,n}^{\leq}$ si $\Delta_{n<}^+ = \emptyset$ et $\Delta_{n=}^+ = \emptyset$ (i.e. $n' > n$, $\forall x_i^+ \in \Delta^+$); et $Cl_{i+1,n}^{\leq} = Cl_{i,n}^{\leq} \cup \Delta_{n<}^+ \cup \Delta_{n=}^+$ sinon. Alors $\{x \in A_i : D_{i+1}^+p(x) \cap Cl_{i+1,n}^{\leq} \neq \emptyset\} \cup \{x_i^+ \in \Delta^+ : l_{i+1}p(x_i^+) \leq n\} = (Cl_{i,n}^{\leq}) \cup \{x_i^+ \in \Delta^+ : l_{i+1}p(x_i^+) \leq n\}$

1. Si $n < n'$: Si $\exists x_i^+ \in \Delta_{n>}^+$ tel que $l_{i+1}p(x_i^+) \leq n < n'$, alors $\{x_i^+ \in \Delta_{n>}^+ : l_{i+1}p(x_i^+) \leq n\} = \{\cup_{i=1}^{k'} x_i^+ : x_i^+ \in \Delta_{n>}^+ \text{ et } l_{i+1}p(x_i^+) \leq n\}$. Sinon, si $\forall x_i^+ \in \Delta_{n>}^+$ nous avons $l_{i+1}p(x_i^+) > n$ alors $\{x \in \Delta_{n>}^+ : l_{i+1}p(x_i^+) \leq n\} = \emptyset$, donc $\overline{P}(Cl_{i+1,n}^{\leq}) = \overline{P}(Cl_{i,n}^{\leq})$.
2. Si $n \geq n'$, alors $\{x_i^+ \in (\Delta_{n<}^+ \cup \Delta_{n=}^+) : l_{i+1}p(x_i^+) \leq n\} = \{\cup_{i=1}^{k'} x_i^+ : x_i^+ \in (\Delta_{n<}^+ \cup \Delta_{n=}^+) \text{ et } l_{i+1}p(x_i^+) \leq n\}$ et $\{x \in A_i : D_{i+1}^+p(x) \cap Cl_{i+1,n}^{\leq} \neq \emptyset\} = \overline{P}(Cl_{i,n}^{\leq}) \cup \{x \in A_i \cap D_{i+1}^-p(x_i^+) : D_{i+1}^+p(x) \cap Cl_{i+1,n}^{\leq} \neq \emptyset\}$. Donc, nous avons $\{x \in A_i \cap D_{i+1}^-p(x_i^+) : D_{i+1}^+p(x) \cap Cl_{i+1,n}^{\leq} \neq \emptyset\} \cup \{\cup_{i=1}^{k''} x_i^+ : x_i^+ \in \Delta_{n<}^+ \cup \Delta_{n=}^+\} = \{\cup_{i=1}^{k''} D_{i+1}^-p(x_i^+)\}$, donc $\overline{P}(Cl_{i+1,n}^{\leq}) = \overline{P}(Cl_{i,n}^{\leq}) \cup \cup_{i=1}^{k'} D_{i+1}^-p(x_i^+), \forall x_i^+ \in (\Delta_{n<}^+ \cup \Delta_{n=}^+)$.

Exemple 11 : D'après la proposition 3 et en utilisant les résultats de l'exemple 6, l'approximation supérieure de $Cl_{i+1,n}^{\leq}$ est calculée comme suit : $\overline{P}(Cl_{i+1,1}^{\leq}) = \{A_3, A_6\} \cup \{A_8\}$, $\overline{P}(Cl_{i+1,2}^{\leq}) = \{A_3, A_4, A_5, A_6\} \cup \{A_8\} \cup \{A_{10}\} \cup \{A_2, A_{11}\}$, $\overline{P}(Cl_{i+1,3}^{\leq}) = \{A_1, A_2, A_3, A_4, A_5, A_6\} \cup \{A_7, A_8, A_9, A_{10}, A_{11}\}$.

Proposition 4 : Mise à jour de l'approximation supérieure $\overline{P}(Cl_{i+1,n}^{\geq})$

Soit $x_i^+ \in Cl_{i+1,n'}$ tel que $(n, n') \in N^2$:

$$\overline{P}(Cl_{i+1,n}^{\geq}) = \begin{cases} \overline{P}(Cl_{i,n}^{\geq}), & \text{si } \forall x_i^+ \in \Delta^+, u_{i+1}p(x_i^+) < n \\ \overline{P}(Cl_{i,n}^{\geq}) \cup \cup_{i=1}^{k'} \{x_i^+\}, & \forall x_i^+ \in \Delta_{n<}^+; u_{i+1}p(x_i^+) \geq n > n' \\ \overline{P}(Cl_{i,n}^{\geq}) \cup \cup_{i=1}^{k''} D_{i+1}^+p(x_i^+), & \forall x_i^+ \in (\Delta_{n>}^+ \cup \Delta_{n=}^+), \end{cases}$$

où

1. k' est le nombre de $x_i^+ \in (\Delta_{n<}^+)$ tel que $u_{i+1}p(x_i^+) \geq n > n'$
2. k'' est le nombre de x_i^+ tel que $n' \geq n$; i.e. $k'' = |\Delta_{n>}^+ \cup \Delta_{n=}^+|$

Preuve : Même raisonnement que la proposition 3.

Exemple 12 : D'après la proposition 4 et en utilisant les résultats de l'exemple 6, l'approximation supérieure de $Cl_{i+1,n}^{\geq}$ est calculée comme suit : $\overline{P}(Cl_{i+1,1}^{\geq}) = \{A_1, A_2, A_3, A_4, A_5, A_6\} \cup \{A_7, A_8, A_9, A_{10}, A_{11}\}$, $\overline{P}(Cl_{i+1,2}^{\geq}) = \{A_1, A_2, A_4, A_5\} \cup \{A_7, A_9, A_{10}, A_{11}\}$, $\overline{P}(Cl_{i+1,3}^{\geq}) = \{A_1, A_2\} \cup \{A_7, A_9, A_{11}\}$.

La sortie de l'algorithme *DRSA-Incremental* sont les approximations inférieures et supérieures de toutes les unions de classes de décision. Ces approximations seront données en entrée à un algorithme d'induction, dans ce cas l'algorithme *DomLem*, pour inférer l'ensemble de règles de décision. Nous notons que contrairement à Greco *et al.* (2004), dont l'algorithme proposé actualise directement la base de règles ce qui produit des règles non robustes, l'algorithme que nous proposons intervient au niveau des approximations.

Dans le chapitre suivant, nous allons détailler en quoi l'algorithme incrémental *DRSA-Incremental* est utile et comment il sera appliqué.

3.5 Conclusion

Dans ce chapitre, nous avons adressé la problématique de l'apprentissage incrémental. Ce type d'apprentissage se produit lorsque l'environnement de la décision a un aspect évolutif dans le temps ce qui rend impossible pour la machine (ou l'humain) d'avoir une information complète sur l'échantillon de l'apprentissage. Les informations sur les quelles la décision sera prise sont reçues par portion ce qui rend nécessaire l'actualisation et la révision des décisions déjà prises.

Dans ce manuscrit, nous utiliserons l'approche DRSA (Dominance-based Rough Set Approach) comme un outil pour l'apprentissage supervisé. Cette approche applique une relation de dominance sur les actions d'apprentissage afin d'en inférer un ensemble de règles de décision. Toutefois, dans le cas d'un apprentissage incrémental, DRSA reprend le calcul à zéro ce qui augmente considérablement la complexité temporelle de l'algorithme.

L'algorithme *DRSA-Incremental* que nous avons proposé permet, ainsi, une mise à jour incrémentale des approximations de l'approche DRSA afin de capitaliser sur les données initiales tout en évitant le temps de calcul énorme. L'algorithme est basé sur trois étapes principales : la mise à jour des unions inférieures et supérieures des classes de décision, la mise à jour des ensembles dominés et dominant de chaque action de référence et, finalement, la mise à jour des approximations inférieures et supérieures des unions des classes de décision.

L'algorithme *DRSA-Incremental* sera exploité dans le chapitre suivant afin de proposer une méthode de classification périodique et incrémentale pour la prédiction de la classe de décision à laquelle une action est susceptible d'appartenir. Cette méthode est basée sur l'approche DRSA.

Chapitre 4

MAI2P : Méthode de classification multicritère basée sur l'apprentissage incrémental pour la prédiction périodique

Sommaire

4.1	Travaux antérieurs	84
4.1.1	Méthode basée sur l'approche DRSA pour la prédiction de la faillite des entreprises	85
4.1.2	Méthode basée sur l'approche DRSA pour la prédiction de la performance financière des banques	86
4.2	La méthode <i>MAI2P</i>	87
4.2.1	Phase 1 : Construction de la table de décision de la période P_i	88
4.2.2	Phase 2 : Mise à jour incrémentale des approximations de DRSA pour la construction d'un modèle de préférence	94
4.2.3	Phase 3 : Classification périodique des "Actions potentielles" de la période P_{i+1}	95
4.3	Conclusion	96

Au cours de la dernière décennie, la masse de données collectées et stockées dans les bases de données a considérablement augmenté en raison du progrès logiciel et matériel ce qui a conduit à l'automatisation des processus du traitement des données. Par conséquent, les techniques traditionnelles d'analyse de données sont

devenues inappropriées et d'autres nouvelles techniques sont apparues. Dans ce travail, nous nous focalisons sur les techniques de *machine learning* principalement dédiées aux problèmes de prédiction.

La prédiction est le raisonnement des événements actuels aux propriétés futures et aux événements qu'ils causeront (Shanahan, 1989). Récemment, la prédiction revêt d'une importance particulière dans la littérature de raisonnement temporel. Elle est impliquée dans plusieurs domaines du monde réel tels que la médecine (Delen *et al.*, 2005; Ture *et al.*, 2005), la psychologie (Yaroslavsky *et al.*, 2013; Benazon, 2000), la finance (Zaras, 2011; Shen *et al.*, 2014), la biologie (Moult *et al.*, 1995; Thusberg *et al.*, 2011), l'apprentissage en ligne (Yang *et al.*, 2013; Chaplot *et al.*, 2015), etc. La prédiction repose sur des techniques d'apprentissage diverses définies dans la littérature et appelées techniques de *machine learning*.

Les techniques conventionnelles de *machine learning* (exp. les réseaux de neurones, les chaînes de Markov, les machines à vecteurs de support, etc.) sont certainement prometteuses. Cependant, elles demeurent sensibles au problème des données déséquilibrées qui dégrade considérablement la qualité de la prédiction (cf. Section 2.3) en particulier dans un contexte de données massives. Ce problème peut, toutefois, être surmonté par l'approche DRSA (*Dominance-based Rough Set Approach*) qui est une technique d'apprentissage supervisé, dédiée pour l'aide multicritère à la décision et basée sur les préférences des décideurs humains. En outre, en cas d'apprentissage incrémental, les techniques conventionnelles de *machine learning* et de DRSA, reprennent le calcul à zéro ce qui consomme un temps et un espace énormes. Cependant, notre méthode de classification basée sur l'algorithme *DRSA-Incremental* (cf. Chapitre 3) permet la mise à jour des approximations de DRSA, par suite, de l'ensemble de règles de décision afin de minimiser le temps de calcul à chaque réception d'une nouvelle portion de données qui doit être prise en compte pour l'apprentissage du modèle prédictif. Ces deux raisons justifient notre choix de l'approche DRSA comme étant une technique de classification et d'apprentissage supervisé.

Généralement, l'approche DRSA s'applique pour un objectif de classification (Saad, 2005; Saad *et al.*, 2005; Stańczyk, 2011; Turki *et al.*, 2012; Kujawinska *et al.*, 2016; Ghrab et Saad, 2016) ou bien de prédiction dans un système d'information statique (Shen *et al.*, 2014; Zaras, 2011).

Ce chapitre présente notre méthode de classification multicritère *MAI2P* (*Multicriteria Approach for the Incremental Periodic Prediction*) basée sur l'algorithme *DRSA-incremental* (cf. Chapitre 3) pour un objectif de prédiction dans le cas d'un ensemble d'apprentissage évolutif dans le temps. Elle doit permettre de prédire périodiquement, pour chaque action dans le système d'information, la classe de décision à laquelle elle est susceptible d'appartenir. La prédiction se fait pour une période P_{i+1} en fonction des données de toutes les périodes précédentes $\sum_{t=1}^i P_t$. Sauf que ces données ne sont pas fournies dans une seule portion, mais plutôt reçues d'une manière séquentielle.

Dans ce travail, nous nous focalisons sur l'apprentissage incrémental sous la variation de l'échantillon d'apprentissage (cf. Chapitre 3). Ceci se produit lors de l'enrichissement séquentiel de l'ensemble d'apprentissage. Le principe de l'approche DRSA exige, dans ce cas, la mise à jour des règles de décision ou bien des approximations des classes de décision afin de garantir une prédiction actualisée qui prend en considération l'évolution dans le temps d'un cas du monde réel (exp. les jeux d'échec, les prévisions météo, les activités des apprenants sur l'environnement du MOOC (cf. Section 3.2)).

La méthode *MAI2P* prend en compte les préférences des décideurs humains dans le processus de prise de décision et se compose de trois phases. La première phase vise à construire une table de décision et repose sur trois étapes : d'abord, la construction d'une famille cohérente de critères pour la caractérisation des actions ; puis, l'identification d'un échantillon d'apprentissage représentatif pour les n classes de décision prédéfinies en amont ; et enfin, la classification de chaque "Action de référence" dans l'une de ces classes de décision. La deuxième phase concerne l'inférence d'un modèle de préférence qui aboutit à un ensemble de règles de décision. Elle est basée sur la mise à jour incrémentale des approximations inférieures et supérieures des unions des classes de décision dans DRSA (cf. Chapitre 3). La troisième phase consiste à la classification précoce (prédiction) des "Actions potentielles", en utilisant le modèle de préférence précédemment inféré.

La méthode *MAI2P* sera validée dans un contexte des MOOCs et expérimentée sur des données réelles d'un MOOC français dans le Chapitre 5. Une Solution basée sur la méthode *MAI2P* sera proposée dans le Chapitre 6 pour l'aide au transfert des savoirs factuels et du savoir faire dans le contexte des MOOCs.

Le chapitre est organisé de la manière suivante : La première section présente un état de l'art sur les extensions de DRSA pour des contextes prédictifs. La deuxième section présente la méthode *MAI2P* permettant la prédiction périodique et incrémentale de la classe de décision à laquelle une action est susceptible d'appartenir. La troisième section conclut le chapitre.

4.1 Travaux antérieurs

Généralement, l'approche DRSA est utilisée pour des objectifs de classification multicritère. Saad (2005) a proposé une méthode d'aide à la décision multicritère basée sur l'approche DRSA pour l'identification et l'évaluation des connaissances cruciales dans les organisations. Stańczyk (2011) a combiné l'approche DRSA et la technique ANN (réseaux de neurones artificiels) afin de proposer un classificateur hybride appliqué dans le domaine de la stylométrie. Turki *et al.* (2012) ont couplé une ontologie noyau et une méthode de classification multicritère basée sur DRSA pour l'aide à l'identification des processus sensibles appliqués dans le domaine médical. Kujawinska *et al.* (2016) ont proposé une méthodologie basée sur l'approche DRSA pour l'évaluation de la fabrication des procédés appliquée sur le cas de la coulée en fonte ductile en utilisant sa composition chimique et ses propriétés méca-

niques. Ghrab et Saad (2016) ont proposé une cartographie multicritère basée sur l'approche DRSA pour l'aide à la caractérisation et l'évaluation des connaissances médicales.

Cependant, dans certains cas, et en particulier dans le domaine de finance, l'approche DRSA a été exploitée pour un objectif de prédiction. Elle doit dévoiler des circonstances d'une situation future afin de permettre aux décideurs de prendre une décision adéquate précoce dans le but d'éviter les conséquences indésirables. Elle a été utilisée pour prédire la performance (ou la faillite) des entreprises à court ou à long terme pour la raison de prendre les décisions nécessaires permettant de promouvoir (ou d'éviter) les causes identifiées. Dans cette section, nous présentons deux travaux où l'approche DRSA était exploitée pour un objectif de prédiction.

4.1.1 Méthode basée sur l'approche DRSA pour la prédiction de la faillite des entreprises

Zaras (2011) a proposé une méthode basée-DRSA pour la prédiction hybride de la faillite possible d'une entreprise. La classification est basée sur la formule discriminante $Z = 1.2 * X_1 + 1.4 * X_2 + 3.3 * X_3 + 0.6 * X_4 + 0.99 * X_5$ proposée par (Altman, 1968) tels que X_1, X_2, X_3, X_4 et X_5 sont respectivement les ratios des fonds de roulement, des bénéfices non répartis, des bénéfices avant intérêts et impôts, de la valeur du marché des capitaux propres et de la valeur des ventes ; sur le total des actifs. Trois classes de décision ont été identifiées : La classe de décision B pour les entreprises en faillite si $Z < 0$, la classe de décision M pour les entreprises qui sont sur le bord de la faillite si $0 \leq Z < 2.67$ et la classe de décision P pour les entreprises prospères si $Z \geq 2.67$. Les critères d'évaluation ont été adoptés du travail de Filion et Fortin (1991) sur les capacités promettant la réussite de l'entreprise. Trois sous-groupes de critères ont été exploités : le premier sous-groupe est celui des capacités de gestion et de réseau de contacts. Le deuxième est celui de capacités de gestion, de leadership et de la vision. Le troisième est celui des capacités de gestion, de leadership et de la différenciation. Pour chaque critère une échelle de sept échelons ordonnés selon un ordre croissant de préférence de 1 à 7 ont été fixés (1 : Fort, 6 : Très faible, 7 : aucune idée). La méthode a été testée sur les données de sept entreprises Québécoises. Les décisions de classification des entreprises comme étant en faillite, sur le bord de la faillite ou bien prospères ont été prises par quatre experts de domaine. La valeur de Z a été calculée sur une période de 5 ans. Le modèle de préférence obtenu est construit par cinq règles de décision et il est caractérisé par une qualité d'approximation de 0.57. L'imperfection de cette valeur est due à cause de l'hésitation des décideurs suite aux difficultés fréquentées lors de la procédure de classification. Elle est encore expliquée par le fait que la valeur minimale fixée par Altman (1968) à 1.8 a été remplacée dans ce travail par la valeur 0 ce qui a produit une confusion entre les deux classes B des entreprises en faillite et M des entreprises sur le bord de la faillite.

4.1.2 Méthode basée sur l'approche DRSA pour la prédiction de la performance financière des banques

Shen *et al.* (2014) ont proposé une méthode basée sur l'approche DRSA pour la prédiction de la performance financière des banques commerciales. La méthode est composée de deux phases. La première phase a pour objectif de réduire la complexité des attributs impliqués et d'inférer, par la suite, un modèle de préférence sous la forme d'un ensemble de règles de décision. La deuxième phase vise à peaufiner les règles de décision via la technique d'inférence *neuro-fuzzy*. Cette technique permet d'identifier les intervalles flous de chaque attribut. La première phase est composée de deux étapes : une étape de discrétisation des attributs de condition et de l'attribut de décision et une deuxième étape pour l'inférence d'un ensemble de règles de décision de type *Si-Alors*. La deuxième phase est composée de huit étapes. La première étape consiste à construire les instances d'apprentissage des règles de décision. Ce sont les instances qui supportent les règles de décision dont la force est élevée. L'étape 2 consiste à fixer le type et le nombre de la fonction d'appartenance de chaque attribut pour procéder à l'apprentissage. L'étape 3 consiste à faire l'apprentissage du système d'inférence *neuro-fuzzy* jusqu'à ce que la somme des erreurs quadratiques soit stable et minimisée. Ensuite le système est validé par des données additionnelles. L'étape 4 consiste à l'ajustement de chaque fonction d'apprentissage des attributs de chaque règle. L'étape 5 s'agit de collecter les opinions des experts de domaine pour construire la matrice initiale A des influences directes que peut avoir un critère i sur chaque critère j tel que $a_{ij} = \{0, 1, 2, 3, 4\}$ où 0 désigne que le critère i n'a aucune influence sur le critère j et 4 désigne une influence forte. L'étape 6 est la normalisation de la matrice initiale pour construire une matrice $D = k * A$ tel que $k = \min\{\frac{1}{\max \sum_{j=1}^n a_{ij}}, \frac{1}{\max \sum_{i=1}^n a_{ij}}\}$. L'étape 7 consiste à calculer la matrice totale $T = D * (I - D) - 1$. L'étape 8 finit par mesurer les influences directionnelles des critères en calculant la somme de chaque colonne i appelé di et la somme de chaque ligne i appelé ri . Finalement, si pour chaque i de 1 à n , $ri - di > 0$ alors le critère est considéré comme une cause de la performance. Sinon, si $ri - di < 0$ alors le critère est considéré comme un effet de la performance. Cette méthode est validée sur les données de cinq banques à Taiwan. Le rapport choisi pour mesurer la performance financière est le rendement sur les actifs (ROA). Il indique le développement ou bien la dégradation de la performance financière. De même, 25 critères portant sur six dimensions ont été identifiés et utilisés. Les auteurs ont exploité les données de 2008 au 2011 pour l'apprentissage et les données de l'année 2012 pour la validation. Les banques ont été au début classées d'un ordre décroissant selon la valeur de leur ROA : l'intervalle du premier tiers des banques caractérise la classe de décision "Bon", l'intervalle du deuxième tiers caractérise la classe de décision "Moyen" et l'intervalle du dernier tiers caractérise la classe de décision "Mauvais". Tout au long du travail la classe de décision "Moyen" a été négligée. De même, une échelle de trois échelons "Élevé", "Moyen" et "Faible" a été fixée pour chaque critère. L'application de la méthode a généré quatre règles de décision

raffinée par la technique *neuro-fuzzy*. Les expérimentations ont montré qu’une plus grande liquidité peut influencer davantage la croissance du taux d’investissement (G1) et du taux de garantie (G2). De même, la croissance de G1 et G2 est cruciale pour l’amélioration de la future performance financière.

Tout au long de l’application de l’approche DRSA dans les deux méthodes présentées, le système d’information, et de même l’échantillon d’apprentissage, sont gardés stables. En effet, le processus de prédiction est réalisé sur plusieurs années mais ne nécessitait pas la mise à jour des critères, des actions ou bien des valeurs sur les critères. La valeur de prédiction, dans ce cas, risque d’être obsolète si le contexte est influencé par un autre facteur externe (exp. une révolution, une catastrophe naturelle, la modification des préférences des décideurs, etc.). D’où l’utilité de la prise en considération de l’évolution du système d’information et de l’échantillon d’apprentissage au cours du temps afin de garder une vue dynamique sur un cas du monde réel. Dans ce travail, nous traitons, ainsi, les cas d’un système d’information qui varie dans le temps suite à l’insertion séquentielle des actions d’apprentissage.

4.2 MAI2P : Méthode de classification multicritère et basée sur DRSA pour la prédiction périodique et incrémentale

Dans le reste du chapitre, nous présenterons la méthode *MAI2P* (*Multicriteria Approach for the Incremental Periodic Prediction*) que nous avons proposée pour la prédiction incrémentale et périodique de la classe de décision Cl_i à laquelle une action x est susceptible d’appartenir tels que $i \in \{1 \dots N\}$ et N est le nombre de classes de décision. Cette méthode se compose de trois phases (cf. Figure 4.1) : la première concerne la construction de la table de décision. La seconde vise à inférer un modèle de préférence basé sur la mise à jour incrémentale des approximations de DRSA. La troisième vise la classification de chaque “Action potentielle” dans l’une des N classes de décision prédéfinies, en utilisant le modèle de préférence précédemment inféré.

Notons bien que nous nous situons dans le cas de l’apprentissage incrémental. La méthode *MAI2P* doit fonctionner d’une manière périodique afin de mettre à jour la prédiction effectuée pendant la période P_{i-1} , en fonction de nouvelles informations reçues pendant la période P_i . En d’autres termes, une prédiction concernant l’appartenance d’une action A_j à une classe de décision peut être $A_j \in Cl_r$ pendant la période P_i et $A_j \in Cl_s$ pendant la période P_{i+1} tel que $r \neq s$ et $(r, s) \in N^2$. Une période, dans ce contexte, est définie par l’intervalle du temps qui sépare la réception de deux portions d’informations successives. Ces intervalles du temps peuvent être égaux ou non. La méthode de prédiction périodique et incrémentale est détaillée dans la Figure 4.2.

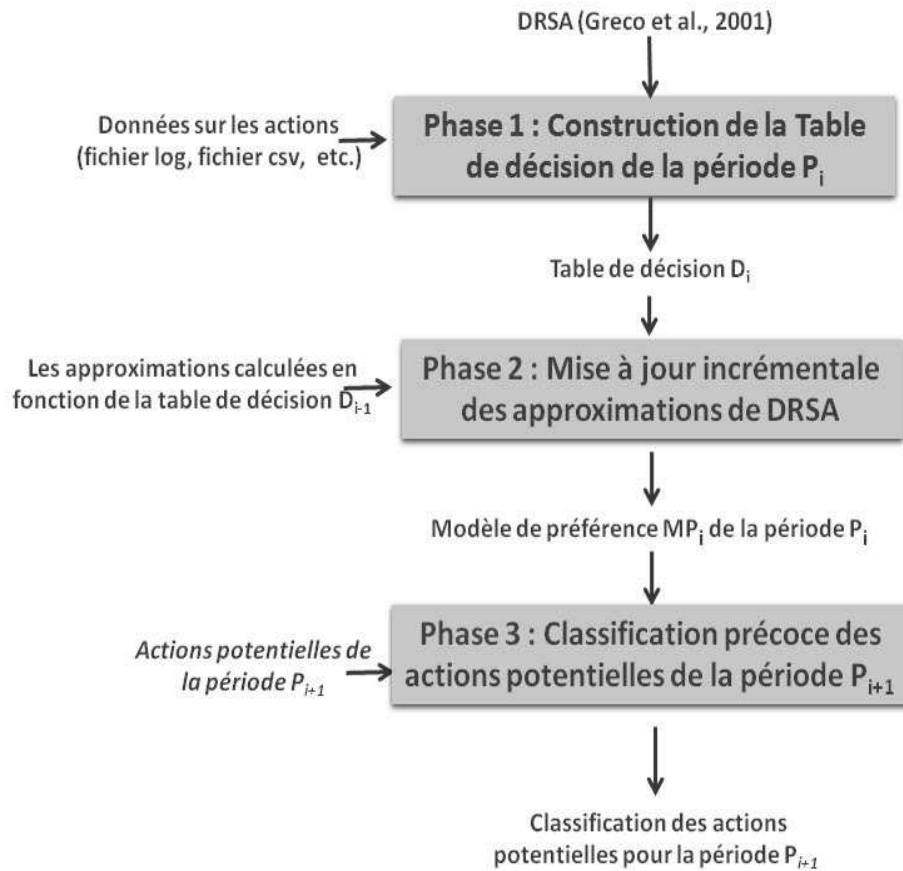


FIGURE 4.1 – Description générale des trois phases de la méthode de classification incrémentale *MAI2P* pour une période P_i

4.2.1 Phase 1 : Construction de la table de décision de la période P_i

Cette phase comprend trois étapes. La première concerne la construction d’une famille cohérente de critères pour la caractérisation des actions. La deuxième étape est la construction d’un ensemble d’“Actions de référence” représentatif pour chacune des N classes de décision prédéfinies. La troisième étape est la classification de chaque “Action de référence” dans l’une des classes de décision.

Étape 1 : Construction d’une famille cohérente de critères

Une famille de critères d’évaluation doit fournir des outils de jugement pour un décideur. Elle doit vérifier la cohérence entre les choix et les attentes du décideur et, aussi, les besoins des acteurs concernés (Beccali *et al.*, 2003).

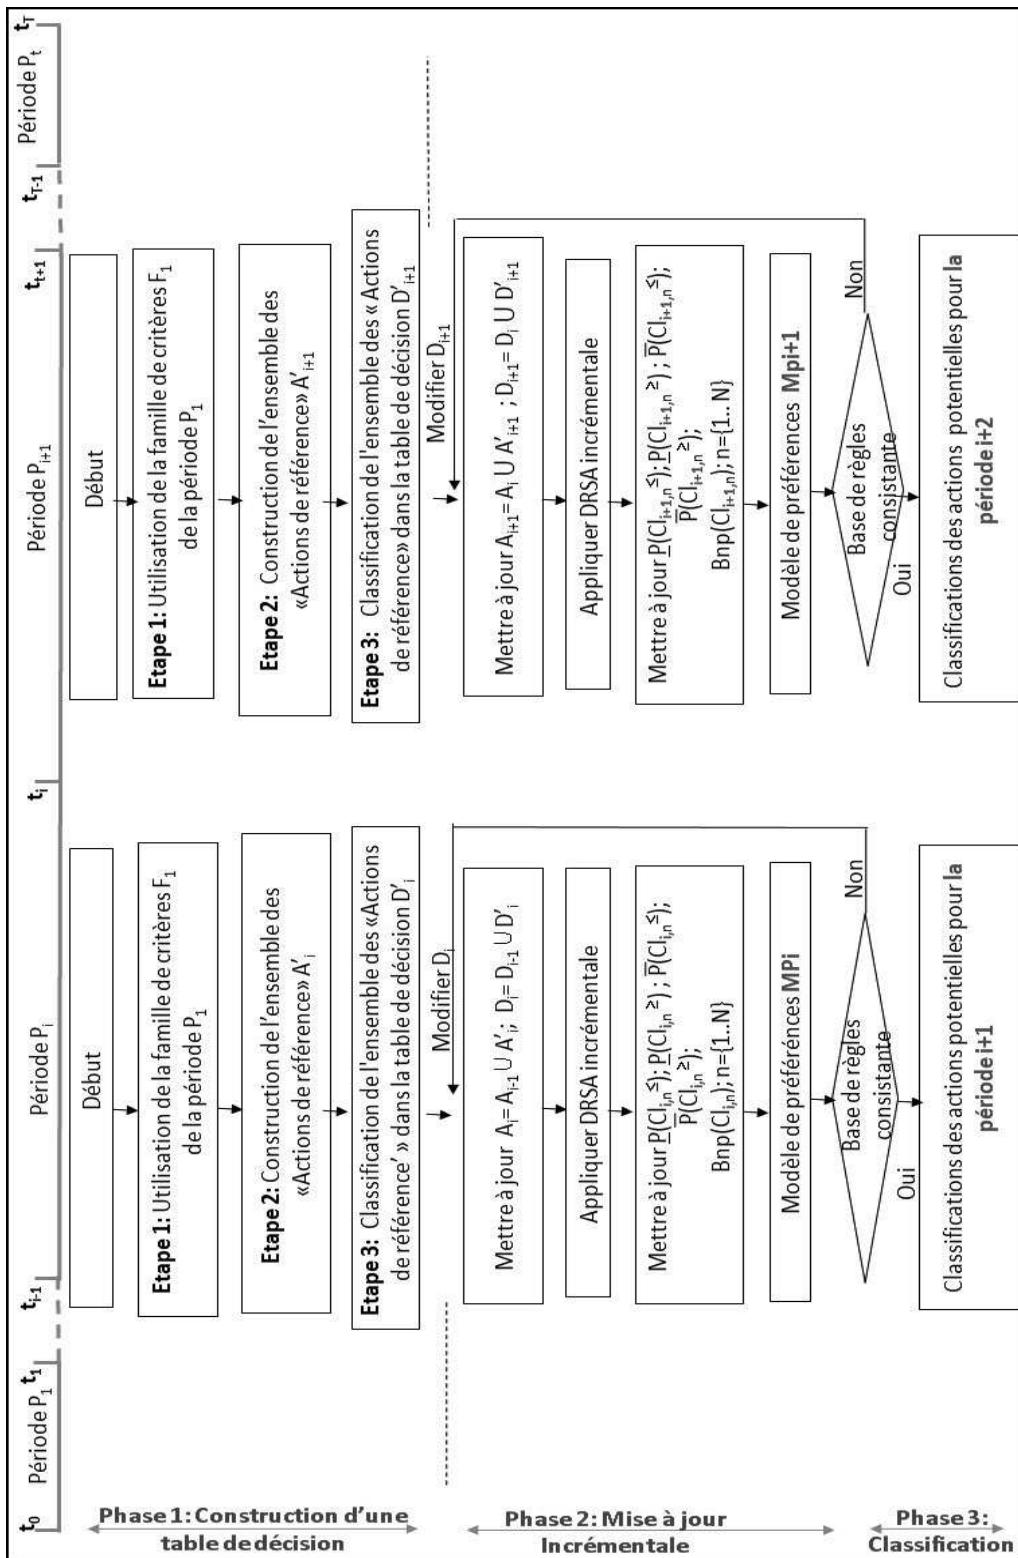


FIGURE 4.2 – Application périodique et incrémentale de la méthode MAI2P

Comparé à un attribut, un critère doit permettre de mesurer les préférences des décideurs selon un point de vue personnel (Mousseau *et al.*, 1996).

Les décideurs jouent un rôle très important dans le processus de construction d'une famille cohérente de critères. Mousseau *et al.* (1996) ont défini deux approches : l'approche descendante et l'approche ascendante. L'approche descendante consiste à décliner un ou plusieurs objectifs stratégiques selon des points de vue et des dimensions (David *et al.*, 2001). L'approche ascendante consiste à construire une famille de critères à partir d'une liste d'indicateurs susceptibles d'influencer l'opinion des décideurs concernant la caractérisation des actions. Dans l'aide à la décision multicritère ces indicateurs sont appelés "Conséquences" (Mousseau *et al.*, 1996). Cette approche est, également, basée sur des informations recueillies durant des interviews avec les experts du domaine. Une approche mixte qui combine à la fois l'approche ascendante et descendante est également possible.

L'approche que nous adoptons dans ce travail pour la construction d'une famille cohérente de critère est l'approche ascendante. Une fois la liste de conséquences est établie, des réunions directes doivent être menées avec le décideur afin d'obtenir ses informations préférentielles sur chaque critère. L'approche DRSA permet de traiter, à la fois, les échelles préférentielles quantitatives et qualitatives. Une échelle intermédiaire qui combine les deux échelles est aussi possible :

- Echelle quantitative : il s'agit d'une échelle numérique dont les échelons sont définis par référence à une unité clairement identifiée de façon à donner sens d'une part, à l'absence de quantité (échelon 0) et, d'autre part, au rapport entre deux échelons quelconques comme étant égal au rapport des nombres qui les caractérisent, chacun d'eux pouvant s'interpréter comme l'addition d'un nombre donné (entier ou fractionnaire) d'unités de la quantité considérée (Roy, 2000).
- Echelle qualitative : c'est une échelle numérique dont les échelons sont définis par référence à une unité clairement identifiée de façon à donner sens (Roy, 2000). Elle vise à fournir une compréhension plus approfondie que l'échelle quantitative.

L'utilisation de l'échelle quantitative n'est pas toujours recommandée puisque les informations qui y sont liées sont imprécises. De ce fait, nous estimons que le recours à des mesures quantitatives n'a pas de réel intérêt. D'après Moussa (2001), *dans un contexte où l'évaluation implique la prise en compte des éléments de nature subjective, il est peu significatif de vouloir faire exprimer les acteurs en termes d'écart ou de ratios de préférences, l'information la plus facile à exprimer et la plus robuste qu'elle soit est donc seulement ordinale.*

La famille de critères dans le contexte d'aide à la décision doit être cohérente afin d'assurer la validité de la comparaison. Une famille cohérente doit alors satisfaire les trois conditions suivantes (Chevalier et Rousseaux, 1999 ; Roy, 1985) :

- Exhaustivité (complétude) : la famille de critères doit être complète. En effet, si l'évaluation de deux actions est équivalente pour tous les critères, la seule conclusion possible est que ces deux actions sont indifférentes, sinon il existe au moins un critère sous-jacent manquant.
- Cohésion : lorsque deux actions sont équivalentes en fonction de tous les critères sauf un seul, l'action avec la meilleure performance sur ce critère doit être préférée par rapport à l'autre action.
- Non-redondance : si un critère est exclu d'une famille, l'une des deux exigences précédentes n'est plus satisfaite.

Dans ce travail, nous considérons que la famille de critères reste stable tout au long du processus de prédiction et donc ne varie pas d'une période à l'autre. Cependant cette famille est trop liée aux préférences du décideur. Par conséquent, le changement du décideur ou bien du contexte dans lequel la décision était prise, entraîne obligatoirement la mise à jour ou même la reconstruction totale de la famille de critères.

Étape 2 : Construction d'un ensemble des "Actions de référence"

Cette étape est relative à l'apprentissage constructif consacré à déduire le modèle de préférence des décideurs. L'apprentissage constructif, contrairement à l'apprentissage descriptif, suppose que le modèle de préférence n'est pas préexistant mais qu'il est construit de manière interactive en impliquant explicitement le décideur (Saad *et al.*, 2006).

Compte tenu de la croissance continue de la masse et du flux de données, il est difficile de les toutes analyser. Par conséquent, il est nécessaire de définir un échantillon d'apprentissage contenant un nombre suffisant d'exemples représentatifs pour chacune des classes de décision prédéfinies Cl_i tel que $i \in \{1, \dots, N\}$. Afin de respecter la terminologie utilisée dans l'approche DRSA (cf. Section 3.1.2), nous appelons les exemples d'apprentissage, "Actions de référence". La construction de cet ensemble s'effectue par le décideur qui peut être soit un individu soit un groupe d'individus. Dans le cas d'un groupe, un processus de concertation doit être mené, concernant le choix d'un ensemble final et unanime des "Actions de référence", jusqu'à ce qu'un accord mutuel entre les différents décideurs soit atteint. Plusieurs méthodes ont été définies dans la littérature afin d'atteindre une décision de groupe dans un contexte de prise de décision (Belton et Pictet, 1997; Saad et Chakhar, 2010; Kraemer et King, 1988).

Étant donné que la dimension humaine est fortement impliquée dans la phase de construction de la table de décision (choix et classification des "Actions de référence"), il faut tenir compte de la taille de l'échantillon à proposer. En effet, d'un point de vue psychologique (Miller, 1956), un décideur humain se caractérise par une capacité cognitive représentant la limite supérieure à laquelle il peut associer ses réponses aux stimuli qui lui sont accordés. Ainsi, pour la construction de l'ensemble

d'apprentissage, il est suffisant que les actions sélectionnées soient représentatives et de qualité, quelque soit leur effectif. Sinon, un échantillon d'apprentissage volumineux peut dévaloriser la qualité des décisions prises par le décideur, et celle du modèle de préférence. L'objectif de cette phase est de construire un ensemble des "Actions de référence" à la fois d'une haute qualité et d'une quantité raisonnable, en harmonie avec la capacité cognitive du décideur humain afin d'inférer un modèle de préférence.

Cependant, puisque la méthode de prédiction que nous proposons doit être appliquée dans un contexte de systèmes d'informations qui évoluent dans le temps, nous traitons le cas d'un ensemble des "Actions de référence" non stables d'une période à une autre tout au long du processus de prédiction. Ainsi, pendant chaque période P_i , le décideur doit définir un nouvel ensemble A'_i des "Actions de référence" qui se rajoute à l'ensemble des "Actions de référence", A_{i-1} , de toutes les périodes précédentes. L'ensemble des "Actions de référence" de la période P_i est donc $A_i = A'_i + A_{i-1}$; $\forall i \in \{2, \dots, T\}$ tel que T est le nombre de périodes constituant le processus de prédiction.

La taille de l'ensemble des "Actions de référence" peut changer d'une période à une autre (*i.e.* $|A'_i| \neq |A'_{i-1}|$) en respectant la capacité cognitive du décideur et aussi la représentation de chacune des classes de décision prédéfinies.

Notons bien que cette étape permet de surmonter le problème de données déséquilibrées affronté par les modèles d'apprentissage classiques (cf. Section 2.3.3). En effet, l'intervention des décideurs humains pour la construction de l'échantillon d'apprentissage permet d'obtenir des sous-ensembles équitables des "Actions de référence" (Bouzayane et Saad, 2017b). Chaque sous ensemble doit contenir un nombre d'actions représentatives pour chaque classe de décision prédéfinie. Les sous-ensembles de l'échantillon doivent avoir des tailles égales ou bien légèrement inégales.

Etape 3 : Classification de l'ensemble des "Actions de référence" dans les classes de décision prédéfinies

Cette étape est composée de deux sous-étapes : (i) la construction de la table d'information, et (ii) la construction d'une table de décision. La table d'information I_i construite pendant la période P_i est une matrice dont les colonnes représentent les " p " critères d'évaluation construits dans la première étape et contenus dans F_i et dont les lignes forment un ensemble de " m " "Actions de référence" identifiées dans la deuxième étape et contenues dans A'_i . Le contenu de la matrice est la fonction d'évaluation $f_i(A_{j,i}, g_{k,i})$ de chaque action $A_{j,i} \in A'_i$ sur chaque critère $g_{k,i} \in F_i$ tel que $i \in \{1..T\}$, $j \in \{1..m\}$ et $k \in \{1..p\}$. Les variables T , m et p sont respectivement le nombre de périodes à considérer pendant le processus de prédiction, la taille $|A'_i|$ de l'ensemble des "Actions de référence" définit à la $i^{\text{ème}}$ période et la taille de l'ensemble $|F_i|$ de la famille de critères.

Par analogie, les variables $A_{j,i}$ et $g_{k,i}$ sont respectivement le $j^{\text{ème}}$ “Action de référence” dans l’ensemble A'_i et le $k^{\text{ème}}$ critère dans la famille de critère F_i . Nous rappelons que A'_i et F_i sont respectivement l’ensemble des “Actions de référence” identifiées pendant la $i^{\text{ème}}$ période et la famille de critères construite pendant la première période et utilisée au cours de la $i^{\text{ème}}$ période. Une fois la table d’information I_i soit complète pendant la $i^{\text{ème}}$ période, des réunions avec le décideur doivent être réalisées afin de construire la table de décision de la $i^{\text{ème}}$ période. Pour ce faire, une colonne doit être insérée à la fin de la table d’information I_i contenant la décision concernant l’affectation de chaque “Action de référence” dans l’une des n classes de décision prédéfinies.

La table de décision est, ainsi, composée de “ m ” lignes et “ $p+1$ ” colonnes (cf. Table 4.1). La décision prise par le décideur concernant la classification de chaque “Action de référence” doit être basée sur les valeurs de la fonction d’évaluation f_i des actions sur l’ensemble de critères, d’une part, et sur l’expertise du décideur dans le domaine d’apprentissage, d’autre part. Nous appelons $D_i = \{d_{1,i}, d_{2,i}, \dots, d_{j,i}, \dots, d_{m,i}\}$ le vecteur de décisions d’assignement de chaque “Action de référence” dans l’une des N classes de décision tel que $d_{j,i} \in \{Cl_i, i \in \{1 \dots N\}\}$ est l’affectation du $j^{\text{ème}}$ “Action de référence” $A_{j,i} \in A'_i$ dans l’une des N classes de décision.

De même, dans certains cas, le décideur ne peut pas être représenté par un seul individu mais par plusieurs qui ne partagent pas forcément les mêmes préférences concernant la décision d’affectation de chaque “Action de référence” dans l’une des classes de décision. Cependant, dans cette étape il est obligatoire d’avoir une unanimité entre les différents décideurs afin de pouvoir construire une table de décision unique permettant d’inférer un modèle de préférence unique. Par conséquent, afin d’atteindre une décision de groupe, nous pouvons appliquer l’approche constructive de Belton et Pictet (1997) qui est basée sur trois cadres génériques : (i) le partage- le groupe se comporte comme un seul décideur et s’accorde sur une préférence commune. Il adapte les résultats communs et partagés d’une discussion entre les différentes parties prenantes. Durant cette étape, des rencontres directes avec les décideurs peuvent être menées pour identifier la cause de l’incohérence et parvenir à un compromis ; (ii) l’agrégation- les préférences des différentes parties prenantes sont agrégées et une préférence commune est obtenue par le biais du vote ou du calcul. Ce cas nécessite l’acceptation de la fonction globale par le groupe ; et (iii) la comparaison- les parties prenantes déclarent leurs préférences individuelles et celles-ci sont utilisées dans un processus de négociation où l’objectif est de trouver un consensus.

La sortie de cette phase est une table de décision complète D_i (cf. Table 4.1) construite à la période P_i . Elle représente l’entrée de la deuxième phase de la méthode MAI2P.

TABLE 4.1 – Exemple d’une table décision construite à la *Période_j*

	g_1	...	g_k	...	g_p	D_i
$A_{1,j}$	$f(A_{1,j}, g_1)$...	$f(A_{1,j}, g_k)$...	$f(A_{1,j}, g_p)$	Cl_i
$A_{2,j}$	$f(A_{2,j}, g_1)$...	$f(A_{2,j}, g_k)$...	$f(A_{2,j}, g_p)$	Cl_i
...	Cl_i
$A_{k,j}$	$f(A_{k,j}, g_1)$...	$f(A_{k,j}, g_k)$...	$f(A_{k,j}, g_p)$	Cl_i
...	Cl_i
$A_{n,j}$	$f(A_{n,j}, g_1)$...	$f(A_{n,j}, g_k)$...	$f(A_{n,j}, g_p)$	Cl_i

4.2.2 Phase 2 : Mise à jour incrémentale des approximations de DRSA pour la construction d’un modèle de préférence

Cette phase applique l’algorithme *DRSA-Incremental* (cf. Section 3.1.2) sur la table de décision D_i construite pendant la période P_i afin d’en inférer un modèle de préférence MP_i . Le modèle de préférence est un ensemble de règles de décision susceptibles de classer chaque action dans l’une des classes de décision prédéfinies. Il est inféré en appliquant un algorithme d’induction qui prend en entrée les approximations inférieures et supérieures des unions inférieures et supérieures des classes de décision (cf. Chapitre 3). Dans ce travail, nous avons utilisé l’algorithme d’induction *DomLem* proposé par l’approche DRSA (Greco *et al.*, 2001a). Cet algorithme génère un ensemble minimal de règles de décision couvrant tous les exemples dans la table de décision. Cette phase se déroule pendant la période P_i du processus de prédiction, une fois la table de décision soit complète, tel que $i \in \{1, \dots, T - 1\}$. Elle considère, à la fois, l’ensemble des “Actions de référence”, A_{i-1} , de toutes les périodes précédentes et l’ensemble des “Actions de référence”, A'_i , de la période P_i . Cette phase est composée de deux étapes : (i) appliquer l’algorithme *DRSA-Incremental* sur la table de décision D_i pour mettre à jour les approximations supérieures et inférieures des unions de classes de décision de l’approche DRSA (cf. Chapitre 3); (ii) appliquer l’algorithme *DomLem* sur ces approximations actualisées afin d’en inférer un modèle de préférence qui aboutit à un ensemble à jour de règles de décision (cf. Table 4.2).

La sortie de l’algorithme *DomLem* doit inférer un modèle de préférence sous la forme d’un ensemble de règles de décision. Le modèle de préférence a l’objectif de classer les “Actions potentielles” pendant la période P_{i+1} du processus de prédiction. La sortie de cette phase représente l’entrée de phase 3.

TABLE 4.2 – Exemple d’un modèle de préférence pour une *Période_j*

Règle	Règles
Règle_{1,j}	Si $f(A_{i,j}, g_{1,j}) \leq r_1 \wedge \dots \wedge f(A_{i,j}, g_{l,j}) \leq r_l \wedge \dots \wedge f(A_{i,j}, g_{n,j}) \leq r_n$ Alors $A_{i,j} \in Cl_1^{\leq}$
Règle_{2,j}	Si $f(A_{i,j}, g_{1,j}) \leq r_1 \wedge \dots \wedge f(A_{i,j}, g_{l,j}) \leq r_l \wedge \dots \wedge f(A_{i,j}, g_{n,j}) \leq r_n$ Alors $A_{i,j} \in Cl_2^{\leq}$
Règle_{3,j}	Si $f(A_{i,j}, g_{1,j}) \geq r_1 \wedge \dots \wedge f(A_{i,j}, g_{l,j}) \leq r_l \wedge \dots \wedge f(A_{i,j}, g_{n,j}) \geq r_n$ Alors $A_{i,j} \in Cl_2^{\geq}$
Règle_{4,j}	Si $f(A_{i,j}, g_{1,j}) \geq r_1 \wedge \dots \wedge f(A_{i,j}, g_{l,j}) \leq r_l \wedge \dots \wedge f(A_{i,j}, g_{n,j}) \geq r_n$ Alors $A_{i,j} \in Cl_3^{\geq}$

4.2.3 Phase 3 : Classification périodique des “Actions potentielles” de la période P_{i+1}

La troisième phase exploite les règles de décision précédemment inférées afin d’attribuer chacune des “Actions potentielles” dans l’une des N classes de décision prédéfinies.

Roy (1997) a défini une “action potentielle” comme étant un terme générique utilisé pour décrire un objet ou un référent d’une décision. Une action est considérée comme potentielle, si elle peut être implémentée ou simplement lorsqu’elle est considérée comme “fertile” dans un contexte d’aide à la décision. La notion d’action potentielle clarifie la nature de ce qui constitue le problème décisionnel et formalise l’objet de la décision. Par exemple, nous considérons que la prédiction des profils apprenants dans un contexte des MOOCs est basée sur ses données démographiques. Alors, tout apprenant n’ayant pas rempli le formulaire d’enregistrement lors de son inscription au MOOC ne peut pas être considéré comme un “Apprenant potentiel”.

Cette phase s’exécute pendant la période P_{i+1} tout au long du processus de prédiction tel que $i \in \{2, \dots, T\}$. Elle commence par l’évaluation de toutes les “Actions potentielles” sur l’ensemble de critères construits. Ensuite, il consiste à appliquer les règles de décision inférées pendant la période P_i . La sortie de cette phase est l’ensemble des “Actions potentielles” classées selon les classes de décision prédéfinies. Cette classification reste valable uniquement pour une période avant qu’une nouvelle portion de données soit disponible. Si c’est le cas, la méthode MAI2P doit être exécuté du nouveau afin de prendre en considération la variation dans le temps du système d’information et donc de garder une connaissance dynamique et actualisée sur l’environnement d’apprentissage.

La méthode MAI2P s’exécute d’une manière itérative tout au long du processus de prédiction : la première et la deuxième phases se déroulent pendant toutes les

périodes P_i tel que $i \in \{1, \dots, T-1\}$ alors que la troisième phase se déroule pendant la période P_{i+1} ; tel que $i \in \{2, \dots, T\}$. Les trois phases sont enchaînées de telle sorte que chaque phase prend en entrée la sortie de la précédente (cf. Figure 4.2).

4.3 Conclusion

Dans ce chapitre, nous avons proposé une méthode de classification multicritère et incrémentale *MAI2P* (*Multicriteria Approach for the Incremental Periodic Prediction*) basée sur l’approche DRSA (Dominance-based rough Set Approche) pour la prédiction périodique de la classe de décision à laquelle une action est susceptible d’appartenir dans une période ultérieure. L’approche DRSA est une technique d’apprentissage supervisé, dédiée au problème de tri en aide multicritère à la décision et basée sur la théorie des ensembles approximatifs. La méthode *MAI2P* est composée de trois phases : La première est la construction d’une table de décision. La deuxième phase infère un modèle de préférences en appliquant l’algorithme *DRSA-Incremental* de mise à jour incrémentale des approximations inférieures et supérieures des unions des classes de décision de DRSA (cf. Chapitre 3) sur la table de décision construite. La troisième phase exploite le modèle de préférence inféré afin de prédire la classe de décision à laquelle appartiendra chaque action. La première phase repose sur trois étapes : (i) la construction d’une famille cohérente de critères pour la caractérisation des actions, (ii) la construction d’un échantillon d’apprentissage représentatif pour chacune des N classes de décision appelé “Actions de référence”, et (iii) la classification de l’ensemble des “Actions de référence” dans les N classes de décision prédéfinies. Le processus de prise de décision s’effectue en fonction des préférences des décideurs humains.

La méthode *MAI2P* répond à la problématique d’évolution séquentielle de système d’information. Elle est basée sur l’algorithme d’apprentissage incrémental *DRSA-Incremental* que nous avons défini pour la mise à jour incrémentale des approximations inférieures et supérieures suite à l’enrichissement séquentiel du système d’information (cf. Chapitre 3). Elle est appliquée périodiquement à la fin de chaque période afin de prédire les classifications de la période suivante. La troisième phase se déroule au début de chaque période P_{i+1} durant le processus de prédiction, en fonction des données résultantes de l’application de la première et de la deuxième phase pendant la période P_i .

La méthode *MAI2P* est générique dans le sens où elle peut être appliquée dans plusieurs domaines pour la prédiction incrémentale et périodique dans un système d’informations évolutif dans le temps. Cependant, l’intervention des décideurs humains dans le choix de l’ensemble d’apprentissage et dans le processus de classification des “Actions de référence” peut conduire à des contraintes temporelles ce qui empêche l’application de la méthode *MAI2P* dans un contexte de prédiction où la décision doit être prise en temps réel.

Notre choix de l’approche DRSA comme étant une technique d’apprentissage supervisé et incrémental pour un objectif de prédiction est justifié par deux raisons :

d'une part, l'approche DRSA implique la dimension humaine dans le processus de prise de décision ce qui permet de surmonter la problématique de données déséquilibrées qui caractérise les techniques conventionnelles de *machine learning*. D'autre part, l'approche DRSA infère des règles de décision de la forme *Si Conditions Alors décision* qui sont faciles à comprendre et à interpréter.

Dans le chapitre suivant, nous validons la méthode *MAI2P* dans un contexte des MOOCs afin de prédire périodiquement les trois classes de décision : C11 des "Apprenants en risque", C12 des "Apprenants en difficulté" et C13 des "Apprenants leaders".

Chapitre 5

Expérimentation et évaluation de la méthode *MAI2P*

Sommaire

5.1	Contexte applicatif	99
5.1.1	Présentation du MOOC “Pensée Design”	100
5.1.2	Problème d’abandon dans le MOOC “Pensée Design”	103
5.2	Application de notre méthode <i>MAI2P</i>	104
5.2.1	Phase1 : Construction de la table de décision . . .	105
5.2.2	Phase 2 : Mise à jour incrémentale des approximations de DRSA pour la construction d’un modèle de préférence	108
5.2.3	Phase 3 : Classification périodique des “Apprenants potentiels”	108
5.3	Evaluation	108
5.3.1	L’algorithme <i>DRSA-Incremental</i> vs. l’algorithme non-incrémental	109
5.3.2	Evaluation de la qualité de prédiction	110
5.4	Conclusion	115

L’objectif de ce chapitre est d’expérimenter et de valider notre méthode de classification multicritère pour la prédiction périodique et incrémentale *MAI2P* (*Multicriteria Approach for the Incremental Periodic Prediction*) dans un contexte d’un MOOC français offrant le module “Pensée Design” qui vise, principalement, le transfert des savoir-faire. L’algorithme *DRSA-Incremental* que nous avons proposé et intégré dans la méthode *MAI2P* sera également comparé à l’algorithme de DRSA conventionnel en considérant le temps de calcul.

Le MOOC “Pensée Design” a été animé par une équipe pédagogique composée de trois personnes, dont un tuteur et deux assistants pédagogiques. Cette taille est considérée très réduite par rapport au nombre d’apprenants qui a atteint 2360 ce qui a rendu le processus d’accompagnement de plus en plus complexe. La participation et l’échange sur le forum étaient volontaires. Nous avons, ainsi, enregistré 438 questions sur le contenu du cours, qui ont été posées sur le forum dont 41% uniquement étaient répondues par l’équipe pédagogique, alors que 39% d’entre elles ont été négligées. Les 20% des questions restantes étaient répondues par les apprenants dont l’exactitude n’était pas garantie. Le MOOC “Pensée Design” a aussi enregistré un taux d’abandon de 80%. D’où notre objectif est de favoriser la collaboration entre les apprenants du MOOC “Pensée Design” et de renforcer l’équipe pédagogique en identifiant les apprenants susceptibles de l’aider à mener au mieux le processus d’accompagnement, appelés “Apprenants leaders”.

Ce chapitre explique les différentes étapes d’application de notre méthode *MAI2P* sur le MOOC “Pensée Design”. Cette méthode doit permettre de prédire d’une manière incrémentale et hebdomadaire, à la fin de chaque semaine, durant la diffusion du MOOC, les trois classes de décision suivantes : Cl_1 des “Apprenants en risque” qui envisagent abandonner le cours au début de la semaine suivante du MOOC, la classe de décision Cl_2 des “Apprenants en difficulté” mais qui n’ont pas l’intention de quitter le MOOC au moins durant la semaine suivante, et la classe de décision Cl_3 des “Apprenants leaders” qui ont la capacité d’accompagner les apprenants de deux autres classes de décision pendant la semaine suivante du MOOC. La méthode *MAI2P* prend en compte les données démographiques et dynamiques des apprenants et repose sur les préférences de l’équipe pédagogique du MOOC “Pensée Design”. Elle doit permettre de (1) construire une famille de critère cohérente et susceptible de caractériser les profils des apprenants, (2) prendre en considération le caractère évolutif du profil d’un apprenant dans le temps, et (3) surmonter le problème de données déséquilibrées.

Dans ce chapitre, nous présentons, dans un premier temps, notre contexte applicatif (MOOC “Pensée Design”), puis nous décrivons le problème d’abandon dans ce MOOC. La deuxième partie détaille les différentes étapes de l’application de notre méthode *MAI2P*. Finalement, nous présentons les résultats de l’évaluation de la méthode *MAI2P* dans le MOOC “Pensée Design” en mettant l’accent sur la complexité temporelle de l’algorithme *DRSA-Incremental* proposé et de la qualité de prédiction.

5.1 Contexte applicatif

Cette section est dédiée à la présentation d’un cas d’application d’un MOOC ayant permis de valider notre méthode de classification multicritère pour la prédiction périodique et incrémentale des classes de décision aux quelles les apprenants sont susceptibles d’appartenir. Nous décrivons dans cette section notre cadre applicatif et nous positionnerons la problématique de l’abandon.

5.1.1 Présentation du MOOC “Pensée Design”

Le MOOC utilisé pour valider notre méthode *MAI2P* est un MOOC français offert par une institution supérieure en France, sur la plateforme Unow¹ et propose le module “Pensée Design”. Ce module s’agit d’une méthode créative de résolution de problèmes et de production d’idées nouvelles. La méthode “Pensée Design” se fonde sur une démarche centrée sur l’utilisateur, à qui elle véhicule l’objectif de préparer l’innovation en découvrant un mode de pensée et une culture qui dépassent de loin la simple question de l’esthétique. Le MOOC “Pensée Design” avait l’objectif de faire apprendre aux apprenants *comment* les designers ont mis au point un processus de conception qui s’applique à n’importe quel secteur et qui permet de transformer un enjeu et une problématique en véritable projet d’innovation. Grâce à cette question de “*Comment*”, l’équipe pédagogique du MOOC “Pensée Design” doit assurer la transmission, pas seulement des savoirs factuels, mais aussi du savoir-faire.

Ce MOOC a réuni 2360 apprenants de différents pays. Avant son lancement et pendant le processus d’inscription, chaque apprenant était invité à remplir un questionnaire démographique sur ses données d’identité, son cursus universitaire, sa motivation en matière de suivi de ce MOOC et sa disponibilité hebdomadaire envisagée.

Ce MOOC a duré cinq semaines. Il nécessitait une disponibilité hebdomadaire entre une et trois heures sans exiger aucune connaissance préalable sur la thématique proposée. Il était animé par une équipe pédagogique composée par un tuteur et deux assistantes pédagogiques. D’autres assistants de la plateforme Unow peuvent aussi intervenir sur le forum en cas de problème technique.

Le MOOC “Pensée Design” propose, en alternance, trois moyens d’évaluation qui sont les quiz, les évaluations facultatives et les évaluations obligatoires. Un quiz est un questionnaire à choix multiples qui est habituellement utilisé par les MOOCs étant donné la simplicité de l’évaluation qui se fait automatiquement. Les évaluations facultatives sont des exercices proposés par le tuteur sans être ensuite évalués. Les apprenants ont l’alternative de publier leurs réponses sur le forum afin qu’ils soient critiqués par d’autres apprenants. Les évaluations obligatoires sont des exercices évalués par les paires. Chaque travail soumis par un apprenant doit être évalué par un autre groupe d’apprenants en fonction d’une échelle bien définie par l’équipe pédagogique. Ces apprenants évaluateurs sont appelés paires de l’apprenant en question et sont, également, désignés par l’équipe pédagogique. Le contenu hebdomadaire du MOOC “Pensée Design” est diffusé comme suit :

- Semaine 1 : Quatre sessions de vidéos d’une durée de sept minutes environ ont été proposées. La formation était enrichie par deux interviews d’experts du domaine “Pensée Design”. La première semaine était conclue par une activité facultative et un Quiz. Deux forums ont été proposés : un forum

1. <https://www.unow.fr/>

pour échanger sur le contenu du cours et un autre pour soumettre et discuter l'activité facultative.

- Semaine 2 : Trois sessions de vidéos d'une durée de cinq minutes environ ont été proposées. La formation était enrichie par un tutoriel d'aide à la navigation. La deuxième semaine était conclue par un Quiz. En outre, un *workbook* était publié proposant un projet qui doit être travaillé par un apprenant en fonction des tâches apprises chaque semaine jusqu'à la fin du MOOC où ce *workbook* doit contenir un projet complet selon les cinq étapes de la méthode "Pensée Design". Quatre forums ont été proposés : un forum "Questions et échanges" pour échanger sur le contenu du cours, un autre forum "Postez votre challenge" où les apprenants étaient invités à définir un problème auquel ils envisagent la solution design, un forum "Fiche de cinq pourquoi" pour discuter les cinq questions clé de la méthode "Pensée Design" et un forum "Empathie" où les apprenants peuvent soumettre la première version du *workbook*.
- Semaine 3 : Deux sessions de vidéos d'une durée de cinq minutes environ ont été proposées, enrichies de vidéos complémentaires "pour aller plus loin". Un *hangout* a été aussi diffusé pour discuter en direct avec le tuteur du MOOC. La troisième semaine était conclue par une activité obligatoire *peer-to-peer* et un Quiz.
- Semaine 4 : Deux sessions de vidéos d'une durée de cinq minutes environ ont été proposées, enrichies de vidéos complémentaires "pour aller plus loin". Un deuxième *hangout* a aussi diffusé pour discuter en direct avec le tuteur du MOOC. La quatrième semaine était conclue par un Quiz uniquement.
- Semaine 5 : Pas de vidéos publiées dans cette semaine pour permettre aux apprenants de se concentrer sur la deuxième version de leur prototype et du leur *workbook*. Un interview d'expert a été publié. La cinquième semaine était conclue par un Quiz final et une activité *peer-to-peer*.

Afin de respecter les préférences d'apprentissage des apprenants (Ernst et Clark, 2013; Seery *et al.*, 2006), une version pdf de chaque vidéo diffusée était mise à la disposition des apprenants sur l'environnement du MOOC. Le MOOC offre un badge hebdomadaire pour chaque apprenant ayant fini l'activité de la semaine et un certificat général dès la réalisation d'un score global de 70%. Un questionnaire de satisfaction a été mis en ligne afin de permettre aux apprenants d'exprimer leur contentement par rapport à la qualité de la formation.

La Figure 5.1 montre que la participation dans les forums "Questions et échanges" portant sur le contenu du cours diminue progressivement au cours du temps. Ceci reste relatif à la diminution considérable de nombre d'apprenants. En revanche, le taux de participation s'élève quand il s'agit d'un échange concernant une activité obligatoire ou facultative. En effet, pour répondre à une activité, les apprenants

font appel à leurs savoirs (savoirs factuels et savoir-faire) inférés suite à l'absorption des informations résultantes de l'interprétation des données échangées durant la formation du MOOC (cf. Chapitre 1). En cas où ils n'arrivent pas à répondre à une partie de l'activité ou à son intégralité, les apprenants seront obligés d'échanger sur le forum afin d'avoir l'information susceptible de leur débloquer. Cependant, l'échange sur le contenu du cours reste volontaire puisqu'il n'y a aucun motif de participation au forum qu'y est dédié. En outre, nous remarquons que le taux de participation augmente légèrement dans la cinquième semaine par rapport à celui de la quatrième. Evidemment, quand il s'agit d'une activité *peer-to-peer* les apprenants demandent plus d'aide étant donnée la complexité de ce type d'évaluation par rapport à un simple quiz.

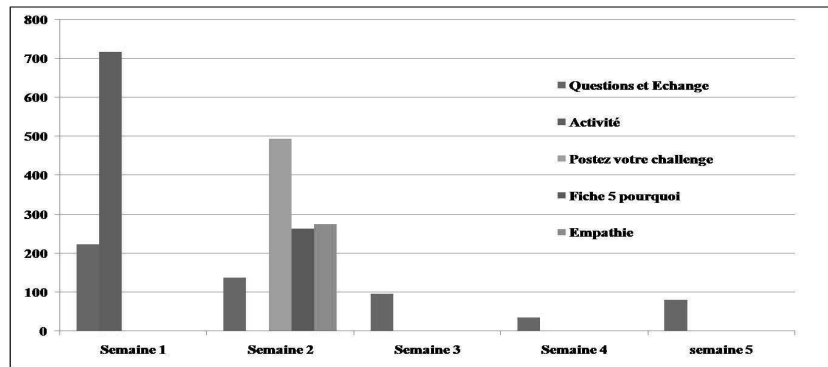


FIGURE 5.1 – Taux de participation dans les forums du MOOC “Pensée Design”

La Table 5.1 représente les taux d'accès d'apprenants aux ressources déposées par l'équipe pédagogique dans l'intention de leur transférer les savoirs factuels et le savoir-faire nécessaires pour réaliser les objectifs du MOOC. Le matériel du cours est la composante la plus importante du MOOC ce qui justifie le taux de participation relativement élevé par rapport à celui du forum. Nous remarquons ainsi que le taux de participation diminue progressivement d'une semaine à une autre vu le nombre hebdomadaire élevé d'apprenants qui abandonnent le MOOC (cf. Figures 5.2 et 5.3). L'accès aux sessions de vidéos présentées par le tuteur demeure beaucoup plus important que celui des interviews. En effet, les interviews sont publiées à titre complémentaire pour ceux qui souhaitent avoir plus d'informations qui ne seront pas pris en compte lors de proposition des activités. Les *hangouts*, une fois organisés, réalisent un taux de participation très satisfaisant puisqu'ils représentent le seul moyen d'interaction directe avec l'équipe pédagogique.

La Figure 5.2 présente le nombre d'apprenants ayant participé aux activités (quiz et *peer-to-peer*) proposées par le MOOC “Pensée Design”. Nous remarquons que le nombre de participants diminue progressivement tout au long de la formation. Cette diminution est relative à l'élévation progressive du taux d'abandon (cf. Figure 5.3). Deux chutes considérables ont été remarquées au niveau de la troisième

TABLE 5.1 – Taux d'accès aux ressources pédagogiques proposées durant le MOOC "Pensée Design"

	Sem 1	Sem 2	Sem 3	Sem 4	Sem 5
Session 1	2025	1139	784	512	-
Session 2	1542	1084	651	489	-
Session 3	1484	952	-	-	-
Session 4	1381	-	-	-	-
Interview 1	1181	634	324	207	52
Interview 2	818	485	267	168	86
Interview 3	-	-	-	-	212
<i>Hangouts</i>	-	-	447	-	475

et cinquième semaines. Ceci revient à la nature de l'activité *peer-to-peer* qui est plus au moins complexe et nécessite plus d'implication. Concernant le quiz de la cinquième semaine, nous constatons une augmentation du taux de participation puisqu'il était conclu par un certificat de participation.

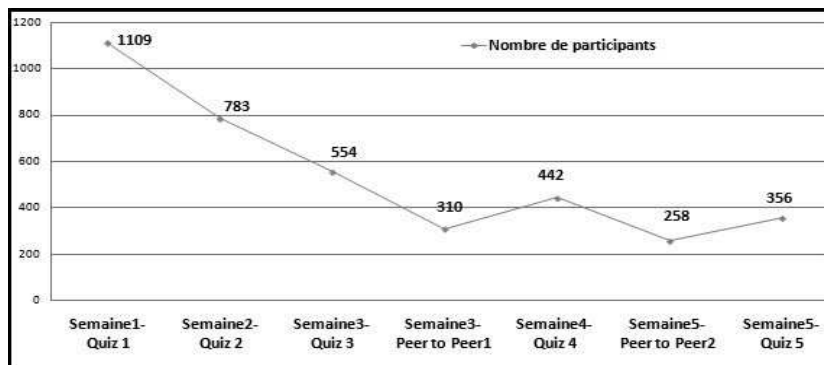


FIGURE 5.2 – Taux de participation dans les activités proposées par le MOOC "Pensée Design"

5.1.2 Problème d'abandon dans le MOOC "Pensée Design"

Comme tout MOOC, "Pensée Design" a marqué un taux d'abandon excessif qui a atteint 80% à la fin de la cinquième semaine (cf. Figure 5.3).

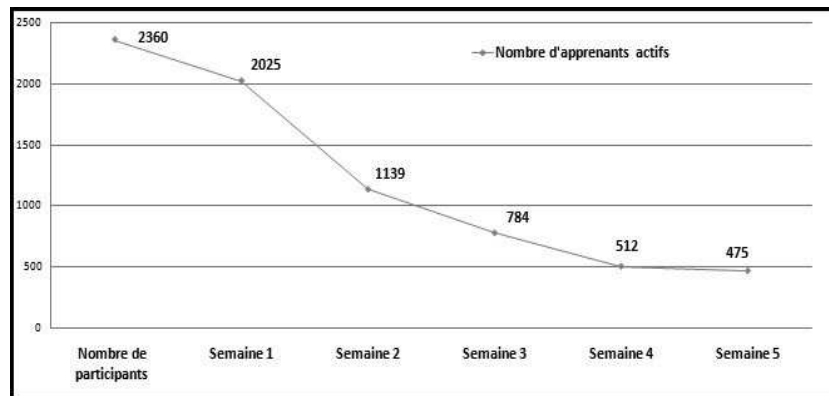


FIGURE 5.3 – Taux d’abandon hebdomadaire du MOOC “Pensée Design”

Nous constatons un véritable pic d’abandon enregistré au niveau de la première semaine (entre le premier jour du MOOC et le premier quiz) où le nombre de participants a été réduit à la moitié environ (de 2360 à 1139). Ce pic peut être expliqué par trois raisons. La première concerne le principe du MOOC qui ne permet l’accès en *offline* (accès suite à sa clôture) qu’aux apprenants qu’y étaient initialement inscrits. D’autres termes, suite à sa clôture le MOOC reste accessible uniquement aux apprenants inscrits sans permettre d’établir de nouvelles inscriptions. Ainsi, les apprenants s’y inscrivent juste pour garantir la possibilité d’accès en mode *offline* en ayant l’intention préalable de ne pas le suivre en mode *online*. La deuxième raison concerne les caractéristiques du MOOC qui peuvent ne pas correspondre à la situation de l’apprenant (cf. Section 2.2.2). Par exemple, les objectifs du MOOC ne satisfont pas les attentes de l’apprenant ou bien la disponibilité exigée ne peut pas être remplie par l’apprenant ce qui le conduit à se retirer même avant de commencer la formation. La troisième raison est liée à la motivation initiale de l’apprenant par rapport à sa participation au MOOC. En effet, il y en a des apprenants qui s’y inscrivent juste par curiosité afin de découvrir le concept de ce nouvel outil d’apprentissage. Ces apprenants sont appelés “*lurkers*” et quittent le MOOC dès la première évaluation.

Le taux d’abandon à la fin des autres semaines demeure aussi considérable mais beaucoup moins que celui de la première semaine. Ce taux s’élève à chaque fois qu’une activité *peer-to-peer* est proposée étant données la difficulté et la disponibilité exigée par ce type d’évaluation.

5.2 Application de notre méthode *MAI2P* sur le MOOC “Pensée Design”

Dans cette section, nous appliquons notre méthode *MAI2P* (cf. Chapitre 4) dans le contexte des MOOCs en considérant le cas applicatif du MOOC “Pensée

Design”. L’objectif de la méthode est de prédire d’une manière périodique et incrémentale les trois classes de décision : la classe de décision Cl_1 des “Apprenants en risque”, la classe de décision Cl_2 des “Apprenants en difficulté” et la classe de décision Cl_3 des “Apprenants leaders”. Les classes de décision sont définies en amont par l’équipe pédagogique du MOOC en question, en fonction de leurs préférences et leurs objectifs. La méthode MAI2P repose sur trois phases (cf. Chapitre 4) : la première concerne la construction d’une table de décision, la deuxième applique l’algorithme *DRSA-Incremental* que nous avons proposé pour la mise à jour incrémentale des approximation de DRSA afin de construire un modèle de préférence, la troisième vise la classification des “Apprenants potentiels” dans l’une des trois classes de décision suscitées en exploitant le modèle de préférence précédemment inféré. Etant donnée la nature dynamique du contexte des MOOCs, la méthode s’exécute d’une manière périodique : la première et la deuxième phases s’exécutent à la fin de chaque semaine du MOOC et la troisième au début de chaque semaine du même MOOC. Le décideur dans ce contexte est l’équipe pédagogique du MOOC “Pensée Design” qui est composée d’un tuteur et de deux assistants pédagogiques.

5.2.1 Phase1 : Construction de la table de décision

La première phase est composée de trois étapes : la construction d’une famille cohérente de critère pour la caractérisation des profils des apprenants, la construction d’un échantillon d’apprentissage représentatif pour chacune des trois classes de décision et, finalement, la classification de l’ensemble des “Actions de référence”.

- **Etape 1. Construction d’une famille cohérente de critère :** Afin de construire une famille cohérente de critères, nous avons adopté l’approche ascendante définie par Mousseau *et al.* (1996). Cette approche consiste à construire une famille de critères à partir d’une liste d’indicateurs susceptibles d’influencer l’opinion des décideurs concernant la caractérisation des actions, et sur des informations recueillies durant des interviews avec les experts du domaine. Par conséquent, nous avons, dans un premier temps, établi une étude bibliographique rigoureuse afin d’identifier les “conséquences” permettant de caractériser les profils des apprenants. Les conséquences identifiées sont présentées dans les Sections 2.2.2 et 2.2.3. Elles sont statiques qui représentent le profil démographique de l’apprenant, ou bien dynamique qui tracent ses activités lors de son processus d’apprentissage. Ces conséquences sont identifiées par les chercheurs comme indicateurs forts pour la prédiction des profils des apprenants. Ensuite, nous avons organisé des réunions avec l’équipe pédagogique du MOOC “Pensée Design” afin de valider une liste finale de critères en fonction de leurs préférences. Une famille de onze critères a été construite et validée (cf. Table 5.2). Cette famille a été utilisée pour toutes les semaines du MOOC. Cependant, elle peut être modifiée d’un MOOC à un autre selon les préférences de l’équipe pédagogique.

TABLE 5.2 – Famille cohérente de critères

Critère	Description	Echelle	P
g_1 : Niveau d'études	Indique le niveau d'études actuel de l'apprenant, ou bien le dernier diplôme obtenu	1 : Elève ; 2 : Etudiant ; 3 : Doctorant ; 4 : Docteur	↑
g_2 : Compétence technique	Indique à quel point l'apprenant maîtrise l'utilisation des outils informatiques	1 : Basique ; 2 : Moyen ; 3 : Expert	↑
g_3 : Maîtrise de la langue	Indique à quel point l'apprenant maîtrise la langue adaptée par le MOOC	1 : Basique ; 2 : Moyen ; 3 : Professionnel	↑
g_4 : Motivation	Indique la motivation de la participation de l'apprenant au MOOC	1 : Juste pour découvrir le MOOC ; 2 : Echanger les idées avec les autres apprenants ou avoir un certificat ; 3 : Echanger les idées avec les autres apprenants et avoir un certificat	↑
g_5 : Expérience avec les MOOCs	Indique si l'apprenant a une expérience préalable sur l'apprentissage via les MOOCs	0 : Aucune expérience ; 1 : Au moins une expérience	↑
g_6 : Maîtrise du sujet du MOOC	Indique à quel point l'apprenant maîtrise le thème abordé par le MOOC	0 : Aucune connaissance ; 1 : Connaissance moyenne ; 2 : Connaissance approfondie	↑
g_7 : Probabilité de continuité	Indique la probabilité que l'apprenant finisse le MOOC	1 : Très faible ; 2 : Faible ; 3 : Moyenne ; 4 : Forte ; 5 : Très forte	↑
g_8 : Disponibilité	Indique la disponibilité hebdomadaire estimative consacrée pour le suivi du MOOC	1 : Moins d'une heure ; 2 : Entre 1 et 2 heures ; 3 : Entre 2 et 3 heures ; 4 : Plus que 4 heures	↑
g_9 : Nombre de publications sur le forum	Indique le nombre hebdomadaire de messages publiés sur le forum par un apprenant	1 : $n=0$; 2 : $n \in \{1, 2\}$; 3 : $n \in \{3, 4\}$; 4 : $n \geq 5$	↑
g_{10} : Nombre de ressources consultées	Indique le nombre hebdomadaire des ressources pédagogiques consultées et/ou téléchargés	1 : $n < 10$; 2 : $10 \leq n < 20$; 3 : $20 \leq n < 30$; 4 : $30 \leq n < 40$; 5 : $n \geq 40$	↑
g_{11} : Score	Indique le score hebdomadaire que l'apprenant obtient sur les activités soumises	1 : $0 \leq Score < 6$; 2 : $6 \leq Score < 7$; 3 : $7 \leq Score < 8$; 4 : $8 \leq Score \leq 10$	↑

- **Etape 2. Construction d'un ensemble d'“Apprenants de référence” :** L'ensemble d'“Apprenants de référence” est un échantillon d'apprentissage qui doit être représentatif pour chacune des classes de décision :
 - Cl_1 . La classe de décision des “Apprenants en risque” correspondant à ceux qui risquent d'abandonner le cours au début de la semaine suivante du MOOC.
 - Cl_2 . La classe de décision des “Apprenants en difficulté” correspondant à ceux qui ont des difficultés mais qui sont toujours actifs dans l'environnement du MOOC et n'ont pas l'intention de le quitter au moins durant la semaine suivante.
 - Cl_3 . La classe de décision des “Apprenants leaders” correspondant à ceux qui sont capables de diriger et supporter une équipe d'apprenants en leur fournissant une réponse précise et immédiate.

Cet ensemble doit être, à la fois, de qualité et d'une taille raisonnable qui respecte la capacité cognitive de l'équipe pédagogique Miller (1956). Puisque les informations sur les apprenants proviennent par portion d'une manière périodique et vu la nature ouverte du MOOC qui encourage à l'entrée/sortie libres des apprenants, l'ensemble des “Apprenants de référence” ne peut pas être stable pendant toutes les semaines du MOOC. Par conséquent, à la fin de chaque semaine dès la délibération des scores, nous avons organisé des réunions avec l'équipe pédagogique afin de construire cet échantillon. Par conséquent, nous avons construit quatre ensembles des “Apprenants de références” A'_i tel que $i \in \{1, 2, 3, 4\}$ et $|A'_i| = 30$. Puisque nous sommes dans un contexte d'apprentissage incrémental, l'ensemble des “Apprenants de référence” de chaque semaine doit être rajouté aux échantillons de toutes les semaines précédentes. Dans notre cas, nous obtenons : $|A_1| = 30$, $|A_2| = 60$, $|A_3| = 90$ et $|A_4| = 120$.

- **Etape 3. Classification des “Apprenants de référence” dans les trois classes de décision :** Les données du MOOC “Pensée Design” sont enregistrées dans un fichier CSV (*Comma-Separated Values*). Nous avons utilisé ce fichier à la fin de chaque semaine afin d'évaluer les “Apprenants de référence” sur l'ensemble de critères en fonction des échelons préférentiels fixés par l'équipe pédagogique. Ensuite, nous avons organisé des réunions avec l'équipe pédagogique afin de classer chaque “Apprenant de référence” dans l'une des trois classes de décision. Pour l'affectation des “Apprenants de référence” dans les classes de décision, l'équipe pédagogique se base sur son expertise et sur l'évaluation des profils de ces apprenants sur l'ensemble de critères. Les quatre tables de décision, D'_i tel que $i \in \{1, 2, 3, 4\}$, que nous avons construites sont présentées dans l'Annexe B.

5.2.2 Phase 2 : Mise à jour incrémentale des approximations de DRSA pour la construction d’un modèle de préférence

Le modèle de préférence se traduit par l’ensemble de règles de décision permettant la classification des apprenants dans l’une des trois classes de décision ; Cl_1 des “Apprenants en risque”, Cl_2 des “Apprenants en difficulté” ou Cl_3 des “Apprenants leaders”. Cette phase a été appliquée à la fin de chaque semaine S_i une fois que la table de décision D_i est complète tel que $i \in \{1, 2, 3, 4\}$. Elle est basée sur deux étapes (cf. Chapitre 3) : il s’agit, tout d’abord, d’appliquer notre algorithme *DRSA-Incremental* (cf. Annexe A) que nous avons proposé pour la mise à jour incrémentale des approximations inférieures et supérieures de DRSA afin de respecter la génération séquentielle de l’ensemble des “Apprenants de référence”, et d’éviter le calcul à zéro qui consomme un temps de calcul énorme. Ensuite, nous avons appliqué l’algorithme *DomLem* qui prend en entrée les approximations calculées pour en inférer les règles de décision. Les quatre modèles de préférences inférés dans cette étape sont présentés dans l’Annexe C.

5.2.3 Phase 3 : Classification périodique des “Apprenants potentiels”

Cette phase concerne la classification des “Apprenants potentiels” dans l’une des classes de décision : Cl_1 des “Apprenants en risque”, Cl_2 des “Apprenants en difficulté” et Cl_3 des “Apprenants leaders”. Dans le cas du MOOC “Pensée Design” les apprenants potentiels sont ceux qui ont rempli le questionnaire démographique. Les autres apprenants ne peuvent pas être classés en raison de leurs données manquantes. Cette opération a réduit le nombre d’apprenants de 2360 à 1535 apprenants. Cette phase était appliquée au début de chaque semaine S_i du MOOC en appliquant le modèle de préférence inféré à la fin de la semaine S_{i-1} sur l’ensemble d’apprenants potentiels tel que $i \in \{2, 3, 4, 5\}$.

5.3 Evaluation

Les expérimentations présentées dans cette section montreront, d’abord, une étude comparative entre les deux algorithmes de DRSA classique et *DRSA-Incremental* en fonction de la complexité temporelle. Elles permettront, par la suite, d’évaluer la performance hebdomadaire du modèle de préférence qui reflète la qualité de la prédiction des profils des apprenants. Pour ce faire, nous avons développé un prototype de prise de décision qui combine à la fois l’algorithme de *DRSA-Incremental*, pour le calcul et la mise à jour des approximations de DRSA, et l’algorithme *DomLem* pour l’inférence du modèle de préférence.

Les expérimentations sont réalisées avec une machine personnelle avec Windows 7 et Intel (R) *Core^{DM}* i3-3110M CPU 2.4 GHz et la mémoire 4,0 Go. Les algorithmes sont codés par Java et exécutés dans Eclipse.

5.3.1 L’algorithme *DRSA-Incremental* vs. l’algorithme non-incrémental

La table 5.3 représente une comparaison entre un algorithme non incrémental et notre algorithme *DRSA-incremental* utilisés pour le calcul de l’approximation inférieure et supérieure des unions des classes de décision de l’approche DRSA. Nous sommes dans le cas où l’ensemble d’actions de référence varie d’une manière séquentielle. L’algorithme non incrémental reprend alors le calcul à zéro en prenant en entrée la nouvelle table de décision. L’algorithme *DRSA-Incremental* met à jour les approximations selon les actions insérées. Les deux algorithmes sont corrects et fournissent le même résultat. Sauf que la mise à jour incrémentale permet de minimiser le temps d’exécution.

TABLE 5.3 – Comparaison du temps d’exécution mis par un algorithme non incrémental et l’algorithme *DRSA-Incremental* pour le calcul des approximations DRSA (nombre de critères = 12, nombre de classes de décision = 3)

	Nombre d’objets	Algorithme non incrémental (s)	Algorithme incrémental (s)
Semaine 1-2	30	0.008	0.008
Semaine 2-3	60	0.016	0.010
Semaine 3-4	90	0.026	0.012
Semaine 4-5	120	0.035	0.035

Nous constatons que l’algorithme *DRSA-Incremental* met moins que la moitié de l’intervalle du temps mis par l’algorithme non incrémental. La différence du temps augmente proportionnellement avec le nombre d’actions dans l’échantillon. Il est aussi à noter que le MOOC “Pensée Design” sur lequel nous avons testé la méthode s’étend uniquement sur cinq semaines. Alors qu’un MOOC peut prendre dix, seize, dix-huit semaines ou même plus. Dans des tels cas, la minimisation de la complexité temporelle de l’algorithme s’avère de plus en plus intéressante.

Cependant, si nous souhaitons appliquer notre méthode sur d’autres MOOCs différents (équipe pédagogique différente, sujet différent, etc.), il est possible de modifier l’ensemble de critères ou bien aussi l’ensemble de classes de décision à traiter. Ainsi, les deux tableaux ci-dessous, représentent les résultats des simulations effectuées afin d’étudier la sensibilité de l’algorithme *DRSA-Incremental* par rapport à

la variation de l'ensemble d'attributs et aussi de celui de classes de décision.

TABLE 5.4 – Comparaison du temps d'exécution par rapport à l'augmentation du nombre de critères (trois classes de décision)

Algorithme incrémental	Nombre d'actions	12 critères	24 critères	48 critères
Semaine 1-2	30	0.008	0.008	0.008
Semaine 2-3	60	0.010	0.011	0.014
Semaine 3-4	90	0.012	0.014	0.019
Semaine 4-5	120	0.016	0.017	0.025

La table 5.4 montre que le temps d'exécution augmente en fonction du nombre de critères. Plus le nombre de critères est élevé, plus le temps nécessaire pour mettre à jour les approximations est élevé. L'algorithme proposé est, également, sensible au nombre de critères.

TABLE 5.5 – Comparaison du temps d'exécution par rapport au nombre de classes de décision (12 attributs)

Algorithme incrémental	Nombre d'actions	Deux classes de décision	Trois classes de décision	Quatre classes de décision	Cinq classes de décision
Semaine 1-2	30	0.004	0.008	0.09	0.010
Semaine 2-3	60	0.006	0.010	0.011	0.014
Semaine 3-4	90	0.008	0.012	0.019	0.020
Semaine 4-5	120	0.011	0.016	0.021	0.026

Finalement, dans la table 5.5 nous avons comparé le temps d'exécution par rapport au nombre de classes de décision traitées. Ainsi, le temps d'exécution augmente à chaque fois que le nombre des classes de décision augmente. L'algorithme incrémental est ainsi sensible au nombre de classes de décision.

5.3.2 Evaluation de la performance du modèle de préférence et de la qualité de prédiction

La qualité de prédiction est évaluée, dans ce travail, par le biais de quatre mesures : le rappel, la précision, la F-mesure et l'exactitude (cf. Annexe D). Les

matrices de confusion ainsi que les résultats détaillés sont présentés dans l'Annexe E. Nous présentons, tout d'abord, les deux approches pessimiste/optimiste et cumulative/non-cumulative que nous avons considérées et développées dans ce travail :

- L'approche pessimiste/optimiste : les règles de décision inférées en appliquant l'algorithme *DomLem*, sont basées sur les unions supérieures et inférieures des classes de décision. Ainsi, une règle de décision peut classer une action dans "au-plus Cl_1 ", "au-plus Cl_2 ", "au-moins Cl_2 " et "au-moins Cl_3 ". Cependant, Une action classée dans "au-plus Cl_2 " peut appartenir à Cl_1 ou à Cl_2 . De même, une action classée dans "au-moins Cl_2 " peut appartenir à la classe Cl_2 ou bien Cl_3 . Puisqu'une action doit être classée dans uniquement une seule classe de décision, alors l'approche pessimiste affecte les actions appartenant à "au-plus Cl_2 " à la classe Cl_1 et ceux appartenant à "au-moins Cl_2 " à la classe Cl_2 . L'approche optimiste les affecte respectivement à la classe Cl_2 et Cl_3 .
- L'approche cumulative/non-cumulative : la phase de l'apprentissage du modèle peut être non-cumulative, donc basée uniquement sur l'échantillon ("Apprenants de référence") défini dans la semaine courante du MOOC pour prédire pour la semaine suivante (*i.e* $A_i = A'_i, \forall i \in \{1, \dots, t-1\}$). Egalement, elle peut être cumulative si on rajoute à l'échantillon d'apprentissage de la semaine courante, les échantillons de toutes les semaines précédentes (*i.e* $A_i = A'_i + A_{i-1}, \forall i \in \{2, \dots, t\}$).

Ces deux approches ont permis de révéler quatre cas de figures possibles pour l'application et la validation de la méthode *MAI2P* : une approche non-cumulative pessimiste, une approche cumulative pessimiste, une approche non-cumulative optimiste et une approche cumulative optimiste. La comparaison de ces quatre approches, en considérant la F-mesure globale, est présentée dans la Figure 5.4.

Nous constatons, ainsi, que l'approche cumulative pessimiste donne une meilleure qualité de prédiction. En effet, comme nous l'avons précisé, l'approche DRSA s'intéresse à la qualité de l'échantillon d'apprentissage plutôt qu'à sa taille. Ainsi, pour respecter la capacité cognitive du décideur, nous choisissons généralement des ensembles d'apprentissage d'une taille limitée. Cependant, la taille de l'échantillon est aussi importante pour diversifier les exemples à considérer lors de la prédiction. L'approche cumulative a, ainsi, remédié à la limitation liée à la taille de l'échantillon d'apprentissage et donc a mené à des résultats meilleurs par rapport à l'approche non-cumulative. En outre, dans un MOOC nous avons toujours une classe majoritaire qui est la classe des apprenants qui sont en risque d'abandonner le MOOC. En effet, si nous considérons les facteurs externes de l'abandon tels que le manque du temps et l'absence d'un engagement concret (cf. Section 2.2.2), un "apprenant en difficulté" (*i.e* appartenant à Cl_2) est plus susceptible d'abandonner le MOOC (donc appartenir à la classe de décision Cl_1) qu'à être un "Apprenant

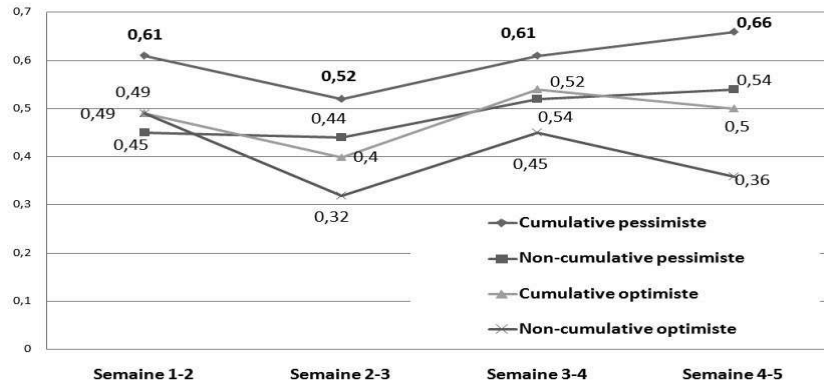


FIGURE 5.4 – Comparaison de la F-mesure globale calculée pour les quatre approches de DRSA pendant la diffusion du MOOC

Leader” (*i.e* classé dans la classe de décision Cl_3), d’où l’efficacité de l’approche pessimiste par rapport à celle qui est optimiste.

Par conséquent, dans le reste du chapitre nous nous focaliserons sur l’approche cumulative pessimiste. Nous évaluerons la qualité de prédiction d’une semaine à une autre durant la diffusion du MOOC et pour chaque classe de décision : Cl_1 des “Apprenants en risque”, Cl_2 des “Apprenants en difficulté” et Cl_3 des “Apprenants leaders”.

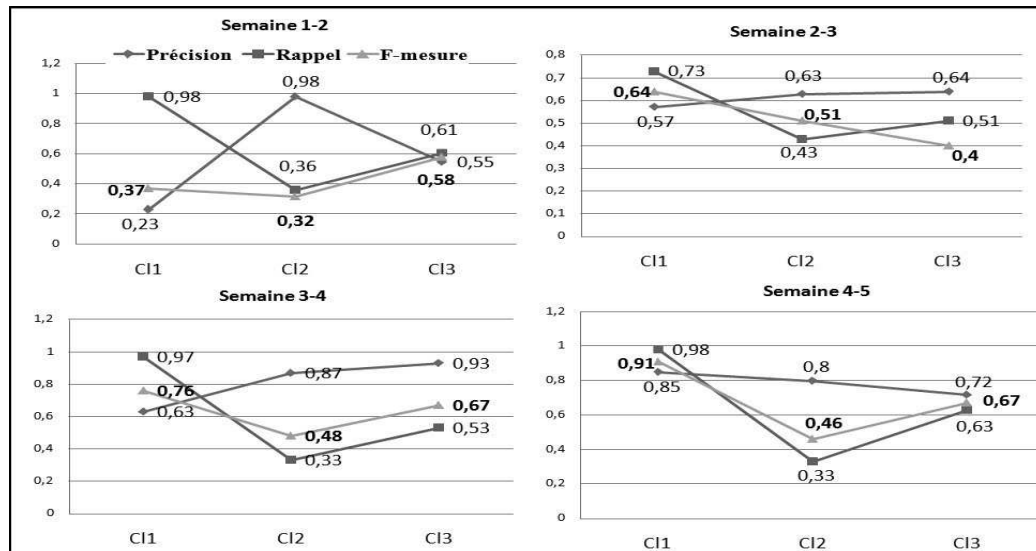


FIGURE 5.5 – Les mesures de performance de la prédiction pour chaque classe de décision durant la diffusion du MOOC

La Figure 5.5 représente les mesures du rappel (*i.e* le nombre de réponses pertinentes prédites par rapport au nombre total des réponses pertinentes existantes), précision (*i.e* parmi les réponses prédites combien de réponses sont pertinentes) et F-mesure (valeur harmonique entre rappel et précision). Les courbes nous permettent de constater :

- Rappel : le rappel de la classe de décision Cl_1 , des “Apprenants en risque”, a une valeur très satisfaisante (entre 0.73 et 0.98) pour toutes les semaines. Ceci revient à deux raisons : premièrement, cette classe est majoritaire et représente 90% de toutes les actions. Deuxièmement, l’adoption de l’approche pessimiste a permis de dévier le modèle vers cette classe majoritaire. Ces deux facteurs ont permis de prédire le maximum des “Apprenants en risque”. Le rappel de la classe Cl_3 , des “Apprenants leaders”, a donné aussi des mesures plus au moins satisfaisantes (entre 0.51 et 0.67) puisque plusieurs actions de cette classe ont été considérées plutôt “en difficulté” vu l’effet de l’approche pessimiste. Le rappel de la classe de décision Cl_2 reste relatif à celui des deux classes Cl_1 et Cl_3 .
- Précision : la précision de la classe Cl_1 augmente progressivement et considérablement d’une semaine à une autre (0.23 pour la première semaine et 0.85 pour la quatrième semaine). Ceci est le résultat du nombre de *lurkers* qui diminue aussi progressivement durant la diffusion du MOOC et surtout au début de la deuxième semaine. Les *lurkers* sont les participants passifs qui s’inscrivent juste pour découvrir le concept du MOOC et commencent à l’abandonner dès la première évaluation. Ces apprenants peuvent être actifs durant la première semaine tout en ayant l’intention d’abandonner. Cette catégorie d’apprenants, dont le comportement ne reflète pas l’intention, ne permet pas au modèle de prédire précisément les “Apprenants en risque”. De même, la précision de la classe Cl_3 des “Apprenants leaders” est améliorée d’une semaine à une autre (0.55 pour la première semaine et 0.93 pour la troisième). Evidemment, à un stade avancé du MOOC les apprenants soient plus engagés ce qui nous donne une information plus précise sur leurs profils (plus de participation sur les forums, plus d’activité sur le site et aussi les scores sont plus significatifs dans le cas des activités *peer-to-peer* d’où la bonne qualité de prédiction de la troisième semaine).

Cependant, les deux mesures de rappel et précision ne peuvent pas, ensemble, donner une indication sur la performance du modèle de préférence puisque, généralement, quand l’une est élevée l’autre est basse. Par conséquent, la F-mesure est proposée pour harmoniser ces deux mesures.

La Figure 5.6 met l’accent sur la variation de la F-mesure des trois classes de décision Cl_1 , Cl_2 et Cl_3 d’une semaine à une autre tout au long de la diffusion du MOOC. Les points clés que nous pouvons révéler et expliquer dans ces courbes sont comme suit :

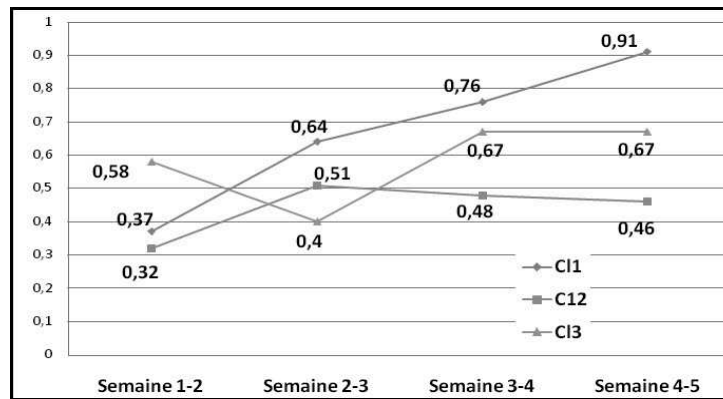


FIGURE 5.6 – La variation de la F-mesure de chacune des classes de décision pendant les quatre semaines du MOOC

- La F-mesure de la classe Cl_1 , des “Apprenants de risque”, augmente au cours du temps : cela dit que la performance de la prédiction concernant la classe Cl_1 augmente au cours du temps. En effet, le MOOC est connu par les *lurkers*. Ces apprenants restent actifs au bout de la première semaine mais en ayant une intention préalable d’abandonner la formation. Ce type d’apprenants dégrade la performance du modèle de prédiction qui est basé sur le profil et le comportement de l’apprenant et non pas sur son intention. Par conséquent, plus le nombre de *lurkers* diminue plus la qualité de la prédiction est meilleure.
- La F-mesure de la classe Cl_3 , des “Apprenants leaders” augmente progressivement au cours du temps. En effet, d’une semaine à une autre, les apprenants multiplient leur participation au forum ce qui donne une information plus ample sur leur profils. Aussi, les évaluations proposées par le MOOC sont de plus en plus complexes d’une semaine à une autre. Evidemment, une évaluation complexe (*i.e. peer-to-peer*) permet de mieux évaluer un apprenant qu’un simple Quiz. Cela est bien justifié par la dégradation de la F-mesure de la classe Cl_3 dans la semaine 2-3. En effet, le MOOC “Pensée Design” a proposé un quiz à la fin de la semaine 2 et une activité *peer to peer* à la fin de la troisième semaine. Cependant, les apprenants qui passent un quiz avec succès peuvent se bloquer au niveau d’une activité *peer-to-peer* ou même abandonner le MOOC à cause de la complexité de cette dernière. Ceci est susceptible de se répercuter sur la qualité de la prédiction.

Finalement, la Figure 5.7 représente une comparaison entre la F-mesure globale et l’exactitude globale du modèle de prédiction durant toutes les semaines du MOOC. Nous remarquons que l’exactitude donne des valeurs qui sont meilleures que la F-mesure. En effet, comparée à une mesure d’exactitude, la F-mesure permet la répartition des erreurs dans les prédictions pour un ensemble de données.

En revanche, l'exactitude permet uniquement de savoir si la prédiction (ou bien la classification) est acceptable en général. Elle reste beaucoup plus superficielle que la F-mesure. En cas de problème de données déséquilibrées, la mesure d'exactitude est généralement utilisée puisqu'elle n'est pas en mesure de détecter ce problème et permet d'obtenir des bons résultats, ce qui n'est pas le cas avec la F-mesure.

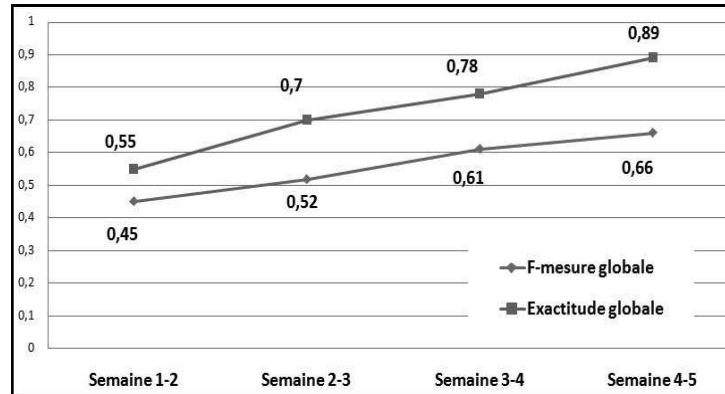


FIGURE 5.7 – Comparaison entre la F-mesure globale et l'exactitude globale des classes de décision durant les quatre semaines du MOOC

En résumé et sur la base de ces résultats, nous confirmons que notre méthode *MAI2P* a réalisé des résultats très satisfaisants (F-mesure globale a atteint 0.66 pour la semaine 4-5 et 0.61 pour la semaine 1-2 ; la valeur de l'exactitude est évolutive atteignant 0.89). Grâce à l'intervention de l'équipe pédagogique, cette méthode a surmonté le problème des données déséquilibrées puisque l'échantillon est basé sur la qualité des actions qu'il contient et non pas sur la taille (Bouzayane et Saad, 2017b). La famille de critères a réussi à bien caractériser les trois classes de décision en harmonisant le profil démographique et le comportement ce qui nous a permis de mener une prédiction et ne pas une simple classification. L'approche cumulative nous a permis aussi d'avoir un échantillon de qualité plus diversifié et plus riche. L'algorithme *DRSA-Incremental* nous a permis de minimiser le temps de calcul. Finalement, l'approche pessimiste a aidé à prendre en considération les facteurs externes du MOOC qui peuvent d'une manière ou autre pousser un apprenant actif à abandonner la formation.

5.4 Conclusion

Dans ce chapitre, nous avons validé notre méthode *MAI2P* sur des données réelles provenant d'un MOOC français proposé par une école d'enseignement supérieur en France et diffusé sur la plateforme française *Unow*. *MAI2P* est une méthode d'apprentissage supervisé basée sur l'aide à la décision multicritère et

prend en considération les préférences des décideurs humains. Elle permet de prédire d'une manière hebdomadaire et incrémentale les trois classes de décision : Cl_1 des "Apprenants en risque", Cl_2 des "Apprenants en difficulté" et Cl_3 des "Apprenants leaders". Elle est composée de trois phases : La construction d'une table de décision, la mise à jour des approximations inférieures et supérieures de l'approche DRSA pour la construction d'un modèle de préférence, et la classification des "Apprenants potentiels". La troisième phase est appliquée périodiquement au début de chaque semaine du MOOC en utilisant le modèle de préférence inféré à la fin de la semaine précédente du même MOOC.

Les expérimentations ont été basées sur les quatre mesures de précision, rappel, F-mesure et exactitude. Elles ont démontré une qualité de prédiction satisfaisante qui atteint une F-mesure = 0.66 et une exactitude=0.89. Le modèle de préférence est sensible au nombre de *lurkers*, à l'état d'avancement du MOOC et au type de l'activité. Notre algorithme *DRSA-Incremental* a considérablement diminué le temps de calcul par rapport à l'algorithme de DRSA non-incrémental. L'intervention de l'équipe pédagogique (décideur humain) dans la construction de l'ensemble d'apprentissage ainsi que l'approche cumulative adopté ont permis de surmonter le problème de données déséquilibrées. De même, son intervention pour la construction de la famille de critères a aidé à bien caractériser le profil démographique et le comportement des apprenants afin de pouvoir prédire la classe de décision à laquelle ils sont susceptibles d'appartenir d'une semaine à une autre. Finalement, l'approche pessimiste a permis de prendre en compte les facteurs extérieurs pouvant inciter un apprenant à abandonner le MOOC même si son comportement prouve qu'il est un apprenant actif.

La validation de notre méthode *MAI2P* sur le MOOC "Pensée Design" nous a permis de construire une famille cohérente de onze critères en appliquant une approche ascendante basée, à la fois, sur une étude bibliographique rigoureuse et sur les préférences de l'équipe pédagogique. Cette liste peut servir comme une liste préliminaire pour toute autre équipe pédagogique qu'elle pourra mettre à jour selon ses préférences.

Notre méthode *MAI2P* peut être utilisée pour des MOOCs similaires, *i.e* des MOOCs avec la même équipe pédagogique et le même sujet, ou bien sur d'autres MOOCs. Dans le deuxième cas, nous devons mobiliser la nouvelle équipe pédagogique afin de prendre en compte leurs préférences.

Dans le chapitre suivant notre méthode *MAI2P* sera intégrée dans un système de recommandation afin de proposer une solution permettant de (i) minimiser le taux d'abandon par l'identification précoce des "Apprenants en risque", et donc les aider à poursuivre le MOOC ; et(ii) l'amélioration de l'appropriation individuelle des savoirs échangés par l'identification des "Apprenants leaders" qui seront mobilisés pour soutenir les autres apprenants tout au long de leur formation.

Chapitre 6

KTI-MOOC : Un système de recommandation pour l'aide au transfert des connaissances dans les MOOCs

Sommaire

6.1	Travaux antérieurs	119
6.1.1	Systèmes de recommandation pré-engagement à un MOOC	119
6.1.2	Systèmes de recommandation post-engagement à un MOOC	121
6.2	Système de recommandation <i>KTI-MOOC</i>	124
6.2.1	Définition du contexte de la recommandation	124
6.2.2	Processus de recommandation des “Apprenants leaders”	125
6.3	Architecture du système <i>KTI-MOOC</i>	130
6.4	Expérimentations et résultats	133
6.4.1	Quelques interfaces	133
6.4.2	Performance de l’algorithme de recommandation sur le temps d’exécution	135
6.4.3	Evaluation sur la couverture de l’espace item	136
6.5	Conclusion	137

A partir des années 90, les systèmes de recommandation ont été reconnus comme une discipline de recherche particulièrement utilisée par les sites web de commerce électronique dans le but d'aider les utilisateurs à choisir parmi une grande masse d'articles ceux qui répondent le mieux à leurs besoins et respectent leurs préférences. Grâce à leur utilisation fréquente, les définitions données à un système de recommandation sont nombreuses dont celle de Burke (2002) le définissant comme un outil logiciel qui a pour effet de guider les utilisateurs d'une manière personnalisée aux objets intéressants ou utiles dans un grand espace des options possibles. De même, Xiao et Benbasat (2007) les ont définis comme étant des agents logiciels qui suscitent les intérêts et les préférences des consommateurs pour en faire des recommandations en conséquence. Ces agents ont le potentiel de soutenir et d'améliorer la qualité des décisions que font les consommateurs lors de la recherche et la sélection des produits en ligne. Ainsi, malgré leur multitude, les définitions restent unanimes sur la nécessité de la prise en considération des préférences des utilisateurs afin de leurs filtrer, parmi un ensemble massif d'items, ceux qui leurs correspondent aux mieux.

Les systèmes de recommandation sont, aujourd'hui, incorporés dans une diversité de domaines qui souffrent d'une masse grandissante de données dans laquelle il faut fouiller tels que la médecine (Hoens *et al.*, 2013; Wiesner et Pfeifer, 2010; Duan *et al.*, 2011), le commerce (Kim et Ahn, 2008; Wu *et al.*, 2015; Palopoli *et al.*, 2013) et l'e-learning (Hsu, 2008; Aher et Lobo, 2013; Dascalu *et al.*, 2015; Wang *et al.*, 2016a;b). Également, deux systèmes de recommandation exemplaires émergeant de l'e-commerce sont mis en place pour notre utilisation quotidienne qui sont Amazon (Linden *et al.*, 2003) pour la recommandation de livres et Netflix pour la recommandation de films (Tuzhilin *et al.*, 2008). Les termes liés aux systèmes de recommandation, tels que la personnalisation et le filtrage, sont basés sur des techniques bien étudiées permettant la prise en considération à la fois du profil utilisateur et aussi celui de l'item (produit, service, article, etc.) à recommander. Les différentes techniques de filtrage de recommandations ainsi que leurs avantages et limitations sont détaillés dans l'Annexe F.

Dans ce chapitre, nous impliquons les systèmes de recommandation dans le domaine d'apprentissage en ligne pour l'aide au transfert des savoirs entre les apprenants d'un MOOC. Le système de recommandation devrait guider les apprenants afin de trouver l'information pertinente dont ils cherchent quand ils se trouvent face à une masse grandissante de données numérisées et hétérogènes. Ainsi, nous proposons de recommander à chaque apprenant qui a besoin d'aide, une liste personnalisée des "Apprenants leaders" susceptibles de l'accompagner durant son processus d'apprentissage médiatisé sur le MOOC. L'approche de recommandation repose sur deux phases : la première concerne la prédiction périodique et incrémentale des trois classes de décision : Cl_1 des "Apprenants en risque", Cl_2 des "Apprenants en difficulté" et Cl_3 des "Apprenants leaders" (cf. Chapitre 5). La deuxième phase exploite le résultat de la première afin de recommander pour chaque "Apprenant en

risque” ou “Apprenant en difficulté” une liste des “Apprenants leaders” appropriée à son profil. La recommandation est basée sur le filtrage démographique et doit aider au transfert (transmission et appropriation) des savoirs factuels et des savoir-faire entre un “Apprenant leader” et un “Apprenant en risque” ou un “Apprenant en difficulté”.

Ce chapitre est organisé comme suit : la première section discute les travaux antérieurs concernant l’application des systèmes de recommandation dans le contexte des MOOCs. La deuxième section présente notre système de recommandation *KTI-MOOC* (*Recommender system for the Knowledge Transfer Improvement within a MOOC*) proposé pour l’aide au transfert des savoirs dans les MOOCs. La troisième section décrit l’architecture fonctionnelle du système de recommandation *KTI-MOOC*. La quatrième section expérimente et évalue notre système de recommandation proposé. La cinquième section conclut le chapitre.

6.1 Travaux antérieurs

Etant donnée la primeur du domaine des MOOCs, les systèmes de recommandation qui y sont impliqués ne sont pas nombreux. Cependant, nous pouvons classer les travaux existants en deux approches : Les systèmes de recommandation pré-engagement à un MOOC qui envisagent aider les apprenants à choisir un MOOC approprié auquel ils peuvent s’inscrire, et les systèmes de recommandations post-engagement à un MOOC qui envisagent assister les apprenants durant leur processus d’apprentissage une fois inscrits à un MOOC.

6.1.1 Systèmes de recommandation pré-engagement à un MOOC

Ce type de recommandation a pour objectif de remédier au problème de prolifération des MOOCs. Les auteurs, dans ce cas, se focalisent sur les facteurs externes qui incitent les apprenants à abandonner le MOOC tels que la langue, la date du début du MOOC, la durée, le programme, etc. La recommandation doit alors aider les apprenants à choisir le MOOC approprié à leurs besoins et à leurs profils afin de pouvoir aller jusqu’au bout.

Bousbahi et Chorfi (2015) ont proposé un système, appelé MOOC-Rec, pour la recommandation d’une liste des URLs des MOOCs répondant à une requête spécifique d’un utilisateur. La recommandation est basée sur la technique CBR (Case Base Reasoning). Cette technique repose sur une base des cas dont chacun est accompagné par une solution et représenté par un vecteur $\langle \text{Attribut}, \text{Valeur} \rangle$. Dans ce travail, les attributs représentent le titre du MOOC, la localisation de l’université qui le propose, la langue du MOOC, la disponibilité hebdomadaire exigée et les frais. A chaque attribut est accordé un poids, fixé de 1 à 5, correspondant à l’ordre chronologique selon lequel l’utilisateur avait coché les attributs dans l’interface. La

phase de recherche est basée sur le degré de similarité entre la requête de l'utilisateur et chaque cas stocké dans la base des cas. La similarité est calculée par la distance de Levenshtein (Levenshtein, 1966). Les cas recommandés sont ordonnés selon un ordre descendant de valeurs de similarité. Pour la réutilisation des cas, ce papier utilise la technique d'adaptation nulle qui cherche d'abord dans la base de cas un cas similaire sinon elle lance une nouvelle recherche sur le web. Si un nouveau cas est construit, il sera recommandé et donc stocké dans la base de cas. Pour résoudre le problème de démarrage à froid, MOOC-Rec peuple la base de cas par des caractéristiques sources d'apprentissage extraites du Web.

Symeonidis et Malakoudis (2016) ont proposé un système de recommandation appelé MoocRec¹ pour recommander à chaque utilisateur cible une liste des MOOCs lui permettant d'acquérir les compétences nécessaires pour décrocher un emploi souhaité. Les utilisateurs sont d'abord demandés de fournir des informations sur leurs études et l'emploi idéal qu'ils souhaitent occuper. Le système de recommandation est basé sur deux moteurs de recherche : un moteur de recherche pour fouiller dans Coursera et EdX afin d'inférer les compétences liées à chaque MOOC et un autre moteur de recherche pour fouiller dans le site LinkedIn² pour inférer les compétences liées aux différents emplois. Cela permet finalement d'inférer les MOOCs correspondants à chaque emploi souhaité. La recommandation est basée sur deux types de filtrage : le filtrage basé connaissance est utilisé pour faire la correspondance entre la description du MOOC et les compétences de l'utilisateur cible. Le filtrage collaboratif vise à recommander à l'utilisateur cible ce que d'autres utilisateurs, souhaitant le même emploi, ont déjà apprécié en fonction de leurs évaluations explicites et implicites. La liste des MOOCs recommandés est triée selon le nombre de compétences que le cours assure, ensuite selon la date de début du MOOC.

Gutiérrez-Rojas *et al.* (2014) ont proposé un système de recommandation, appelé MOOCRANK³, pour recommander à un utilisateur cible les MOOCs les plus appropriés à ses objectifs d'apprentissage. Ce travail fait la correspondance entre les objectifs prévus de l'apprentissage et ceux qui sont réalisés auprès de chaque utilisateur cible. La recommandation est appliquée dans le domaine des sciences de l'information et repose sur la taxinomie *Computer Science Curricula 2013* (CSC2013) proposée par Sahami *et al.* (2013). Cette taxinomie représente une description des objectifs d'apprentissage dans ce domaine informatique. Ainsi, cette même taxonomie est utilisée pour annoter les objectifs visés par le MOOC et les objectifs prévus par l'utilisateur. L'approche de filtrage consiste à afficher les cours recommandés en fonction de leur adéquation au profil utilisateur. L'adéquation est calculée par le nombre de correspondances entre les objectifs prévus par l'apprenant et ceux fournis par le MOOC. Pour remédier au problème de démarrage au froid, la taxonomie est d'abord peuplée par les objectifs identifiés lors d'une recherche dans les

1. <http://moocrec.com/>

2. <https://www.linkedin.com/>

3. <http://www.moocrank.com/>

plateformes des MOOCs. Ensuite, chaque apprenant est demandé de décrire les objectifs atteints suite à chaque MOOC suivi. Ces descriptions seront finalement exploitées pour enrichir et peupler la taxonomie.

D'autres sites existent sur le web pour ce même objectif de recommandation, tels que <https://www.class-central.com/#> où la recommandation est basée sur les centres d'intérêts de l'utilisateur et sa plateforme préférée. Aussi, le site <http://coursetalk.org> qui recommande des MOOCs basé sur le domaine et la spécialité auxquels l'apprenant est intéressé.

6.1.2 Systèmes de recommandation post-engagement à un MOOC

Contrairement aux systèmes de recommandation pré-engagement qui cherchent à remédier au nombre massif des MOOCs, les systèmes de recommandation post-engagement s'intéressent à la massification des données et des apprenants au sein du même MOOC et visent le support des apprenants durant leur processus d'apprentissage une fois inscrits.

Yang *et al.* (2014) ont abordé la problématique de surcharge des discussions dans les forums du MOOC qui empêche l'apprenant de trouver l'information qui l'intéresse. Ils ont proposé un modèle pour la recommandation d'une liste de discussions à chaque apprenant basé sur la correspondance entre ses préférences et le contenu de chaque discussion. Les deux filtrages collaboratif et basé-contenu sont mis en place. La recommandation est le résultat de trois modélisations : la modélisation de contenu des discussions des forums qui repose sur l'analyse des mots, la modélisation de préférences de l'apprenant qui sont extraites de l'historique de sa participation dans les discussions précédentes et la modélisation de la connexion sociale de l'apprenant basée sur ses interactions avec les pairs. Ces trois modélisations sont données en input à une matrice de factorisation adaptative (Chen *et al.*, 2012) selon une fenêtre de temps fixée afin de prédire le comportement des apprenants dans la fenêtre de temps suivante en fonction de leur comportement durant la fenêtre de temps passé. Les expérimentations ont montré qu'un tel modèle a permis d'améliorer la performance des apprenants surtout dans le cas où la fenêtre de temps choisie est réduite.

Li et Mitros (2015) ont proposé un système XBlock⁴ pour recommander aux apprenants une liste de ressources de réhabilitation pertinentes pour un problème donné afin de leur fournir des interventions avec plus de profondeur et moins d'échafaudages que les forums. Le système est basé sur la technique de *crowdsourcing* où une combinaison, entre ce que les apprenants experts ont publié pour résoudre un problème et de ce que les apprenants novices ont besoin sur un thème commun, est effectuée. La *crowdsourcing* est une technique de production participative qui sollicite le grand public ou bien les consommateurs d'un système pour résoudre

4. <https://github.com/pmitros/RecommenderXBlock>

un problème. Dans ce contexte, elle est considérée comme une solution plus économique et plus pratique pour créer des outils de réhabilitation. Pour chaque ensemble de problème est attribué un thème et pour chaque ressource est accordé un titre, un lien, un résumé, une capture d'écran et une liste des votes. Les ressources recommandées peuvent être votées par les apprenants. L'équipe pédagogique du MOOC a le droit de modifier, supprimer ou enrichir la ressource.

Onah et Sinclair (2015) ont proposé un algorithme basé sur la technique de filtrage collaboratif pour recommander à un apprenant cible des ressources appropriées à son profil afin de supporter son parcours d'apprentissage durant sa participation au MOOC. Tout apprenant dans le système est demandé de noter chaque ressource utilisée sur une échelle de 1 à 5. Sur la base de cette notation, une fonction de prédiction est calculée afin de prédire le degré d'appréciation de l'apprenant cible à chaque ressource. Les ressources seront ainsi recommandées en fonction du degré d'appréciation prédit.

Labarthe *et al.* (2016a) ont proposé un module de recommandation intégré pour recommander à chaque apprenant une liste d'apprenants pertinents, disponibles et prêts à partager leurs connaissances. L'objectif du travail est de favoriser l'interaction entre les apprenants. Les apprenants sont recommandés en fonction de leurs profils et activités. En cliquant sur un apprenant recommandé, l'apprenant cible aura le choix de lui envoyer un message privé, le signaler comme favorisé, le signaler comme ignoré, ou bien ouvrir une fenêtre de chat avec lui. Contrairement à un apprenant favorisé, un apprenant ignoré ne sera plus recommandé à l'apprenant cible concerné. Validé sur un MOOC de gestion des projets (Labarthe *et al.*, 2016b), ce système de recommandation a prouvé un impact considérable sur la participation des apprenants, leur complétude du MOOC, leur succès aux évaluations et leur interaction avec les autres apprenants.

La table 6.1 représente un récapitulatif sur les travaux post-engagement au MOOC et mettant le point sur les contributions et les limitations de chacun d'entre eux.

Dans ce travail, nous nous situons dans les solutions post-engagement. Nous proposons, ainsi, un système de recommandation permettant de renforcer l'équipe pédagogique et de supporter les apprenants inscrits au MOOC durant leur processus d'apprentissage. Notre objectif dépasse le simple partage de l'information transmise via le système du MOOC, et vise le transfert (transmission et appropriation) des savoirs factuels et des savoir-faire entre les apprenants. En effet, la recommandation proposée ne se limite pas à mettre à la disposition des apprenants les ressources pédagogiques (exp. une vidéo, image, pdf, etc.) qui sont jugées cruciales ou appropriées à leurs profils et leurs besoins. Elle vise plutôt la recommandation des individus (*i.e.* une ressource humaine) pour favoriser l'échange mutuel de l'information entre un "Apprenant leader" et l'apprenant récepteur ("Apprenant en risque" ou "Apprenant en difficulté") ce qui permet d'atteindre une compréhension réciproque pour chaque information échangée (Devirieux, 2007). L'"Apprenant leader" peut, bien évidemment, transmettre des ressources pédagogiques à l'apprenant

TABLE 6.1 – Synthèse sur les travaux antérieurs dans le cas de recommandation post-engagement

Auteurs	Outils	Contributions	Limites
Yang <i>et al.</i> (2014)	-Filtrage hybride (basé contenu et collaboratif) -Matrice de factorisation	- Combiner la modélisation du contenu des discussions, la connexion sociale et les intérêts des apprenants, -Utiliser une fenêtre de temps adaptable.	- Problème de démarrage à Froid : cas du premier utilisateur, - (a) Uniquement les participants aux forums sont concernés par l'aide - (b) Pas d'indication sur l'impact des recommandations sur le processus d'apprentissage
Li et Mitros (2015)	-Filtrage collaboratif, -Technique de crowdsourcing	- Utiliser des solutions préexistantes : pas de recours à des informations supplémentaires, - Fournir une recommandation riche en informations.	- (a) -(b) -La pertinence des ressources recommandées n'est pas garantie - Problème de démarrage à froid.
Onah et Sinclair (2015)	- Filtrage collaboratif	- Fournir des recommandations diverses et riches, - Ne pas exiger des informations supplémentaires.	- Pas d'indication sur l'effet des recommandations sur le processus d'apprentissage. - Uniquement les apprenants actifs sont concernés par l'aide. - Problème de démarrage à froid : cas de nouvel utilisateur et nouvel item.
Labarthe <i>et al.</i> (2016a;b)	- Filtrage basé sur l'activité et le profil	- Solliciter la dimension humaine pour améliorer le processus d'accompagnement	- Identification intuitive des apprenants pertinents. - Pas d'indication sur la fonction de similarité adoptée. - Pas d'indication claire sur le type de filtrage.

cible mais dont le contenu et l'utilité seront discutés grâce à la communication (exp. écrite, auditive, audio-visuelle) menée entre eux via le système de recommandation. En effet, la communication supportée par la technologie pour l'échange de solutions peut parfaitement constituer le point de départ à un réel transfert de connaissances et donner lieu à une construction mutuelle de savoirs (Depover *et al.*, 2000). En outre, la communication dans un contexte d'apprentissage médiatisé, tels que les MOOCs, permet des échanges beaucoup plus naturels sans risquer qu'un temps d'attente trop long entre la question et la réponse puisse conduire à un désinvestissement de l'apprenant par rapport à la tâche qui lui est proposée (Eastmond, 1994). De ce fait, la recommandation des individus comme étant une source d'information peut garantir l'appropriation des savoirs auprès des apprenants cibles ("Apprenants en risque" et "Apprenants en difficulté").

Notre système de recommandation *KTI-MOOC* est proche de celui de Labarthe *et al.* (2016a), sauf que la phase de prédiction des trois profils d'apprenants basée sur notre méthode *MAI2P* (cf. Chapitre 5) est développée avec plus de rigueur. De même, elle repose sur l'intervention de l'équipe pédagogique qui permet la construction d'une famille cohérente de critère pour la caractérisation des profils de l'ensemble des apprenants. En outre, la technique de filtrage démographique que

nous adoptons est plus peaufinée dans la mesure où elle est basée sur des attributs définis dans la littérature comme étant des catalyseurs et inhibiteurs de transfert des savoirs à distance. Le reste du chapitre sera consacré à la présentation et la validation du système de recommandation *KTI-MOOC*.

6.2 *KTI-MOOC* : un système de recommandation pour l'aide au transfert des savoirs dans les MOOCs

Dans le Chapitre 5, nous avons détaillé notre méthode de prédiction hebdomadaire des “Apprenants leaders” qui sont sensés accompagner les “Apprenants en risque” et les “Apprenants en difficulté” durant leur participation au MOOC. Dans cette section, afin de tenir compte de l’hétérogénéité des profils apprenants au sein du même MOOC, nous proposons de recommander à chaque “Apprenant en risque” ou “Apprenant en difficulté” la liste des “Apprenants leaders” appropriée à son profil. En outre, puisque notre objectif est d’aider au transfert des savoirs entre un “Apprenant leader” et un “Apprenant en risque” ou un “Apprenant en difficulté”, la recommandation doit considérer les facteurs inhibiteurs et catalyseurs d’un tel processus. Dans la suite, nous présentons le système de recommandation *KTI-MOOC* (*Recommender system for the Knowledge Transfer Improvement within a MOOC*).

6.2.1 Définition du contexte de la recommandation

Tout système de recommandation est caractérisé par trois éléments principaux : l’objectif de la recommandation, la cible (utilisateur courant, utilisateur actif) à qui recommander et l’objet (item, produit, service, article) à recommander.

Objectif de la recommandation

L’objectif de notre système de recommandation *KTI-MOOC* est l’aide au transfert des savoirs factuels et des savoir-faire auprès des apprenants lors de la diffusion d’un MOOC. En effet, le nombre massif d’apprenants d’une part et la taille limitée de l’équipe pédagogique d’autre part, rendent inefficace le processus de transfert et, aussi, d’accompagnement. En outre, l’apprentissage dans un tel contexte repose à la fois, sur les informations transmises par l’équipe pédagogique et celles transmises par les apprenants dont l’exactitude et la pertinence ne sont pas garanties. L’objectif de *KTI-MOOC* est, ainsi, de proposer une solution pour minimiser les obstacles de transfert et de permettre aux apprenants de profiter d’avantage de la formation qu’ils suivent.

Cible de la recommandation

L'utilisateur cible d'un système de recommandation est l'utilisateur bénéficiaire de la recommandation. Dans notre système *KTI-MOOC*, l'utilisateur cible est un apprenant appartenant à la classe de décision Cl_1 des "Apprenant en risque" ou bien à la classe de décision Cl_2 des "Apprenant en difficulté". Ce sont les apprenants que nous envisageons aider en leur permettant d'une source pertinente de l'information dont ils ont besoin afin de ne pas abandonner le MOOC. Cette liste d'apprenants varie d'une semaine à une autre durant la diffusion du MOOC. Elle est le résultat de l'application hebdomadaire de notre méthode de prédiction multicritère et incrémentale, *MAI2P*, dans le contexte des MOOCs (cf. Chapitre 5).

Objet de la recommandation

L'objet de la recommandation est l'item à recommander à l'utilisateur cible afin de réaliser un objectif défini. Généralement, l'objet de la recommandation est un ensemble différent de l'ensemble d'utilisateurs tels que des films, des produits, des livres, des localisations, etc. Cependant, pour le cas du système de recommandation *KTI-MOOC* les utilisateurs cibles de la recommandation et les objets de la recommandation font partie du même ensemble. Nous recommandons des apprenants à des apprenants. L'objet de la recommandation est un ou plusieurs apprenants appartenant à la classe de décision Cl_3 des "Apprenant leaders". De même, cet ensemble varie d'une semaine à une autre en fonction du résultat de notre méthode de prédiction *MAI2P*.

6.2.2 Processus de recommandation des "Apprenants leaders"

Le processus de recommandation adopté par le système *KTI-MOOC* repose sur la technique de filtrage démographique. Ce filtrage catégorise les utilisateurs en fonction de leurs données démographiques (exp. sexe, âge, pays, niveau d'études, etc.). Les recommandations sont produites selon les évaluations des utilisateurs du même groupe (appelé aussi niche ou voisinage) sur l'ensemble des items. Le filtrage démographique repose sur l'hypothèse que deux utilisateurs qui ont évolué dans un même environnement sont plus susceptibles d'avoir le même goût et de partager les mêmes préférences. Le processus de recommandation est composé de trois étapes : (1) le profilage, (2) le calcul de similarité, et (3) la prédiction des appréciations des utilisateurs (cf. Figure (6.1)).

Modélisation du profil apprenant

La modélisation du profil utilisateur est un domaine de recherche qui concerne l'amélioration de l'interaction homme-machine en prédisant les intérêts des utilisateurs (Shani *et al.*, 2007). Le profil repose sur deux notions clés qui sont le modèle

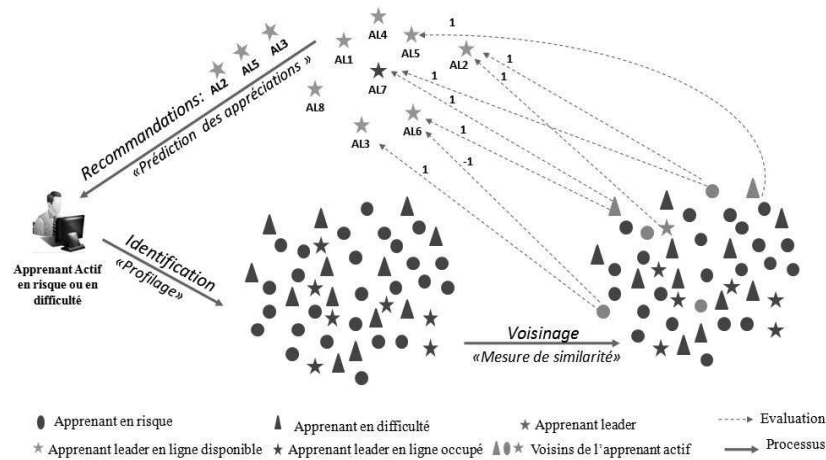


FIGURE 6.1 – Processus de recommandation : cas d’un “Apprenant en risque” ou un “Apprenant en difficulté”

de représentation et les informations à considérer. Dans la littérature, plusieurs modèles de représentation ont été proposés, dont le modèle vectoriel (Dumais *et al.*, 2016), le modèle sémantique (Sridevi et Umarani, 2013) et le modèle multidimensionnel (Amato et Straccia, 1999). Dans ce travail, nous adoptons la représentation vectorielle puisque les informations que nous traitons font partie de la même dimension et sont considérées comme sémantiquement indépendantes. Les informations à inclure dans le modèle de représentation peuvent être entrées manuellement par l'utilisateur, ou extraites automatiquement à partir du contenu des ressources qu'il a consultées (Bonnin, 2010). Elles doivent satisfaire la finalité de la recommandation qui est dans notre cas l'aide au transfert des savoirs factuels et du savoir-faire. Ces informations doivent permettre au système de recommandation de minimiser la distance entre le profil de l'apprenant transmetteur des savoirs et celui de l'apprenant récepteur de ces savoirs afin de mener au mieux le processus de transfert entre eux. En d'autres termes, ces informations doivent représenter les facteurs inhibant le processus de transfert tels que la langue, le pays et le domaine d'études.

- La langue : la langue a été prouvée par plusieurs travaux de recherche comme étant un obstacle puissant par rapport au processus de transfert de savoirs. Dans le domaine de gestion des connaissances, Welch et Welch (2008) ont prouvé que la langue impacte, à la fois, la capacité de transmettre la connaissance de la part du transmetteur et aussi la capacité d'absorber la connaissance de la part du récepteur. L'étude effectuée par Chiu *et al.* (2006) a aussi prouvé l'impacte de la langue sur la qualité de la connaissance transférée. Dans le contexte du MOOC, Barak (2015) a prouvé que la langue est une forte barrière pour la compréhension et la complétude du MOOC.
- Le domaine d'études : le domaine d'études partagé permet aux acteurs d'avoir

un langage scientifique et technique similaire. selon Grundstein (2009) les personnes qui partagent la même culture peuvent avoir des schémas d'interprétation Arduin (2013) proches leur permettant de donner un même sens à une connaissance codifiée, ce qui aide à augmenter le niveau de la commensurabilité (Kuhn *et al.*, 1970) entre eux et donc à faire réussir le processus de transfert. Gooderham (2007) a aussi mis l'accent sur l'impact de la distance culturelle sur la qualité du processus de transfert de connaissances. Cela dit que les personnes issues du même domaine d'études peuvent se comprendre mieux que deux personnes de cultures différentes.

- La distance géographique : par rapport à l'interaction en face-à-face, l'interaction à distance met beaucoup d'inconvénients surtout lorsqu'il s'agit d'un transfert du savoir-faire. La distance géographique a été prouvée par Gooderham (2007) comme étant un inhibiteur du processus de transfert des connaissances. Ambos et Ambos (2009) ont constaté que plus la distance entre le transmetteur et le récepteur est courte, plus l'efficacité du transfert des connaissances est élevée. Dans le contexte des MOOCs, cela permet aussi de prendre en considération le décalage entre les faisceaux horaires qui complique la correspondance entre les apprenants. Il est ainsi de préférence que le transmetteur et le récepteur proviennent de la même ville pour tenter une interaction en face-à-face si possible.

Ces informations sont aussi expliquées dans la Section 1.6. Elles sont à considérer pour construire les profils des apprenants et, par suite, calculer la similarité entre les "Apprenants leaders" et les apprenants cibles. Il est de préférence de minimiser la distance linguistique, culturelle et géographique entre l'apprenant transmetteur et l'apprenant récepteur des savoirs.

Identification du voisinage

Le voisinage d'un apprenant cible est représenté par les apprenants qui lui sont plus proches considérant la langue, le domaine d'études et la distance géographique. Nous sommes, du coup, face à un problème de minimisation de distance. Plusieurs mesures de distance ou de similarité ont été définies dans la littérature dont les plus prometteuses sont le coefficient de corrélation de Pearson, la similarité de cosinus et la distance euclidienne.

La similarité de Cosinus s'applique uniquement sur des valeurs numériques et permet de calculer la similarité entre deux vecteurs en déterminant le cosinus de l'angle entre eux. Elle est fréquemment utilisée en tant que mesure de ressemblance entre deux documents et elle exige donc un moyen de convertir les mots d'un document en nombres (par exemple chercher un document vectorisé dans un corpus de documents aussi vectorisés). Le coefficient de corrélation de pearson s'applique sur deux variables dépendantes de caractère quantitatif dont l'une permet d'expliquer l'autre (par exemple la corrélation entre l'altitude en centaines de mètres et la tem-

pérature au niveau de la mer). Ces deux mesures ne sont pas donc applicables dans notre contexte ce qui justifie notre choix de travailler avec la distance euclidienne.

La Distance euclidienne a une limite inférieure égale à zéro indiquant une correspondance parfaite sans limite supérieure proportionnelle. Soient $(x_1, x_2, \dots, x_k, \dots, x_n)$ et $(y_1, y_2, \dots, y_k, \dots, y_n)$ les représentations vectorielles relatives aux profils de deux apprenants x et y respectivement. La distance euclidienne entre les deux profils est calculée comme suit :

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (6.1)$$

tel que $x_i - y_i = 0$ si $x_i = y_i$ et $x_i - y_i = 1$ si $x_i \neq y_i$.

Dans notre cas nous considérons uniquement quatre attributs ($n=4$) qui sont la langue, le domaine d'études, le pays et la ville d'où la représentation d'un apprenant X est comme suit :

$$X = (x_1 = \text{Langue}, x_2 = \text{Domaine d'études}, x_3 = \text{Pays}, x_4 = \text{Ville})$$

Aussi, nous considérons que les quatre attributs ont la même importance et donc aucune pondération ne sera appliquée.

Prédiction basée sur le filtrage démographique

Comme nous l'avons déjà expliqué, le filtrage démographique est basé sur les évaluations faites par le voisinage démographique de l'utilisateur cible. La recommandation, dans notre cas, consiste aux "Apprenants leaders" qui ont été précédemment appréciés par les apprenants similaires à l'apprenant cible, dits son voisinage.

Afin de recommander à un apprenant la liste de leaders appropriés à son profil et qui sont susceptibles de l'accompagner durant une session de navigation sur l'environnement du MOOC, nous devons prédire le taux d'appréciation $r_{c,l}$ d'un apprenant cible c pour un apprenant leader l , en utilisant les évaluations données par son voisinage pour ce même apprenant leader.

$$\hat{r}_{c,l} = \frac{\sum_{(v \in V_l(c))} w_{c,v} r_{v,l}}{\sum_{(v \in V_l(c))} |w_{c,v}|} \quad (6.2)$$

Dans la formule (6.2), les variables c, l, v désignent respectivement l'apprenant cible, l'apprenant leader et l'apprenant voisin de l'apprenant cible. L'ensemble $v_l(c)$ est le voisinage de l'apprenant cible qui a évalué l'"Apprenant leader" en question. La variable $w_{c,v}$ reflète le poids du voisin, calculé par son degré de similarité avec l'apprenant cible. Le taux $r_{v,l}$ est l'évaluation donnée par le voisin v à l'"Apprenant leader" l en question.

Le dénominateur de la formule (6.2) a été ajouté pour un objectif de normalisation pour éviter le cas où la somme des poids dépasse la valeur 1 qui peut donner

une valeur d'appréciation prédite hors intervalle. De même, le poids a été utilisé en valeur absolue afin de traiter le cas des évaluations négatives pouvant engendrer des valeurs inacceptables. Plus de détails sur cette mesure et autres existent dans (Ricci *et al.*, 2011).

Afin de prendre en considération les cas particuliers possibles et de gérer les situations de conflits, nous avons appliqué des hypothèses simplificatrices :

- HS1 : Afin de faire face au nombre des “Apprenants en risque” et des “Apprenants en difficulté” élevé par rapport au nombre des “Apprenants leaders” en ligne, nous fixons le nombre des “Apprenants leaders” recommandés à trois. Autrement dit, un apprenant cible ne peut pas contacter plus que trois “Apprenants leaders” à la fois.
- HS2 : Afin de respecter la capacité humaine d'un “Apprenant leader” nous lui proposons un maximum d'apprenants cibles en risque ou en difficulté qui ne dépasse pas trois à la fois. Si l'un des apprenants cibles, avec qui l'“Apprenant leader” est en train d'échanger, se déconnecte, il sera remplacé par un autre apprenant à condition que le nombre total reste égal à trois.
- HS3 : Un “Apprenant leader” évalué comme “non pertinent” par un apprenant cible ne lui sera plus recommandé même s'il a été évalué pertinent par son voisinage.
- HS4 : Un “Apprenant leader” apprécié par un apprenant cible, lui sera automatiquement recommandé à l'entête de la liste dès son identification à condition que cet “Apprenant leader” soit en ligne et aussi disponible, donc en train d'échanger avec moins de trois personnes. Cette stratégie du premier arrivé premier servi, permet d'éviter le conflit dans le cas d'un “Apprenant leader” apprécié par deux apprenants cibles en besoin.
- HS5 : En cas de conflit entre un “Apprenant en risque” et un “Apprenant en difficulté”, nous donnons priorité à celui qui est en difficulté partant de l'idée qu'il est le plus motivé à compléter le MOOC. Puisqu'un “Apprenant en risque” est plus susceptible d'abandonner la formation, il est plus profitable d'accompagner un apprenant en difficulté. Rappelons que la motivation est un critère qui a été considéré lors de la prédiction de la classe de décision à laquelle appartiendra un apprenant.
- HS6 : En cas d'un nouvel “Apprenant leader” qui n'est pas encore évalué ou bien le cas de manque des “Apprenants leaders” disponibles, le système complète la liste de trois “Apprenants leaders” à recommander à l'apprenant cible par des “Apprenants leaders” de son voisinage qui soient en ligne et disponibles. Dans ce cas, le système recommande à l'apprenant cible les “Apprenants leaders” qui lui sont similaires au lieu des “Apprenants leaders” appréciés par les apprenants qui lui sont similaires. De même, si un apprenant s'inscrit au milieu de la semaine, et donc n'est pas encore affecté à

une classe de décision, il sera automatiquement classé dans le classe Cl_2 des “Apprenants en difficulté”.

L’algorithme de recommandation des “Apprenants leaders” basé sur la formule (6.2) doit prendre en considération ces hypothèses simplificatrices. Les “Apprenants leaders” en ligne disponibles et d’une valeur $r_{v,l}$ la plus élevée seront recommandés et affichés sur la page personnelle de l’apprenant cible. La liste de trois peut être complétée par des “Apprenants leaders” en ligne disponibles de son voisinage en cas de manque (cf. Figure 6.2).

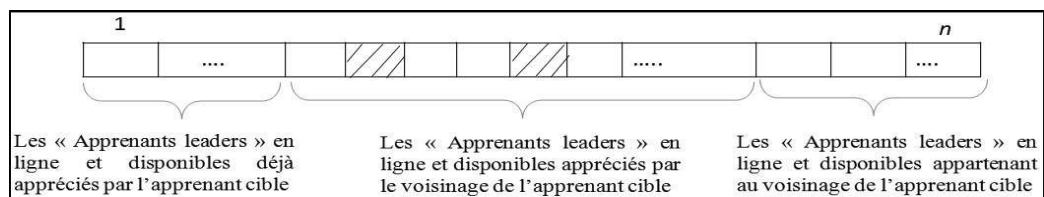


FIGURE 6.2 – Répartition de n-top “Apprenants leaders” recommandés (les cases hachées représentent les “Apprenants leaders” non appréciés par l’apprenant cible)

Ces hypothèses simplificatrices permettent de surmonter quelques limites de filtrage démographique telles que le problème de démarrage à froid. Cependant, cette technique, quand appliquée dans le domaine des MOOCs, demeure soumise à deux limitations majeures : le problème de *Gray Sheep* représenté par les apprenants atypiques qui peuvent exister et dont il est difficile d’en prédire l’appréciation. Le deuxième problème est celui de *shillig* qui se produit lorsque les apprenants se servent des faux profils (cf. Table (F.1) en Annexe).

6.3 Architecture du système de recommandation *KTI-MOOC*

L’architecture fonctionnelle du système de recommandation définit le principe de fonctionnement du système. Le processus est précédé par la définition des classes de décision par l’homme d’études (HE) et le décideur qui est dans ce cas l’équipe pédagogique. Il repose principalement sur les données statiques et dynamiques des apprenants. Ces données sont récupérées à la fin de chaque semaine par des algorithmes d’analyse des traces implémentés dans le système du MOOC et conduisant à la génération d’un fichier CSV (ou bien un fichier log). Le fonctionnement du système commence d’abord par nettoyer le fichier CSV en utilisant les algorithmes de traitement dédiés à ce type de fichiers. Les données seront stockées dans la matrice $Apprenant_i$ qui rassemble toutes les données sur les apprenants pendant la

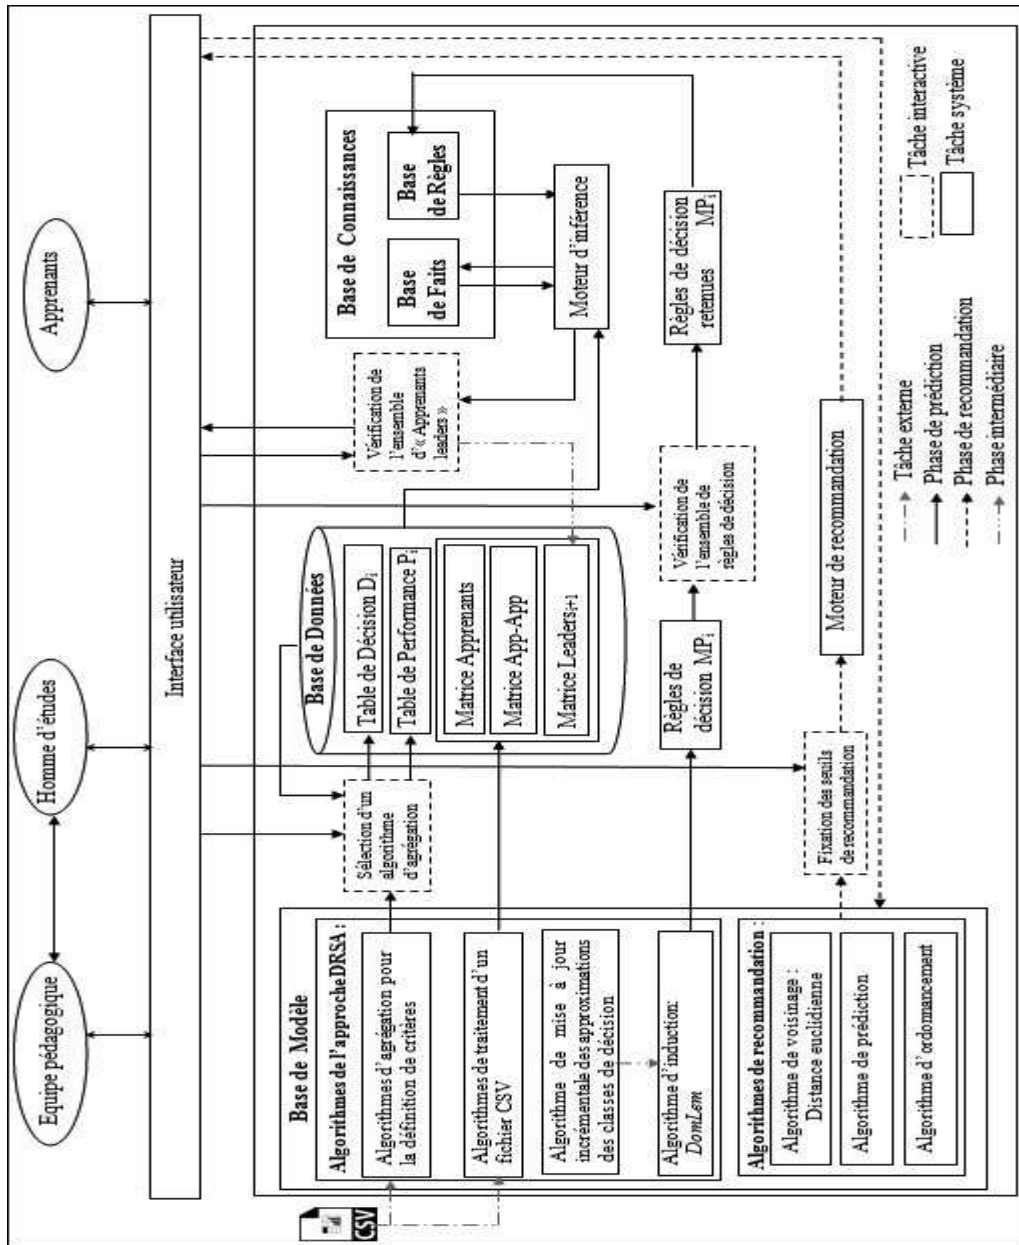


FIGURE 6.3 – Architecture du système de recommandation KTI-MOOC

$Semaine_i$ du MOOC et la matrice Apprenant-Apprenant qui rassemble les évaluations données par les apprenants aux “Apprenants leaders” dès le début de la diffusion du MOOC. Le fichier CSV est aussi exploité par l’HE et l’équipe pédagogique afin de collectivement construire la famille de critères permettant de caractériser le profil et le comportement d’un apprenant. Ils doivent se mettre d’accord sur l’algorithme d’agrégation approprié pour agréger les critères à retenir et contrôler leur redondance. A la fin de chaque $Semaine_i$ du MOOC, ces données seront stockées dans la table de décision D_i . Cette table contient, également, les valeurs des évaluations de chaque apprenant sur l’ensemble de critères. Ces valeurs sont le résultat de l’algorithme de traitement du fichier CSV de la $Semaine_i$. La table de décision D_i contient, de plus, l’affectation de chaque apprenant dans l’une des trois classes de décision : Cl_1 des “Apprenants en risque”, Cl_2 des “Apprenants en difficulté” ou bien Cl_3 des “Apprenants leaders”. La décision d’affectation est prise par l’équipe pédagogique avec l’aide de l’HE. Ensuite, un algorithme de mise à jour incrémentale est appliqué sur la table de décision D_i afin de calculer les approximations de l’approche DRSA de la $Semaine_i$. Ces approximations sont fournies en entrée à l’algorithme d’induction *DomLem* afin d’en inférer un modèle de préférence MP_i qui résulte en un ensemble de règles de décision. Le modèle de préférence doit être vérifié par l’HE et l’équipe pédagogique afin de le valider ou d’en sélectionner un sous ensemble consistant. Au début de chaque $Semaine_{i+1}$ du MOOC, la table de performance est remplie en utilisant le fichier CSV de la $Semaine_i$ et l’algorithme d’agrégation défini. Les apprenants contenus dans la table de performance sont appelés “Apprenants potentiels”. Les informations contenues dans la table P_i seront transformées en “*Faits_i*”. Les règles de décision sélectionnées dans la $Semaine_i$ doivent être appliquées sur ces “*Faits_i*” pour prédire les “Apprenants leaders” de la $Semaine_{i+1}$. La liste des “Apprenants leaders” doit être validée par l’HE et l’équipe pédagogique qui peuvent capitaliser sur leur expérience pour la valider ou en définir une sous liste finale. Les données sur ces apprenants seront stockées dans la matrice $Leaders_{i+1}$ qui est actualisée en temps réel. La liste des “Apprenants leaders” représente les items de la phase de recommandation. Les “Apprenants en risque” et les “Apprenants en difficulté”, une fois connectés, représentent la cible de la recommandation. Les apprenants du MOOC sont les utilisateurs du système *KTI-MOOC*. Les données démographiques concernant les apprenants items et les apprenants cibles sont stockées dans la matrice $Apprenants_i$ qui doit être actualisée au début de chaque $Semaine_{i+1}$. Un algorithme de voisinage basé sur la distance euclidienne est appliqué sur cette matrice afin d’identifier le voisinage de chaque utilisateur. Un algorithme de prédiction permettant de prédire l’appréciation de l’apprenant cible vis-à-vis de chaque “Apprenant leader” est appliqué sur la matrice *Apprenant-Apprenant*. Un algorithme d’ordonnancement est finalement appliqué afin d’afficher à l’apprenant cible les N-top “Apprenants leaders” appropriés à son profil. Ces trois algorithmes de recommandation sont basés sur des seuils qui doivent être discutés et fixés par l’HE et l’équipe pédagogique tels que le nombre des “Apprenants leaders” à recommander et le nombre d’apprenants

cibles à proposer pour un “Apprenant leader”.

6.4 Expérimentations et résultats

Dans ce travail, l’application de l’approche DRSA pour la prédiction périodique des “Apprenants leaders” nous a permis de garantir la qualité des recommandations que le système propose. En effet, notre méthode de classification multicritère, périodique et incrémentale *MAI2P* basée sur notre algorithme *DRSA-Incremental* a été testée sur des données réelles provenant d’un MOOC Français (cf. Chapitre 5). La performance du modèle de préférence était très satisfaisante avec une F-mesure et une Exactitude qui atteignent respectivement 0.66 et 0.89.

Ainsi, dans cette section nous allons évaluer le système de recommandation proposé sur deux autres aspects : la performance sur le temps d’exécution et la couverture de l’espace item (Shani et Gunawardana, 2011). Les algorithmes sont codés avec Java et exécutés sur une machine personnelle avec Windows 7, Intel (R) *CoreTM* i3-3110M CPU @ 2.4 GHz et 4.0 GB de mémoire.

6.4.1 Quelques interfaces

La figure 6.4 représente la page d’accueil accessible pour tout apprenant inscrit au MOOC. C’est l’interface lui permettant d’accéder à sa page personnelle une fois que les données d’identification sont valides.

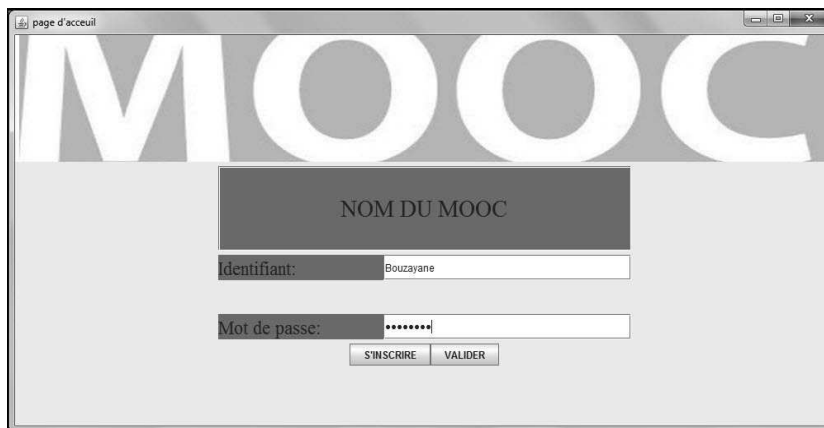


FIGURE 6.4 – Page d’accueil de l’environnement du MOOC

Dès que l’apprenant clique sur le bouton “Valider”, l’algorithme de recommandation s’exécute afin de l’identifier (cf. Figure 6.5). Si l’apprenant X est un “Apprenant en risque” ou “Apprenant en difficulté”, alors il sera identifié comme étant un utilisateur cible, auquel sont calculés le voisinage et la fonction de prédiction

afin d'en inférer les n-top "Apprenants leaders" appropriés. Si l'apprenant X est un "Apprenant leader", il présentera l'objet de la recommandation.

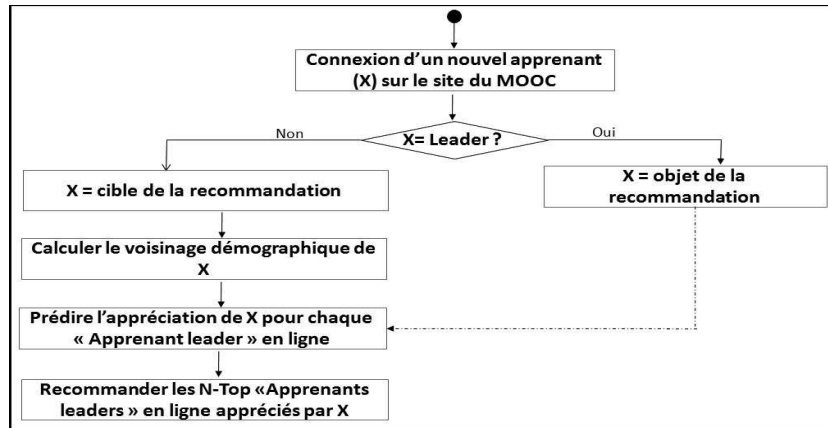


FIGURE 6.5 – Processus de recommandation pour un apprenant X

La Figure 6.6 représente la page personnelle d'un "Apprenant en risque" ou un "apprenant en difficulté". Le système de recommandation *KTI-MOOC* est un module intégré dans l'environnement du MOOC qui doit apparaître sous forme d'une liste déroulante, appelée *widget*, sur la page personnelle de l'apprenant cible, en bas et à droite de la page. La liste contient l'ensemble des "Apprenants leaders" personnalisée en fonction du profil de l'apprenant cible en question.

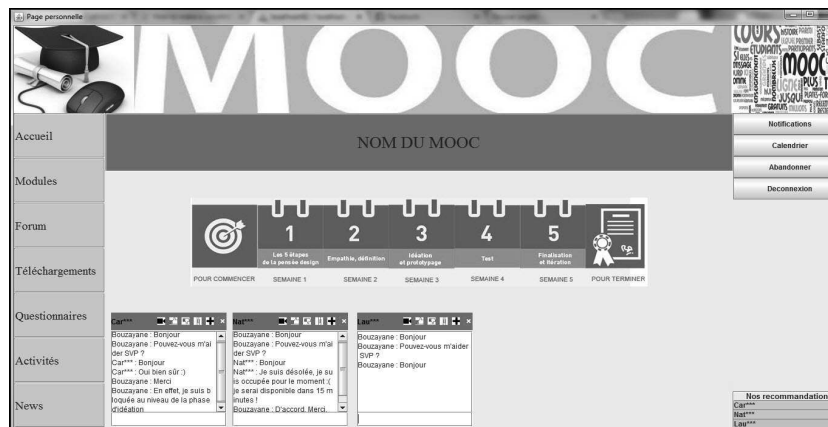


FIGURE 6.6 – Page personnelle d'un apprenant du MOOC suite à l'intégration du *widget KTI-MOOC*

Dès qu'il clique sur un nom de la liste recommandée, une fenêtre de *Chat* est ouverte pour l'apprenant cible ("Apprenant en risque" ou "apprenant en difficulté") lui permettant (par ordre d'apparition sur la fenêtre de *Chat*) de :

- Ouvrir une discussion audio ou bien audio-visuelle avec l'“Apprenant leader” recommandé.
- Fournir un retour de pertinence sur l'“Apprenant leader” contacté (bouton *like* pour un retour positif et un bouton *dislike* pour un retour négatif).
- Joindre et envoyer un fichier (exp. image, pdf, vidéo, etc.).
- Ajouter un autre apprenant à la discussion.
- Fermer la fenêtre de *Chat*.

L'apprenant cible peut, sinon, se contenter d'une discussion par écrit via la fenêtre affichée.

6.4.2 Performance de l'algorithme de recommandation sur le temps d'exécution

La Figure 6.7 montre le résultat des simulations effectuées sur des données semi-réelles tout en modifiant le nombre d'apprenants et aussi le nombre des évaluations enregistrées dans la base de données.

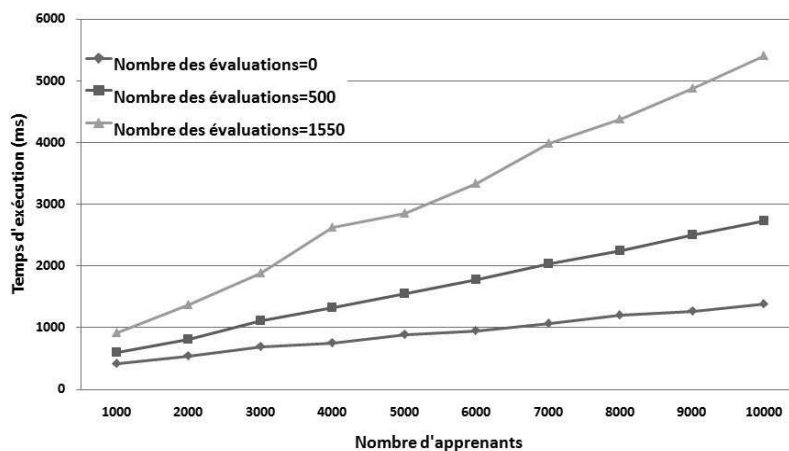


FIGURE 6.7 – Temps d'exécution de l'algorithme de recommandation : étude de la sensibilité par rapport au nombre d'apprenants et celui des évaluations

Nous avons ainsi constaté que l'algorithme de recommandation que nous proposons est sensible aux deux facteurs suscités. L'algorithme de recommandation est plus rapide lorsque moins d'apprenants sont inscrits et moins d'évaluations sont données. Cela semble logique parce que le filtrage démographique traite les données démographiques de tous les apprenants ainsi que les évaluations qu'ils soumettent.

6.4.3 Evaluation sur la couverture de l'espace item

Plus que la qualité de la recommandation, il est aussi important d'évaluer la couverture de l'espace item ("Apprenants leaders") du système proposé. Cette couverture désigne la proportion des "Apprenants leaders" que le système de recommandation peut recommander. Elle est calculée par le pourcentage des "Apprenants leaders" recommandés par le système par rapport au nombre total des "Apprenants leaders". Dans notre cas, la couverture de l'espace item dépend du nombre des "Apprenants leaders" disponibles à recommander et aussi du nombre des "Apprenants en risque" ou bien les "Apprenants en difficulté" que nous envisageons aider.

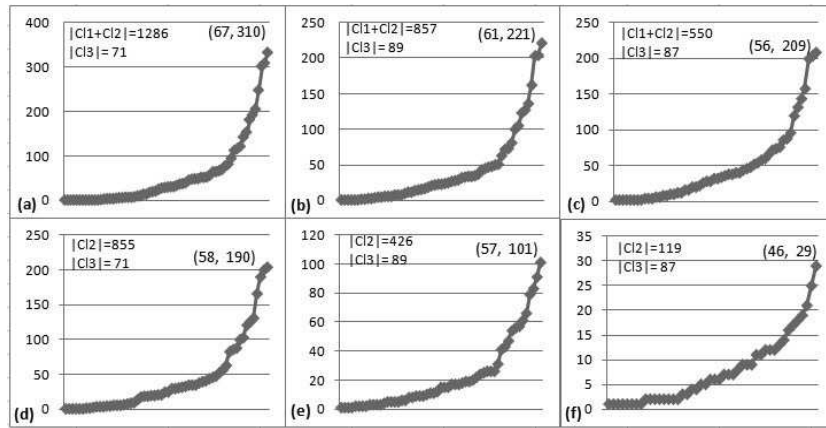


FIGURE 6.8 – Couverture de l'espace item et diversité des recommandations proposées (Axe des abscisses : Identifiant de l'apprenant leader recommandé ; Axe des ordonnées : Nombre de recommandations d'un apprenant leader).

La Figure 6.8 représente les résultats des simulations effectuées sur des ensembles distincts de données en modifiant la taille de l'ensemble cible de recommandation. Les "Apprenants leaders" sont ordonnés selon un ordre croissant de leur fréquence de recommandation. Dans les courbes supérieures ((a), (b) et (c)) la recommandation concerne les "Apprenants en risque" classés dans la classe Cl_1 et les "Apprenants en difficulté" classés dans la classe de décision Cl_2 . Par contre, dans les courbes inférieures ((d), (e) et (f)) la recommandation concerne uniquement les "Apprenants en difficulté". Nous constatons que la couverture sur l'espace item diminue en diminuant la taille de l'ensemble cible de la recommandation ($\frac{67}{71}=0.94$, $\frac{61}{89}=0.68$ et $\frac{56}{87}=0.64$ respectivement pour les courbes (a), (b) et (c) ; $\frac{58}{71}=0.81$, $\frac{57}{89}=0.64$ et $\frac{46}{87}=0.52$ respectivement pour les courbes (d), (e) et (f)). Cela revient à l'hétérogénéité des profils apprenants qui diminue en fonction de leur nombre et aussi à la borne que nous avons imposée sur la taille de la recommandation (3 apprenants leaders uniquement peuvent être recommandés pour chaque apprenant en besoin) qui ont empêché de trouver des paires démographiques pour quelques "Apprenants leaders" et par conséquent nous obtenons une couverture

plus réduite. Dans ce cas, un “Apprenant leader” sera recommandé plusieurs fois ce qui influe la diversité de la recommandation. Cependant, dans tous les cas, plus que la moitié des “Apprenants leaders” a été recommandée.

A ce niveau, nous n’avons pas intégré notre système *KTI-MOOC* sur les plateformes dédiées aux MOOCs afin de pouvoir valider son utilité et son effet réels sur les apprenants. Une telle expérimentation nous permettra, cependant, de vérifier la fréquence d’utilisation du système par les apprenants et son impact sur la qualité du processus d’apprentissage qu’ils mènent, d’une part ; et la minimisation du taux d’abandon, d’autre part.

6.5 Conclusion

Dans ce chapitre nous avons proposé notre système de recommandation *KTI-MOOC* conçu pour l’aide au transfert de savoirs dans un contexte des MOOCs. Il a l’objectif d’aider les apprenants à trouver un apprenant source d’une information pertinente. L’approche de recommandation est basée sur deux phases : la prédiction périodique et incrémentale des “Apprenants en risque”, des “Apprenants en difficulté” et des “Apprenants leaders” qui représentent, à la fois, la cible et l’objet de la recommandation. Cette phase est basée sur notre méthode *MAI2P* qui intègre notre algorithme *DRSA-Incremental* de mise à jour incrémentale des approximations de DRSA. La deuxième phase consiste à appliquer un algorithme de recommandation afin de proposer pour chaque “Apprenant en risque” ou “Apprenant en difficulté”, la liste des “Apprenants leaders” appropriée à son profil. Cette étape de correspondance, ou *matching*, a pris en compte les facteurs inhibiteurs d’un processus de transfert de savoirs. La recommandation est basée sur le filtrage démographique et la distance euclidienne. Nous avons aussi détaillé l’architecture fonctionnelle de notre système de recommandation *KTI-MOOC*. Des hypothèses simplificatrices ont été aussi définies pour surmonter quelques limitations.

Le système de recommandation *KTI-MOOC* a été également développé et validé sur des données semi-réelles sur les deux aspects : le temps d’exécution et la couverture minimale qui était d’une valeur très satisfaisante atteignant 0.94. La qualité des items recommandés (“Apprenants leaders”) a été déjà validée dans le Chapitre 5 et a prouvé des résultats satisfaisants considérant la F-mesure et l’exactitude.

Contrairement aux travaux antérieurs qui recommandaient des ressources pédagogiques, nous avons choisi de recommander des ressources humaines. Cela permet de mener un processus de transfert où le transmetteur et le récepteur des savoirs interagissent et communiquent ensemble afin de garantir la phase d’appropriation que nous jugeons primordiale pour le processus de transfert. La communication supportée par la technologie pour l’échange de solutions peut parfaitement constituer le point de départ à un réel transfert de connaissances et donner lieu à une construction mutuelle de savoirs (Depover *et al.*, 2000).

Le système de recommandation *KTI-MOOC* est un module intégré dans l'environnement du MOOC qui doit apparaître sous forme d'une liste déroulante, appelée *widget*, sur la page personnelle de l'apprenant cible, en bas et à droite de la page. La liste contient l'ensemble des "Apprenants leaders" personnalisée en fonction du profil de l'apprenant cible en question. La fenêtre de chat permet à l'apprenant cible de déclencher une communication audio-visuelle avec l'"Apprenant leader" recommandé, évaluer son intervention et son aide ou bien lui écrire un message.

Conclusion générale et perspectives

L'objectif de la thèse est l'aide au transfert des connaissances tacites et explicites dans les environnements d'apprentissage en ligne. L'aide envisagée concerne les deux phases de transmission de données et d'appropriation (absorption) des informations. Notre cas applicatif est les MOOCs (*Massive Open Online Courses*) qui sont des formations en ligne, diffusées gratuitement et accessibles par un nombre massif d'apprenants de profils hétérogènes. Ils sont toutefois animés par une équipe pédagogique d'une taille réduite qui se trouve incapable d'accompagner l'intégralité des apprenants. Outre que l'équipe pédagogique, les MOOCs sont enrichis par les données provenant des apprenants dont l'exactitude et la pertinence de la connaissance qui en est inférée ne sont pas toujours garanties. Ainsi, l'absence de l'accompagnement de la part de l'équipe pédagogique et l'absence de l'information exacte et immédiate conduisent, généralement, les apprenants à abandonner la formation (Hone et El Said, 2016 ; Labarthe *et al.*, 2016a ; El Said, 2016). Les MOOCs éprouvent un taux d'abandon excessif qui atteint 90% (Yang *et al.*, 2013 ; Pomerol *et al.*, 2015).

Dans ce travail, nous avons proposé une méthode *MAI2P* (*Multicriteria Approach for the Incremental Periodic Prediction*) basée sur l'aide multicritère à la décision afin de prédire périodiquement les trois classes d'apprenants : Cl_1 des "Apprenants en risque" qui envisagent quitter le MOOC au début de la semaine suivante, Cl_2 des "Apprenants en difficulté" qui ont des lacunes pédagogiques mais n'ont pas l'intention de quitter la formation au moins pour la semaine suivante, et Cl_3 des "Apprenants leaders" susceptibles de fournir une information appropriée et immédiate pour chaque apprenant des deux autres classes. Etant donné le caractère dynamique du MOOC, les données d'apprentissage ne sont pas fournies dans une seule portion, mais plutôt reçues en plusieurs portions séquentielles. Pour cela, la méthode *MAI2P* s'exécute d'une manière incrémentale en utilisant un algorithme *DRSA-Incremental* que nous avons proposé pour la mise à jour des règles de décision à chaque fois qu'on incrémente l'échantillon d'apprentissage. Ensuite, nous avons développé un système de recommandation basé sur cette liste hebdomadaire des classes d'apprenants afin de recommander pour chaque "Apprenant en risque" ou "Apprenant en difficulté" une liste ordonnée des "Apprenants leaders" en ligne.

Le système de recommandation est basé sur la technique de filtrage démographique et la distance euclidienne. La correspondance (dit aussi *matching*) entre un “Apprenant leader” (transmetteur de la connaissance) et un “Apprenant en risque” ou un “Apprenant en difficulté” (récepteur de la connaissance) doit minimiser les obstacles inhibant le transfert de connaissance (distance culturelle, linguistique, géographique). Ainsi, la liste recommandée varie d’un apprenant à un autre selon son profil. En outre, pour un même apprenant, la liste recommandée peut être modifiée à chaque fois qu’il se connecte en fonction de la disponibilité des “Apprenants leaders”.

La méthode *MAI2P* et l’algorithme *DRSA-Incremental* sont génériques qui peuvent être appliqués pour des objectifs de prédiction basée sur l’aide multicritère à la décision. Ils s’adaptent à un cas de système d’information dynamique où les données d’apprentissage sont fournies en portions dont chacune nécessite la mise à jour des règles de décision. Ils sont validés dans un cas d’un MOOC Français proposé par un établissement d’enseignement supérieur en France. Comparé à l’algorithme de *DRSA* conventionnel, l’algorithme *DRSA-Incremental* a minimisé considérablement le temps de calcul. Il était toutefois sensible au nombre d’actions et de critères contenus dans le système d’information. La qualité de la prédiction fournie par la méthode *MAI2P* était satisfaisante d’une F-mesure = 0.66 et Exactitude = 0.89. Egalement, le système de recommandation *KTI-MOOC* (*Recommender system for Knowledge Transfer Improvement within a MOOC*) a été validé sur des données semi-réelles en considérant la couverture minimale et le temps d’exécution. L’algorithme de recommandation était, en effet, sensible au nombre d’apprenants participants au MOOC et au nombre d’évaluations enregistrées. La couverture a été très satisfaisante d’une valeur qui a atteint 0.94%.

Bilan des contributions apportées

En guise de conclusion, cette thèse présente plusieurs apports qui se résument dans les points suivants :

Contribution 1. Définition des concepts de base du transfert des connaissances : Suite à une étude bibliographique approfondie, nous avons constaté que les travaux antérieurs étaient sujets sur l’objet de transfert. Il n’était pas suffisamment claire si nous sommes effectivement en train de transférer des connaissances, et si le terme “Transfert des connaissances” reste valable en cas d’une connaissance tacite. En effet la connaissance tacite est incarnée dans la tête des connaisseurs et une fois externalisée, n’est plus tacite ce qui remet en cause le terme “transfert d’une connaissance tacite”. Ainsi, nous avons défini une donnée comme étant *une entité matérielle située dans le monde physique et perçue par un agent cognitif*. La perception est liée à un ensemble de signaux détectés par le système perceptif de l’agent cognitif. Parmi les données existantes, l’agent cognitif sélectionne et acquiert celles dont il a besoin afin de construire ce que

nous appelons “une donnée de sens”. Une information est, ainsi, *le résultat d’une interprétation d’une donnée de sens*. De même, nous avons choisi de ne plus parler d’une connaissance, mais plutôt d’un *savoir factuel* et d’un *savoir-faire*. Un savoir factuel est un état de croyance qui concerne une description et qui affecte une valeur de vérité à une description qui peut être factuelle ou instructionnelle (Ghrab, 2016). Un savoir-faire est *une disposition à réaliser avec succès un type d’action*. La connaissance englobe, ainsi, les quatre concepts de donnée, information, savoir factuel et savoir-faire. Nous avons aussi défini le partage de données comme *“la mise à disposition par un groupe d’agents cognitifs d’un ensemble de données”*. Pour définir le transfert, nous avons adopté la définition de (Davenport et Prusak, 1998) en considérant que l’objet de transfert est plutôt l’information et non pas la connaissance. Cependant, l’information transférée a certainement l’objectif de véhiculer un savoir factuel ou un savoir-faire. Du coup, dans ce travail nous parlons d’un transfert d’informations source de savoirs (savoirs factuels ou savoir-faire). En conclusion, nous avons montré que *“nous partageons des données pour le transfert des informations sources des savoirs factuels et des savoir-faire”*.

Contribution 2. Algorithme de mise à jour incrémentale des approximations de l’approche DRSA : Dans ce travail nous avons proposé un algorithme pour la mise à jour incrémentale des approximations de l’approche DRSA à chaque fois qu’une portion de donnée est rajoutée à l’échantillon dans un contexte d’apprentissage supervisé incrémental. Les approximations inférieures (et supérieures) de DRSA (Dominance-based Rough Set Approach) Greco *et al.* (2001a) sont les actions qui ont été classées avec certitude (ou d’une manière possible) dans une classe de décision. Elles se donnent en entrée à un algorithme *DomLem* (Greco *et al.*, 2001a) pour en inférer un ensemble de règles de décision. Ces ensembles sont susceptibles d’être modifiés à chaque fois que l’ensemble d’apprentissage est modifié. De ce fait, afin de garder un ensemble consistant et à jour de règles de décision, nous devons mettre à jour les approximations de DRSA. Dans ce cas, l’algorithme de DRSA conventionnelle reprend le calcul à zéro ce qui consomme un temps de calcul énorme. L’algorithme *DRSA-Incremental* que nous avons proposé est basé sur l’algorithme DRSA conventionnelle (Greco *et al.*, 2001a) et le théorème de décision P-généralisée (Kotlowski *et al.*, 2008). Il repose sur trois étapes : la mise à jour des unions inférieures et supérieures des classes de décision, la mise à jour des ensembles P-dominés et P-dominant de chaque action et la mise à jour des approximations inférieures et supérieures des unions des classes de décision. L’algorithme *DRSA-Incremental* est générique et s’applique à n’importe quel contexte où l’approche DRSA est appliquée sur un système d’information dynamique. Dans notre contexte, l’algorithme *DRSA-Incremental* n’est pas une obligation puisque la décision que nous devons prendre n’est pas en temps réel. Cependant, nous l’avons proposé dans le cadre de l’amélioration de notre travail. Validé sur des données semi-réelles, *DRSA-Incremental* a considérablement minimisé le temps de calcul. Il était toutefois sensible au nombre de critères et d’actions

dans le système d'information.

Contribution 3. Une méthode multicritère pour la prédiction périodique et incrémentale : nous avons proposé une méthode *MAI2P* (*Multicriteria Approach for the Incremental and Periodic Prediction*). La méthode *MAI2P* permet la prédiction périodique de n classes de décision. Elle intègre l'algorithme *DRSA-Incremental* afin de considérer l'incrémental de l'échantillon d'apprentissage. Elle est composée de trois phases : la construction d'une table de décision, la construction d'un modèle de préférence sous la forme d'un ensemble de règles de décision et la classification des "Actions potentielles". La première phase est composée de trois étapes : la construction d'une famille de critère pour la caractérisation des actions, la construction périodique de l'ensemble d'échantillon d'apprentissage appelé "Actions de référence" et la construction hebdomadaire de la table de décision. Elle repose fortement sur les préférences des décideurs. La deuxième phase prend en entrée la table de décision hebdomadaire sur laquelle s'applique l'algorithme *DRSA-Incremental* afin de mettre à jour le modèle de préférence. La troisième phase fournit une prédiction sur l'appartenance de chaque "Action potentielle" à une classe de décision parmi les n classes prédéfinies. La méthode *MAI2P* est générique et s'applique dans n'importe quel domaine où la finalité est la classification précoce des actions dans un système d'information dynamique. L'intervention du décideur humain dans le processus de décision et de choix de l'ensemble d'apprentissage a permis de surmonter le problème de données déséquilibrées (Bouzayane et Saad, 2017a).

Contribution 4. Une solution pour l'aide au transfert des informations source de savoirs dans les MOOCs : nous avons proposé une solution basée sur un système de recommandation qui intègre la méthode *MAI2P*. En premier temps, la méthode *MAI2P* permet de classer (prédire) au début de chaque semaine et d'une manière hebdomadaire les trois classes de décision : Cl_1 des "Apprenants en risque", Cl_2 des "Apprenants en difficulté" et Cl_3 des "Apprenants leaders". La prédiction est basée sur les critères statiques et dynamiques qui caractérisent les apprenants. Ensuite ces trois classes de décision sont données en entrée au système de recommandation *KTI-MOOC* (*Recommender system for Knowledge Transfer Improvement within a MOOC*). Le système *KTI-MOOC* recommande pour chaque "Apprenant en risque" ou "Apprenant en difficulté" une liste personnalisée des "Apprenants leaders". La personnalisation est basée sur la technique de filtrage démographique et la distance euclidienne et vise à inhiber les obstacles de transfert des connaissances entre eux. Comparé aux travaux antérieurs, notre travail basé sur la prédiction a apporté une solution pour les concepteurs du MOOC. Elle peut, à la fois, aider les apprenants à mieux comprendre le contenu de la formation et à avoir immédiatement l'information dont ils ont besoin, et aussi l'équipe pédagogique à mener au mieux leur MOOC. Sur un plan technique, la méthode *MAI2P* a permis de surmonter le problème d'apprentissage en présence

des données déséquilibrées qui figure bien dans le contexte des MOOCs vu la classe majoritaire des “Apprenants en risque”.

Contribution 5. Construction d’une famille cohérente de critères pour la caractérisation des profils apprenants : dans ce travail, nous avons construit une famille cohérente de onze critères lors de l’application de la méthode *MAI2P* dans un MOOC Français. Nous avons adopté une approche ascendante basée sur une étude bibliographique afin d’identifier les indicateurs pouvant caractériser les profils apprenants selon les classes de décision définies. Ensuite, des réunions ont été conduites avec l’équipe pédagogique de ce MOOC afin d’éliciter leurs préférences et valider une famille. Alors, la famille construite peut servir comme une famille préliminaire sur laquelle une autre équipe pédagogique peut se baser afin de construire sa propre famille en fonction de ses préférences et point de vue.

Perspectives

Différentes perspectives peuvent être apportées à notre travail de thèse. En effet, les améliorations touchent principalement à la méthode *MAI2P* et au système de recommandation *KTI-MOOC*. Nous détaillons, dans ce qui suit ces améliorations.

Perspective 1. Extension de la méthode *MAI2P* pour la prédiction basée sur le transfert d’apprentissage : Les modèles de prédiction proposés dans un contexte des MOOCs peuvent être divisés en deux catégories (Boyer et Veeramachaneni, 2015) : la prédiction basée sur l’apprentissage en *in-situ* qui tente d’apprendre un modèle prédictif à partir des données du même MOOC (Yuan et Powell, 2013 ; Balakrishnan et Coetzee, 2013 ; Chaplot *et al.*, 2015) et la prédiction basée sur le transfert d’apprentissage qui tente de transférer des échantillons d’apprentissage d’un ou plusieurs MOOCs précédents pour établir un modèle prédictif pour un autre MOOC (Whitehill *et al.*, 2017a;b ; Boyer et Veeramachaneni, 2015 ; Xing *et al.*, 2016 ; He *et al.*, 2015). La différence principale entre les deux méthodes est que l’apprentissage en *in-situ* utilise une information partielle pour établir la prédiction pour un même MOOC alors que le transfert d’apprentissage utilise une information complète pour la prédiction pour d’autres MOOCs (Boyer et Veeramachaneni, 2015). En appliquant les techniques conventionnelles de *machine learning*, Boyer et Veeramachaneni (2015) et Whitehill *et al.* (2017a) ont prouvé que la qualité de prédiction basée sur le transfert d’apprentissage n’était pas satisfaisante par rapport à la qualité réalisée par l’apprentissage en *in-situ*.

Dans ce travail, la méthode de prédiction *MAI2P* est basée sur l’apprentissage en *in-situ*. Notre perspective est, ainsi, d’appliquer cette méthode en utilisant le transfert d’apprentissage pour avoir une prédiction sur d’autres MOOCs. Ceci nous permettra de (1) nous positionner par rapport aux autres techniques d’apprentis-

sage et tester l'impact de l'aide multicritère à la décision sur la qualité de prédiction et (2) prédire les profils des apprenants pour la première semaine du MOOC qui est une période critique mais généralement négligée étant donnée l'absence de l'échantillon d'apprentissage (Jiang *et al.*, 2014).

Nous pouvons identifier deux cas de transfert de l'apprentissage : transfert dans des MOOCs similaires ou bien dans des MOOCs différents. D'après Whitehill *et al.* (2017b), les MOOCs similaires sont ceux qui appartiennent à la même discipline (Science de l'information, Astronomie, Médecine, etc.). En revanche, Boyer et Veeramachaneni (2015) considère que les MOOCs similaires partagent la même population d'apprenants, la même équipe pédagogique et la même équipe technique. Dans notre cas, puisque la méthode *MAI2P* est fortement basée sur les préférences de l'équipe pédagogique et sur les caractéristiques du MOOC, notre perspective se limite au transfert d'apprentissage dans les MOOCs similaires qui partagent la même équipe pédagogique et la même discipline pour garantir la validité de la famille de critères.

Perspective 2. Construction des ontologies pour l'amélioration de la qualité de la recommandation :

Une ontologie est une spécification formelle explicite d'une conceptualisation partagée d'un domaine d'intérêt (Staab et Studer, 2010). Plusieurs recherches actuelles tentent d'intégrer les ontologies dans le domaine des MOOCs. Shatnawi *et al.* (2014a) ont utilisé une ontologie de domaine pour représenter le contenu du cours et fournir des éléments de réponses aux questions posées sur le forum. Shatnawi *et al.* (2014b) ont proposé une ontologie de domaine afin de regrouper les messages du forum d'un MOOC qui sont sémantiquement similaires en *clusters* en fonction de leurs thèmes. Ceci permet de personnaliser les interactions des apprenants avec le système du MOOC. Sammour *et al.* (2015) ont utilisé le web sémantique pour représenter les pages web des MOOCs et améliorer les recommandations proposées aux apprenants. Muruganandam et Srinivasan (2017) ont proposé un modèle d'ontologie pour la représentation des profils d'apprenants. Ces profils sont stockés sous forme d'ontologie d'une structure et d'une information bien définies qui servent pour la prédiction du comportement des apprenants et pour personnaliser l'aide selon leurs besoins. Dans tous ces travaux, les ontologies ont prouvé des améliorations considérables de la qualité d'apprentissage via les MOOCs. De ce fait, nos perspectives s'orientent vers l'intégration des ontologies dans notre contexte afin d'améliorer notre méthode d'aide au transfert des savoirs factuels et du savoir-faire.

Dans ce travail, nous avons considéré uniquement l'appropriation individuelle du savoir-faire et des savoirs factuels, dans le sens où les échanges seront traités par paire (un "Apprenant leader" et un "Apprenant en risque" ou bien un "Apprenant leader" et un "Apprenant en difficulté") sans s'assurer qu'un groupe d'apprenants infère la même connaissance de l'ensemble des informations échangées. Cependant, la collaboration entre les apprenants est citée parmi les facteurs du succès d'un MOOC (Al-Atabi et DeBoer, 2014 ; Staubitz *et al.*, 2014). Ainsi, pour nos travaux

futurs nous envisageons favoriser la collaboration et, donc, aborder la dimension collective de l'appropriation. Alors, une ontologie de domaine est également souhaitable dans ce cadre afin de permettre les apprenants d'une conceptualisation unifiée sur un domaine spécifique. En effet, les apprenants du MOOC ont des profils hétérogènes et ne partagent pas forcément la même conceptualisation ce qui peut impacter la compréhension et l'appropriation collective des informations. L'ontologie de domaine est importante étant donnée que plusieurs MOOCs peuvent être proposés dans un seul domaine et donc une seule ontologie peut avoir des utilisations multiples.

Pour ce faire, nous envisageons rebondir sur l'ontologie COOK (*Core Ontology of Organization's Know-How and Knowing-That*) proposée dans le cadre des travaux menés par notre équipe de recherche (Ghrab et Saad, 2016; Ghrab *et al.*, 2017). Cette ontologie définit une taxinomie des savoirs factuels et des savoir-faire et a été appliquée dans le domaine médicale. Nous allons, en premier temps, approfondir la notion du collectif dans l'ontologie COOK et ensuite la réutiliser dans le domaine des MOOCs.

Perspective 3 : Utilisation d'une information contextuelle et d'une ontologie pour l'amélioration du processus de recommandation.

Dans ce travail, la recommandation repose sur le filtrage démographique qui est exclusivement basé sur les informations données explicitement par les apprenants (*i.e.* pays, ville, niveau d'études, langue maîtrisée) et stockées dans la base de connaissances afin de représenter leurs profils. Cette phase peut être améliorée de deux manières.

D'une part, plusieurs travaux actuels ont prouvés l'apport de l'information contextuelle dans l'amélioration de la qualité de la recommandation (Mendes *et al.*, 2016; Guillou, 2016; Braunhofer et Ricci, 2017). L'information contextuelle représente soit la connaissance des situations contextuelles sous lesquelles les notes ont été acquises, soit la connaissance de la situation contextuelle (en temps réel) de l'utilisateur cible demandant une recommandation (Codina *et al.*, 2016). Musumba et Nyongesa (2013) ont identifié trois environnements contextuels : (i) l'environnement informatique, tels que les processeurs disponibles, les périphériques accessibles pour l'entrée et la sortie des utilisateurs, la capacité du réseau, la connectivité et le coût du calcul ; (ii) l'environnement de l'utilisateur, tel que l'emplacement et le contexte social ; et (iii) l'environnement physique, comme la température, l'éclairage et les niveaux de bruit. Dans les MOOCs, nous sommes face à des contextes divers étant donnée l'hétérogénéité des profils apprenants. Ainsi, l'information contextuelle peut aider à personnaliser la correspondance entre les profils apprenants et donner une information plus précise sur leurs profils (exp. disponibilité, mobilité, etc.). Elles peuvent également minimiser le problème de *shilling* qui se produit quand les utilisateurs se servent des faux profils ce qui conduit à des données falsifiées aux inputs des systèmes. Dans ce cas, les informations contextuelles implicites peuvent corriger quelques champs.

D'autre part, nous pouvons profiter d'avantage de l'apport des ontologies dans les domaines de bases de données et de modélisation des connaissances (Pierra *et al.*, 2005). Les ontologies, dans ce cas, représentent un modèle conceptuel et partageable d'un domaine et visent à décrire de façon consensuelle un ensemble d'informations. Cependant, les relations entre les données que nous traitons dans ce travail peuvent être ambiguës (exp. le nom d'une même ville existe dans deux pays différents) ou dépendants (exp. langue et pays). Notre objectif est de représenter les données structurées dans la base comme étant les instances d'une ontologie. Toute instance doit appartenir à une seule classe de base, qui est la borne inférieure (au sens de la relation de subsumption) des classes d'appartenance, et elle ne peut être décrite que par les propriétés qui lui sont applicables. Ceci permettra d'éviter les confusions qui peuvent se produire lors du calcul du voisinage et donc d'améliorer la qualité de la prédiction surtout dans ce contexte de données massives et hétérogènes.

Perspective 4 : Réutilisation de la cartographie CK-Cartography pour le partage de savoirs.

Une cartographie de connaissances est la représentation et la visualisation des connaissances sous des entités graphiques véhiculant une signification dans le but de partage, de transfert et de création des connaissances entre au moins deux personnes (Bertschi *et al.*, 2011 ; Tergan et Keller, 2005). Parmi les travaux de recherche menés dans notre équipe nous citons la proposition d'un prototype de cartographie des savoirs factuels et du savoir-faire, appelé *CK-Cartography* (Ghrab, 2016). Validée dans un domaine médical, la *CK-Cartography* a permis la contextualisation du savoir-faire pour répondre à plusieurs questions telles que : Par qui le savoir-faire est détenu (individu ou collectif) ? Par qui (individu ou collectif), il est utilisé ? Est-il individuel ou collectif ? Est-il explicite ou tacite ? Quel est son support de stockage s'il est explicite ? Quel est le type du support ?

Tenons compte de l'apport de la cartographie *CK-Cartography* dans le domaine médical, nous souhaitons la réutiliser au contexte des MOOCs et la faire communiquer avec le système de recommandation *KTI-MOOC*. En effet, dans ce travail nous avons proposé un système qui recommande des "Apprenants leaders" aux apprenants qui ont besoin d'aide (*i.e.* les "Apprenants en risque" et les "Apprenants en difficulté"). Cependant, le nombre des "Apprenants leaders" peut être relativement réduit par rapport à celui des autres. De ce fait, nous favorisons toute solution pouvant minimiser le recours récurrent aux "Apprenants leaders" pour respecter leur capacité cognitive (Miller, 1956). Comme le cas d'une cartographie, par exemple, où l'apprenant peut trouver des éléments de réponse à ses questions dans ses noeuds sans forcément déclencher une conversation avec un "Apprenant leader".

La cartographie que nous envisageons proposer doit regrouper tous les savoirs partagés sur le site du MOOC en leurs identifiant : le contenu, le détenteur (s'il est le tuteur, un "Apprenant leader" ou un "Apprenant en difficulté" par exemple), la date de l'ajout de ce savoir, les évaluations qui ont été accordées à ce savoir par d'autres apprenants dans le cas échéant, etc. Une telle cartographie permettra,

donc, de localiser les savoirs dont les apprenants cherchent en donnant une idée sur leur utilité. En effet, un savoir détenu et partagé par le tuteur ou bien par un “Apprenant leader” sera plus utile qu’un savoir partagé par un “Apprenant en difficulté”.

La cartographie de *CK-Cartography* est entièrement basée sur des variables statiques. Cependant, dans le contexte des MOOCs, les variables ne sont plus statiques vu qu’un apprenant, par exemple peut alterner entre les trois classes de décision, il peut de même changer son emplacement, etc. Pour cela, nous envisageons proposer une cartographie basée sur *CK-Cartography* mais qui soit dynamique en fonction de plusieurs variables (Saulnier *et al.*, 2006 ; DiBiase *et al.*, 1992). Un autre défi que nous allons rencontrer dans ce cas, est la taille de la cartographie. En effet, dans le domaine médical nous pouvons gérer le nombre des noeuds (où chaque noeud encapsule un savoir) ajoutés, en revanche, dans les MOOCs ce nombre peut être considérablement amplifié vu le nombre excessif d’apprenants et la masse grandissante de données qu’ils véhiculent. Ceci peut impacter le fonctionnement et la clarté de la cartographie.

Publications

Articles journaux

S. Bouzayane and I. Saad. **A preference ordered classification to leader learners identification in a MOOC.** *Journal of Decision Systems. Special Issue on Knowledge Sharing and Decision Making in the Age of Digital.* vol. 26, no 2, pp. 189-202, 2016. [<http://dx.doi.org/10.1080/12460125.2017.1252233S>].

S. Bouzayane and I. Saad. **Rough set based argumentative approach to support collaborative multicriteria knowledge classification.** *Journal of Decision Systems (JDS)*, DOI :10.1080/12460125.2014.888836, vol.23 (2), pp.167-189, Mars 2014. [<http://www.tandfonline.com/doi/pdf/10.1080/12460125.2014.888836#.VBrO0vl5O8A>]

Chapitres

S. Bouzayane and I. Saad. **How to Help a Pedagogical Team of a MOOC Identify the “Leader Learners”?** In : Bajwa D., Koeszegi S., Vetschera R. (eds) *Group Decision and Negotiation. Theory, Empirical Evidence, and Application.* GDN 2016. *Lecture Notes in Business Information Processing*, vol. 274, pp. 140-151, Springer, ChamS, 2017.

S. Bouzayane and I. Saad. **Multicriteria decision aid method for knowledge sharing.** Book chapter : *Decision Support Systems IV - Information and Knowledge Management in Decision Processes*, Euro Working Group Conferences, EWG-DSS, *Lecture Notes in Business Information Processing* 221, Springer 2014, ISBN 978-3-319-21536-5, pp. 13-25, 2015.

S. Bouzayane, I. Brigui-Chtioui and I. Saad. **An argumentation based Rough Set Theory for Knowledge Management.** Book chapter : *Information Systems for Knowledge Management*, Wiley-ISTE Edition, ISBN : 9781848216648, Chapter 4, pp. 93-126, February 2014. [<http://eu.wiley.com/WileyCDA/WileyTitle/productCd-1848216645.html>].

Actes de Conférences internationales avec comité de lecture

S. Bouzayane and I. Saad. **Prediction Method based DRSA to Improve the Individual Knowledge Appropriation in a Collaborative Learning Environment : Case of MOOCs.** *Proceedings of the 50th hawaii international conference on system sciences*, pp. 124-133, Janvier 2017.

S. Bouzayane, and I. Saad. **Weekly Predicting the At-risk MOOC Learners Using Dominance-based Rough Set Approach.** *5th Conference on European MOOCs Stakeholders Summit (EMOOCs'2017)*, pp. 160-169, Madrid, Spain, 22- 26 May, 2017.

S. Bouzayane and I. Saad, **Incremental Updating Algorithm of the Approximations in DRSA to Deal with the Dynamic Information Systems of MOOCs.** *In the international conference on Knowledge Management, Information and Knowledge Systems (KMIKS 2017)*, pp. 55-66, Hammamet, Tunisie, April 2017.

S. Bouzayane, I. Saad, G. Kassel and F. Gargouri, **Recommender System based on a Periodic Multicriteria Decision Approach for the Support Personalization within a MOOC.** *In the international conference on Knowledge Management, Information and Knowledge Systems (KMIKS 2017)*, pp. 67-78, Hammamet, Tunisie, April 2017.

S. Bouzayane, and I. Saad. **Multicriteria Decision Aid Approach to Referent Learners Identification within a MOOC.** *Proceedings of the 4th Conference on European MOOCs Stakeholders Summit (EMOOCs'2016)*, pp. 237-247, Graz, Austria, 22-24 February, 2016,.

[<http://emoocs2016.eu/wp-content/uploads/2016/02/proceedings-emoocs2016.pdf>]

S. Bouzayane and I. Saad, **Knowledge sharing within the MOOCs.** *In the international conference on Knowledge Management, Information and Knowledge Systems (KMIKS 2015)*, pp. 153-162, Hammamet, Tunisie, April 2015.

S. Bouzayane, I. Saad, F. Gargouri and G. Kassel. **Filtering based rough set theory to support the inter- and intra- organizational knowledge sharing.** *10th International Conference on Knowledge Management (ICKM 2014)*, Antalya Turkey, 24-26 November 2014.

S. Bouzayane, I. Saad, F. Gargouri and G. Kassel. **Toward a recommendation system for inter and intra-organizational knowledge sharing.** *11th International Conference on Intellectual Capital, Knowledge Management & Organizational Learning (ICICKM2014)*, pp. 493-501, Sydney, Australia, 6-7 November 2014. [<http://academic-conferences.org/icickm/icickm2014/icickm14-proceedings.htm>]

S. Bouzayane, I. Brigui-Chtioui and I. Saad, **An argumentation based Rough Set Theory for Knowledge Management**. *In the international conference on Knowledge Management, Information and Knowledge Systems*, pp. 77-88, Hammamet, 2013.

Conférences nationales

S. Bouzayane and I. Saad. **Le transfert de connaissances en présentiel et à distance**. *33ème édition de la manifestation scientifique INFORSID*, Biarritz, France, 26-29 Mai 2015.

S. Bouzayane and I. Saad. **Stratégies argumentatives pour la classification collaborative multicritères des connaissances cruciales**. 14ème conférence Extraction et Gestion des Connaissances (EGC 2014), *Dans : Revue des Nouvelles Technologies de l'Information, vol. RNTI-E-26*, pp. 569-572, Rennes, France, Janvier 2014. [<http://editions-rnti.fr/?inprocid=1001981>]

S. Bouzayane et I. Saad. **Des interactions stratégiques argumentatives pour l'aide à la décision multicritère**. *12ème rencontres des jeunes chercheurs en intelligence artificielle (RJCIA)*, hébergée par RFIA'2014, Rouen, France, 30 juin - 01 juillet 2014. [https://rjcia2014.greyc.fr/sites/rjcia2014.greyc.fr/files/rjcia2014_submission_9.pdf]

Workshop

S. Bouzayane and I. Saad, **Dominance-based Rough Set Approach to Learn in the Presence of Class Imbalance**. *Workshop on Learning in the Presence of Class Imbalance and Concept Drift*, International Joint Conference on Artificial Intelligence (IJCAI'2017), August 20, 2017, Melbourne, Australia. (Accepté, Non encore publié).

S. Bouzayane, I. Brigui-Chtioui and I. Saad, **An argumentation based Rough Set Theory for Knowledge Management**. *Workshop on Artificial intelligence for Knowledge Management*, 20th European Conference on Artificial Intelligence (ECAI 2012), Montpellier, France, 2012 (accepté, non publié)

Annexe A

Algorithme incrémental

Algorithme 2 : Algorithme Incrémental pour la mise à jour des approximations de DRSA lors de l'addition d'un ensemble d'actions

Données :
 $\forall x \in K, D_i^+p(x)$ et $D_i^-p(x)$ de la *semaine*_{*i*}
 $\forall n \in T, \overline{P}(Cl_{i,n}^{\geq}), \overline{P}(Cl_{i,n}^{\leq}), \underline{P}(Cl_{i,n}^{\leq})$ et $\underline{P}(Cl_{i,n}^{\geq})$ de la *semaine*_{*i*}
 Un ensemble Δ^+ contenant les nouvelles actions
Résultat :
 $\overline{P}(Cl_{i+1,n}^{\geq}), \overline{P}(Cl_{i+1,n}^{\leq}), \underline{P}(Cl_{i+1,n}^{\leq})$ et $\underline{P}(Cl_{i+1,n}^{\geq})$ de la *semaine*_{*i+1*}

Début
pour *i* de 1 à $|\Delta^+|$ **faire**
 | Calculer $D_{i+1}^+p(x_i^+)$ et $D_{i+1}^-p(x_i^+)$;
fin
pour *n* de 1 à *N* **faire**
 | Calculer $\Delta_{n<}^+, \Delta_{n>}^+$ et $\Delta_{n=}^+$;
fin
pour *i* de 1 à $|K|$ **faire**
 | **pour** *j* de 1 à $|\Delta^+|$ **faire**
 | | **si** $x_i \in D_{i+1}^+p(x_j^+)$ **alors**
 | | | $D_{i+1}^-p(x_i) \leftarrow D_{i+1}^-p(x_i) \cup \{x_j^+\}$;
 | | **fin**
 | | **si** $x_i \in D_{i+1}^-p(x_j^+)$ **alors**
 | | | $D_{i+1}^+p(x_i) \leftarrow D_{i+1}^+p(x_i) \cup \{x_j^+\}$;
 | | **fin**
 | **fin**
fin
pour *i* de 1 à $|\Delta^+|$ **faire**
 | Calculer $l_{i+1}p(x_i^+)$ et $u_{i+1}p(x_i^+)$
fin
pour *n* de 1 à *N* **faire**
 | **pour** *i* de 1 à $|\Delta_{n>}^+|$ **faire**
 | | Calculer ΔM_n ;
 | | $\underline{P}(Cl_{i+1,n}^{\leq}) \leftarrow \underline{P}(Cl_{i,n}^{\leq}) - M_n$;
 | | $\overline{P}(Cl_{i+1,n}^{\geq}) \leftarrow \overline{P}(Cl_{i,n}^{\geq}) \cup D_{i+1}^+p(x_i^+)$;
 | | **si** $n < l_{i+1}p(x_i^+)$ **alors**
 | | | $\underline{P}(Cl_{i+1,n}^{\geq}) \leftarrow \underline{P}(Cl_{i,n}^{\geq}) \cup \{x_i^+\}$;
 | | **fin**
 | | **si** $n = l_{i+1}p(x_i^+)$ **alors**
 | | | $\underline{P}(Cl_{i+1,n}^{\geq}) \leftarrow \underline{P}(Cl_{i,n}^{\geq}) \cup \{x_i^+\}$;
 | | | $\overline{P}(Cl_{i+1,n}^{\leq}) \leftarrow \overline{P}(Cl_{i,n}^{\leq}) \cup \{x_i^+\}$;
 | | **fin**
 | | **si** $n > l_{i+1}p(x_i^+)$ **alors**
 | | | $\overline{P}(Cl_{i+1,n}^{\leq}) \leftarrow \overline{P}(Cl_{i,n}^{\leq}) \cup \{x_i^+\}$;
 | | **fin**
 | **fin**
 | **pour** *i* de 1 à $|\Delta_{n=}^+|$ **faire**
 | | **si** $n < l_{i+1}p(x_i^+)$ **alors**
 | | | $\underline{P}(Cl_{i+1,n}^{\geq}) \leftarrow \underline{P}(Cl_{i,n}^{\geq}) \cup \{x_i^+\}$;
 | | **fin**
 | | **si** $n = l_{i+1}p(x_i^+)$ **alors**
 | | | $\underline{P}(Cl_{i+1,n}^{\geq}) \leftarrow \underline{P}(Cl_{i,n}^{\geq}) \cup \{x_i^+\}$;
 | | **fin**
 | | **si** $n > u_{i+1}p(x_i^+)$ **alors**
 | | | $\underline{P}(Cl_{i+1,n}^{\leq}) \leftarrow \underline{P}(Cl_{i,n}^{\leq}) \cup x_i^+$;
 | | **fin**
 | | **si** $n = u_{i+1}p(x_i^+)$ **alors**
 | | | $\underline{P}(Cl_{i+1,n}^{\leq}) \leftarrow \underline{P}(Cl_{i,n}^{\leq}) \cup x_i^+$;
 | | **fin**
 | | $\overline{P}(Cl_{i+1,n}^{\geq}) \leftarrow \overline{P}(Cl_{i,n}^{\geq}) \cup D_{i+1}^+(x_i^+)$
 | | $\overline{P}(Cl_{i+1,n}^{\leq}) \leftarrow \overline{P}(Cl_{i,n}^{\leq}) \cup D_{i+1}^-(x_i^+)$
 | **fin**
 | **pour** *i* de 1 à $|\Delta_{n<}^+|$ **faire**
 | | Calculer ΔX_n ;
 | | $\underline{P}(Cl_{i+1,n}^{\geq}) \leftarrow \underline{P}(Cl_{i,n}^{\geq}) - \Delta X_n$;
 | | $\overline{P}(Cl_{i+1,n}^{\leq}) \leftarrow \overline{P}(Cl_{i,n}^{\leq}) \cup D_{i+1}^-p(x_i^+)$;
 | | **si** $n < u_{i+1}p(x_i^+)$ **alors**
 | | | $\overline{P}(Cl_{i+1,n}^{\geq}) \leftarrow \overline{P}(Cl_{i,n}^{\geq}) \cup \{x_i^+\}$;
 | | **fin**
 | | **si** $n = u_{i+1}p(x_i^+)$ **alors**
 | | | $\overline{P}(Cl_{i+1,n}^{\geq}) \leftarrow \overline{P}(Cl_{i,n}^{\geq}) \cup x_i^+$;
 | | | $\underline{P}(Cl_{i+1,n}^{\leq}) \leftarrow \underline{P}(Cl_{i,n}^{\leq}) \cup x_i^+$;
 | | **fin**
 | | **si** $n > u_{i+1}p(x_i^+)$ **alors**
 | | | $\underline{P}(Cl_{i+1,n}^{\leq}) \leftarrow \underline{P}(Cl_{i,n}^{\leq}) \cup x_i^+$;
 | | **fin**

Annexe B

Tables de décision

TABLE B.1 – Table de décision $Semaine_{1,2}$

id	$g_{1,1}$	$g_{2,1}$	$g_{3,1}$	$g_{4,1}$	$g_{5,1}$	$g_{6,1}$	$g_{7,1}$	$g_{8,1}$	$g_{9,1}$	$g_{10,1}$	$g_{11,1}$	D_1
15	2	2	3	3	1	2	2	2	1	1	1	1
3486	2	2	3	3	1	2	4	3	1	2	1	1
7977	2	3	2	3	1	0	3	3	1	1	1	1
12529	2	2	3	3	1	1	5	4	2	1	1	1
13631	2	2	3	1	1	2	2	1	1	1	1	1
14011	2	3	3	2	1	0	2	2	1	1	1	1
16469	2	1	3	2	1	2	4	2	1	2	1	1
22267	2	2	3	1	1	2	4	3	1	1	1	1
29739	2	2	3	2	1	0	5	3	2	3	1	1
35983	2	2	3	2	1	2	4	3	1	2	4	1
13168	2	3	3	3	1	0	5	3	1	2	4	2
18182	2	1	3	1	1	0	5	3	1	1	2	2
19933	2	1	2	2	1	0	3	3	1	2	1	2
20259	2	1	3	1	1	0	5	2	1	5	4	2
21089	2	3	3	3	1	0	5	3	1	2	4	2
22981	2	3	3	2	2	2	3	2	2	3	3	2
24520	2	2	3	3	1	2	3	3	1	5	2	2
25711	2	2	3	2	0	0	3	2	1	3	4	2
26859	2	3	2	2	1	0	5	2	1	3	3	2
36430	2	2	3	2	0	2	3	2	1	3	4	2
37155	2	2	2	3	0	2	4	3	2	4	4	3
27239	4	2	3	2	1	2	5	4	2	5	4	3
36097	2	2	3	2	1	2	3	3	3	2	4	3
37772	2	2	3	1	0	0	3	2	4	2	4	3
36337	2	3	3	2	1	0	5	3	2	3	4	3
35991	2	3	1	3	0	1	4	3	2	4	4	3
35959	2	3	2	3	1	1	5	4	2	5	4	3
36104	2	2	3	1	0	2	5	3	4	4	4	3
36364	4	1	3	3	0	0	4	3	2	5	4	3
37526	2	1	3	3	0	2	5	3	4	5	4	3

TABLE B.2 – Table de décision *Semaine*_{2,3}

id	$g_{1,2}$	$g_{2,2}$	$g_{3,2}$	$g_{4,2}$	$g_{5,2}$	$g_{6,2}$	$g_{7,2}$	$g_{8,2}$	$g_{9,2}$	$g_{10,2}$	$g_{11,2}$	D_2
37125	3	1	3	2	0	1	4	2	2	5	4	1
37193	2	3	3	2	0	2	4	2	1	2	4	1
37372	2	1	3	2	1	2	3	2	1	1	1	1
37417	2	1	3	2	1	0	2	2	3	5	4	1
37471	2	2	3	2	0	0	4	3	1	3	4	1
37551	2	1	3	1	0	0	4	3	1	2	1	1
37587	1	3	3	1	1	2	5	2	1	1	1	1
11919	2	2	3	3	1	1	4	2	1	5	4	1
36253	4	1	1	3	1	0	5	3	1	4	4	1
36345	4	3	3	3	0	0	5	3	1	3	4	1
21411	1	2	3	3	1	1	5	3	2	1	1	2
31600	2	1	3	2	1	2	4	2	1	1	1	2
35980	2	3	3	3	1	1	3	3	1	4	4	2
35980	2	3	3	3	1	1	3	3	1	4	4	2
36082	2	1	3	3	1	0	5	3	1	1	1	2
36525	1	1	3	3	1	0	3	3	1	3	3	2
36718	2	3	2	1	0	0	4	3	1	4	3	2
36358	2	1	3	3	1	0	3	3	3	5	4	2
36532	2	2	3	3	0	0	3	2	3	4	4	2
36562	2	2	3	2	1	0	3	3	1	4	1	2
36747	2	2	3	2	0	2	2	3	4	2	4	3
37107	1	2	3	2	1	0	3	3	4	5	4	3
5248	2	2	3	2	1	0	3	3	2	5	4	3
37553	2	2	3	1	1	0	5	2	2	3	4	3
36238	2	3	3	2	1	0	2	3	2	4	4	3
16048	1	3	3	3	1	0	5	2	2	4	4	3
11803	2	3	3	2	1	0	4	2	3	5	4	3
37031	2	1	3	1	1	2	3	2	2	4	4	3
37105	2	3	2	3	1	0	5	3	2	5	3	3
36219	2	2	3	2	0	0	3	2	2	3	4	3

TABLE B.3 – Table de décision $Semaine_{3,4}$

id	$g_{1,3}$	$g_{2,3}$	$g_{3,3}$	$g_{4,3}$	$g_{5,3}$	$g_{6,3}$	$g_{7,3}$	$g_{8,3}$	$g_{9,3}$	$g_{10,3}$	$g_{11,3}$	D_3
1631	2	2	1	2	1	0	3	2	1	5	1	1
18182	2	1	3	1	1	0	5	3	1	3	1	1
20786	2	3	2	3	1	0	5	3	1	3	1	1
21491	2	2	3	2	1	0	3	2	1	1	1	1
26859	2	3	2	2	1	0	5	2	1	1	1	1
37621	2	3	3	3	1	0	5	3	1	1	1	1
37703	2	3	3	2	0	0	4	2	2	1	1	1
3530	2	3	2	1	1	0	4	3	1	4	4	1
1395	2	2	3	2	1	2	3	2	2	4	2	1
30062	2	2	3	2	1	0	3	2	2	3	2	1
337	2	2	3	3	1	0	5	3	1	3	2	2
1359	2	3	2	3	1	1	5	2	2	1	1	2
26781	2	2	3	3	1	2	5	3	1	5	1	2
29215	2	2	3	1	1	1	4	2	1	3	3	2
36265	2	3	3	1	0	0	4	3	3	3	1	2
36289	2	2	3	3	1	2	3	3	1	4	4	2
36720	2	2	3	3	0	0	3	3	3	3	1	2
36173	2	3	3	3	0	2	3	2	2	5	4	2
36244	2	2	3	3	0	1	4	2	3	3	3	2
28912	4	3	1	1	1	0	4	3	2	4	4	2
35991	2	3	1	3	0	1	4	3	2	3	3	3
39175	2	3	3	2	1	2	3	3	2	4	4	3
36288	2	2	3	2	1	0	3	2	3	3	4	3
36238	2	3	3	2	1	0	2	3	3	5	3	3
5248	2	2	3	2	1	0	3	3	3	3	3	3
36211	2	1	3	3	0	2	4	3	2	4	4	3
5580	2	2	3	3	1	2	4	2	2	4	3	3
35964	2	2	3	3	0	0	4	3	2	4	4	3
14714	2	3	2	3	1	0	5	2	2	5	3	3
36056	2	2	3	3	1	0	5	3	2	3	2	3

TABLE B.4 – Table de décision $Semaine_{4,5}$

id	$g_{1,4}$	$g_{2,4}$	$g_{3,4}$	$g_{4,4}$	$g_{5,4}$	$g_{6,4}$	$g_{7,4}$	$g_{8,4}$	$g_{9,4}$	$g_{10,4}$	$g_{11,4}$	D_4
1346	2	2	2	3	1	0	4	2	1	3	4	1
21273	2	1	3	2	1	0	5	3	1	1	1	1
27385	2	3	3	2	1	0	5	2	1	2	1	1
29215	2	2	3	1	1	1	4	2	1	2	4	1
36211	2	1	3	3	0	2	4	3	2	3	4	1
36265	2	3	3	1	0	0	4	3	3	5	4	1
36532	2	2	3	3	0	0	3	2	1	2	4	1
36639	2	1	3	3	0	0	5	3	1	1	1	1
37280	2	3	3	2	0	0	4	3	1	1	4	1
41344	2	3	3	1	0	0	2	1	1	1	1	1
11872	2	3	3	2	1	2	3	2	1	1	4	2
15748	2	3	2	1	1	2	2	2	1	2	4	2
16048	1	3	3	3	1	0	5	2	1	2	4	2
35957	2	2	3	2	0	0	4	2	1	2	3	2
35969	2	3	2	3	1	0	3	2	1	2	1	2
36264	2	3	3	2	1	0	3	2	2	2	3	2
36287	2	2	3	3	0	0	4	3	1	4	4	2
36427	2	2	3	3	0	0	5	2	1	3	4	2
36604	1	2	2	3	0	0	5	4	1	2	4	2
36626	2	3	3	3	0	2	5	3	1	2	4	2
39175	2	3	3	2	1	2	3	3	2	3	4	3
35991	2	3	1	3	0	1	4	3	3	4	4	3
36747	2	2	3	2	0	2	2	3	2	4	4	3
36364	4	1	3	3	0	0	4	3	2	4	4	3
36238	2	3	3	2	1	0	2	3	2	2	4	3
27239	4	2	3	2	1	2	5	4	3	2	4	3
37526	2	1	3	3	0	2	5	3	4	3	4	3
37526	2	1	3	3	0	2	5	3	4	3	4	3
36097	2	2	3	2	1	2	3	3	3	3	4	3
23324	1	2	3	1	1	1	3	2	2	3	4	3

Annexe C

Modèles de préférences

TABLE C.1 – Modèle de préférence $MP_{1,2}$

Classe de décision	Règles de décision	Force
Au plus Cl_1 (Cl_1^{\leq})	Si $f(A_{i,2}, g_{7,2}) \leq 2$ Alors $A_{i,2} \in Cl_1^{\leq}$	42%
	Si $f(A_{i,2}, g_{4,2}) \leq 1 \wedge f(A_{i,2}, g_{11,2}) \leq 1$ Alors $A_{i,2} \in Cl_1^{\leq}$	28%
Au plus Cl_2 (Cl_2^{\leq})	Si $f(A_{i,2}, g_{9,2}) \leq 1$ Alors $A_{i,2} \in Cl_2^{\leq}$	85%
	Si $f(A_{i,2}, g_{11,2}) \leq 3$ Alors $A_{i,2} \in Cl_2^{\leq}$	70%
Au moins Cl_2 (Cl_2^{\geq})	Si $f(A_{i,2}, g_{2,2}) \geq 3 \wedge f(A_{i,2}, g_{7,2}) \geq 5$ Alors $A_{i,2} \in Cl_2^{\geq}$	26%
	Si $f(A_{i,2}, g_{3,2}) \geq 3 \wedge f(A_{i,2}, g_{10,2}) \geq 3 \wedge f(A_{i,2}, g_{11,2}) \geq 2$ Alors $A_{i,2} \in Cl_2^{\geq}$	52%
	Si $f(A_{i,2}, g_{7,2}) \geq 5 \wedge f(A_{i,2}, g_{11,2}) \geq 2$ Alors $A_{i,2} \in Cl_2^{\geq}$	52%
Au moins Cl_3 (Cl_3^{\geq})	Si $f(A_{i,2}, g_{9,2}) \geq 3$ Alors $A_{i,2} \in Cl_3^{\geq}$	40%
	Si $f(A_{i,2}, g_{2,2}) \geq 3 \wedge f(A_{i,2}, g_{10,2}) \geq 4$ Alors $A_{i,2} \in Cl_3^{\geq}$	20%
	Si $f(A_{i,2}, g_{1,2}) \geq 4$ Alors $A_{i,2} \in Cl_3^{\geq}$	20%
	Si $f(A_{i,2}, g_{2,2}) \geq 3 \wedge f(A_{i,2}, g_{7,2}) \geq 5 \wedge f(A_{i,2}, g_{9,2}) \geq 2$ Alors $A_{i,2} \in Cl_3^{\geq}$	20%
	Si $f(A_{i,2}, g_{4,2}) \geq 3 \wedge f(A_{i,2}, g_{6,2}) \geq 2 \wedge f(A_{i,2}, g_{10,2}) \geq 4 \wedge f(A_{i,2}, g_{11,2}) \geq 4$ Alors $A_{i,2} \in Cl_3^{\geq}$	20%

TABLE C.2 – Modèle de préférence $MP_{2,3}$

Classe de décision	Règles de décision	Force
Au plus Cl_1 (Cl_1^{\leq})	Si $f(A_{i,3}, g_{10,3}) \leq 1 \wedge f(A_{i,3}, g_{7,3}) \leq 2$ Alors $A_{i,3} \in Cl_1^{\leq}$	20%
Au plus Cl_2 (Cl_2^{\leq})	Si $f(A_{i,3}, g_{9,3}) \leq 1$ Alors $A_{i,3} \in Cl_2^{\leq}$	80%
	Si $f(A_{i,3}, g_{10,3}) \leq 3 \wedge f(A_{i,3}, g_{11,3}) \leq 3$ Alors $A_{i,3} \in Cl_2^{\leq}$	52%
Au moins Cl_2 (Cl_2^{\geq})	Si $f(A_{i,3}, g_{10,3}) \geq 4 \wedge f(A_{i,3}, g_{2,3}) \geq 3$ Alors $A_{i,3} \in Cl_2^{\geq}$	20%
	Si $f(A_{i,3}, g_{7,3}) \geq 5 \wedge f(A_{i,3}, g_{9,3}) \geq 2 \wedge$ $f(A_{i,3}, g_{10,3}) \geq 3 \wedge f(A_{i,3}, g_{11,3}) \geq 2$ Alors $A_{i,3} \in Cl_2^{\geq}$	20%
	Si $f(A_{i,3}, g_{3,3}) \geq 2 \wedge f(A_{i,3}, g_{7,3}) \geq 3 \wedge$ $f(A_{i,3}, g_{8,3}) \geq 2 \wedge f(A_{i,3}, g_{10,3}) \geq 3 \wedge$ $f(A_{i,3}, g_{11,3}) \geq 2 \wedge f(A_{i,3}, g_{1,3}) \geq 2$ Alors $A_{i,3} \in Cl_2^{\geq}$	70%
	Si $f(A_{i,3}, g_{3,3}) \geq 3 \wedge f(A_{i,3}, g_{5,3}) \geq 1 \wedge$ $f(A_{i,3}, g_{7,3}) \geq 3 \wedge f(A_{i,3}, g_{8,3}) \geq 3 \wedge$ $f(A_{i,3}, g_{10,3}) \geq 3$ Alors $A_{i,3} \in Cl_2^{\geq}$	25%
Au moins Cl_3 (Cl_3^{\geq})	Si $f(A_{i,3}, g_{9,3}) \geq 4$ Alors $A_{i,3} \in Cl_3^{\geq}$	25%
	Si $f(A_{i,3}, g_{2,3}) \geq 3 \wedge f(A_{i,3}, g_{9,3}) \geq 2 \wedge$ $f(A_{i,3}, g_{10,3}) \geq 4$ Alors $A_{i,3} \in Cl_3^{\geq}$	30%

TABLE C.3 – Modèle de préférence $MP_{3,4}$

Classe de décision	Règles de décision	Force
Au plus Cl_1 (Cl_1^{\leq})	Si $f(A_{i,4}, g_{4,4}) \leq 2 \wedge f(A_{i,4}, g_{7,4}) \leq 2 \wedge f(A_{i,4}, g_{8,4}) \leq 2 \wedge f(A_{i,4}, g_{11,4}) \leq 2$ Alors $A_{i,4} \in Cl_1^{\leq}$	23%
	Si $f(A_{i,4}, g_{7,4}) \leq 2 \wedge f(A_{i,4}, g_{10,4}) \leq 1 \wedge f(A_{i,4}, g_{11,4}) \leq 1$ Alors $A_{i,4} \in Cl_1^{\leq}$	10%
Au plus Cl_2 (Cl_2^{\leq})	Si $f(A_{i,4}, g_{9,4}) \leq 1$ Alors $A_{i,4} \in Cl_2^{\leq}$	71%
	Si $f(A_{i,4}, g_{10,4}) \leq 1 \wedge f(A_{i,4}, g_{11,4}) \leq 2$ Alors $A_{i,4} \in Cl_2^{\leq}$	28%
Au moins Cl_2 (Cl_2^{\geq})	Si $f(A_{i,4}, g_{4,4}) \geq 3 \wedge f(A_{i,4}, g_{9,4}) \geq 2 \wedge f(A_{i,4}, g_{10,4}) \geq 4$ Alors $A_{i,4} \in Cl_2^{\geq}$	23%
	Si $f(A_{i,4}, g_{2,4}) \geq 3 \wedge f(A_{i,4}, g_{4,4}) \geq 3 \wedge f(A_{i,4}, g_{5,4}) \geq 1 \wedge f(A_{i,4}, g_{7,4}) \geq 5 \wedge f(A_{i,4}, g_{11,4}) \geq 2$ Alors $A_{i,4} \in Cl_2^{\geq}$	10%
	Si $f(A_{i,4}, g_{11,4}) \geq 3 \wedge f(A_{i,4}, g_{10,4}) \geq 3 \wedge f(A_{i,4}, g_{4,4}) \geq 2 \wedge f(A_{i,4}, g_{6,4}) \geq 1 \wedge f(A_{i,4}, g_{7,4}) \geq 3 \wedge f(A_{i,4}, g_{8,4}) \geq 2$ Alors $A_{i,4} \in Cl_2^{\geq}$	28%
Au moins Cl_3 (Cl_3^{\geq})	Si $f(A_{i,4}, g_{9,4}) \geq 4$ Alors $A_{i,4} \in Cl_3^{\geq}$	16%
	Si $f(A_{i,4}, g_{2,4}) \geq 3 \wedge f(A_{i,4}, g_{4,4}) \geq 3 \wedge f(A_{i,4}, g_{8,4}) \geq 3 \wedge f(A_{i,4}, g_{9,4}) \geq 2 \wedge f(A_{i,4}, g_{10,4}) \geq 4$ Alors $A_{i,4} \in Cl_3^{\geq}$	10%

TABLE C.4 – Modèle de préférence $MP_{4,5}$

Classe de décision	Règles de décision	Force
Au plus Cl_1 (Cl_1^{\leq})	Si $f(A_{i,5}, g_{2,5}) \leq 2 \wedge f(A_{i,5}, g_{7,5}) \leq 3 \wedge f(A_{i,5}, g_{8,5}) \leq 2 \wedge f(A_{i,5}, g_{9,5}) \leq 1 \wedge f(A_{i,5}, g_{10,5}) \leq 2 \wedge f(A_{i,5}, g_{11,5}) \leq 2$ Alors $A_{i,5} \in Cl_1^{\leq}$	10%
Au plus Cl_2 (Cl_2^{\leq})	Si $f(A_{i,5}, g_{9,5}) \leq 1$ Alors $A_{i,5} \in Cl_2^{\leq}$	75%
	Si $f(A_{i,5}, g_{10,5}) \leq 1 \wedge f(A_{i,5}, g_{11,5}) \leq 2$ Alors $A_{i,5} \in Cl_2^{\leq}$	25%
Au moins Cl_2 (Cl_2^{\geq})	Si $f(A_{i,5}, g_{2,5}) \geq 3 \wedge f(A_{i,5}, g_{5,5}) \geq 1 \wedge f(A_{i,5}, g_{7,5}) \geq 5 \wedge f(A_{i,5}, g_{11,5}) \geq 2$ Alors $A_{i,5} \in Cl_2^{\geq}$	12%
	Si $f(A_{i,5}, g_{3,5}) \geq 3 \wedge f(A_{i,5}, g_{5,5}) \geq 1 \wedge f(A_{i,5}, g_{7,5}) \geq 5 \wedge f(A_{i,5}, g_{10,5}) \geq 3 \wedge f(A_{i,5}, g_{11,5}) \geq 2$ Alors $A_{i,5} \in Cl_2^{\geq}$	10%
	Si $f(A_{i,5}, g_{3,5}) \geq 3 \wedge f(A_{i,5}, g_{6,5}) \geq 1 \wedge f(A_{i,5}, g_{7,5}) \geq 3 \wedge f(A_{i,5}, g_{8,5}) \geq 2 \wedge f(A_{i,5}, g_{10,5}) \geq 3 \wedge f(A_{i,5}, g_{11,5}) \geq 3$ Alors $A_{i,5} \in Cl_2^{\geq}$	27%
Au moins Cl_3 (Cl_3^{\geq})	Si $f(A_{i,5}, g_{9,5}) \geq 4$ Alors $A_{i,5} \in Cl_3^{\geq}$	20%

TABLE C.5 – Cores : l'ensemble de critères pertinents pour la classification faite par le décideur

Semaine	Core
Semaine 1-2	$g_7, g_8, g_9, g_{10}, g_{11}$
Semaine 2-3	$g_2, g_3, g_5, g_6, g_7, g_8, g_9, g_{11}$
Semaine 3-4	g_9, g_{11}
Semaine 4-5	$g_2, g_3, g_4, g_4, g_9, g_{11}$

Annexe D

Mesures de performances des modèles de prédiction

- Vrai positif (VP) : élément de la classe positive correctement prédit.
- Vrai négatif (VN) : élément de la classe négative correctement prédit.
- Faux positif (FP) : élément de la classe positive mal prédit.
- Faux négatif (FN) : élément de la classe négative mal prédit.

Ces informations peuvent être visualisés sous forme d'une matrice de confusion :

TABLE D.1 – Matrice de confusion

		Classe prédite	
		Classe négative	Classe positive
Classe réelle	Classe négative	VN	FN
	Classe positive	FP	VP

- Précision. Proportion d'éléments bien classés pour une classe donnée

$$Precision = \frac{VP}{VP+FP}$$

- Rappel. Proportion d'éléments bien classés par rapport au nombre d'éléments de la classe à prédire

$$Rappel = \frac{VP}{VP+FN}$$

- F-mesure. Mesure de compromis et d'harmonie entre précision et rappel

$$F - mesure = \frac{2 * precision * rappel}{precision + rappel}$$

164 ANNEXE D. MESURES DE PERFORMANCES DES MODÈLES DE PRÉDICTION

Il est possible de calculer tous ces indicateurs pour chaque classe. La moyenne sur chaque classe de ces indicateurs donne des indicateurs globaux sur la qualité du classifieur.

- Précision moyenne

$$Precision_{moyenne} = \frac{1}{k} \sum_{i=1}^k \frac{VP_i}{VP_i + FP_i}$$

- Rappel moyen

$$Rappel_{moyen} = \frac{1}{k} \sum_{i=1}^k \frac{VP_i}{VP_i + FN_i}$$

- F-mesure moyenne

$$F - mesure_{moyenne} = \frac{2 * precision_{moyenne} * rappel_{moyen}}{precision_{moyenne} + rappel_{moyen}}$$

- *Accuracy* (Exactitude) : C'est la proportion de résultats corrects obtenus par un classifieur.

$$Accuracy = \frac{VP + VN}{VP + VN + FP + FN}$$

Annexe E

Mesures de performance des approches de prédiction

- VP : Vrai Positif, VN : Vrai Négatif, FP : Faux Positif, FN : Faux Négatif
- Pr : Précision, Rap : Rappel
- F-mes : Fmesure, F-G : F-mesure Globale

E.1 Approche optimiste non-cumulative

TABLE E.1 – Approche optimiste non-cumulative

	Cl_1	VP	FP	VN	FN	Pr	Rap	F-mes	F-G
S1-2	Cl_1	162	269	1018	86	0.37	0.65	0.47	0.49
	Cl_2	765	90	185	495	0.89	0.60	0.71	
	Cl_3	14	235	1273	13	0.05	0.51	0.09	
S2-3	Cl_1	356	302	522	355	0.54	0.50	0.51	0.32
	Cl_2	58	82	680	715	0.41	0.07	0.11	
	Cl_3	49	688	796	2	0.06	0.96	0.11	
S3-4	Cl_1	18	2	710	805	0.9	0.02	0.03	0.45
	Cl_2	434	596	255	250	0.42	0.63	0.50	
	Cl_3	27	458	1049	1	0.05	0.96	0.09	
S4-5	Cl_1	1039	15	345	136	0.98	0.88	0.92	0.67
	Cl_2	160	106	1124	145	0.60	0.52	0.55	
	Cl_3	50	165	1315	5	0.23	0.90	0.36	

E.2 Approche optimiste cumulative

TABLE E.2 – Approche optimiste cumulative

	Cl_1	VP	FP	VN	FN	Pr	Rap	F-mes	F-G
S1-2	Cl_1	162	269	1018	86	0.37	0.65	0.47	0.49
	Cl_2	765	90	185	495	0.89	0.60	0.71	
	Cl_3	14	235	1273	13	0.05	0.51	0.09	
S2-3	Cl_1	202	149	675	509	0.57	0.28	0.37	0.40
	Cl_2	252	323	439	521	0.43	0.32	0.36	
	Cl_3	45	564	920	6	0.07	0.88	0.12	
S3-4	Cl_1	78	15	697	745	0.83	0.09	0.16	0.54
	Cl_2	612	724	120	79	0.45	0.88	0.59	
	Cl_3	20	86	1428	1	0.18	0.95	0.30	
S4-5	Cl_1	292	29	329	885	0.90	0.24	0.37	0.50
	Cl_2	201	868	354	112	0.18	0.64	0.28	
	Cl_3	43	102	1378	12	0.29	0.78	0.42	

E.3 Approche pessimiste non-cumulative

TABLE E.3 – Approche pessimiste non-cumulative

	Cl_1	VP	FP	VN	FN	Pr	Rap	F-mes	F-G
S1-2	Cl_1	244	984	302	5	0.19	0.97	0.31	0.45
	Cl_2	275	14	261	985	0.95	0.21	0.34	
	Cl_3	5	13	1495	22	0.27	0.18	0.20	
S2-3	Cl_1	633	635	189	78	0.49	0.89	0.63	0.44
	Cl_2	82	60	702	691	0.57	0.10	0.17	
	Cl_3	23	102	1382	28	0.18	0.45	0.25	
S3-4	Cl_1	613	403	309	210	0.60	0.74	0.66	0.52
	Cl_2	278	216	628	413	0.57	0.40	0.47	
	Cl_3	10	15	1499	11	0.4	0.47	0.43	
S4-5	Cl_1	1172	274	84	5	0.81	0.99	0.89	0.54
	Cl_2	28	13	1209	285	0.68	0.08	0.14	
	Cl_3	32	16	1464	23	0.66	0.58	0.61	

E.4 Approche pessimiste cumulative

TABLE E.4 – Approche pessimiste cumulative

	Cl_1	VP	FP	VN	FN	Pr	Rap	F-mes	F-G
S1-2	Cl_1	244	984	302	5	0.19	0.97	0.31	0.45
	Cl_2	275	14	261	985	0.95	0.21	0.34	
	Cl_3	5	13	1495	22	0.27	0.18	0.20	
S2-3	Cl_1	515	384	446	190	0.57	0.73	0.64	0.52
	Cl_2	334	193	571	437	0.63	0.43	0.51	
	Cl_3	29	80	1396	30	0.26	0.49	0.4	
S3-4	Cl_1	800	457	255	23	0.63	0.97	0.76	0.61
	Cl_2	230	32	819	454	0.87	0.33	0.48	
	Cl_3	15	1	1506	13	0.93	0.53	0.67	
S4-5	Cl_1	1158	204	154	19	0.85	0.98	0.91	0.66
	Cl_2	104	26	1200	205	0.80	0.33	0.46	
	Cl_3	31	12	1474	18	0.72	0.63	0.67	

Annexe F

Les systèmes de recommandation

F.1 Synthèse sur les techniques de filtrage

Dans la littérature, plusieurs techniques de filtrage ont été proposées pour définir un système de recommandation, à savoir le filtrage collaboratif (Goldberg *et al.*, 1992), le filtrage basé contenu (Pazzani et Billsus, 2007), le filtrage basé connaissance (Burke *et al.*, 1996), le filtrage démographique (Burke, 2002), etc. L'objectif de ces techniques est de trouver une correspondance entre le profil utilisateur et le profil de l'item.

F.1.1 Filtrage collaboratif

Cette technique est l'une des techniques de recommandation les plus anciennes et les plus prometteuses. Elle fournit des recommandations en appliquant le principe de correspondance qui rassemble les utilisateurs ayant des intérêts similaires. L'idée est de prévoir les items souhaités par un utilisateur actif sur la base des avis (évaluations, notes, votes, etc.) exprimés par d'autres personnes sur ces mêmes items. Cette technique définit un voisinage pour chaque utilisateur : c'est l'ensemble des utilisateurs ayant apprécié des items qui ont été déjà appréciés par l'utilisateur cible. Le filtrage collaboratif prend en entrée les évaluations prononcées par tous les utilisateurs du système y compris l'utilisateur cible. Il applique, par la suite, une fonction de similarité pour déterminer le voisinage. Une fonction de prédiction est enfin utilisée afin de prédire l'évaluation qui pourra être donnée par l'utilisateur cible à un item qu'il n'a pas encore vu et évalué. Deux approches de filtrage collaboratif existent :

- Utilisateur-à-Utilisateur : ce type de filtrage cherche à trouver les utilisateurs ayant des avis similaires. Si deux utilisateurs u_1 et u_2 ont déjà apprécié les mêmes items, alors s'il existe un item i qui est apprécié par u_1 et n'est pas encore vu par u_2 , cet item sera recommandé à u_2 . Cette approche est coûteuse en temps de calcul quand elle est appliquée sur un système hébergeant un nombre massif d'items et aussi d'utilisateurs.

- Item-à-Item : ce type a été proposé par Linden *et al.* (2003) pour minimiser le temps de calcul consommé par l'approche Utilisateur-à-Utilisateur. Elle raisonne ainsi sur l'item au lieu de l'utilisateur. Si deux items i_1 et i_2 ont été appréciés par un ensemble d'utilisateurs, cela dit que les utilisateurs ayant apprécié l'item i_1 apprécieront aussi l'item i_2 . Donc, l'item i_2 sera recommandé pour tout utilisateur ayant apprécié i_1 .

Le filtrage collaboratif est généralement basé sur une fonction de similarité (la distance euclidienne, le coefficient de la corrélation de Pearson, la distance cosinus, etc.) ou une fonction de clustering (KNN, modèle bayésien, etc.) pour l'identification du voisinage et une fonction de prédiction pour prédire l'appréciation de l'utilisateur cible par rapport à chaque item apprécié par le voisinage sélectionné.

F.1.2 Filtrage basé contenu

Le filtrage basé-contenu a aussi ses racines dans ce domaine de recherche. Contrairement au filtrage collaboratif basé uniquement les évaluations des utilisateurs, le filtrage basé-contenu s'appuie sur les caractéristiques des utilisateurs et celles des items pour prédire les recommandations. Il est ainsi basé sur l'analyse et la représentation des items pour la construction d'un "profil item" et de même sur l'analyse et la représentation de préférences de l'utilisateur pour la construction d'un "profil utilisateur". Les préférences de l'utilisateur ont été extraits à partir de son historique de recherche et de ce qu'il a déjà apprécié dans le passé. Afin de trouver une correspondance entre le profil utilisateur et chaque profil item, plusieurs algorithmes ont été définis (les arbres de décision tels que ID3 (Quinlan, 1986), l'algorithme du plus proche voisin (Salton, 1989), l'algorithme de Relevance feedback (Rocchio, 1971). Ces algorithmes doivent fournir une estimation de la probabilité qu'un utilisateur appréciera un nouvel item. Le filtrage basé contenu est particulièrement prometteur pour la recherche de document de nature textuelle sur le web en utilisant la technique d'extraction de mots clé (Witten *et al.*, 1999) et la mesure TF-IDF (Term Frequency-Inverse Document Frequency) (Salton et McGill, 1986). Un exemple détaillé sur la mise en place de cette technique est présenté dans (Lang, 1995) pour le filtrage des actualités sur le net.

F.1.3 Filtrage basé connaissance

Le filtrage basé connaissance est aussi une technique prometteuse malgré que son utilisation reste limitée par rapport aux deux types de filtrage suscités. Il applique des inférences sur un ensemble d'items pour trouver celui qui doit répondre à un besoin spécifique d'un utilisateur cible. Cette technique prend en entrée le profil utilisateur, les paramètres contextuels et les caractéristiques de tous les items. Le filtrage basé connaissances fait l'intermédiaire entre les caractéristiques du modèle de l'utilisateur (*i.e.* ses exigences) et les caractéristiques des items (*i.e.* le catalogue). Le modèle de l'utilisateur peut avoir n'importe quelle structure de connaissance

(requête, une partie d'une ontologie, etc.) qui supporte au mieux le processus d'inférence. Le processus conversationnel de recommandation basée sur la connaissance respecte toujours les trois étapes suivantes : d'abord, les utilisateurs spécifient leurs exigences. Ensuite, les systèmes essaient de comparer les exigences avec les caractéristiques des items existants pour trouver des solutions. Enfin, si une solution est trouvée, elle sera évidemment recommandée, sinon les utilisateurs auront une opportunité pour changer leurs exigences. Cette procédure fonctionne de manière itérative jusqu'à atteindre le but. Les recommandations des utilisateurs sont indépendantes de leurs goûts individuels mais sont principalement basées sur leurs connaissances sur le champ de l'item recherché. Par exemple, un système utilisant le filtrage basé connaissance pour la recommandation d'un restaurant dans une ville spécifique nécessite les préférences de l'utilisateur cible telles que l'emplacement, la cuisine préférée, le rapport qualité/prix, etc.

F.1.4 Filtrage démographique

Ce filtrage catégorise les utilisateurs en fonction de leurs données démographiques (sexe, âge, pays, niveau d'études, etc). Les recommandations sont produites selon les évaluations des utilisateurs du même groupe (appelé aussi niche) sur l'ensemble des items. Ce type repose sur l'hypothèse que deux utilisateurs qui ont évolués dans un même environnement sont plus susceptibles d'avoir le même goût et de partager les mêmes préférences.

La Figure (6.3) distingue les quatre techniques en ce qui concerne la source de connaissance et les inputs sur lesquels la recommandation est basée.

Les techniques que nous avons citées ci-dessus sont les plus exploitées dans la littérature et dans les projets du monde réel. Cependant, plusieurs autres techniques ont été définies tels que le filtrage basé sur l'utilité (Burke, 2002), les approches basées sur les implications statistiques¹ (Couturier, 2005), les approches multi-agents² (Shi, 2004), etc.

F.2 Inconvénients et avantages des techniques de filtrage

Chacune des techniques de filtrage adoptées par les systèmes de recommandation est caractérisée par des avantages aussi bien que des limitations. Dans cette

1. Ce filtrage est par exemple utilisé pour la recommandation des films sur le site Allociné <http://www.allocine.fr/>. Ce site est basé sur les annotations données par la presse. Utilise des "règles d'implication", calculées par un moteur de recherche nommé "CHIC", informant que la presse qui a apprécié un film a également apprécié une liste d'autres films.

2. Ce filtrage est développé pour le programme de télévision TV-anytime. Il est basé sur trois agents : Agent de filtrage pour filtrer les informations en fonction de la similitude entre le programme et l'utilisateur, agent d'adaptation pour adapter le profil utilisateur au type des informations filtrées et agent utilisateur pour accueillir les intérêts de l'utilisateur et lui donner par la suite la possibilité de les modifier pour une fin d'adaptation.

F.2. INCONVÉNIENTS ET AVANTAGES DES TECHNIQUES DE FILTRAGE 171

section, nous rappelons les principaux avantages et limitations les plus cités dans la littérature (Burke, 2002 ; 2007 ; Soualah-Alila, 2015 ; Bonnin, 2010).

- a Cross-genre niches : ce terme réfère à la novelleté et à l'originalité des items recommandés. Le filtrage dans ce cas doit renvoyer à l'utilisateur des items non familiers.
- b Connaissance du domaine : le filtrage n'exige aucune connaissance préalable sur le domaine. Le coût d'acquisition d'une telle connaissance est généralement élevé.
- c Feed-back implicite suffisant : le filtrage peut se contenter d'utiliser les données fournies par le système de traçabilité sans faire recours aux évaluations explicites.
- d Adaptabilité : la qualité de la recommandation s'améliore au cours du temps vu l'enrichissement continu de la base de données (évaluations ; préférences...).
- e Démarrage à froid, cas d'un nouvel utilisateur : se produit lorsque l'utilisateur actif est nouveau et donc le système n'a pas assez d'informations sur ses évaluations précédentes ce qui rend difficile sa catégorisation.
- f Démarrage à froid, cas d'un nouvel item : se produit lorsque l'item n'a pas encore reçu suffisamment d'évaluations ce qui minimise sa recommandation malgré sa pertinence.
- g Problème de densité des évaluations : se produit lorsque le nombre d'utilisateurs est limité par rapport aux nombre d'items ou bien d'utilisateurs évaluent les mêmes items ce qui réduit l'espace de recommandation.
- h Le Gray sheep : se produit lorsque les utilisateurs ont des goûts atypiques ou particuliers qui sont difficiles à catégoriser.
- i Le shilling : se produit quand les utilisateurs se servent des faux profils afin de voter pour ou contre les items ce qui amène à des évaluations falsifiées aux inputs des systèmes.
- j Connaissance démographique : ce genre de connaissances n'est pas toujours disponible puisqu'il touche généralement à la vie privée des utilisateurs. D'autres techniques sont alors exigées afin de respecter la confidentialité du domaine.

Table 1 synthétise les quatre approches en mettant l'accent sur les avantages et les inconvénients de chacune.

TABLE F.1 – Synthèse sur les quatre techniques de filtrage

Technique	Background	Input	Avantages	Limitations
Collaboratif : “Montrez-moi ce que mes pairs ont apprécié”	Les notes données aux items par l'ensemble de tous les utilisateurs	Les notes données aux items par l'utilisateur actif	A ; B ; D	E ; F ; G ; H ; I
Basé contenu : “Montrez-moi les similaires à ce que j'ai aimé dans le passé”	Caractéristiques de tous les items	Les notes données aux items par l'utilisateur actif	B ; C ; D	E ; H ; I
Basé connaissance : “Montrez-moi ce qui satisfait mes besoins”	Caractéristiques de tous les items	Description des besoins de l'utilisateur actif	D	H ; I
Démographique : “Montrez-moi ce que mes patriotes ont apprécié”	Les informations démographiques des utilisateurs	Les informations démographiques de l'utilisateur actif	A ; B ; D	E ; F ; G ; H ; I ; J

F.3 Modèles hybrides

Les modèles hybrides combinent deux ou plusieurs techniques à la fois afin de profiter de leurs avantages et de palier leurs limitations. Ils sont principalement définis par (Burke, 2002 ; 2007) sous plusieurs types. La combinaison la plus fréquente dans la littérature est celle du filtrage collaboratif et filtrage basé contenu (Melville *et al.*, 2002 ; Cotter et Smyth, 2000). Burke (2007) a défini sept techniques principales d'hybridation :

- Pondération : le score des différentes composantes de recommandation sont combinées numériquement.
- Commutation : selon le cas, le système choisit et applique la technique la plus appropriée parmi les techniques existantes.
- Mixte : concaténer dans une même liste les différentes recommandations issues de chaque technique appliquée à part.
- Combinaison de caractéristiques : les caractéristiques provenant de différentes sources de connaissances sont combinées ensemble et données à un algorithme de recommandation unique.
- Augmentation de caractéristiques : une seule technique de recommandation est d'abord utilisée pour calculer une ou plusieurs caractéristiques qui seront par la suite fournies en input à la technique suivante.
- Cascade : appliquer une hiérarchie sur les modèles, les moins haut placés servant à renforcer les scores de ressources obtenus avec les modèles plus haut placés.

- Meta-niveaux : une technique de recommandation est appliquée et produit une sorte de modèle, qui sera utilisé en input par la technique suivante.

Plusieurs autres exemples sur des systèmes de recommandation basés sur des approches hybrides sont détaillés dans (Ricci *et al.*, 2011).

Bibliographie

- ABOU-ZEID, E.-S. (2002). An ontology-based approach to inter-organizational knowledge transfer. *Journal of Global Information Technology Management*, 5(3):32–47. 35
- AHER, S. B. et LOBO, L. (2013). Combination of machine learning algorithms for recommendation of courses in e-learning system based on historical data. *Knowledge-Based Systems*, 51:1–14. 118
- AJZEN, I. (2005). *Attitudes, personality, and behavior*. McGraw-Hill Education (UK). 21
- AL-ATABI, M. et DEBOER, J. (2014). Teaching entrepreneurship using massive open online course (mooc). *Technovation*, 34(4):261–264. 144
- ALONDERIENE, R., PUNDZIENE, A. et KRISCIUNAS, K. (2006). Tacit knowledge acquisition and transfer in the process of informal learning. *Problems and perspectives in management*, 4(3):134–145. 16
- ALRAIMI, K. M., ZO, H. et CIGANEK, A. P. (2015). Understanding the moocs continuance : The role of openness and reputation. *Computers & Education*, 80:28–38. 49
- ALTMAN, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The journal of finance*, 23(4):589–609. 85
- AMATO, G. et STRACCIA, U. (1999). User profile modeling and applications to digital libraries. In *International Conference on Theory and Practice of Digital Libraries*, pages 184–197. Springer. 126
- AMBOS, T. C. et AMBOS, B. (2009). The impact of distance on knowledge transfer effectiveness in multinational corporations. *Journal of International Management*, 15(1):1–14. 127
- AMNUEYPORNSAKUL, B., BHAT, S. et CHINPRUTTHIWONG, P. (2014). Predicting attrition along the way : The uiuc model. In *Proceedings of the EMNLP 2014 Workshop on Analysis of Large Scale Social Interaction in MOOCs*, pages 55–59. 55, 57, 58

- ANDERSON, J. R. (1993). Problem solving and learning. *American Psychologist*, 48(1):35. 28
- ARDUIN, P.-E. (2013). *Vers une métrique de la commensurabilité des schémas d'interprétation*. Thèse de doctorat, Université Paris-Dauphine. 3, 15, 34, 127
- ARGOTE, L. et INGRAM, P. (2000). Knowledge transfer : A basis for competitive advantage in firms. *Organizational behavior and human decision processes*, 82(1): 150–169. 20, 21, 22
- ARGYRIS, C. et SCHÖN, D. A. (2002). *Apprentissage organisationnel : théorie, méthode, pratique*. De Boeck Supérieur. 28
- ARROW, K. (1971). The economic implications of learning by doing. *Readings in the theory of growth : a selection of papers from the 'Review of Economic Studies'*, page 131. 28
- ARROW, K. (1974). The limits of organization. 38
- ASHENAFI, M. M., RONCHETTI, M. et RICCARDI, G. (2016). Predicting student progress from peer-assessment data. *In EDM*, pages 270–275. 70
- BACCIANELLA, S., ESULI, A. et SEBASTIANI, F. (2010). Sentiwordnet 3.0 : An enhanced lexical resource for sentiment analysis and opinion mining. *In LREC*, volume 10, pages 2200–2204. 54
- BALAKRISHNAN, G. et COETZEE, D. (2013). Predicting student retention in massive open online courses using hidden markov models. *Electrical Engineering and Computer Sciences University of California at Berkeley*. 53, 57, 58, 70, 143
- BALMISSE, G. (2002). Gestion des connaissances(ouils et applications du knowledge management). *Entreprendre. Informatique*. 14
- BANATHY, B. (1994). Designing educational systems : Creating our future in a changing world. *Systemic change in education*, pages 27–34. 32
- BARAK, M. (2015). The same mooc delivered in two languages : Examining knowledge construction and motivation to learn. *Proceedings of the EMOOCS*, pages 217–223. 51, 126
- BARBER, M., DONNELLY, K., RIZVI, S. et SUMMERS, L. (2013). An avalanche is coming. london : Institute for public policy research. 43
- BARTOL, K. M. et SRIVASTAVA, A. (2002). Encouraging knowledge sharing : The role of organizational reward systems. *Journal of Leadership & Organizational Studies*, 9(1):64–76. 14

- BARWISE, J. et SELIGMAN, J. (1997). *Information flow : the logic of distributed systems*, volume 44. Cambridge University Press. 13
- BATES, T. (2012). What's right and what's wrong about coursera-style moocs. 44
- BECCALI, M., CELLURA, M. et MISTRETTA, M. (2003). Decision-making in energy planning. application of the electre method at regional level for the diffusion of renewable energy technology. *Renewable energy*, 28(13):2063–2087. 88
- BEDNAR, A. K., CUNNINGHAM, D., DUFFY, T. M. et PERRY, J. D. (1992). Theory into practice : How do we link. *Constructivism and the technology of instruction : A conversation*, pages 17–34. 30
- BELTON, V. et PICTET, J. (1997). A framework for group decision using a mcda model : sharing, aggregating or comparing individual information? *Journal of decision systems*, 6(3):283–303. 91, 93
- BENAZON, N. R. (2000). Predicting negative spousal attitudes toward depressed persons : A test of coyne's interpersonal model. *Journal of Abnormal Psychology*, 109(3):550–554. 83
- BERGER, P. et LUCKMANN, T. (1967). La construcción social. *Xa Realidad. Buenos Aires*. 15
- BERNUS, P., NEMES, L. et WILLIAMS, T. J. (1996). *Architectures for enterprise integration*. Springer Science & Business Media. 32
- BERTSCHI, S., BRESCIANI, S., CRAWFORD, T., GOEBEL, R., KIENREICH, W., LINDNER, M., SABOL, V. et MOERE, A. V. (2011). What is knowledge visualization? perspectives on an emerging discipline. *In Information Visualisation (IV), 2011 15th International Conference on*, pages 329–336. IEEE. 146
- BILLET, S. (1998). Appropriation and ontogeny : identifying compatibility between cognitive and sociocultural contributions to adult learning and development. *International Journal of Lifelong Education*, 17(1):21–34. 23
- BŁASZCZYŃSKI, J., GRECO, S. et SŁOWIŃSKI, R. (2012). Inductive discovery of laws using monotonic rules. *Engineering Applications of Artificial Intelligence*, 25(2):284–294. 6, 61
- BOISBOUVIER, d. (2011). Ecosystèmes d'affaires & de connaissances : Une lecture suivant les analogies du jeu de go. Mémoire de D.E.A., SKEMA Campus Paris La Défense. 14
- BONNIN, G. (2010). *Vers des systemes de recommandation robustes pour la navigation Web : inspiration de la modélisation statistique du langage*. Thèse de doctorat, Université Nancy II. 126, 171

- BONTIS, N., CROSSAN, M. M. et HULLAND, J. (2002). Managing an organizational learning system by aligning stocks and flows. *Journal of management studies*, 39(4):437–469. 31
- BOUGHZALA, I. et BRIGGS, R. O. (2012). A value frequency model of knowledge sharing : an exploratory study on knowledge sharability in cross-organizational collaboration. *Electronic Markets*, 22(1):9–19. 37
- BOUSBAHI, F. et CHORFI, H. (2015). Mooc-rec : a case based recommender system for moocs. *Procedia-Social and Behavioral Sciences*, 195:1813–1822. 119
- BOUZAYANE, S. et SAAD, I. (2017a). Dominance-based rough set approach to learn in the presence of class imbalance. *Workshop on Learning in the Presence of Class Imbalance and Concept Drift, International Joint Conference on Artificial Intelligence (IJCAI)*. 142
- BOUZAYANE, S. et SAAD, I. (2017b). Prediction method based drsa to improve the individual knowledge appropriation in a collaborative learning environment : Case of moocs. *In Proceedings of the 50th Hawaii International Conference on System Sciences*, pages 124–133. 61, 92, 115
- BOYER, S. et VEERAMACHANENI, K. (2015). Transfer learning for predictive models in massive open online courses. *In International Conference on Artificial Intelligence in Education*, pages 54–63. Springer. 143, 144
- BRAUNHOFER, M. et RICCI, F. (2017). Selective contextual information acquisition in travel recommender systems. *Information Technology & Tourism*, 17(1):5–29. 145
- BRESLOW, L., PRITCHARD, D. E., DEBOER, J., STUMP, G. S., HO, A. D. et SEATON, D. T. (2013). Studying learning in the worldwide classroom : Research into edx’s first mooc. *Research & Practice in Assessment*, 8. 58
- BRINTON, C. G. et CHIANG, M. (2015). Mooc performance prediction via clicks-stream data and social learning networks. *In Computer Communications (INFOCOM), 2015 IEEE Conference on*, pages 2299–2307. IEEE. 52
- BROWN, J. S., COLLINS, A. et DUGUID, P. (1989). Situated cognition and the culture of learning. *Educational researcher*, 18(1):32–42. 30
- BURKE, R. (2002). Hybrid recommender systems : Survey and experiments. *User modeling and user-adapted interaction*, 12(4):331–370. 118, 168, 170, 171, 172
- BURKE, R. (2007). Hybrid web recommender systems. *In The adaptive web*, pages 377–408. Springer. 171, 172

- BURKE, R. D., HAMMOND, K. J. et YOUNG, B. C. (1996). Knowledge-based navigation of complex information spaces. *In Proceedings of the national conference on artificial intelligence*, volume 462, page 468. 168
- CABRERA, A., COLLINS, W. C. et SALGADO, J. F. (2006). Determinants of individual engagement in knowledge sharing. *The International Journal of Human Resource Management*, 17(2):245–264. 22
- CASTANO-MUNOZ, J., KALZ, M., KREIJNS, K. et PUNIE, Y. (2016). Influence of employer support for professional development on moocs enrolment and completion : Results from a cross-course survey. *Research Track*, page 251. 44
- CHANDRASEKARAN, M. K., KAN, M.-Y., TAN, B. C. et RAGUPATHI, K. (2015). Learning instructor intervention from mooc forums : Early results and issues. *arXiv preprint arXiv :1504.07206*. 56, 57, 58
- CHAPLOT, D. S., RHIM, E. et KIM, J. (2015). Predicting student attrition in moocs using sentiment analysis and neural networks. *In AIED Workshops*. 53, 54, 57, 58, 83, 143
- CHATURVEDI, S., GOLDWASSER, D. et DAUMÉ III, H. (2014). Predicting instructor’s intervention in mooc forums. *In ACL (1)*, pages 1501–1511. 55, 56, 57
- CHEN, H., LI, T., QIAO, S. et RUAN, D. (2010). A rough set based dynamic maintenance approach for approximations in coarsening and refining attribute values. *International Journal of Intelligent Systems*, 25:1005—1026. 71
- CHEN, T., ZHANG, W., LU, Q., CHEN, K., ZHENG, Z. et YU, Y. (2012). Svdfeature : a toolkit for feature-based collaborative filtering. *Journal of Machine Learning Research*, 13(Dec):3619–3622. 71, 121
- CHEVALIER, J. et ROUSSEAU, P. (1999). Classification in lea : building of a coherent family of criteria. *The International Journal of Life Cycle Assessment*, 4(6):352–356. 90
- CHIU, C.-M., HSU, M.-H. et WANG, E. T. (2006). Understanding knowledge sharing in virtual communities : An integration of social capital and social cognitive theories. *Decision support systems*, 42(3):1872–1888. 36, 126
- CHRISTENSEN, G., STEINMETZ, A., ALCORN, B., BENNETT, A., WOODS, D. et EMANUEL, E. J. (2013). The mooc phenomenon : Who takes massive open online courses and why ? 44
- CHYI LEE, C. et YANG, J. (2000). Knowledge value chain. *Journal of management development*, 19(9):783–794. 16

- CISEL, M. (2014a). Analyzing completion rates in the first french xmooc. *Proceedings of the European MOOC Stakeholder Summit*, 26. 51
- CISEL, M. (2014b). Mooc : les conditions de la réussite. *Distances et médiations des savoirs. Distance and Mediation of Knowledge*, 2(8). 49
- CLOW, D. (2013). Moocs and the funnel of participation. *In Proceedings of the Third International Conference on Learning Analytics and Knowledge*, pages 185–189. ACM. 43
- CODINA, V., RICCI, F. et CECCARONI, L. (2016). Distributional semantic pre-filtering in context-aware recommender systems. *User Modeling and User-Adapted Interaction*, 26(1):1–32. 145
- COHEN, W. M. et LEVINTHAL, D. A. (1990). Absorptive capacity : A new perspective on learning and innovation. *Administrative science quarterly*, pages 128–152. 20, 21, 38, 49
- COLOMO-PALACIOS, R., CASADO-LUMBRERAS, C., SOTO-ACOSTA, P. et MISRA, S. (2014). Providing knowledge recommendations : an approach for informal electronic mentoring. *Interactive Learning Environments*, 22(2):221–240. 35
- COTTER, P. et SMYTH, B. (2000). Ptv : Intelligent personalised tv guides. *In AAAI/IAAI*, pages 957–964. 172
- COUTURIER, R. (2005). Un système de recommandation basé sur l’analyse statistique implicite. *In Troisièmes Rencontres Internationales–Terzo Convegno Internazionale-Third International Conference*, pages 151–156. 170
- CREELMAN, A., EHLERS, U. et OSSIANNILSSON, E. (2014). Perspectives on mooc quality-an account of the efquel mooc quality project. *INNOQUAL-International Journal for Innovation and Quality in Learning*, 2(3):78–87. 43
- CUMMINGS, J. N. (2004). Work groups, structural diversity, and knowledge sharing in a global organization. *Management science*, 50(3):352–364. 22
- CURNOW, C., MULVANEY, R., CALDERON, R., WEINGART, E., NICELY, K., KELLER-GLAZE, H. et FALLESEN, J. (2006). Advanced learning theories applied to leadership development. Rapport technique, DTIC Document. 31
- DANIEL, J. (2012). Making sense of moocs : Musings in a maze of myth, paradox and possibility. *Journal of interactive Media in education*, 2012(3). 43
- DARADOUMIS, T., BASSI, R., XHAFI, F. et CABALLÉ, S. (2013). A review on massive e-learning (mooc) design, delivery and assessment. *In P2P, Parallel, Grid, Cloud and Internet Computing (3PGCIC), 2013 Eighth International Conference on*, pages 208–213. IEEE. 49, 55

- DASCALU, M.-I., BODEA, C.-N., MOLDOVEANU, A., MOHORA, A., LYTRAS, M. et de PABLOS, P. O. (2015). A recommender agent based on learning styles for better virtual collaborative learning experiences. *Computers in Human Behavior*, 45:243–253. 118
- DAVENPORT, T. H. et PRUSAK, L. (1998). *Working knowledge : How organizations manage what they know*. Harvard Business Press. 15, 20, 21, 26, 27, 39, 141
- DAVID, A., HATCHUEL, A. et LAUFER, R. (2001). *Les nouvelles fondations des sciences de gestion*. Vuibert. 90
- DAVIS, G. B., OLSON, M. H., AJENSTAT, J. et PEAUCELLE, J. L. (1986). *Système d'information pour le management : les bases*. 33
- DEBOER, J., HO, A. D., STUMP, G. S. et BRESLOW, L. (2014). Changing “course” reconceptualizing educational variables for massive open online courses. *Educational researcher*, page 0013189X14523038. 49
- DELEN, D., WALKER, G. et KADAM, A. (2005). Predicting breast cancer survivability : a comparison of three data mining methods. *Artificial intelligence in medicine*, 34(2):113–127. 83
- DENG, W., WANG, G., YANG, S. et HU, F. (2011). A new method for inconsistent multicriteria classification. *In International Conference on Rough Sets and Knowledge Technology*, pages 600–609. Springer. 62
- DEPOVER, C. et al. (2000). Un modèle d'apprentissage à distance basé sur le partage des connaissances. 123, 137
- DEVIRIEUX, C. J. (2007). *Pour une communication efficace : Quoi dire et comment le dire*. PUQ. 36, 122
- DHORNE, L., DEFLANDRE, J.-P., BERNAERT, O., BIANCHI, S. et THIROUARD, M. (2017). Mentoring learners in moocs : A new way to improve completion rates? *In European Conference on Massive Open Online Courses*, pages 29–37. Springer. 49
- DI BIASE, D., MAC EACHREN, A. M., KRYGIER, J. B. et REEVES, C. (1992). Animation and the role of map design in scientific visualization. *Cartography and geographic information systems*, 19(4):201–214. 147
- DODIG-CRNKOVIC, G. (2005). System modeling and information semantics. *In Proceedings of the fifth promote IT conference*. Janis Bubenko, Owen Eriksson, Hans Fernlund, and Mikael Lind (Studentlitteratur : Lund). 13

- DOODY, J. P. (2003). Information required for integrated coastal zone management : Conclusions from the european demonstration programme. *Coastal Management*, 31(2):163–173. 14
- DORSEY, D. W. (2003). Hiring for knowledge-based competition. *Managing knowledge for sustained competitive advantage : Designing strategies for effective human resource management*, 21:155. 22
- DOWNES, S. (2013). What makes a mooc massive. *Retrieved April*, 15:2014. 42
- DOWNES, S. et SIEMENS, G. (2008). Cck08-the distributed course. *The MOOC guide*. 42
- DRETSKE, F. (1981). The pragmatic dimension of knowledge. *Philosophical studies*, 40(3):363–378. 15
- DUAN, L., STREET, W. N. et XU, E. (2011). Healthcare information systems : data mining methods in the creation of a clinical recommender system. *Enterprise Information Systems*, 5(2):169–181. 118
- DUMAIS, S., CUTRELL, E., CADIZ, J. J., JANCKE, G., SARIN, R. et ROBBINS, D. C. (2016). Stuff i’ve seen : a system for personal information retrieval and re-use. *In ACM SIGIR Forum*, volume 49, pages 28–35. ACM. 126
- EASTMOND, D. V. (1994). Adult distance study through computer conferencing. *Distance Education*, 15(1):128–152. 123
- EDUCAUSE, E. (2013). 7 things you should know about moocs. *Educause Learning Initiative*. 2, 42
- EL SAID, G. R. (2016). Understanding how learners use massive open online courses and why they drop out thematic analysis of an interview study in a developing country. *Journal of Educational Computing Research*, page 0735633116681302. 3, 49, 139
- ELKAN, C. (2001). The foundations of cost-sensitive learning. *Proc. Int’l Joint Conf. Artificial Intelligence*, pages 973–978. 57
- ENGLE, D., MANKOFF, C. et CARBREY, J. (2015). Coursera’s introductory human physiology course : Factors that characterize successful completion of a mooc. *The International Review of Research in Open and Distributed Learning*, 16(2). 51
- ERMINE, J.-L., BOUGHZALA, I. et TOUNKARA, T. (2006). Critical knowledge map as a decision tool for knowledge transfer actions. *Electronic Journal of Knowledge Management*, 4(2):129–140. 35

- ERNST, J. V. et CLARK, A. C. (2013). Preferential learning of students in a post-secondary introductory engineering graphics course : A preliminary study focused on students at-risk. *120th ASEE Annual Conference and Exposition*, 23:1–9. 101
- ERTMER, P. A. et NEWBY, T. J. (1993). Behaviorism, cognitivism, constructivism : Comparing critical features from an instructional design perspective. *Performance improvement quarterly*, 6(4):50–72. 28
- FANTL, J. (2012). Knowledge how. *The Stanford Encyclopedia of Philosophy*. 18
- FETZER, J. H. (2004). Information : Does it have to be true? *Minds and Machines*, 14(2):223–229. 13
- FILION, L. J. et FORTIN, P.-A. (1991). *Vision et relations : clefs du succès de l'entrepreneur*. Les éditions de l'entrepreneur. 85
- FINI, A. (2009). The technological dimension of a massive open online course : The case of the cck08 course tools. *The International Review of Research in Open and Distributed Learning*, 10(5). 52
- FIOL, C. M. et LYLES, M. A. (1985). Organizational learning. *Academy of management review*, 10(4):803–813. 31
- FLORIDI, L. (2004). Outline of a theory of strongly semantic information. *Minds and machines*, 14(2):197–221. 13
- FLORIDI, L. (2008). The method of levels of abstraction. *Minds and machines*, 18(3):303–329. 13
- FLORIDI, L. (2011). *The philosophy of information*. Oxford University Press. 13, 15
- FORTIER, J.-Y. et KASSEL, G. (2004). Managing knowledge at the information level : an ontological approach. In *Proceedings of the ECAI'2004 Workshop on Knowledge Management and Organizational Memories*, pages 39–45. vii, 47, 48
- GARVIN, D. A. (1993). Building a learning organization. *Harvard business review*, 71(4):78–91. 31
- GHOSHAL, S. et BARTLETT, C. A. (1994). Linking organizational context and managerial action : The dimensions of quality of management. *Strategic Management Journal*, 15(S2):91–112. 38
- GHRAB, S. (2016). *Elaboration d'une cartographie multicritère pour l'aide à la caractérisation et l'évaluation des connaissances médicales*. Thèse de doctorat, Université de Sfax en Tunisie. 18, 19, 26, 35, 39, 141, 146

- GHRAB, S. et SAAD, I. (2016). Identifying crucial know-how and knowing-that for medical decision support. *International Journal of Decision Support System Technology (IJDSST)*, 8(4):14–33. 26, 62, 83, 85, 145
- GHRAB, S., SAAD, I., KASSEL, G. et GARGOURI, F. (2017). A core ontology of know-how and knowing-that for improving knowledge sharing and decision making in the digital age. *Journal of Decision Systems*, 26(2):138–151. 26, 145
- GIBAUD, B. et KASSEL, G. (2013). Sémantique des données de l'observation : une approche ontologique. Rapport technique, Boston, MA, USA. 13
- GILBERT, M. et CORDEY-HAYES, M. (1996). Understanding the process of knowledge transfer to achieve successful technological innovation. *Technovation*, 16(6):301–312. 21
- GOLDBERG, D., NICHOLS, D., OKI, B. M. et TERRY, D. (1992). Using collaborative filtering to weave an information tapestry. *Communications of the ACM*, 35(12):61–70. 168
- GOLDSTEIN, I. L. (1980). Training in work organizations. *Annual review of psychology*, 31(1):229–272. 20, 21
- GOODERHAM, P. N. (2007). Enhancing knowledge transfer in multinational corporations : a dynamic capabilities driven model. *Knowledge Management Research & Practice*, 5(1):34–43. 36, 127
- GRAHAM, G. (1999). *The Internet : a philosophical inquiry*. Psychology Press. 13
- GRANT, R. M. (1996). Toward a knowledge-based theory of the firm. *Strategic management journal*, 17(S2):109–122. 16
- GRECO, S., MATARAZZO, B. et SLOWINSKI, R. (2000). *Multicriteria classification by dominance-based rough set approach*. Università degli studi. 62
- GRECO, S., MATARAZZO, B. et SLOWINSKI, R. (2001a). Rough sets theory for multicriteria decision analysis. *EJOR*, 129(1):1–45. 8, 61, 64, 68, 94, 141
- GRECO, S., MATARAZZO, B., SLOWINSKI, R. et STEFANOWSKI, J. (2001b). An algorithm for induction of decision rules consistent with the dominance principle. In *Rough sets and current trends in computing*, pages 304–313. Springer. 68
- GRECO, S., SLOWINSKI, R., STEFANOWSKI, J. et ZURAWSKI, M. (2004). Incremental versus nonincremental rule induction for multicriteria classification. *Transaction on Rough Sets II*, pages 33–53. 62, 69, 71, 81
- GRICE, H. P. (1991). *Studies in the Way of Words*. Harvard University Press. 13

- GRUNDSTEIN, M. (2009). Gameth® : a constructivist and learning approach to identify and locate crucial knowledge. *International Journal of Knowledge and Learning*, 5(3-4):289–305. 34, 127
- GRUNDSTEIN, M., ARDUIN, P.-E. et ROSENTHAL-SABROUX, C. (2014). From information system to information and knowledge system. *In Italian Chapter of the Association for Information Systems (itAIS)*. 3, 34, 39
- GUÀRDIA, L., MAINA, M. et SANGRÀ, A. (2013). Mooc design principles : A pedagogical approach from the learner’s perspective. *eLearning Papers*, (33). 50
- GUILLOU, F. (2016). *On recommendation systems in a sequential context*. Thèse de doctorat, Université Lille 3. 145
- GUTIÉRREZ-ROJAS, I., LEONY, D., ALARIO-HOYOS, C., PÉREZ-SANAGUSTÍN, M. et DELGADO-KLOOS, C. (2014). Towards an outcome-based discovery and filtering of moocs using moocrank. *Proceedings of the Second MOOC European Stakeholders Summit*, pages 50–57. 120
- HALAWA, S., GREENE, D. et MITCHELL, J. (2014). Dropout prediction in moocs using learner activity features. *Experiences and best practices in and around MOOCs*, 7. 52, 70
- HALL, M. A. (1999). *Correlation-based feature selection for machine learning*. Thèse de doctorat, The University of Waikato. 4, 61
- HAMORI, M. (2017). The drivers of employer support for professional skill development in moocs. *In European Conference on Massive Open Online Courses*, pages 203–209. Springer. 44
- HARDEN, R. et CROSBY, J. (2000). The good teacher is more than a lecturer : the twelve roles of the teacher. retrieved october 30th, 2009. 32
- HARDER, B. (2013). Are moocs the future of medical education? *BMJ : British Medical Journal (Online)*, 346. 43
- HAWLEY, K. (2003). Success and knowledge-how. *American Philosophical Quarterly*, 40(1):19–31. 17, 26, 39
- HAYES, S. (2015). Moocs and quality : A review of the recent literature. 43
- HE, J., BAILEY, J., RUBINSTEIN, B. I. et ZHANG, R. (2015). Identifying at-risk students in massive open online courses. *In AAAI*, pages 1749–1755. 143
- HEY, J. (2004). The data, information, knowledge, wisdom chain : the metaphorical link. *Intergovernmental Oceanographic Commission*, 26. 15

- HLOSTA, M., HERRMANNOVA, D., VACHOVA, L., KUZILEK, J., ZDRAHAL, Z. et WOLFF, A. (2014). Modelling student online behaviour in a virtual learning environment. 42, 50
- HOENS, T. R., BLANTON, M., STEELE, A. et CHAWLA, N. V. (2013). Reliable medical recommendation systems with patient privacy. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 4(4):67. 118
- HONE, K. S. et EL SAID, G. R. (2016). Exploring the factors affecting mooc retention : A survey study. *Computers & Education*, 98:157–168. 3, 50, 139
- HSU, M.-H. (2008). A personalized english learning recommender system for esl students. *Expert Systems with Applications*, 34(1):683–688. 118
- HU, Q., CHAKHAR, S., SIRAJ, S. et LABIB, A. (2017). Spare parts classification in industrial manufacturing using the dominance-based rough set approach. *European Journal of Operational Research*. 6
- HUEMER, M. (2010). Sense-data. *Stanford encyclopedia of philosophy*. 25
- JIANG, S., WILLIAMS, A., SCHENKE, K., WARSCHAUER, M. et O'DOWD, D. (2014). Predicting mooc performance with week 1 behavior. *In Educational Data Mining 2014*. 144
- JOHNSON, D. W. et JOHNSON, R. T. (1994). *Learning together and alone. Cooperative, competitive, and individualistic learning*. ERIC. 31
- JOHNSON, S. D., ARAGON, S. R., SHAIK, N. et PALMA-RIVAS, N. (2000). Comparative analysis of learner satisfaction and learning outcomes in online and face-to-face learning environments. *Journal of interactive learning research*, 11(1):29. 32
- JONSSON, A. (2008). A transnational perspective on knowledge sharing : lessons learned from ikea's entry into russia, china and japan. *The international review of retail, Distribution and Consumer Research*, 18(1):17–44. 22
- JORDAN, K. (2014). Initial trends in enrolment and completion of massive open online courses. *The International Review of Research in Open and Distributed Learning*, 15(1). 49
- KARSENTI, T. (2013). What the research says. *International Journal of Technologies in Higher Education*, 10(2):23–37. 43
- KHALIL, H. et EBNER, M. (2013). "how satisfied are you with your mooc?"-a research study on interaction in huge online courses. *In EdMedia : World Conference on Educational Media and Technology*, volume 2013, pages 830–839. 45

- KIM, K.-j. et AHN, H. (2008). A recommender system using gaussian k-means clustering in an online shopping market. *Expert systems with applications*, 34(2):1200–1209. 118
- KING, W. R. (2008). An integrated architecture for an effective knowledge organization. *Journal of Knowledge Management*, 12(2):29–41. 23
- KIZILCEC, R. F. et HALAWA, S. (2015). Attrition and achievement gaps in online learning. In *Proceedings of the Second (2015) ACM Conference on Learning@Scale*, pages 57–66. ACM. 50, 52
- KIZILCEC, R. F., PIECH, C. et SCHNEIDER, E. (2013). Deconstructing disengagement : analyzing learner subpopulations in massive open online courses. In *Proceedings of the third international conference on learning analytics and knowledge*, pages 170–179. ACM. 52
- KLOFT, M., STIEHLER, F., ZHENG, Z. et PINKWART, N. (2014). Predicting mooc dropout over weeks using machine learning methods. In *Proceedings of the EMNLP 2014 Workshop on Analysis of Large Scale Social Interaction in MOOCs*, pages 60–65. 41, 52, 58
- KOGUT, B. et ZANDER, U. (1992). Knowledge of the firm, combinative capabilities, and the replication of technology. *Organization science*, 3(3):383–397. 15, 16
- KOLLER, D., NG, A., DO, C. et CHEN, Z. (2013). Retention and intention in massive open online courses : In depth. *Educause Review*, 48(3):62–63. 49
- KOP, R., FOURNIER, H. et MAK, J. S. F. (2011). A pedagogy of abundance or a pedagogy to support human beings? participant support on massive open online courses. *The International Review Of Research In Open And Distributed Learning*, 12(7):74–93. 58
- KOTLOWSKI, W., BLASZCZYNSKI, J., GRECO, S. et SLOWINSKI, R. (2008). Stochastic dominance-based rough set model for ordinal classification. *Infor Sci*, 178:4019–4037. 8, 62, 67, 68, 141
- KRAEMER, K. L. et KING, J. L. (1988). Computer-based systems for cooperative work and group decision making. *ACM Computing Surveys (CSUR)*, 20(2):115–146. 91
- KRISHNA VENI, C. et SOBHA RANI, T. (2011). On the classification of imbalanced datasets. *International Journal of Computer Science & Technology*, 2:145–148. 57
- KUHN, T. S., LAKATOS, I. et MUSGRAVE, A. (1970). Criticism and the growth of knowledge. *Criticism and the growth of knowledge*. 127

- KUJAWINSKA, A., ROGALEWICZ, M., DIERING, M., PILACINSKA, M., HAMROL, A. et KOCHANSKI, A. (2016). Assessment of ductile iron casting process with the use of the drsa method. *Journal of Mining and Metallurgy. Section B : Metallurgy*, 52(1):25. 83, 84
- LABARTHE, H., BACHELET, R., BOUCHET, F. et YACEF, K. (2016a). Increasing mooc completion rates through social interactions : a recommendation system. *EMOOCs, Research Track*, pages 471–480. 3, 35, 36, 122, 123, 139
- LABARTHE, H., BOUCHET, F., BACHELET, R. et YACEF, K. (2016b). Does a peer recommender foster students' engagement in moocs? *In 9th International Conference on Educational Data Mining*, pages 418–423. 50, 122, 123
- LAM, A. *et al.* (1998). Tacit knowledge, organisational learning and innovation a societal perspective. Rapport technique, DRUID, Copenhagen Business School, Department of Industrial Economics and Strategy/Aalborg University, Department of Business Studies. 16, 19
- LANG, K. (1995). Newsweeder : Learning to filter netnews. *In Proceedings of the 12th international conference on machine learning*, pages 331–339. 169
- LATHIKA, K. (2016). Student centred learning. *International Journal of Current Research and Modern Education (IJCRME)*, 1(1):677–680. 32
- LEE, J.-N. (2001). The impact of knowledge sharing, organizational capability and partnership quality on is outsourcing success. *Information & Management*, 38(5):323–335. 22
- LEGENBRE, M.-F. (2008). Chapitre 1. la notion de compétence au cœur des réformes curriculaires : effet de mode ou moteur de changements en profondeur? *In Compétences et contenus*, pages 27–50. De Boeck Supérieur. 30
- LEVENSHTAIN, V. I. (1966). Binary codes capable of correcting deletions, insertions, and reversals. *In Soviet physics doklady*, volume 10, pages 707–710. 120
- LI, S., LI, T. et LIU, D. (2013a). Incremental updating approximations in dominance-based rough sets approach under the variation of the attribute set. *Knowl.-Based Syst*, 40:17–26. 71
- LI, S., LI, T. et LIU, D. (2013b). Dynamic maintenance of approximations in dominance-based rough set approach under the variation of the object set. *Int. J. Intell. Syst.*, 28:729–751. 62, 71, 72
- LI, S.-W. D. et MITROS, P. (2015). Learnersourced recommendations for remediation. *In Advanced Learning Technologies (ICALT), 2015 IEEE 15th International Conference on*, pages 411–412. IEEE. 121, 123

- LIM, K. K., AHMED, P. K. et ZAIRI, M. (1999). Managing for quality through knowledge management. *Total Quality Management*, 10(4-5):615–621. 17
- LIN, N. (1999). Building a network theory of social capital. *Connections*, 22(1):28–51. 16
- LINDEN, G., SMITH, B. et YORK, J. (2003). Amazon. com recommendations : Item-to-item collaborative filtering. *IEEE Internet computing*, 7(1):76–80. 118, 169
- LIYANAGE, C., ELHAG, T., BALLAL, T. et LI, Q. (2009). Knowledge communication and translation—a knowledge transfer model. *Journal of Knowledge management*, 13(3):118–131. 22
- MACHLUP, F. (1982). *Knowledge-Its Creation, Distribution, and Economic Significance : Vol. Ii-the Branches of Learning*. Princeton University Press. 15
- MACKNESS, J., MAK, S. et WILLIAMS, R. (2010). The ideals and reality of participating in a mooc. *Proceedings of the 7th International Conference on Networked Learning*, pages 266–274. 43
- MAKHIJA, M. V. et GANESH, U. (1997). The relationship between control and partner learning in learning-related joint ventures. *Organization science*, 8(5): 508–527. 14
- MANNING, J. et SANDERS, M. (2013). How widely used are mooc forums ? a first look. *Signals : Thoughts on Online Learning*. 58
- MARSDEN, P. V. (1990). Network data and measurement. *Annual review of sociology*, 16(1):435–463. 38
- MELVILLE, P., MOONEY, R. J. et NAGARAJAN, R. (2002). Content-boosted collaborative filtering for improved recommendations. *In Aaai/iaai*, pages 187–192. 172
- MENDES, N., ALVES, B. et PAIVA, S. (2016). Context-aware mobile recommender system based on activity patterns. *In Mobile Data Management (MDM), 2016 17th IEEE International Conference on*, volume 2, pages 70–74. IEEE. 145
- MICHALSKI, R. S. (1988). Incremental learning of concept descriptions : A method and experimental results. pages 263–288. 61
- MILLER, G. A. (1956). The magical number seven, plus or minus two : some limits on our capacity for processing information. *Psychological review*, 63(2):81. 4, 91, 107, 146

- MOON, S., POTDAR, S. et MARTIN, L. (2014). Identifying student leaders from mooc discussion forums through language influence. *EMNLP 2014*, page 15. 56
- MORRIS, N. P., HOTCHKISS, S. et SWINNERTON, B. (2015). Can demographic information predict mooc learner outcomes? *Proceedings of the European MOOC Stakeholder Summit*, pages 199–207. 50, 51
- MOULT, J., PEDERSEN, J. T., JUDSON, R. et FIDELIS, K. (1995). A large-scale experiment to assess protein structure prediction methods. *Proteins : Structure, Function, and Bioinformatics*, 23(3):2–4. 83
- MOUSSA, N. (2001). Aide multicriterea l'évaluation qualitative par inférence de modeles de tri ordinal sur une hiérarchie de criteres. *These de doctorat, Université Paris-Dauphine*. 90
- MOUSSEAU, B. R., VINCENT et ROY, B. (1996). A theoretical framework for analysing the notion of relative importance of criteria. *J. Multi-Criteria Decis. Anal.*, 5:145–159. 90, 105
- MURUGANANDAM, S. et SRINIVASAN, N. (2017). Personalised e-learning system using learner profile ontology and sequential pattern mining-based recommendation. *International Journal of Business Intelligence and Data Mining*, 12(1):78–93. 144
- MUSUMBA, G. W. et NYONGESA, H. O. (2013). Context awareness in mobile computing : A review. *International Journal of Machine Learning and Applications*, 2(1):5–pages. 145
- NAHAPIET, J. et GHOSHAL, S. (1998). Social capital, intellectual capital, and the organizational advantage. *Academy of management review*, 23(2):242–266. 36
- NAZIR, U., DAVIS, H. et HARRIS, L. (2015). First day stands out as most popular among mooc leavers. *International Journal of e-Education, e-Business, e-Management and e-Learning*, 5(3):173. 50
- NELSON, R. R. et WINTER, S. G. (2009). *An evolutionary theory of economic change*. Harvard University Press. 37
- NING, W. (2016). *Towards a Competency Recommender System from Collaborative Traces*. Thèse de doctorat, University OF Technology OF Compiègne. 35, 36
- NONAKA, I. et KONNO, N. (1998). The concept of " ba " : Building a foundation for knowledge creation. *California management review*, 40(3):40–54. 1, 33, 34, 39
- NONAKA, I. et TAKEUCHI, H. (1995). *The knowledge-creating company : How Japanese companies create the dynamics of innovation*. Oxford university press. 16, 33

- NONAKA, I., TOYAMA, R. et KONNO, N. (2000). Seci, ba and leadership : a unified model of dynamic knowledge creation. *Long range planning*, 33(1):5–34. 15
- ONAH, D. F. et SINCLAIR, J. (2015). Collaborative filtering recommendation system : a framework in massive open online courses. *INTED2015 Proceedings*, pages 1249–1257. 122, 123
- ONAH, D. F., SINCLAIR, J. et BOYATT, R. (2014). Dropout rates of massive open online courses : behavioural patterns. *EDULEARN14 Proceedings*, pages 5825–5834. 50
- OUAMANI, F., BEN SAOUD, N. B. et BEN GHÉZALA, H. H. (2014). Management of socio-cultural knowledge using an ontology-based socio-cultural user profile in a computer-supported collaborative learning environment. *Journal of Decision Systems*, 23(1):40–54. 59
- PALOPOLI, L., ROSACI, D. et SARNÉ, G. M. (2013). A multi-tiered recommender system architecture for supporting e-commerce. In *Intelligent Distributed Computing VI*, pages 71–81. Springer. 118
- PAPPANO, L. (2012). The year of the mooc. *The New York Times*, 2(12):2012. 42
- PATRU, M. et BALAJI, V. (2016). Making sense of moocs : A guide for policy-makers in developing countries. 42
- PAULIN, D. et SUNESON, K. (2012). Knowledge transfer, knowledge sharing and knowledge barriers—three blurry terms in km. *The Electronic Journal of Knowledge Management*, 10(1):81–91. 22, 23, 24
- PAWLAK, Z. (1992). Rough sets. *International Journal & Computer Sciences*, pages 341—356. 64
- PAZZANI, M. J. et BILLISUS, D. (2007). Content-based recommendation systems. In *The adaptive web*, pages 325–341. Springer. 168
- PELTIER, J. W., DRAGO, W. et SCHIBROWSKY, J. A. (2003). Virtual communities and the assessment of online marketing education. *Journal of Marketing Education*, 25(3):260–276. 50
- PELTIER, J. W., SCHIBROWSKY, J. A. et DRAGO, W. (2007). The interdependence of the factors influencing the perceived quality of the online learning experience : A causal model. *Journal of Marketing Education*, 29(2):140–153. 50
- PHAM, P. et WANG, J. (2015). Attentivelearner : improving mobile mooc learning via implicit heart rate tracking. In *International Conference on Artificial Intelligence in Education*, pages 367–376. Springer. 53

- PIAGET, J. et INHELDER, B. (1973). *Memory and intelligence*. Basic Books (AZ). 23
- PIERRA, G., DEHAINSALA, H., AMEUR, Y. A. et BELLATRECHE, L. (2005). Bases de données à base ontologique. principe et mise en oeuvre. *Ingénierie des systèmes d'information*, 10(2):91–115. 146
- PIQUER FORCADA, M. *et al.* (2014). Designing, developing and implementing a mooc : improve your writing skills. 43
- POLANYI, M. (1962). Tacit knowing : Its bearing on some problems of philosophy. *Reviews of modern physics*, 34(4):601. 16, 37
- POMEROL, J.-C., EPELBOIN, Y. et THOURY, C. (2015). *MOOCs : Design, use and business models*. John Wiley & Sons. 3, 41, 48, 139
- PUNTAMBEKAR, S. (1999). An integrated approach to individual and collaborative learning in a web-based learning environment. *In Proceedings of the 1999 conference on Computer support for collaborative learning*, page 57. International Society of the Learning Sciences. 31
- QUINLAN, J. R. (1986). Induction of decision trees. *Machine learning*, 1(1):81–106. 169
- RAMESH, A., GOLDWASSER, D., HUANG, B., DAUME III, H. et GETOOR, L. (2014). Learning latent engagement patterns of students in online courses. *In Twenty-Eighth AAAI Conference on Artificial Intelligence*. 52
- REILLY, C. (2013). Moocs deconstructed : Variables that affect mooc success rates. *In E-Learn : World Conference on E-Learning in Corporate, Government, Healthcare, and Higher Education*, volume 2013, pages 1308–1338. 55
- REIX, R. (1995a). *Savoir tacite et savoir formalisé dans l'entreprise*. 19
- REIX, R. (1995b). *Systèmes d'information et management des organisations*. Vuibert. 32
- REN, Z., RANGWALA, H. et JOHRI, A. (2016). Predicting performance on mooc assessments using multi-regression models. *arXiv preprint arXiv :1605.02269*. 54, 57
- RICCI, F., ROKACH, L. et SHAPIRA, B. (2011). *Introduction to recommender systems handbook*. Springer. 129, 173
- ROCCHIO, J. J. (1971). Relevance feedback in information retrieval. 169
- ROGERS, E. M. (2010). *Diffusion of innovations*. Simon and Schuster. 37

- ROGOFF, B. (2008). Observing sociocultural activity on three planes : Participatory appropriation, guided participation, and apprenticeship. *Pedagogy and practice : Culture and identities*, pages 58–74. 24
- ROSÉ, C. P. et SIEMENS, G. (2014). Shared task on prediction of dropout over time in massively open online courses. *In Proc. of EMNLP*, volume 14, page 39. 41, 58
- ROSS, D. A., LIM, J., LIN, R.-S. et YANG, M.-H. (2008). Incremental learning for robust visual tracking. *International journal of computer vision*, 77(1):125–141. 70
- ROY, B. (1985). *Méthodologie multicritère d" aide à la décision*. Economica. 63, 90
- ROY, B. (1997). *L'aide à la décision aujourd'hui : que devrait-on en attendre ?* Document du LAMSADE. Laboratoire d'Analyse et Modélisation de Systèmes pour l'Aide à la Décision, Université Paris-Dauphine. 95
- ROY, B. (2000). Un glossaire d'aide à la décision en français et anglais. *Bulletin du Groupe de Travail Européen*, 3(1):1–6. 64, 90
- ROY, B. et BOUYSSOU, D. (1993). Aide multicritère à la décision : Méthodes et cas. *Economica, Paris*. 63
- RUIZ-MERCADER, J., MEROÑO-CERDAN, A. L. et SABATER-SÁNCHEZ, R. (2006). Information technology and learning : Their relationship and impact on organisational performance in small businesses. *International Journal of Information Management*, 26(1):16–29. 31
- RUPING, S. (2001). Incremental learning with support vector machines. *In Data Mining, 2001. ICDM 2001, Proceedings IEEE International Conference on*, pages 641–642. IEEE. 61
- RYLE, G. (1945). Knowing how and knowing that : The presidential address. *In Proceedings of the Aristotelian society*, volume 46, pages 1–16. JSTOR. 16, 17
- RYLE, G. (2009). *The concept of mind*. Routledge. 17
- SAAD, I. (2005). *Une contribution méthodologique pour l'aide à l'identification et l'évaluation des connaissances nécessitant une opération de capitalisation*. Thèse de doctorat, Université Paris-Dauphine. 62, 63, 83, 84
- SAAD, I. et CHAKHAR, S. (2010). Aggregation procedure based on majority principle for collective identification of firm's crucial knowledge. *In World Summit on Knowledge Society*, pages 346–352. Springer. 91

- SAAD, I., GRUNDSTEIN, M. et SABROUX, C. R. (2006). Generalizing gameth : Inference rule procedure. *In Proceedings ISMICK'06 International Symposium on the Management of Industrial and Corporate Knowledge Innovation*. 91
- SAAD, I., ROSENTHAL-SABROUX, C. et GRUNDSTEIN, M. (2005). Improving the decision making process in the design project by capitalizing on company's crucial knowledge. *Group Decision and Negotiation*, 14(2):131–145. 62, 83
- SAHAMI, M., ROACH, S. *et al.* (2013). Computer science curricula 2013–ironman draft version 1.0. *Computer*, pages 50–199. 120
- SALTON, G. (1989). Automatic text processing : The transformation, analysis, and retrieval of. *Reading : Addison-Wesley*. 169
- SALTON, G. et MCGILL, M. J. (1986). Introduction to modern information retrieval. 169
- SAMMOUR, G., AL-ZOUBI, A., GLADUN, A., KHALA, K. et SCHREURS, J. (2015). Semantic web and ontologies for personalisation of learning in moocs. *In Intelligent Computing and Information Systems (ICICIS), 2015 IEEE Seventh International Conference on*, pages 183–186. IEEE. 144
- SAMUEL, A. L. (1959). Some studies in machine learning using the game of checkers. *IBM Journal of research and development*, 3(3):210–229. 70
- SAULNIER, A., THIEVRE, J. et VIAUD, M.-L. (2006). La perception du mouvement dans la visualisation : le cas des graphes. *Revue d'Interaction Homme-Machine Vol*, 7(2). 147
- SAVVAS, I. et BASSILIADES, N. (2009). A process-oriented ontology-based knowledge management system for facilitating operational procedures in public administration. *Expert Systems with Applications*, 36(3):4467–4478. 35
- SAWYER, R. K. (2005). *The Cambridge handbook of the learning sciences*. Cambridge University Press. 30
- SCHUMAN, R. (2013). The king of moocs abdicates the throne. *Slate*. *Abgerufen von*. 49
- SCHUNK, D. H. (1991). Self-efficacy and academic motivation. *Educational psychologist*, 26(3-4):207–231. 28, 29
- SCRIBNER, S. (1985). Vygotsky's uses of history. *Culture, communication, and cognition : Vygotskian perspectives*, pages 119–145. 23

- SEERY, N., WALDMANN, T. et GAUGHRAN, W. (2006). A participative pedagogical approach to knowledge comprehension based on students' preferential learning styles. *In Proceedings of the American Society for Engineering Education Annual Conference, Chicago, IL.* 101
- SELLIN, C. K. (2011). *Des organisations centrées processus aux organisations centrées connaissance : la cartographie de connaissances comme levier de transformation des organisations. Le cas de la démarche de " Transfert de Savoir-Faire" chez Total.* Thèse de doctorat, Ecole Centrale Paris. 35
- SHANAHAN, M. (1989). Prediction is deduction but explanation is abduction. *International Joint Conf on Artificial Intelligence*, pages 1055–1060. 83
- SHANI, G. et GUNAWARDANA, A. (2011). Evaluating recommendation systems. *In Recommender systems handbook*, pages 257–297. Springer. 133
- SHANI, G., ROKACH, L., MEISLES, A., NAAMANI, L., PIRATLA, N. et BEN-SHIMON, D. (2007). Establishing user profiles in the mediascout recommender system. *In Computational Intelligence and Data Mining, 2007. CIDM 2007. IEEE Symposium on*, pages 470–476. IEEE. 125
- SHANNON, C. (1993). *Collected papers.* 13
- SHANNON, C. E. et WEAVER, W. (2002). The mathematical theory of communication. 13
- SHATNAWI, S., GABER, M. M. et COCEA, M. (2014a). Automatic content related feedback for moocs based on course domain ontology. *In International Conference on Intelligent Data Engineering and Automated Learning*, pages 27–35. Springer. 144
- SHATNAWI, S., GABER, M. M. et COCEA, M. (2014b). Text stream mining for massive open online courses : review and perspectives. *Systems Science & Control Engineering : An Open Access Journal*, 2(1):664–676. 144
- SHEN, K.-Y., TZENG, G.-H. *et al.* (2014). Drsa-based neuro-fuzzy inference systems for the financial performance prediction of commercial banks. *Int. J. Fuzzy Syst*, 16(2):173–183. 62, 83, 86
- SHI, X. (2004). An intelligent knowledge-based recommendation system. *In International Conference on Intelligent Information Processing*, pages 431–435. Springer. 170
- SHUM, S. B. et FERGUSON, R. (2012). Social learning analytics. *Educational technology & society*, 15(3):3–26. 41

- SIEMENS, G. (2005). Connectivism : Learning as network-creation. *ASTD Learning News*, 10(1). 42
- SIEMENS, G. (2008). Learning and knowing in networks : Changing roles for educators and designers. *ITFORUM for Discussion*, pages 1–26. ix, 29
- SIEMENS, G. (2012). What is the theory that underpins our moocs. *Documento en línea. Accesible en <http://www.elearnspace.org/blog/2012/06/03/what-is-the-theory-that-underpinsour-moocs>*. 31, 42
- SIEMENS, G. (2014). Connectivism : A learning theory for the digital age. 30, 31
- SILVER, D. (2011). Machine lifelong learning : challenges and benefits for artificial general intelligence. *Artificial general intelligence*, pages 370–375. 69
- SINGLEY, M. K. et ANDERSON, J. R. (1989). *The transfer of cognitive skill*. Numéro 9. Harvard University Press. 20, 21
- SOUALAH-ALILA, F. (2015). *CAMLearn : Une Architecture de Système de Recommandation Sémantique Sensible au Contexte. Application au Domaine du M-Learning*. Thèse de doctorat, Université de Bourgogne. 171
- SPENCER, J. A. et JORDAN, R. K. (1999). Learner centred approaches in medical education. *Bmj*, 318(7193):1280–1283. 32
- SPENDER, J.-C. (1996). Making knowledge the basis of a dynamic theory of the firm. *Strategic management journal*, 17(S2):45–62. 19
- SRIDEVI, K. et UMARANI, R. (2013). Web personalization approaches : a survey. *International Journal of Advanced Research in Computer and Communication Engineering*, 2(3). 126
- STAAB, S. et STUDER, R. (2010). *Handbook on ontologies*. Springer Science & Business Media. 144
- STAŃCZYK, U. (2011). On performance of drsa-ann classifier. *Hybrid Artificial Intelligent Systems*, pages 172–179. 83, 84
- STAŃCZYK, U. (2013). On preference order of drsa conditional attributes for computational stylistics. *In International Conference on Database and Expert Systems Applications*, pages 26–33. Springer. 62
- STAUBITZ, T., RENZ, J., WILLEMS, C. et MEINEL, C. (2014). Supporting social interaction and collaboration on an xmooc platform. *Proc. EDULEARN14*, pages 6667–6677. 144
- STEFANOWSKI, J. (2001). Algorithms of rule induction for knowledge discovery. *Habilitation Thesis published as Series Rozprawy*, (361). 68, 71

- STEIN, R. M. et ALLIONE, G. (2014). Mass attrition : An analysis of drop out from a principles of microeconomics mooc. 52
- SUN, P.-C., TSAI, R. J., FINGER, G., CHEN, Y.-Y. et YEH, D. (2008). What drives a successful e-learning? an empirical investigation of the critical factors influencing learner satisfaction. *Computers & education*, 50(4):1183–1202. 32
- SUNAR, A. S., ABDULLAH, N. A., WHITE, S. et DAVIS, H. C. (2015). Analysing and predicting recurrent interactions among learners during online discussions in a mooc. 53, 55
- SURIEL, R. L. et ATWATER, M. M. (2012). From the contribution to the action approach : White teachers' experiences influencing the development of multicultural science curricula. *Journal of research in Science Teaching*, 49(10):1271–1295. 51
- SUTTON, R. S. (1988). Learning to predict by the methods of temporal differences. *Machine learning*, 3(1):9–44. 61, 70
- SVEIBY, K. E. (1997). *The new organizational wealth : Managing & measuring knowledge-based assets*. Berrett-Koehler Publishers. 23
- SYMEONIDIS, P. et MALAKOUDIS, D. (2016). Moocrec. com : Massive open online courses recommender system. 120
- SZULANSKI, G. (1996). Exploring internal stickiness : Impediments to the transfer of best practice within the firm. *Strategic management journal*, 17(S2):27–43. 37
- SZULANSKI, G., CAPPETTA, R. et JENSEN, R. J. (2004). When and how trustworthiness matters : Knowledge transfer and the moderating effect of causal ambiguity. *Organization science*, 15(5):600–613. 22
- TARONDEAU, J.-C. (1998). *Le Management des savoirs*. Presses universitaires de France. 19
- TAYLOR, C., VEERAMACHANENI, K. et O'REILLY, U.-M. (2014). Likely to stop? predicting stopout in massive open online courses. *arXiv preprint arXiv :1408.3382*. 53
- TERGAN, S.-O. et KELLER, T. (2005). *Knowledge and information visualization : Searching for synergies*, volume 3426. Springer. 146
- THUSBERG, J., OLATUBOSUN, A. et VIHINEN, M. (2011). Performance of mutation pathogenicity prediction methods on missense variants. *Human mutation*, 32(4): 358–368. 83

- TING, K. (2002). An instance-weighting method to induce cost-sensitive trees. *IEEE Trans. Knowledge and Data Eng.*, 14(3):659–665. 57
- TRUCH, A., HIGGS, M., BARTRAM, D. et BROWN, A. (2002). Knowledge sharing and personality. *In Henley Knowledge Management Forum.* 23
- TSUCHIYA, S. (1993). Improving knowledge creation ability through organizational learning. *In ISMICK'93 Proceedings, International Symposium on the Management of Industrial and Corporate Knowledge*, pages 87–95. 15
- TURE, M., KURT, I., KURUM, A. T. et OZDAMAR, K. (2005). Comparing classification techniques for predicting essential hypertension. *Expert Systems with Applications*, 29(3):583–588. 83
- TURKI, M., SAAD, I., GARGOURI, F. et KASSEL, G. (2012). A decision support system for identifying sensitive organization's processes. *Journal of Decision Systems*, 21(4):275–290. 62, 83, 84
- TUZHILIN, A., KOREN, Y., BENNETT, J., ELKAN, C. et LEMIRE, D. (2008). Large-scale recommender systems and the netflix prize competition. *In KDD Proceedings*, pages 1–34. 118
- Van den HOOFF, B. et HENDRIX, L. (2005). Eagerness and willingness to share : The relevance of different attitudes towards knowledge sharing. *OKLC.* 22, 23
- VAPNIK, V. (1995). The nature of statistical learning theory. 57
- VILLIOT-LECLERCQ, E. (2007). *Modèle de soutien à l'élaboration et à la réutilisation de scénarios pédagogiques.* Thèse de doctorat, Citeseer. 29
- WALTON, R. E. (1975). The diffusion of new work structures : Explaining why success didn't take. *Organizational Dynamics*, 3(3):3–22. 38
- WANG, N., ABEL, M.-H., BARTHÈS, J.-P. et NEGRE, E. (2016a). An answerer recommender system exploiting collaboration in cqa services. *In Computer Supported Cooperative Work in Design (CSCWD), 2016 IEEE 20th International Conference on*, pages 198–203. IEEE. 118
- WANG, N., ABEL, M.-H., BARTHÈS, J.-P. et NEGRE, E. (2016b). Recommending competent person in a digital ecosystem. *In Industrial Informatics and Computer Systems (CIICS), 2016 International Conference on*, pages 1–6. IEEE. 118
- WANG, S. et NOE, R. A. (2010). Knowledge sharing : A review and directions for future research. *Human Resource Management Review*, 20(2):115–131. 22
- WEI CHOO, C. et CORREA NETO, R. (2010). Beyond the ba : managing enabling contexts in knowledge organizations. *Journal of Knowledge Management*, 14(4): 592–610. 23

- WELCH, D. E. et WELCH, L. S. (2008). The importance of language in international knowledge transfer. *Management International Review*, 48(3):339–360. 126
- WHITEHILL, J., MOHAN, K., SEATON, D., ROSEN, Y. et TINGLEY, D. (2017a). Delving deeper into mooc student dropout prediction. *arXiv preprint arXiv :1702.06404*. 143
- WHITEHILL, J., MOHAN, K., SEATON, D., ROSEN, Y. et TINGLEY, D. (2017b). Mooc dropout prediction : How to measure accuracy? *In Proceedings of the Fourth (2017) ACM Conference on Learning@ Scale*, pages 161–164. ACM. 143, 144
- WIESNER, M. et PFEIFER, D. (2010). Adapting recommender systems to the requirements of personal health record systems. *In Proceedings of the 1st ACM International Health Informatics Symposium*, pages 410–414. ACM. 118
- WINTER, S. (1998). Knowledge and competence as strategic assets. *The strategic management of intellectual capital*, 187. 37
- WINTER, S. G. (1995). Four rs of profitability : rents, resources, routines, and replication. *In Resource-based and evolutionary theories of the firm : Towards a synthesis*, pages 147–178. Springer. 37
- WITTEN, I. H., PAYNTER, G. W., FRANK, E., GUTWIN, C. et NEVILL-MANNING, C. G. (1999). Kea : Practical automatic keyphrase extraction. *In Proceedings of the fourth ACM conference on Digital libraries*, pages 254–255. ACM. 169
- WOLFF, A., ZDRAHAL, Z., HERRMANNOV, D., KUZILEK, J. et HLOSTA, M. (2014). Developing predictive models for early detection of at-risk students on distance learning modules. *In Workshop : Machine Learning and Learning Analytics at LAK*. 50, 52
- WU, D., ZHANG, G. et LU, J. (2015). A fuzzy preference tree-based recommender system for personalized business-to-business e-services. *IEEE Transactions on Fuzzy Systems*, 23(1):29–43. 118
- XIAO, B. et BENBASAT, I. (2007). E-commerce product recommendation agents : use, characteristics, and impact. *MIS quarterly*, 31(1):137–209. 118
- XING, W., CHEN, X., STEIN, J. et MARCINKOWSKI, M. (2016). Temporal prediction of dropouts in moocs : Reaching the low hanging fruit through stacking generalization. *Computers in Human Behavior*, 58:119–129. 54, 143
- YANG, D., PIERGALLINI, M., HOWLEY, I. et ROSE, C. (2014). Forum thread recommendation for massive open online courses. *In Educational Data Mining 2014*, pages 257–260. 121, 123

- YANG, D., SINHA, T., ADAMSON, D. et ROSÉ, C. P. (2013). Turn on, tune in, drop out : Anticipating student dropouts in massive open online courses. *In Proceedings of the 2013 NIPS Data-driven education workshop*, volume 11, page 14. 3, 41, 48, 49, 83, 139
- YAROSLAVSKY, I., ROTTENBERG, J. et KOVACS, M. (2013). The utility of combining rsa indices in depression prediction. *Journal of Abnormal Psychology*, 122(2):314–321. 83
- YUAN, L. et POWELL, S. (2013). Moocs and disruptive innovation : Implications for higher education. *eLearning Papers, In-depth*, 33(2):1–7. 2, 43, 143
- ZARAS, K. (2011). The dominance-based rough set approach (drsa) applied to bankruptcy prediction modeling for small and medium businesses. *Multiple Criteria Decision Making/The University of Economics in Katowice*, pages 287–295. 62, 83, 85
- ZELENY, M. (1987). Management support systems : towards integrated knowledge management. *Human systems management*, 7(1):59–70. 15
- ZHANG, J., LI, T. et RUAN, D. (2012). Rough sets based matrix approaches with dynamic attribute variation in set-valued information systems. *International Journal of Approximate Reasoning*, 53:620–635. 71
- ZHANG, Q., PECK, K. L., HRISTOVA, A., JABLOKOW, K. W., HOFFMAN, V., PARK, E. et BAYECK, R. Y. (2016). Exploring the communication preferences of mooc learners and the value of preference-based groups : Is grouping enough? *Educational Technology Research and Development*, 64(4):809–837. 51
- ZHENGHAO, C., ALCORN, B., CHRISTENSEN, G., ERIKSSON, N., KOLLER, D. et EMANUEL, E. (2015). Who’s benefiting from moocs, and why. *Harvard Business Review*, 25. 44