

UNIVERSITE SAAD DAHLAB DE BLIDA

Faculté des Sciences

Département d'informatique

MEMEOIRE DE MAGISTER

En Informatique

Spécialité : Système d'information et de connaissance

UTILISATION DES RESEAUX BAYESIENS POUR CALCULER LA FIABILITE DES SYSTEMES

Par

ZAHRA FATMA ZOHRA

Devant le jury composé de :

A.GUESSOUM	Professeur, USDB de Blida	Président
F.NADER	Maitre de conférences A, ESI d'Alger	Examineur
R.CHALAL	Maitre de conférences A, ESI d'Alger	Examineur
S. OUKID	Maitre de conférences A, USDB de Blida	Rapporteur
Y. SEMMAR	Maitre Assistant A, USDB de Blida	Co-rapporteur

Blida, Octobre 2010

RESUME

Les Réseaux Bayésiens (RBs) et les Réseaux Bayésiens Dynamiques (RBDs) sont particulièrement appropriés à la collecte et la représentation de connaissances incertaines, mais aussi ils permettent d'effectuer les calculs probabilistes et les analyses statistiques d'une manière efficace.

Les méthodes d'apprentissage de modèles de réseaux Bayésien ont transformé ces derniers en un outil de découverte de connaissances. Par conséquent ils sont devenus un outil intégré d'extraction, de représentation et aussi d'exploitation de connaissances.

Les chercheurs ont commencé récemment, à vérifier et examiner les capacités de cette méthodologie dans la modélisation et l'analyse des systèmes complexes où la sûreté de fonctionnement est un facteur crucial. En effet, La fiabilité des systèmes est devenue un des domaines d'applications des réseaux Bayésiens et les réseaux Bayésiens sont devenus par conséquent, un outil d'analyse et d'estimation de la fiabilité.

Les réseaux Bayésiens attirent de plus en plus l'attention des chercheurs en domaine de la fiabilité grâce à leurs propriétés de modélisation qui ont permis de modéliser efficacement, certains aspects de la fiabilité qui représentent des challenges pour les méthodes classiques d'analyse de fiabilité. L'aspect temporel, en d'autre terme la fiabilité dynamique est un des thèmes les plus traités. Ceci est reflété par le nombre important des travaux de recherche menés dans ce contexte publiés dans ces dix dernières années.

Dans ce travail, nous proposons une méthode générique d'analyse et d'estimation de la fiabilité des systèmes dynamiques en utilisant les RBs comme un outil d'extraction de connaissances pour la construction de modèles de réseau Bayésien dynamique modélisant la fiabilité des systèmes. Ceci en exploitant les données (de test ou de retour d'expérience) prise de l'historique de ces derniers.

Le modèle construit est utilisé pour l'estimation de la fiabilité via le mécanisme d'inférence des RBs

Mots-clés : Analyse de fiabilité, Réseaux Bayésiens dynamiques, Apprentissage des réseaux Bayésiens, extraction de connaissances, Estimation de fiabilité.

ملخص

شبكات بياز(ش ب) و شبكات بياز الدينامكية (ش ب د) مناسبة خاصة لجمع وتمثيل المعرفة في المجالات غير مؤكدة ولكن أيضا تمكننا من أداء حساب الإحتمالات والتحليلات الإحصائية بطريقة فعالة.

في الآونة الأخيرة ، بدأ الباحثون بدراسة والتحقق من قدرات هذه المنهجية في النمذجة وتحليل الأنظمة المعقدة حيث الاعتمادية أمر بالغ الأهمية. في الواقع، وأصبحت الاعتمادية واحد من المجالات من التطبيقات لشبكات بياز ولذلك أصبحت شبكات بياز أداة لتحليل وتقدير الاعتمادية.

شبكات بايز تجتذب اهتماما متزايدا من الباحثين في مجال الاعتمادية من خلال خصائص النمذجة والتي يمكن أن نموذج فعال لجوانب من الموثوقية التي تمثل التحديات التي تواجه الطرق التقليدية للتحليل الموثوقية. الجانب الزمني، وبعبارة أخرى الموثوقية ديناميكية هي واحدة من أكثر المواضيع التي تمت مناقشتها بإسهاب. ويتجلى هذا في عدد كبير من الأبحاث التي أجريت في هذا الصدد، نشرت في العقد الماضي.

في هذه الدراسة، نقترح طريقة عامة لتحليل و تقدير إعتماكية الأنظمة الدينامكية بإستعمال شبكات بياز كأداة إستخراج معلومات من أجل بناء نماذج من شبكات بياز وهذا عن طريق استغلال البيانات التاريخية من أجل بناء بطريقة أوتوماتكية ، دون تدخل من الخبراء، أنظمة من طراز شبكات بياز الدينامكية لتقدير وتحليل مدى موثوقية النظم الدينامكية.

الكلمات الرئيسية: تحليل الاعتمادية، شبكات بياز الدينامكية، تعلم شبكات بياز الدينامكية ، اكتشاف المعرفة، تقدير الاعتمادية.

Abstract

Bayesian Networks (BN) and Dynamic Bayesian Networks (DBN) are particularly suitable for collecting and representing knowledge on uncertain domains but also enable to perform probabilistic calculus and statistical analyses in an efficient manner.

The methods of learning Bayesian networks models transformed the latter into a tool of knowledge discovery. Consequently they became an integrated tool of extraction, representation and also of exploitation of knowledge.

Researchers began recently, to examine and verify the capabilities of this methodology in the modeling and analysis of complex safety critical systems. Indeed, system reliability has become one of the areas of applications of Bayesian networks and Bayesian networks have become therefore a tool for reliability analysis and estimation.

Bayesian networks are attracting increasing attention from researchers in the field of reliability through their modeling properties that can effectively model aspects of reliability that represent challenges to the traditional methods of reliability analysis. The temporal aspect, in other words the dynamic reliability is one of the topics most frequently discussed. This is reflected by the large number of research conducted in this context published in the last decade.

In this work, we propose a holistic method that exploits historical data of systems by using dynamic Bayesian networks like a tool of knowledge extraction for the construction of models of dynamic Bayesian network modeling the reliability of systems. This is done, by exploiting the data of (test or experience feedback) catch of the history of the latter. The built model is used for the estimate of reliability via the mechanism of inference of Bayesian networks

Keywords: Dependability analysis, Dynamic Bayesian Network, learning Bayesian networks, knowledge discovery, reliability estimation.

REMERCIEMENTS

ELhamdo Lilah, je remercie mon dieu tout puissant qui m'a donné la force et la volonté de mener ce travail jusqu'à la fin.

Je tiens particulièrement à exprimer ma reconnaissance à Mme Oukis-Khouas Saliha, ma directrice d'étude, pour sa disponibilité, son écoute, sa patience et ses conseils, qui m'ont été toujours précieux, sa confiance, son investissement scientifique et humain qui ont été essentiels à la réalisation de ce travail.

Je voudrais également exprimer toute ma gratitude à Mme Semmar Yasmina qui, en sa qualité de promotrice, m'a fait l'honneur de m'avoir proposé ce sujet en collaboration avec Mme Oukid, et pour ses conseils et sa disponibilité et son aide.

Je remercie les membres du jury : Mr Guessoum, Mme Nadar et Mr Chalal qui m'ont honoré par leur acceptation d'examiner ce modeste travail.

Je remercie ma mère, maman je ne trouve ni les mots ni la façon la plus appropriée pour te dire merci pour ton soutien, tes encouragements,et pour une liste infinie de ce que tu fais pour moi (je t'aime maman).

Je remercie mon père pour ses encouragements.

Je remercie également mon frère Redouane, merci d'être non seulement un frère mais aussi un ami et merci d'être toujours à mes côtés. Sans oublier mon frère Rachid et mes neveux Mohamed et Issam et aussi mes nièces : Hayet et la petite Ahlem.

Mes remerciements vont aussi à mes enseignants et mes collègues et amis en particulier, Melle Arkam Meriem, Mme Rezoug Nachida, Mr chabane Yahia, Mr Sidemou Rédha et tous qui ont contribué à l'aboutissement de ce travail de près ou de loin.

TABLE DES MATIERES

INTRODUCTION GENERALE _____	19
1. Introduction _____	19
2. MOTIVATIONS _____	20
3. PROBLEMATIQUE _____	21
4. OBJECTIFS _____	22
5. GUIDE DE LECTURE _____	23
CHAPITRE I : LES RESEAUX BAYESIENS _____	25
I.1 INTRODUCTION _____	25
I.2 RESEAUX BAYESIENS _____	25
I.2.1 Représentation de la causalité _____	27
I.2.2 Circulation de l'information dans un réseau Bayésien _____	27
I.2.2.1 Connexions séquentielle _____	28
I.2.2.2 Connexions divergente _____	29
I.2.2.3 Connexions convergente (ou V-structure) _____	30
I.2.2.4 Le Critère de d-Séparation _____	31
I.2.2.5 Le Critère de "Directed Global Markov" _____	31
I.2.3 Types des réseaux Bayésiens _____	32
I.2.3.1 Réseaux Bayésiens discret _____	32
I.2.3.2 Réseaux Bayésiens continu _____	32
I.2.3.3 Réseaux Bayésiens hybride _____	32
I.2.3.4 Réseau Bayésien orienté objet (RBOO) _____	33
I.2.4 Conditions d'utilisation des réseaux Bayésiens _____	33
I.3 CONSTRUCTION D'UN RESEAU BAYESIEN _____	34
I.3.1 Identification des variables du modèle _____	34
I.3.2 Tirer la structure du réseau _____	34
I.3.2.1 La construction d'un réseau Bayésien en collaboration avec les experts du domaine _____	35
I.3.2.2 La construction d'un réseau Bayésien à partir des données statistique (Modélisation basé sur les données) _____	35
I.4.3 Vérification du modèle _____	35
I.4.4 Construire les tables de probabilité conditionnelle (Estimation des paramètres) _____	36
I.5 INFERENCE _____	38

I.5.1 Méthodes exactes _____	38
I.5.1.1 Messages locaux _____	38
I.5.1.2 Ensemble de coupe _____	39
I.5.1.3 Arbre de jonction _____	39
I.5.1.4 Elimination de variables _____	41
I.5.1.5 Explication la plus probable _____	41
I.5.1.6 Méthodes symboliques _____	42
I.5.1.7 Méthodes différentielles _____	43
I.5.2 Méthodes d'inférence approchées _____	43
I.5.2.1 Simulation stochastique par Chaîne de Monte-Carlo _____	43
I.5.2.2 Méthodes variationnelles _____	46
I.5.2.3 Méthodes de recherche de masse _____	47
I.5.2.4 Loopy belief propagation _____	47
I.5.2.5 Simplification du réseau _____	47
I.6 LES CHAINES DE MARKOV _____	48
I.6.1 Définition et propriétés _____	48
II.7 MODELES DYNAMIQUES _____	49
I.7.2 Approche basé sur l'évènement _____	52
I.7.2.1 Définition formelle d'un réseau bayésien temporel d'évènements _____	52
I.7.2.2 Mécanisme d'inférence dans réseau bayésien temporel d'évènements _____	53
I.8 CONCLUSION _____	54
CHAPITRE II : APPRENTISSAGE DES RESAUX BAYESIENS _____	56
II.1 INTRODUCTION _____	56
II.2 APPRENTISSAGE DES PARAMETRES _____	56
II.2.1 Apprentissage des paramètres à partir d'une base de données complète _____	57
II.2.1.1 Approche fréquentiste _____	58
II.2.1.2 Approche Bayésienne _____	59
II.2.2 Base de données incomplète _____	60
II.2.2.1 Approche fréquentiste _____	61
II.2.2.2 Approche Bayésienne _____	62
II.3 APPRENTISSAGE DE STRUCTURE À PARTIR DES DONNEES _____	62
II.3.1 Complexité de l'apprentissage de structure _____	63
II.3.2 Hypothèses pour l'apprentissage de structure _____	64

II.3.3 APPRENTISSAGE DE STRUCTURE À PARTIR DE DONNÉES COMPLÈTES	65
II.3.3.1 Méthodes basées sur la recherche d'indépendances conditionnelles	65
II.3.3.1.1 Méthodes procédant par tests statistiques	65
II.3.3.2 FONCTION D'EVALUATION OU DE SCORE	72
II.3.4 APPRENTISSAGE DE STRUCTURE À PARTIR DES DONNEES INCOMPLETES	81
II.3.4.3 Méthodes à base de score pour données incomplètes	84
II.3.4.3.1 L'algorithme SEM	84
II.3.4.4 L'APPRENTISSAGE DES RESEAUX BAYESIENS CONTINUES ET HYBRIDES	86
II.4 APPRENTISSAGE DE RESEAUX BAYESIENS DYNAMIQUES	87
II.5 CONCLUSION	87
CHAPITRE III : LES RESEAUX BAYESIENS Pour l'EXTRACTION, la REPRESENTATION ET l'EXPLOITATION DE CONNAISSANCES	88
III.1 INTRODUCTION	88
III.2 GESTION DES CONNAISSANCES	88
III.2.1 Epistémologie de la connaissance	89
III.2.2 La connaissance tacite et explicite	89
III.3 PROCESSUS D'EXTRACTION DE CONNAISSANCES	90
III.4 DATA MINING	95
III.4.1 Classification des techniques de la Fouille de données	96
III.4.1.1 Classification de données	98
III.4.1.2 Groupement (Clustering)	99
III.4.1.3 Règles d'association	100
III.4.2 Domaines d'application du Data Mining	101
III.5 ETAT DE L'ART SUR LES RESEAUX BAYESIENS POUR LA GESTION DE CONNAISSANCES	101
III.5.1 Règle d'association et réseaux Bayésiens	101
III.5.2 Réseaux Bayésien pour la classification (Apprentissage non supervisé)	102
III.5.2.2 Bayes naïve augmentée	103
III.5.2.3 Bayes naïve augmentée par un arbre	104
III.5.2.5 Classifieur naïf augmenté par une forêt : FAN Forêt optimale	104
III.5.3 Réseaux Bayésien pour le Clustering (Apprentissage supervisé)	104
III.5.4 Discussion	105

III.5.2 Les réseaux Bayésiens un outil intégré pour l'extraction, la représentation et l'exploitation des connaissances _____	106
III.5.2.1 Préparation des données _____	108
III.5.2.2 Recherche du modèle _____	108
III.5.2.3 Interprétation et évaluation du résultat _____	109
III.6 CONCLUSION _____	111
CHAPITRE IV : LA FIABILITE DES SYSTEMES _____	113
IV.1 INTRODUCTION _____	113
IV.2 DEFINITIONS ET CONCEPTS MATHEMATIQUES _____	113
IV.2.1 Définitions _____	113
IV.2.2 Historique de la fiabilité _____	116
IV.2.3 Métriques de la fiabilité _____	117
IV.2.3.1 Fonctions et formules générales de la fiabilité _____	117
IV.2.3.2 Modèles mathématiques de la fiabilité _____	119
IV.3 L'INTERET DE L'EVALUATION DE LA FIABILITE _____	123
IV.4 LES RESEAUX DE LA FIABILITE _____	124
IV.4.1 Configuration séquentiel (série) _____	124
IV.4.2 Configuration parallèle _____	125
IV.4.3 Configuration M-Out-OF-N _____	126
IV.4. 4 Configuration de réserve (STANDBY) _____	127
IV.4. 5 Configuration (Bridge) _____	128
IV.5 LES METHODES D'EVALUATION ET D'ANALYSE DE LA FIABILITE _____	128
IV. 5.1 L'ANALYSE DES ARBRES DE DEFAILLANCE _____	129
IV.5.1.1 Les étapes de la mise en œuvre d'une analyse d'arbre de défaillance	129
IV.5.1.2 Définition des frontières de l'analyse et l'évènement principal de l'AD	130
IV.5.1.3 Symboles utilisés dans la représentation des arbres de défaillance	131
IV.5.1.4 Catégories des composants et des défauts de composant _____	132
IV.5.1.5 Evaluation qualitative d'un arbre de défaillance _____	133
IV.5.1.6 Evaluation quantitative d'un arbre de défaillance _____	137
IV.5.1.7 Extension des arbres de défaillance (les arbres de défaillance dynamiques) _____	138
IV.5.2 L'AMDEC (Analyse des Modes des Défaillances et leurs effets et Criticités)	140
IV.5.2.1 L'analyse fonctionnelle _____	141
IV.5.2.2 Rédaction des tableaux AMDEC _____	142

IV.5.2.3 Indice de criticité ou de sévérité	147
IV.5.3 LA METHODE DE REDUCTION DE RESEAU	147
IV.5.4 METHODE D'ANALYSE DE LA CAUSE DE DEFAILLANCE COMMUNE	148
IV.5.5 LA METHODE DE MARKOV	151
IV.5.6 LES CHAINES DE MARKOV POUR LA FIABILITE	151
IV.5.6.1 Chaines de Markov	152
IV.5.6.2 Le processus Markovien discret indépendant du temps	152
IV.5.6.3 Le processus Markovien discret dépendant du temps	154
IV.5.7 METHODE DE DECOMPOSITION	154
IV.6 CONCLUSION	155
CHAPITRE V : LES RESEAUX BAYESIENS POUR LA FIABILITE : ETAT DE L'ART	156
V.1 INTRODUCTION	156
V.2 APERCU GENERAL SUR L'UTILISATION DES RESEAUX BAYESIENS POUR LA MODELISATION ET L'ANALYSE DE LA FIABILITE DES SYSTEMES	156
V.3 LES MODELES STATIQUES DES RESEAUX BAYESIENS POUR MODELISER LA FIABILITE DES SYSTEMES	161
V.3.1 Construction directe des modèles de RB pour l'estimation de la fiabilité	161
V.3.2 Construction des modèles de réseau Bayésien basée sur les méthodes classiques d'analyse de fiabilité	163
V.3.2.1 Construction d'un modèle de réseau Bayésien pour l'analyse de fiabilité à base des arbres de défaillance	163
V.3.2.2 Les réseaux Bayésiens et la théorie d'évidence pour modéliser la fiabilité des systèmes complexes	168
V.3.3 DISCUSSION	175
V.3.3.1 Les variables Multi-Valeurs	175
V.3.3.2 Les réseaux Bayésiens pour modéliser les modes de défaillance dépendants et la propagation de l'incertitude	176
V.4 LES MODELES DYNAMIQUES DES RESEAUX BAYESIENS POUR MODELISER LA FIABILITE DYNAMIQUE	179
V.4.1 Construction des modèles de réseau Bayésien à base d'arbres de défaillance dynamiques pour modéliser la fiabilité dynamique	180
V.4.2 Réseau Bayésien Temporel Discret pour modéliser la fiabilité des systèmes dynamiques	183
V.4.2.1 Représentation de l'aspect temporel	184
V.4.2.2 La table des probabilités à priori	185
V.4.2.3 Tables de probabilités conditionnelles TPCs	186

V.4.3 Réseau Bayésien temporel continu pour modéliser la fiabilité des systèmes dynamiques _____	187
V.4.4 Réseau Bayésien orienté objets dynamique pour modéliser la fiabilité des systèmes dynamiques complexe _____	187
V.4.4.1 Unification de système de la connaissance fonctionnement et dysfonctionnement _____	188
V.4.4.2 Modélisation de la fiabilité en utilisant les RBOO _____	189
V.4.5 DISCUSSION _____	192
V. 5 CONCLUSION _____	194
CHAPITRE VI : RESEAUX BAYESIENS : UN MODELE DE GESTION DE CONNAISSANCES, APPLICATION A LA FIABILITE DES SYSTEMES _____	195
VI.1 INTRODUCTION _____	195
VI.2 UNE METHODE GENERIQUE POUR L'ANALYSE ET L'ESTIMATION DE LA FIABILITE A BASE DE RESEAUX BAYESIENS DYNAMIQUES _____	196
VI.2.1 Principe _____	197
VI.2.2 Construction et exploitation d'un modèle de RBD pour modéliser la fiabilité d'un système _____	198
VI.3.2 Construction du modèle de réseau Bayésien dynamique _____	204
VI.3.2.1 Apprentissage de structure du modèle _____	206
VI.3.2.2 Apprentissage des paramètres du modèle _____	208
VI.3 OPTIMISATION DU MODELE PROPOSE _____	209
VI.3.1 Métaheuristiques _____	209
VI.3.1.1 Les métaheuristiques à solution unique _____	210
VI.3.1.2 Les métaheuristiques à population de solutions _____	214
VI.3.2 Optimisation par colonie de fourmis (OCF) pour l'apprentissage de structure des réseaux Bayésiens _____	219
VI.3.3 L'apprentissage de structure du modèle proposé à base d'optimisation par colonie de fourmis _____	220
VI.3.3.1 Métaheuristique d'optimisation par colonie de fourmis _____	221
VI.4.3.2 Application à l'apprentissage de structure d'un réseau bayésien _____	223
VI.4 CAS DES BASE DE DONNEES INCOMPLETE _____	230
VI.5 TESTS ET VALIDATION _____	231
VI.5.1 Exemple N°1 : Le système « AHRS » _____	233
VI.5.1 Exemple N°2 : Le système « CPU » _____	236
VI.6 DISCUSSION _____	239
VI.7 CONCLUSION _____	241

CONCLUSION ET PERSPECTIVES _____	242
1. CONTRIBUTIONS _____	243
2. PERSPECTIVES _____	246
ANNEXE A _____	248
ANNEXE B _____	251
ANNEXE C _____	259
ANNEXE D _____	263
REFERENCES _____	271

LISTE DES ILLUSTRATIONS, GRAPHIQUES ET TABLEAUX

Figure I.1: Exemple d'un réseau Bayésien (parties qualitative et quantitative).	26
Figure I.2: Présentation de relation de causalité.	27
Figure I.3: La structure du modèle de RB de l'Exemple I.1 (Cambriolage ou tremblement de terre).	28
Figure I.4 : Une Connexion séquentielle sans évidence significative sur Alarme, une évidence sur Cambriolage influencera notre croyance sur l'appel de Watson et vice versa.	29
Figure I.5 : Une Connexion séquentielle avec une évidence significative sur Alarme, une évidence sur Cambriolage n'aura pas un effet sur notre croyance sur l'appel de Watson et vice versa.	29
Figure I.6 : Une Connexion séquentielle sans évidence significative sur Alarme, une évidence sur Cambriolage influencera notre croyance sur l'appel de Watson et vice versa.	29
Figure I.7 : Une Connexion séquentielle sans évidence significative sur Alarme, une évidence sur Cambriolage influencera notre croyance sur l'appel de Watson et vice versa.	30
Figure I.8 : Une Connexion séquentielle sans évidence significative sur Alarme, une évidence sur Cambriolage influencera notre croyance sur l'appel de Watson et vice versa.	30
Figure I.9 : Une Connexion séquentielle sans évidence significative sur Alarme, une évidence sur Cambriolage influencera notre croyance sur l'appel de Watson et vice versa.	30
Figure I.10 : Un exemple simple.	31
Figure I.11 : Échelle de probabilité.	37
Figure I.12 : Un exemple générique de chaîne de Markov à trois états représentée dans l'espace des états de X.	49
Figure I.13 : Un diagramme représente le processus d'évolution temporelle instantanée en utilisant l'approche basée sur les tranches de temps (Time-Sliced).	50
Figure I.14 : Modèle temporel avec des tranches du temps dupliquées.	51
Figure I.15 : Inférence RBD.	51
Figure III.1 : Les étapes de processus KDD.	91
Figure III.2 : Positionnement de la discipline du Data Mining.	96
Figure III.3: Taxonomie des méthodes du Data Mining [82].	98

Figure III.4 : Réseau Bayésien naïf. _____	103
Figure III.5 : Réseau Bayésien naïf augmenté (par un arbre). _____	103
Figure III.6 : Les RBs pour l'extraction et l'exploitation des connaissances. ____	110
Figure IV.1 : La courbe baignoire [93], [94]. _____	120
Figure IV.2 : Différentes parties de la courbe baignoire pour $\beta < 1$, $\beta = 1$, $\beta > 1$. ____	120
Figure IV.2: un système de k unités en série. _____	124
Figure IV.3 : Bloc-diagramme d'un système de k unités parallèles. _____	125
Figure IV.4: Bloc-diagramme d'un système de m-out-of-n unités. _____	126
Figure IV.5: Bloc-diagramme d'un système de réserve avec une unité fonctionnelle et k unités en attente. _____	127
Figure IV.6 : Une configuration bridge composée de cinq unités non identiques. _____	128
Figure IV.7 : Les étapes de l'analyse d'arbre de défaillance. _____	130
Figure IV.8 : Un exemple d'un arbre de défaillance. _____	134
Figure IV.9 : Digramme de décision binaire de $x \rightarrow y$. _____	135
Figure IV.10 : Exemple d'un arbre de défaillance et son diagramme de décision binaire équivalent. _____	136
Figure IV.11 : Coupe minimale de l'exemple. _____	137
Figure IV.12 : Représentation graphique de la porte logique FDEP. _____	139
Figure IV.13: Représentation graphique de la porte logique WSP. _____	139
Figure IV.14 : Représentation graphique de la porte logique PAND. _____	140
Figure IV.15: Indice de criticité. _____	147
Figure IV.16: Bloc-diagramme d'un système parallèle aux défaillances de cause commune. _____	149
Figure IV.17 : Diagramme de l'espace d'état d'un système. _____	151
Figure IV.18 : Une Chaîne de Markov modélisant la fiabilité d'un composant. ____	153
Figure V.1 : Tendances des publications dans le domaine de l'estimation de la fiabilité des systèmes à base de réseaux Bayésiens [103]. _____	158
Figure V.2 : La distribution des références sur les thèmes : Les RBD pour la fiabilité dynamique et les RBs pour la fiabilité. _____	159
Figure V.3 : Tendances des publications dans le domaine de l'estimation de la fiabilité des systèmes à base de réseaux Bayésiens statiques et dynamiques. _	160
Figure V.4 : Les étapes de construction et d'utilisation d'un modèle de RB. ____	162
Figure V.5 : Arbre de défaillance : Porte logique OU. _____	164

Figure V.6 : Modèle de RB équivalent de la porte logique OU. _____	164
Figure V.7 : La porte logique ET d'un arbre de défaillance (a) et son modèle de RB équivalent (b). _____	165
Figure V.8 : La porte logique K/N (2:3) d'un arbre de défaillance (a) et son modèle de RB équivalent (b). _____	166
Figure V.9 : Arbre de défaillance : Porte logique K/N. _____	167
Figure V.10 : Modèle de réseau Bayésien équivalent de la porte logique K/N. _	168
Figure V.11: Réseau d'évidence de la porte logique ET. _____	170
Figure V.12: Réseau d'évidence de la porte logique OU. _____	171
Figure V.13: Réseau d'évidence de la porte logique 2/3. _____	172
Figure V.14: Tendances des publications dans le domaine de l'estimation de la fiabilité dynamique à base de réseaux Bayésiens dynamiques. _____	179
Figure V.15: Représentation graphique des portes logiques dynamiques WSP (a), FDEP (b) et PAND (c). _____	180
Figure V.16: Le RBD représentant la porte logique WSP (a) [118]. _____	181
Figure V.17: Le RBD représentant la porte logique PDEF (b) [118]. _____	181
Figure V.18: Le RBD représentant la porte logique PAND (c) [118]. _____	181
Figure V.20: Architecture du logiciel RADYBAN. _____	182
Figure V.21: Représentation graphique des portes logiques PDG et RBoxes [120]. _____	182
Figure V.22: La porte logique OU et son RBTD équivalent. _____	184
Figure V.23 : La porte logique CSP et son RBTD équivalent. _____	185
Figure V.24: Décomposition fonctionnelle [115]. _____	189
Figure V.25: L'entrée générique de RB et la structure des nœuds de sortie [115]. _____	190
Figure V.26: Le niveau haut de la décomposition fonctionnelle [115]. _____	190
Figure V.27: RB : structure V. _____	191
Figure V.28: RB structure série. _____	192
Figure VI.1 : Processus de découverte et d'exploitation des connaissances modélisant la fiabilité d'un système en utilisant les RBs. _____	197
Figure VI.2 : exemple des données prise de l'historique de fonctionnement d'une centrale thermique productrice d'énergie électrique. _____	198
Figure VI.2 : Structure de données. _____	199

Figure VI.3: Modélisation la dégradation d'un composant à travers le temps (fiabilité) en utilisant le 2TBN.	202
Figure VI.4: Un réseau à priori et un réseau de transition définissant un réseau Bayésien dynamique pour les attributs X_1, X_2, X_3 .	203
Figure VI.5: Le réseau Bayésien dynamique "déroulé" correspondant au réseau Bayésien de la Figure VI.4.	203
Figure VI.6: Les liens temporels et les états de transition dans un système complexe.	204
Figure VI.7: Schéma représentant l'apprentissage de structure du modèle à partir d'une base de cas.	205
Figure VI.7 : Types d'inférence utilisés pour l'analyse et l'évaluation de fiabilité.	209
Figure VI.8 : Les fourmis et le plus court chemin.	218
Figure VI.9 : Exemple de réseau bayésien et son représentant dans l'espace des classes d'équivalence de Markov [5].	224
Figure VI.9 : Le schéma bloque de l'architecture de AHRS.	233
Figure VI.10: Les données générées pour l'exemple AHRS.	234
Figure VI.11 : Le RBD de AHRS construit à partir les données générées (cas où il n'y a pas un mécanisme de réparation ou de maintenance).	235
Figure VI.12 : Les taux de défaillances des composants de système AHRS.	235
Tableau VI.2 : Les résultats obtenus pour l'exemple AHRS.	236
Figure VI.13 : Les données générées pour l'exemple "CPU".	236
Figure VI.14 : Le RBD de CPU construit à partir les données générées (cas où il n'y a pas un mécanisme de réparation ou de maintenance).	237
Figure VI.15 : Les taux de défaillances des composants de CPU.	237
Tableau VI.3: Les résultats obtenus pour l'exemple CPU.	238
Figure VI.15: Le RBD du Bloc N°1 de la centrale thermique.	239

LISTE DES TABLEAUX

Tableau IV.1 : Fonctions et formules mathématiques générales de la fiabilité [94]	117
Tableau IV.2 : Symboles utilisés pour la représentation graphiques des arbres de défaillance [95]	131
Tableau IV.3 : Transformation un évènement en une variable booléenne	134
Tableau IV.4 : Codage des portes logiques d'un arbre de défaillance par les diagrammes de décision binaires	135

Tableau IV.5 : Exemple de hiérarchisation de probabilité de défaillance _____	145
Tableau IV.6 : Tableau de gravité _____	146
Tableau IV.6 : Indice de détection _____	146
Tableau V.1: La table de masse conditionnelle de la porte logique ET _____	170
Tableau V.2: La table de masse conditionnelle de la porte logique OU _____	171
Tableau V.3: La table de masse conditionnelle de la porte logique 2/3 _____	172
Tableau V.4 : Table de masse conditionnelle de la fonction de crédibilité Bel(Etat du système=En marche) _____	174
Tableau V.5: Table de masse conditionnelle de la fonction de plausibilité Pls(Etat du système=En marche) _____	174
Tableau V.5 : Tableau comparatif _____	177
Tableau VI.1 : Structure de base de données générée _____	232
Tableau VI.2 : Les résultats obtenus pour l'exemple AHRS _____	236
Tableau VI.3: Les résultats obtenus pour l'exemple CPU _____	238

INTRODUCTION GENERALE

1. INTRODUCTION

L'aspect aléatoire et le jugement incertain est inhérent à la plupart des problèmes de décision réels. On a besoin donc d'une méthode (un paradigme) qui supporte la représentation des mesures quantitatives de rapports incertains et d'une méthode pour combiner les mesures de façon que le raisonnement et la prise de décision sous l'incertitude peut être automatisé. La théorie des probabilités est la méthode régnante pour traiter l'incertitude, Cependant, d'autres méthodes ont été proposées à savoir la théorie de croyance et les méthodes floues.

Les chercheurs se sont aperçu que les systèmes à base de règles avec des facteurs de certitude ont de sérieuses limitations en tant qu'une méthode pour la représentation de la connaissance et le raisonnement incertain, ils ont tourné leur attention vers une traduction probabiliste des facteurs de certitude, comme les Réseaux Bayésiens (RBs) initiés par *JUDEA PEARL* dans les années 1980 [37].

La représentation des connaissances et le raisonnement à partir de ces représentations a donné naissance à de nombreux modèles. Les modèles graphiques probabilistes, et plus précisément les réseaux bayésiens, se sont révélés des outils très pratiques pour la représentation de connaissances incertaines et le raisonnement à partir d'informations incomplètes, dans de nombreux domaines comme la bio-informatique, la gestion du risque, le marketing, la sécurité informatique, le transport, etc. La partie graphique des RBs offre un outil intuitif inégalable et attractif dans de nombreuses applications où les utilisateurs ont besoin de "comprendre" ce que raconte le modèle qu'ils utilisent. La construction de ces modèles à partir de données permet aussi de découvrir des connaissances utiles aux experts, en allant – sous certaines réserves - jusqu'à la découverte de relations causales [5].

2. MOTIVATIONS

Les réseaux Bayésiens ont été proposés dans le domaine de l'intelligence artificielle comme un formalisme probabiliste pour le raisonnement incertain. La robustesse et la flexibilité de ce formalisme ont été démontrées par le large spectre des problèmes réels dans lesquels il a été testé avec succès.

Un réseau Bayésien est une représentation compacte et intuitive des relations causales entre les entités du domaine d'un problème. Où les entités sont représentées par des variables discrètes sur des ensembles finis qui contiennent des valeurs mutuellement exclusives et exhaustives ou bien par des variables continues qui appartiennent à des intervalles bien précis. De ce fait, plusieurs raisons font des réseaux Bayésiens un formalisme de modélisation intéressant vu leurs caractéristiques :

- ✓ Une représentation compacte et intuitive des relations "cause-effet" et des relations de dépendance et d'indépendance conditionnelle.
- ✓ Un modèle cohérent et fondé mathématiquement qui intègre l'incertitude et génère des décisions normatives.
- ✓ Construction automatique du modèle à partir des données statistiques.
- ✓ Une solution efficace des requêtes en donnant les évidences et la capacité de supporter tout les types d'analyse du résultat produit.

Récemment, certains travaux de recherche ont commencé à vérifier et examiner la capacité de cette méthodologie dans la modélisation et l'analyse des systèmes complexes où la sûreté de fonctionnement est un facteur crucial. En effet, La fiabilité des systèmes est devenue un des domaines d'applications des réseaux Bayésiens.

Les outils de fiabilité sont devenus un moyen indispensable pour la modélisation et l'analyse des systèmes (critiques). Cependant la complexité croissante de tels systèmes nécessite l'amélioration continue de ces outils. Ces derniers doivent capturer non seulement le comportement dynamique et complexe des composants de système, mais ils doivent être également faciles à utiliser, intuitifs, et efficaces. En général, les outils conventionnelles d'analyse de la fiabilité ont un certain nombre d'imperfections comprenant la modélisation

impuissante, l'incapacité de manipuler efficacement les distributions générales de défaillance des composantes, et l'inefficacité en résolvant les grands modèles qui ont des dépendances complexes entre leurs composants.

En particulier, en ce qui concerne les formalismes traditionnels d'analyse de fiabilité, les réseaux Bayésiens montrent une puissance de modélisation accrue. Ils permettent de modéliser d'une façon naturelle (intuitive) par exemple, les variables multi-valeurs, les dépendances locales entre les composants, et l'interaction entre le comportement des composants, trois aspects qui ne peuvent pas être facilement représenté par les arbres de défaillance. En outre, un mécanisme d'inférence général (combinant la prédiction ainsi que le diagnostic) peut être effectué pour calculer les probabilités. Plusieurs extensions du formalisme des réseaux Bayésiens semblent également être d'un grand intérêt: parmi eux on trouve, les réseaux Bayésien dynamiques ou temporelles pour faire face aux comportements des systèmes dynamiques, les réseaux Bayésiens orienté objet pour faire face à la modélisation des systèmes complexes, et les réseaux bayésiens hybrides pour intégrer les facteurs de nature continue de la fiabilité.

3. PROBLEMATIQUE

Les réseaux Bayésiens et les réseaux Bayésiens dynamiques sont particulièrement appropriés à collecter et à représenter les connaissances incertaines mais également, permettent d'effectuer efficacement, les calculs probabilistes et les analyses statistiques. Cependant, parmi les inconvénients des réseaux Bayésiens est qu'il n'y a aucune sémantique qui guide le développement du modèle et garantit sa cohérence quand il est construit par les experts, parce que c'est un processus subjectif.

Grâce aux capacités de modélisation offertes par les réseaux Bayésiens, ces derniers sont utilisés en tant qu'un modèle de représentation et d'interprétation de connaissances. En outre, les réseaux Bayésiens sont équipés d'un mécanisme d'inférence, ce qu'il leur a permis d'être utiles pour la validation des connaissances extraites dans le cadre de processus de Knowledge Discovery (KDD). Ils sont aussi employés comme une technique du Data Mining pour la classification et le clustering, mais pas comme un modèle d'extraction de connaissances à part entière. Cela est dû au fait que le développement des méthodes de construction

automatique des modèles de réseau Bayésien à partir des données est relativement récent.

Concernant le domaine de l'analyse et l'estimation de la fiabilité en utilisant les réseaux Bayésiens, deux grands axes de recherches sont constatés : le premier consiste à convertir le modèle conçu par une méthode classique d'analyse de fiabilité telle que l'analyse d'arbres de défaillance (la méthode la plus usitée) en un réseau Bayésien/réseau Bayésien dynamique équivalent, ce qui mène à un modèle cohérent mais limité par les contraintes imposées par les méthodes traditionnelles et ne permet pas d'exploiter tous les avantages de modélisation offerts par les réseaux Bayésiens; le deuxième axe consiste à trouver de nouvelles méthodologies de construction de modèles de réseau Bayésien représentant le système à étudier. Quoique, des problèmes de validation du modèle conçu se poseront par la suite.

4. OBJECTIFS

Notre étude s'intègre dans le deuxième axe de recherches cité précédemment, du fait que l'objectif de notre travail est le développement d'une méthode holistique pour la construction automatique sans l'intervention des experts, d'un modèle de réseau Bayésien dynamique pour l'estimation et l'analyse de la fiabilité dynamique. Autrement dit, nous proposons un cadre générique de modélisation et d'analyse de fiabilité basé sur le formalisme des réseaux Bayésiens dynamiques.

L'objectif général de ce travail est l'utilisation des réseaux Bayésiens comme un outil intégré d'extraction, de représentation et d'exploitation des connaissances. A cet effet, nous avons proposé d'extraire les connaissances nécessaires à la modélisation de la fiabilité d'un système sous forme d'un réseau Bayésien dynamique à partir des données. Cela dit que nous allons exploiter les données de test (dans le cas d'un nouvel système qui il n'a pas encore été mis en exploitation) ou dans le cas général et idéal, les données prises de l'historique de fonctionnement d'un système quand ce dernier a déjà fonctionné (retour d'expériences) pour construire le réseau bayésien dynamique modélisant la fiabilité d'un système et d'exploiter le modèle généré pour l'analyse et l'estimation de la fiabilité en utilisant les algorithmes d'inférence. Par conséquent, cette

problématique s'intègre dans le cadre de processus de la découverte et d'exploitation de connaissances.

Notre approche permet d'une part de construire un modèle fiable et d'exploiter toutes les capacités des réseaux Bayésiens dans la modélisation des systèmes complexes. et d'autre part de prouver que les réseaux Bayésiens peuvent être utilisés comme un outil intégré d'extraction de représentation et d'exploitation des connaissances.

5. GUIDE DE LECTURE

Dans un premier temps, à travers les trois premiers chapitres du mémoire nous allons aborder les thèmes constituant le contexte du problème : les réseaux Bayésiens et l'apprentissage des réseaux Bayésiens et les réseaux bayésiens pour l'extraction, la représentation et l'exploitation des connaissances. L'étude de ces thèmes est nécessaire pour la compréhension de l'objet de notre travail.

Dans le premier chapitre, nous faisons une étude générale sur les réseaux Bayésiens, leurs propriétés, leur mécanisme et algorithmes d'inférence, ainsi que leurs différents types, plus particulièrement leurs modèles dynamiques.

Dans le deuxième chapitre, nous nous intéressons à l'apprentissage des réseaux Bayésiens et en particulier, leurs modèles dynamiques. L'apprentissage d'un réseau Bayésien se décompose en deux phases. Nous explicitons en premier lieu, les méthodes et les algorithmes d'apprentissage de paramètres des réseaux Bayésiens et de leurs modèles dynamiques dans les deux cas, le cas de l'apprentissage à partir de bases de données complètes et celui de bases de données incomplètes. En deuxième lieu nous présentons les méthodes d'apprentissage de structure des réseaux Bayésiens à partir des bases de données complètes et incomplètes tout en se focalisant sur les méthodes utilisés pour l'apprentissage de structure des réseaux Bayésiens dynamiques.

Le troisième chapitre présente dans une première partie, un état l'art sur l'utilisation des réseaux Bayésiens dans le cadre knowledge discovery, et dans une deuxième partie, notre vision d'utilisation des réseaux Bayésiens comme un modèle intégré d'extraction, de représentation et d'exploitation des connaissances.

Dans une deuxième partie du mémoire, nous présentons dans le quatrième chapitre, ce qu'est la fiabilité des systèmes, sa définition, ses concepts mathématiques, et un bref historique. Un ensemble des méthodes d'analyse de la fiabilité des systèmes est aussi présentées dans ce chapitre.

Le cinquième chapitre présente un état de l'art détaillé sur l'utilisation des réseaux Bayésiens pour l'analyse et l'estimation de la fiabilité des systèmes statiques et dynamiques. Cet état de l'art comprend l'étude des travaux de recherche les plus intéressants publiés dans ce contexte jusqu'à présent. Cet état de l'art dresse un bilan global sur les recherches dans ce domaine.

Dans le sixième et le dernier chapitre, nous présentons notre approche et les outils utilisés. Nous exposons à la fin de ce chapitre quelques exemples pour valider notre travail.

La conclusion générale présente notre contribution et l'apport apporté par rapport aux recherches menés dans ce domaine et enfin les perspectives attendues pour compléter ce travail.

A la fin de document, outre la bibliographie regroupant les différentes références, le lecteur pourra trouver des annexes contenant les principaux rappels quant à certaines notions employées dans notre travail. Parmi celles-ci se trouvent quelques notions de probabilités.

CHAPITRE I : LES RESEAUX BAYESIENS

I.1 INTRODUCTION

L'un des enjeux principaux dans le domaine de la recherche en Intelligence Artificielle (IA) est d'être capable de concevoir et de développer des systèmes dynamiques et évolutifs. De ce fait, ces derniers doivent être équipés de comportements intelligents qui peuvent apprendre et raisonner. Mais dans la plupart des cas, la connaissance acquise n'est pas toujours adéquate pour permettre au système de prendre la décision la plus appropriée.

Pour répondre à ce genre de questions, plusieurs méthodologies ont été proposées, mais seules les approches probabilistes s'adaptent mieux non seulement au raisonnement avec la connaissance et la croyance incertaine, mais aussi à la structure de la représentation de la connaissance. Ces approches probabilistes sont appelées "*réseaux Bayésiens*", mais sont aussi connues sous le nom de "*belief networks*", "*causal networks*".

Dans ce chapitre, nous allons présenter ce que sont les réseaux Bayésiens, leurs propriétés, leur mécanisme d'inférence, ainsi que leurs différents types, et plus particulièrement leurs modèles dynamiques. Le sujet étant très étendu, nous ne saurions le traiter exhaustivement. Nous pouvons néanmoins recommander quelques ouvrages, tels que **[1]** et **[2]** au lecteur souhaitant approfondir le sujet.

I.2 RESEAUX BAYESIENS

Les réseaux Bayésiens sont la combinaison des approches probabilistes et de la théorie de graphes. Autrement dit, ce sont des modèles qui permettent de représenter des situations de raisonnement probabiliste à partir de connaissances incertaines. Ils sont une représentation efficace pour les calculs d'une distribution de probabilités **[3]**.

Ils constituent à la fois un formalisme de représentation des connaissances, ainsi qu'un outil permettant d'expliquer et de prédire l'état de variables d'intérêt d'un domaine de connaissances en fonction de l'état de variables observées. De

part le développement d'algorithmes d'inférences efficaces, les réseaux Bayésiens ont été récemment mis en applications dans de nombreux domaines, tels que l'aide au diagnostic médical et industriel et le calcul de la fiabilité, la surveillance de réseaux de télécommunications, la classification automatique de documents structurés ou encore l'analyse d'images.

Définition I.1: *Un réseau Bayésien (RB) est un graphe orienté sans circuits (GOSC) (DAG pour Direct Acyclic Graph) qui définit une factorisation d'une distribution de probabilité jointe sur des variables qui sont représentées par les nœuds de ce graphe, cette factorisation est donnée par les liens orientés du DAG, plus précisément un graphe orienté sans circuits $G, G = (V, E)$ tel que V dénote l'ensemble des nœuds (ou les sommets) et E dénote l'ensemble des liens orientés (ou les arcs) reliant les nœuds de ce graphe, la distribution de la probabilité jointe $P(X_v)$ sur l'ensemble des variables X_v indexé par V est [1] :*

$$\mathbb{P}(X_v) = \prod_{v \in V} \mathbb{P}(X_v | X_{pa(v)}) \quad (I.1)$$

Où $X_{pa(v)}$ dénote l'ensemble de variables parents de la variable X_v pour chaque nœud.

Autrement dit, un réseau Bayésien se compose de deux parties. Une partie qualitative, qui est un graphe orienté sans circuits dont les nœuds représentent les variables aléatoires, et une partie quantitative définissant l'ensemble de fonctions de probabilité conditionnelles (FPCs). Un exemple d'un réseau Bayésien sur les variables $X = (X_1, \dots, X_n)$ est montré sur la Figure I.1, les deux parties qualitative et quantitative sont représentées.

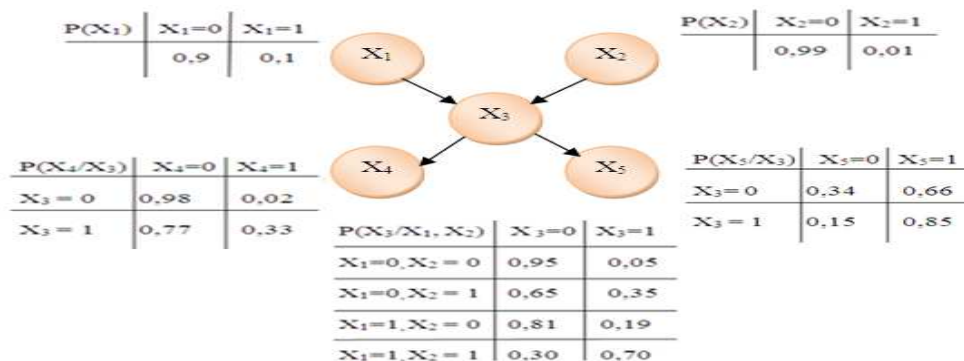


Figure I.1: Exemple d'un réseau Bayésien (parties qualitative et quantitative).

1.2.1 Représentation de la causalité

La causalité joue un rôle important dans la construction des modèles des réseaux probabilistes. Il n'est pas strictement nécessaire que les liens orientés du modèle représentent une interprétation causale dans un réseau Bayésien, par contre dans les modèles avec une représentation explicite des décisions, appelés les diagrammes d'influence "Influence Diagrams" les liens orientés doivent représenter des relations de causalité [1].

Pour représenter correctement les relations de dépendance et d'indépendance qui existent entre les variables d'un domaine du problème, les relations de causalité sont représentées par des arcs orientés de la cause vers l'effet.

Si X est la cause directe de Y , le lien est : $X \rightarrow Y$ et il est représenté graphiquement comme suit:



Figure 1.2: Présentation de relation de causalité.

Par exemple, si on considère les variables *Grippe* et *Fièvre*, considérant que la grippe est la cause de la fièvre et pas le contraire, on peut vérifier ce fait en changeant les états des deux variables, faire disparaître la fièvre en prenant de l'aspirine n'a pas une influence sur l'état de la grippe, tandis que l'élimination de la grippe en prenant un antibiotique, va rendre la température du corps à l'état normal. Ce qui confirme que la *Grippe* est la cause de la *Fièvre* et pas le contraire, alors : ***Grippe* → *Fièvre***.

1.2.2 Circulation de l'information dans un réseau Bayésien

Comme mentionné ci-dessus, le graphe orienté sans circuits d'un réseau Bayésien est une représentation graphique des propriétés de dépendance et d'indépendance d'une distribution de probabilité jointe, pour lire ces propriétés à partir d'un GOSC, on doit connaître les différents types de base possibles des connections qui peuvent exister dans un GOSC.

Pour illustrer ces différents types de connexions, considérant l'exemple présenté dans la Figure I.3, qui montre la structure d'un petit réseau Bayésien fictif, où les variables sont

binaires (c.à.d, elles peuvent prendre seulement deux valeurs faux= 0 et vrais=1).

Exemple I.1: (Cambriolage ou tremblement de terre [1]) Monsieur Holmes travaillait dans son bureau, quand il a reçu l'appel de son voisin Dr Watson lui informant que son alarme de cambriolage a sonné, convaincu qu'un voleur à pénétrer dans sa maison. Mr Holmes prend sa voiture et part à sa maison, à son chemin, il allume la radio, il entend qu'il a eu un petit tremblement de terre dans sa région. Sachant qu'un tremblement de terre à tendance à provoquer la sonnerie de l'alarme de cambriolage, il retourne à son bureau.

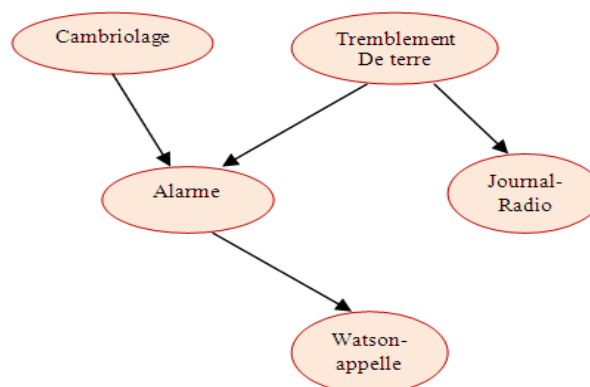


Figure I.3: La structure du modèle de RB de l'Exemple I.1 (Cambriolage ou tremblement de terre).

I.2.2.1 Connexions séquentielle

Considérant la connexion séquentielle présentée sur la Figure I.4. Premièrement, supposant qu'on n'a pas défini une connaissance sur l'état de la variable de milieu **Alarme**. Alors une évidence sur l'état de la variable **Cambriolage** nous fera une mise à jours de notre croyance sur l'état de la variable **Alarme**, qui nous fera à son tour une mise à jours de notre croyance sur l'état de la variable **Watson-appelle**, l'inverse est aussi vrais.




Figure I.4 : Une Connexion séquentielle sans évidence significative sur *Alarme*, une évidence sur *Cambriolage* influencera notre croyance sur *l'appel de Watson* et vice versa.




Figure I.5 : Une Connexion séquentielle avec une évidence significative sur *Alarme*, une évidence sur *Cambriolage* n'aura pas un effet sur notre croyance sur *l'appel de Watson* et vice versa.

Proposition I.1 : L'information peut être transmise à travers d'une connexion séquentielle $X \rightarrow Y \rightarrow Z$ à moins que l'état de Y est inconnu.

I.2.2.2 Connexions divergente




Figure I.6 : Une Connexion divergente sans évidence significative sur *Tremblement de terre*, une évidence sur *Alarme* influencera notre croyance sur *Journal-Radio* et vice versa.




Figure I.7 : Une Connexion divergente avec une évidence significative sur *Tremblement de terre*, une évidence sur *Alarme* n'aura pas un effet sur notre croyance sur *Journal-Radio* et vice versa.

Proposition I.2 : *L'information peut être transmise à travers d'une connexion divergente $X \leftarrow Y \rightarrow Z$ à moins que l'état de Y est inconnu.*

I.2.2.3 Connexions convergente (ou V-structure)




Figure I.8 : Une Connexion convergente sans évidence significative sur *Alarme*, une évidence sur *Cambriolage* influencera notre croyance sur *Tremblement de terre* et vice versa.




Figure I.9 : Une Connexion convergente avec une évidence significative sur *Alarme*, une évidence sur *Cambriolage* influencera notre croyance sur *Tremblement de terre* et vice versa.

Proposition 1.3: *L'information peut être transmise à travers d'une connexion convergente $X \rightarrow Y \leftarrow Z$ seulement si une évidence sur l'état de Y ou un de ses descendants est disponible.*


1.2.2.4 Le Critère de d-Séparation

Un chemin $\pi = (u \dots v)$ dans un DAG, $G = (V, E)$ est dit bloqué par $S \subseteq V$ si π contient un sommet w tel que:

- $w \in S$ et les bords de π ne doivent pas se réunir tête à tête dans w . Ou
- w n'appartient pas à S , de $(w) \cap S = \emptyset$, et les bords de π se réunissent tête à tête dans w .

Pour les arbres (pas nécessairement disjoint) les sous ensembles A, B, S de V , A et B sont dit d-séparé si tous les chemins entre A et B sont bloqués S .

Cela veut dire que deux sommets u et v sont d-séparés si seulement si pour chaque chemin entre u et v il existe un sommet w tel que les bords de chemin se réunissent tête à tête dans w .



1. C et G sont d-connectés
2. C et E sont d-séparés
3. C et E sont d-connectés en donnant l'évidence sur G
4. A et G sont d-séparés en donnant l'évidence sur D et E
5. A et G sont d-connectés en donnant l'évidence sur D

Figure 1.10 : Un exemple simple.

1.2.2.5 Le Critère de "Directed Global Markov"

Le critère de "*Directed Global Markov*" est un critère équivalent au critère de d-Séparation, mais dans certains cas, il est plus efficace parce qu'il demande moins d'inspection des chemins possibles entre les sommets concernés.

Soit $G = (V, E)$ un DAG et A, B, S des ensembles disjoints de V , alors chaque paire de nœuds ($\alpha \in A, \beta \in B$) sont d-séparé par S pour chaque chemin de α à β bloqué par des nœuds S en dans le graphe $G_{An}(A \cup B \cup S)^m$.

I.2.3 Types des réseaux Bayésiens

I.2.3.1 Réseaux Bayésiens discret

Un réseau Bayésien discret $N = (X, G, \mathbb{P})$ consiste en **[1]** :

- Un DAG $G = (V, E)$ avec des nœuds $V = \{v_1, \dots, v_n\}$ et des liens orientés E .
- Un ensemble de variables aléatoires discrètes, X , représentées par les nœuds du graphe.
- Un ensemble de distributions de probabilité conditionnelle \mathbb{P} contenant une distribution $\mathbb{P}(X_v | X_{\text{pa}(v)})$, pour chaque variable aléatoire $X_v \in X$.

I.2.3.2 Réseaux Bayésiens continu

Un réseau Bayésien continu $N = (X, G, \mathbb{P})$ consiste en **[1]** :

- Un DAG $G = (V, E)$ avec des nœuds $V = \{v_1, \dots, v_n\}$ et des liens orientés E .
- Un ensemble de variables continues, X , représentées par les nœuds du graphe.
- Un ensemble de fonctions de densité de probabilité conditionnelle \mathbb{P} contenant une distribution $\mathbb{P}(X_v | X_{\text{pa}(v)})$, pour chaque variable aléatoire $X_v \in X$.

I.2.3.3 Réseaux Bayésiens hybride

Un réseau Bayésien hybride $H = (X, G, \mathbb{P})$ consiste en **[1]** :

- Un DAG $G = (V, E)$ avec des nœuds $V = \{v_1, \dots, v_n\}$ et des liens orientés E .
- Un ensemble de variables aléatoires discrètes et continues, X , représentées par les nœuds du graphe.
- Un ensemble de fonctions de densité et de distribution de probabilité conditionnelle \mathbb{P} , contenant une distribution $\mathbb{P}(X_v | X_{\text{pa}(v)})$, pour chaque variable aléatoire $X_v \in X$.

I.2.3.4 Réseau Bayésien orienté objet (RBOO)

DAPHNE KOLLER et *AVI PFEFFER* présentent dans [4] les fondements théoriques du formalisme « réseau Bayésien orienté objet ». Ce formalisme a été introduit pour représenter les connaissances à grande échelle en utilisant les réseaux Bayésiens.

L'élément de base dans un Réseau Bayésien Orienté Objet (RBOO) est l'objet, la majorité des objets de base sont des variables aléatoires standards comme dans un RB classique. Cependant, un RBOO peut contenir des objets complexes possédant des attributs. Un objet est une collection des propriétés associée à une entité du domaine à modéliser, l'entité peut être physique comme elle peut être aussi abstraite ou une relation entre les différentes entités.

Le mécanisme de base des RBOO décrit ci-dessus supporte un type d'une spécification orienté objet des réseaux Bayésiens, ce qui le rend adéquat pour la réutilisation des modèles et l'encapsulation des sous modèles, fournissant ainsi un outil approprié pour la modélisation hiérarchique et la construction des modèles des réseaux en mode (haut/bas) ou (bas/haut) ou bien en mode mixte à des différents niveaux d'abstraction du système à étudier, ce qui permet un échange meilleur des idées entre les experts du domaine, les ingénieurs et les utilisateurs. La modélisation orienté objet s'adapte mieux au raisonnement humain qui étudie les systèmes en termes des hiérarchies d'abstraction et en parties du fait que Le cerveau humain ne peut pas capturer toutes les détails concernant un système complexe en même temps.

Ces modèles sont particulièrement bien adaptés pour représenter les réseaux Bayésiens dynamiques (Ces derniers sont explicités dans la partie I.7 de ce chapitre).

I.2.4 Conditions d'utilisation des réseaux Bayésiens

Face à un nouveau problème, il faut d'abord déterminer est que le choix d'utiliser les réseaux Bayésiens comme méthodologie de modélisation est correcte, il se peut qu'un réseau Bayésien ne soit pas l'outil le plus adéquat pour résoudre le problème.

- *Des variables bien définies*: par exemple pour un problème médical, les symptômes d'une maladie sont bien définis.
- *Un domaine de problème très structuré avec des relations "cause-effet" identifiables et bien établies*.
- *Incertitude associée aux relations "cause-effet"*: si toutes les relations cause-effet sont déterministes toutes les probabilités conditionnelles auront la valeur 0 ou 1, dans des domaines réels de problèmes, plusieurs types d'incertitudes sont associés au mécanisme "cause-effet" à cause d'informations ou de connaissances incomplètes, du bruit (erreurs de mesure), ou d'abstraction de l'information (ex: discrétisation des valeurs réelles).
- *Résolution d'un problème répétitif*:
- *Maximisation de l'utilité prévue*:

I.3 CONSTRUCTION D'UN RESEAU BAYESIEN

Un réseau Bayésien peut être construit manuellement en interrogeant les experts du domaine, ou semi-automatiquement à partir des données statistiques, ou bien en combinant les deux méthodes. En général le processus de construction passe par deux étapes, la première consiste à construire la structure du réseau et la deuxième consiste à estimer ses paramètres.

I.3.1 Identification des variables du modèle

L'ensemble des variables d'un réseau Bayésien constitue la pierre angulaire du modèle, les variables peuvent être discrètes ou continues, elles peuvent être aussi des variables de *chance (hazard)* qui modélisent les événements du domaine qui ne sont pas sous le contrôle du décideur ou des variables de décision représentant d'une manière précise la décision prise par le décideur.

I.3.2 Tirer la structure du réseau

Pour construire la structure d'un réseau Bayésien, on a deux sources d'informations, des informations provenant des experts du domaine, et des données statistiques. Par conséquent on a deux méthodes de construction d'un

modèle de réseau Bayésien, le choix de la méthode à utiliser est imposé par la source des informations disponibles.

I.3.2.1 La construction d'un réseau Bayésien en collaboration avec les experts du domaine

La construction d'un réseau Bayésien en utilisant les connaissances des experts du domaine est une tâche difficile et consommatrice du temps, elle est menée par un ensemble de spécialistes. Un expert en réseaux Bayésiens dirige le processus de construction, il pose des questions pertinentes, et explique les suppositions encodées dans le modèle au reste du groupe des spécialistes.

I.3.2.2 La construction d'un réseau Bayésien à partir des données statistique (Modélisation basé sur les données)

La modélisation basée sur les données consiste à identifier la structure d'un réseau Bayésien à partir d'une source de données. La base de données peut être complète, comme elle peut être incomplète par conséquent, les méthodes d'apprentissage de structure des réseaux Bayésiens se divise en deux classes, la classe des algorithmes d'apprentissage à partir des données complètes et celle des algorithmes d'apprentissage à partir des données incomplètes.

Puisque la dimension de l'espace de recherche des structures d'un réseau Bayésien est égale au nombre des variables de ce dernier, l'apprentissage de structure des réseaux Bayésiens est un problème NP-difficile et parfois NP-Complet [41], en effet, les algorithmes d'apprentissage de structure peuvent être exactes ou approximatives. Les méthodes d'apprentissage de structure des réseaux Bayésiens sont étudiées d'une façon détaillée dans le chapitre suivant (voir le Chapitre II : Apprentissage des réseaux Bayésiens).

I.4.3 Vérification du modèle

Le modèle une fois construit, il doit être vérifié et validé par les experts du domaine ou en utilisant des méthodes de validation [1].

I.4.4 Construire les tables de probabilité conditionnelle (Estimation des paramètres)

Les tables de probabilité conditionnelle (TBCs) peuvent être construites de deux manières différentes. Si on dispose des données, les TBCs sont construites en utilisant les algorithmes d'apprentissage des paramètres (Voir le chapitre II). Mais, dans de nombreuses applications réelles on dispose généralement de très peu de données. Dans ces situations, l'apprentissage des paramètres du RB passe par l'utilisation des connaissances d'experts pour tenter d'estimer les probabilités conditionnelles [5]. Une première difficulté, souvent appelée élicitation de probabilités dans la littérature, et de manière plus générale dans le domaine de l'acquisition de connaissances, consiste à associer une probabilité de réalisation à un fait (réalisation d'une variable) [6].

Les difficultés liées à cette problématique relèvent généralement de l'ingénierie de la connaissance et de nombreuses méthodes ont été proposées au fil des années.

Ci-dessous, on détaillera trois types de problèmes spécifiques, ainsi que les solutions que l'on peut trouver dans la littérature [6]:

- Le premier problème concerne l'estimation de la probabilité d'un événement par un expert;
- Le deuxième concerne l'estimation d'un événement conditionnellement à un grand nombre de variables ;
- Le troisième problème consiste à être capable d'intégrer différentes sources d'informations multiples, en prenant en compte la fiabilité de différents experts et de différentes sources.

De nombreux travaux existent sur l'élicitation de probabilités [6]. La tâche la plus difficile est de trouver un expert à la fois fiable, disponible, puis de le familiariser à la notion de probabilité. Ensuite il faut tenir compte des biais éventuels : par exemple un expert peut surestimer la probabilité de réussite d'un projet le concernant, etc. La deuxième étape consiste à fournir à l'expert des outils associant des notions qualitatives et quantitatives pour qu'il puisse associer une probabilité aux différents événements. L'outil le plus connu et le plus facile à mettre en place est l'échelle de probabilité, présentée dans la Figure I.11.

Le deuxième problème concerne le cas où un expert doit estimer la probabilité conditionnelle $\mathbb{P}(Y|X_1, X_2, \dots, X_n)$. Pour simplifier, prenons l'hypothèse où toutes les variables (Y et X_i) sont binaires. L'expert devra alors estimer 2^n valeurs : cela devient rapidement irréaliste dès que n est grand, ce qui est le cas pour de nombreux cas d'applications réels. L'idée est alors de simplifier cette probabilité conditionnelle en posant les hypothèses suivantes :

- On peut calculer facilement la probabilité suivante :
 $p_i = p(y|\bar{x}_1, \bar{x}_2, \dots, \bar{x}_i, \bar{x}_n)$;
- « X_i cause Y » est indépendant des autres variables X_j .

Le modèle OU bruité nous dit alors que :

- Si un des X_i est vrai, alors Y est presque toujours vrai (avec la probabilité p_i) ;
- Si plusieurs X_i sont vrais, alors la probabilité que Y soit vrai est donnée par :

$$\mathbb{P}(y|X) = 1 - \prod_{i|\bar{x}_i \in X_p} (1 - p_i) \quad (I.2)$$

Où X_p est l'ensemble des X_i vrais.

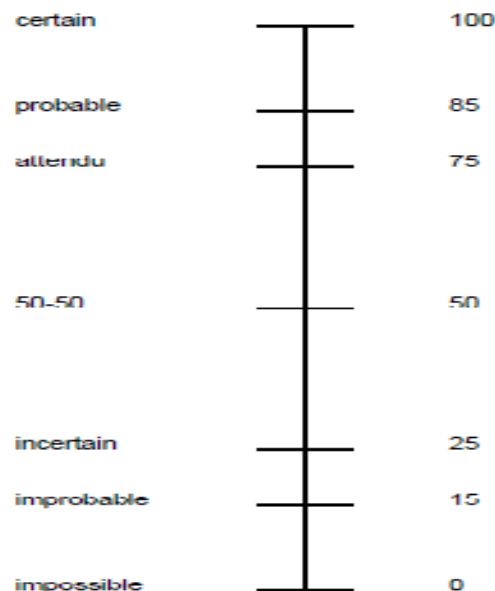


Figure I.11 : Échelle de probabilité.

Ce modèle proposé initialement par J. Pearl [6], a été étendu au cas où Y peut être vrai sans qu'une seule des causes soit vraie (leaky noisy-OR gate) et

aux variables multi-valuées (generalized noisy-OR gate). Cette modélisation simplifiée des probabilités a été utilisée avec succès dans des domaines tels que le diagnostic médical ou le diagnostic de pannes.

Enfin, le dernier type de problème lié à l'ingénierie des connaissances concerne le cas où l'ingénieur doit faire face à des sources d'informations de diverses natures : experts, données collectées selon des moyens variés, etc. La prise en compte de ces différentes sources doit se faire avec précaution pour éviter d'utiliser des données biaisées. Ainsi, un critère a été proposé pour vérifier si les différentes sources d'informations ont été utilisées dans les mêmes conditions. Supposons maintenant que plusieurs experts proposent une estimation sur les mêmes valeurs. Comment combiner ces différents résultats ? La prise en compte de données incertaines a été abordée sous différents angles [5], [6]: la logique floue, et la théorie des croyances ont été proposés pour fusionner les avis de plusieurs experts [5].

I.5 INFERENCE

Une fois qu'un réseau Bayésien a été construit pour étudier un domaine bien précis, on cherche souvent à l'utiliser pour déterminer des probabilités correspondant à certains événements, certaines questions, certaines dépendances. Dans ces cas, les inférences permettent effectivement de calculer la probabilité de chaque nœud lorsque les autres variables sont inconnues [3]. Il existe des méthodes exactes et d'autres approchées permettant d'effectuer ce calcul.

L'inférence exacte ou approchée a été démontrée comme étant un problème NP-difficile [7].

I.5.1 Méthodes exactes

I.5.1.1 Messages locaux

La première méthode d'inférence, introduite par [8] et [9], est celle des messages locaux, plus connue sous le nom de polytree algorithm. Elle consiste en une actualisation, à tout moment, des probabilités marginales, par transmission de messages entre variables voisines dans le graphe d'indépendance. Cette

méthode ne fonctionne de manière exacte que lorsque le réseau Bayésien possède une forme d'arbre (ou polytree en anglais), elle est donc à recommander dans ce cas. Par ailleurs, il existe des adaptations de cette méthode qui permettent d'utiliser les messages locaux même lorsque nous ne sommes pas en présence d'une structure arborescente.

I.5.1.2 Ensemble de coupe

L'algorithme Loop Cutset Conditioning a été introduit très tôt par [10]. Dans cette méthode, la connectivité du réseau est changée en instanciant un certain sous ensemble de variables appelé l'ensemble de coupe (loop cutset). Dans le réseau résultant, l'inférence est effectuée en utilisant l'algorithme des messages locaux. Puis les résultats de toutes les instanciations sont combinés par leurs probabilités a priori. La complexité de cet algorithme augmente donc exponentiellement en fonction de la taille de l'ensemble de coupe.

I.5.1.3 Arbre de jonction

La méthode de l'arbre de jonction (aussi appelée clustering ou clique-tree propagation algorithm) a été introduite par [11] et [12]. Elle est aussi appelée méthode JLO (pour Jensen, Lauritzen, Olessen). Elle est applicable pour toute structure de GSCO contrairement à la méthode des messages locaux. Néanmoins, s'il y a peu de circuits dans le graphe, il peut être préférable d'utiliser une méthode basée sur un ensemble de coupe. Cette méthode est divisée en cinq étapes qui sont:

- moralisation du graphe,
- triangulation du graphe moral,
- construction de l'arbre de jonction,
- inférence dans l'arbre de jonction en utilisant l'algorithme des messages locaux,
- transformation des potentiels de clique en lois conditionnelles mises à jour.

Moralisation :

La moralisation se décompose suivant les étapes suivantes :

- 'Mariage des parents' : pour les nœuds possédant plusieurs parents, liaison des parents deux à deux avec des arcs supplémentaires.
- Récupération du squelette du graphe ainsi obtenu,

Nous obtenons alors un graphe non dirigé dit moralisé (voir Annexe B).

Triangulation :

Pour que les potentiels de toutes les lois conditionnelles soient associés à des sous graphes complets, il suffit de procéder à la triangulation du graphe moral en y ajoutant des arêtes créant des raccourcis dans tout cycle de longueur 4 ou plus, nous obtiendrons alors un graphe moral dit triangulé (voir Annexe B).

L'arbre de jonction :

Définition 1.4 (Arbre de jonction) *Un arbre de jonction est une structure arborescente, ayant l'ensemble des cliques d'un graphe triangulé comme ensemble de nœuds et telle que toutes cliques sur le chemin entre C_i et C_{i_0} doit contenir les nœuds de $C_i \setminus C_{i_0}$ (propriété de l'intersection courante).*

Tout comme le graphe triangulé n'est pas unique, l'arbre de jonction ne l'est pas non plus. Par ailleurs, chaque nœud du graphe triangulé doit apparaître dans au moins une clique utilisée dans la construction de l'arbre de jonction.

Propriété 1.1 (de l'intersection courante) *Pour toute clique C_i , il y a une clique $C_{j(i)}$ avec $j(i) < i$ telle que toute variable commune à C_i et C_{i_0} où $i_0 < i$ appartient à $C_{j(i)}$. Cette propriété nous guide dans la construction d'un arbre de jonction. En effet, pour que l'information sur une variable remonte jusque la clique initiale qui la contient, il est utile que cette variable appartienne à toutes les cliques intermédiaires. JENSEN et al [12] a donné une méthode pour cette construction et le résultat suivant :*

Théorème 1.2 ([12]) *A partir d'un graphe moral triangulé, il est toujours possible de construire un arbre de jonction. Les variables de l'arbre de jonction sont donc des groupes de variables du graphe d'origine. Par envois de messages (les potentiels de cliques) dans l'arbre de jonction, il est possible d'effectuer l'inférence dans n'importe quel GOSC. Les potentiels de clique vont donc être mis à jour, puis il*

sera possible d'en déduire les lois marginales pour les variables d'origine (grâce à la propriété de l'intersection courante).

Même si cette méthode est plus rapide que le Cut-Set conditioning, elle possède le désavantage d'avoir une complexité en mémoire exponentielle en la taille du réseau tandis que la précédente ne nécessite qu'un espace mémoire linéaire en la taille du réseau.

Inversion d'arcs

Cette méthode a été introduite très tôt par [13]. Il s'agit de changer la direction des arcs en utilisant la règle de Bayes jusqu'à ce que le réseau soit transformé de telle manière que les nœuds de la requête soient des enfants des nœuds observés ([14]). Cette méthode est à privilégier soit lorsque l'ensemble des nœuds de la requête est restreint soit lorsque nous savons par avance que nous allons interroger de nombreuses fois les mêmes nœuds en ayant à chaque fois les mêmes nœuds observés.

1.5.1.4 Elimination de variables

L'élimination de variables est décrite dans [15]. Cet algorithme supprime les variables une par une après avoir sommé sur celles-ci. Cette méthode a été généralisée dans [16] par l'algorithme Bucket Elimination. Un ordre des variables doit être donné en entrée et sera alors l'ordre d'élimination des variables. Le nombre de calculs dépend alors de cet ordre puisqu'il influe sur la taille des facteurs futurs. Trouver le meilleur ordre équivaut au problème de trouver l'arbre de plus petite largeur dans le réseau, ce qui est un problème NP-difficile. Cette méthode est avantageuse lorsqu'un ordre d'élimination des variables est déjà connu ou si le réseau est peu dense mais avec de nombreux circuits.

1.5.1.5 Explication la plus probable

La méthode de l'explication la plus probable (MPE pour Most probable explanation) n'est pas réellement une technique d'inférence mais plutôt un problème d'inférence. Ce problème consiste en l'identification de l'état le plus probable. Il est possible d'adapter différentes méthodes d'apprentissage pour

répondre à cette question. La technique la plus commune (et exacte, [17]) pour effectuer cette inférence consiste en le remplacement des signes sommes par des max et les signes produits par des min dans les formules de l'inférence classique. Il est possible d'adapter cette méthode pour trouver le deuxième cas le plus probable ou, plus généralement, le n ème cas le plus probable. Comme pour les autres problèmes d'inférence, il existe également des algorithmes approchés pour résoudre ce problème : par exemple, [18] propose une méthode à base de colonies de fourmis.

1.5.1.6 Méthodes symboliques

L'inférence probabiliste symbolique (SPI pour Symbolic Probabilistic Inference) a été introduite dans [19] et [20]. Cette méthode est orientée par un but : n'effectuer que les calculs nécessaires pour répondre à la requête. Des expressions symboliques peuvent être obtenues en remettant à plus tard l'évaluation des expressions, et en les gardant sous forme symbolique. Par ailleurs, [21] ont proposé une autre technique d'inférence symbolique en modifiant les méthodes existantes d'inférences numériques et en remplaçant les paramètres initiaux par des paramètres symboliques. Ces méthodes ont le désavantage qu'il est difficile de calculer et de simplifier automatiquement des expressions symboliques mais, l'avantage qu'elles orientent les calculs intelligemment.

Citons deux implémentations de ces idées :

Query DAGs concept

Dans la méthode du *Query DAGs* concept, introduite dans [22], le réseau est préalablement transformé en une expression arithmétique appelée le *Query DAG*.

Algorithme des restrictions successives

Cette méthode consistant en la construction d'une expression symbolique a été introduite par *MEKHACHA et al* [23]. Cette expression doit répondre à l'inférence demandée de manière à organiser la suite des sommes et produits à effectuer pour en minimiser le nombre. Pour minimiser ce nombre d'opérations, il faut trouver un bon ordre pour la marginalisation des variables. Des détails concernant cette méthode peuvent être trouvés dans [24]. Le second objectif de

cette méthode est que tous les calculs intermédiaires doivent produire une distribution de probabilité au lieu d'un potentiel. Elle est donc à recommander lorsque cette contrainte est nécessaire.

1.5.1.7 Méthodes différentielles

Les méthodes différentielles transforment un réseau Bayésien en polynôme multivarié ([25]). Elles calculent ensuite les dérivées partielles de ce polynôme. Il est alors possible d'utiliser ces dérivées pour calculer les réponses à de nombreuses requêtes, et cela en temps constant. Cette méthode est très utile lorsque nous effectuons régulièrement les mêmes requêtes car maintenant nous pourrons y répondre en temps constant.

1.5.2 Méthodes d'inférence approchées

Effectuer une inférence exacte est un problème NP-difficile ([26]). Ceci n'est pas étonnant, car il est possible de simuler un problème de satisfaction de contraintes à l'aide d'un réseau Bayésien (en effet, en utilisant que des probabilités 0 et 1, les nœuds d'un réseau bayésien deviennent des portes logiques).

Lorsque la dimension du réseau Bayésien augmente, il est nécessaire d'utiliser de plus en plus de temps de calcul. Or, si les tables de probabilités conditionnelles ne se pas exactes (car évaluées à partir d'une base de cas peu représentative par exemple), l'intérêt d'effectuer une inférence exacte avec ces valeurs approximatives n'est plus probant. Dans ce cas, il peut être intéressant d'effectuer une inférence approchée pour économiser du temps de calcul.

Par ailleurs, pour certains réseaux Bayésiens particuliers, comme les réseaux Bayésiens hybrides, il n'existe pas d'algorithme d'inférence exact, le seul recours pour évaluer des probabilités est alors d'utiliser des algorithmes d'inférence approchés.

1.5.2.1 Simulation stochastique par Chaîne de Monte-Carlo

Les méthodes MCMC (pour Markov Chains Monte Carlo) décrites dans [27] permettent d'échantillonner des variables aléatoires en construisant une chaîne de Markov. Les deux algorithmes à base de MCMC pour faire de l'estimation de

densité les plus répandus, sont l'algorithme de Metropolis- Hastings et l'échantillonneur de Gibbs.

Ces méthodes statistiques approchées ne calculent pas exactement les lois marginales, mais en donnent une estimation. Elles permettent donc de traiter des applications de grande taille en temps raisonnable, ce qui n'est pas le cas des méthodes exactes. Les méthodes statistiques basées sur les principes de Monte-Carlo sont décrites en détail dans [28].

Le principe est ici d'effectuer un certain nombre de tirages aléatoires compatibles avec une loi. Pour cela, la décomposition de la loi jointe en produit de lois conditionnelles permet de mener les calculs. En pratique, chaque variable dont tous les parents sont connus est tirée aléatoirement, jusqu'à ce que toutes les variables aient été simulées. Pour que l'estimation soit fine, il faut alors effectuer un très grand nombre de simulations.

Par ailleurs, ces méthodes sont inefficaces quand certaines probabilités sont très faibles mais elles possèdent l'avantage d'être aisément implémentables et de ne pas être fermées: plus l'algorithme est arrêté tard, plus de cas seront simulés et plus l'évaluation des résultats sera précise.

Algorithme de Metropolis-Hastings

L'algorithme de *Metropolis-Hastings* permet de simuler une loi de densité qui n'est connue qu'à un facteur près, c'est-à-dire que l'on ne connaît que $\frac{\pi(x)}{\pi(y)}$. La transition de l'état x^{t-1} à x suivant la loi $q(x|x^{t-1})$ est alors acceptée avec la probabilité $\alpha(x, x^{t-1})$ définie par :

$$\alpha(x, x^{t-1}) = \min \left(1, \frac{\pi(x)q(x^{t-1}|x)}{\pi(x^{t-1})q(x|x^{t-1})} \right) \quad (I.3)$$

Nous sommes alors en présence d'une chaîne de Markov de loi de transition $p(x, y) = q(x|y)\alpha(x, y)$ avec $y \neq x$. Pour simuler des exemples générés par π , il faut choisir la loi q . La vitesse de convergence dépendra principalement de ce point de départ. Remarquons que cette méthode ne génère pas d'échantillon i.i.d car la probabilité d'acceptation dépend de x^{t-1} .

Il suffit ensuite d'effectuer un comptage dans cette base d'exemples pour obtenir une approximation des probabilités recherchées.

Recuit simulé (ou simulated annealing)

Cette méthode d'optimisation peut être vue comme un algorithme de *Metropolis*. Pour minimiser un critère G , il est possible de simuler la loi $\pi(x) = \exp\left(\frac{-G(x)}{T_i}\right)$ où T_i est la température (généralement définie par $T_i = T_0\beta^i$). Nous sommes donc en présence d'une chaîne de Markov dont le modèle de transition varie au cours du temps. Cette densité tend alors vers un pic de Dirac. Il est possible d'utiliser ce type de technique pour faire de la recherche de structure.

La méthode des Modes Conditionnels Itérés (ICM pour Iterated Conditional Modes) est une méthode sous-optimale basée sur un recuit-simulé à température nulle.

Echantillonnage de Gibbs

Dans le cas où les lois conditionnelles sont connues et que l'objectif est de retrouver des lois jointes, il est possible d'utiliser l'échantillonneur de Gibbs (ou Gibbs sampler) adapté par LAURITZEN [29]. Cette méthode a été introduite par GEMAN *et al* [30]. Supposons que l'on veuille approcher $\mathbb{P}(x, y)$ connaissant $\mathbb{P}(x|y)$ et $\mathbb{P}(y|x)$. Alors choisissons un point de départ (x_0, y_0) . Générons $x_{t+1} \sim p(x|y_{t-1})$ et $y_{t+1} \sim p(y|x_{t-1})$. Le couple (x_t, y_t) est alors une chaîne de Markov et l'échantillon converge vers un échantillon qui aurait été généré par la loi $\mathbb{P}(x, y)$.

Dans le cas particulier des réseaux Bayésiens, la loi $\mathbb{P}(x|y)$, se simplifie en $\mathbb{P}(x|F(x))$. Cette méthode est donc particulièrement adaptée aux réseaux Bayésiens où nous ne stockons que des distributions conditionnelles.

Comme les autres méthodes basées sur la simulation stochastique, celle-ci construit une base d'exemples à partir de laquelle il sera possible d'évaluer les probabilités recherchées. Remarquons que cette méthode ne fonctionne que si les probabilités sont toutes strictement positives. La convergence peut être lente, notamment s'il y a des probabilités très faibles.

1.5.2.2 Méthodes variationnelles

Dans l'état actuel des choses, l'inférence dans les modèles graphiques probabilistes n'est possible que lorsque les distributions de probabilités des variables continues sont gaussiennes et n'ont pas de variables filles discrètes. Lorsque ce cas se présente, il faut avoir recours à des méthodes d'inférence approchée. Une technique pour cela serait de discrétiser toutes les variables, ou encore d'utiliser les méthodes variationnelles. Néanmoins, même lorsque nous ne sommes pas dans ce cas, ces méthodes ont l'avantage d'être peu complexes, et peuvent alors se révéler utiles.

Les méthodes variationnelles ont été introduites pour approcher l'apprentissage par maximum de vraisemblance en présence d'une base d'exemples incomplète. Elles sont alors utilisées pour approcher les intégrales nécessaires pour l'inférence Bayésienne (cf. [31]) ou encore l'apprentissage Bayésien comme proposé par *JORDAN et al* [32] et *WAINWRIGHT et al* [33].

L'approche variationnelle consiste en l'application de l'inégalité de Jensen introduisant une distribution approchée Q .

$$\ln \mathbb{P}(X|\theta) = \ln \sum_H \mathbb{P}(H, X|\theta) = \ln \sum_H Q(H|X) \frac{\mathbb{P}(H, X|\theta)}{Q(H|X)} \quad (1.4)$$

$$\ln \mathbb{P}(X|\theta) \geq \sum_H Q(H|X) \ln \frac{\mathbb{P}(H, X|\theta)}{Q(H|X)} \quad (1.5)$$

En particulier, si la distribution que nous recherchons est exponentielle et de la forme:

$$\mathbb{P}(H, X|\theta) = \frac{1}{Z} \exp(g(H, X|\theta)) \quad (1.6)$$

Où g est une fonction des variables aléatoires (discrètes) X et H , et Z un terme de normalisation. Le problème à résoudre devient alors :

$$\ln \mathbb{P}(X|\theta) \geq \sum_H Q(H|X) g \mathbb{P}(H, X|\theta) - \sum_H Q(H|X) \ln Q(H|X) - \ln Z \quad (1.7)$$

En mettant de côté le terme de normalisation, il reste à calculer les deux termes de la borne efficacement. Cela peut être fait en temps polynomial, car

l'entropie de Q peut être bornée par valeurs inférieures en temps polynomial, et l'espérance de g pour la distribution Q peut également être bornée en temps polynomial.

I.5.2.3 Méthodes de recherche de masse

Ces méthodes ne supposent qu'une petite partie de l'espace de définition des variables contient une grande partie de la masse de probabilité. Elles recherchent alors les instanciations de haute probabilité et les utilisent pour obtenir une bonne approximation ([34] et [35]). Cette méthode est à utiliser lorsque nous voulons négliger les événements de probabilités faibles.

I.5.2.4 Loopy belief propagation

L'algorithme des messages locaux de *PEARL* [36] ne fonctionne de manière exacte que sur des structures en forme d'arbre. Cependant cette méthode a été généralisée dans [37] pour effectuer de l'inférence approchée avec une structure de GOSC quelconque. *MURPHY et al* [38] proposent une étude empirique de la convergence de cet algorithme en présence de cycles, et parfois, certains résultats très mauvais peuvent être obtenus avec cette méthode.

I.5.2.5 Simplification du réseau

Pour effectuer l'inférence plus rapidement, il peut être envisageable de simplifier les paramètres, par exemple en mettant à zéro les probabilités trop faibles, ou encore de simplifier la structure, puis de faire de l'inférence exacte dans ce nouveau réseau. [39] a été le premier à donner ce type de méthode en proposant de retirer du graphe les liens faibles au sens de la dépendance causale. De nombreuses autres techniques ont ensuite été proposées : retirant des arcs, retirant des nœuds ou encore recherchant l'arbre le plus proche du réseau, il est possible de trouver de nombreuses références dans [40].

Les méthodes d'inférence par simplification du réseau sont principalement à construire et à utiliser dans des buts particuliers, par exemple dans le cas de l'utilisation d'une simplification pertinente pour le problème traité.

I.6 LES CHAINES DE MARKOV

Le fondateur de la discipline est *Andrei Andreevich Markov* (1856-1922) un mathématicien russe. Ses travaux sur la théorie des probabilités l'ont amené à mettre au point les chaînes de Markov qui l'ont rendu célèbre. Ceux-ci peuvent représenter les prémices de la théorie du calcul stochastique.

Une chaîne de Markov est une suite de variables aléatoires $(X_n, n \in \mathbb{N})$ qui permet de modéliser l'évolution dynamique d'un système aléatoire : X_n représente l'état du système à l'instant n . La propriété fondamentale des chaînes de *Markov*, dite propriété de *Markov*, est que son évolution future ne dépend du passé qu'au travers de sa valeur actuelle. Autrement dit, conditionnellement à $X_n, (X_0, \dots, X_n)$ et $(X_{n+k}, k \in \mathbb{N})$ sont indépendants. Les applications des chaînes de *Markov* sont très nombreuses (réseaux, génétique des populations, mathématiques financières, gestion de stock, algorithmes stochastiques d'optimisation, simulation, . . .).

I.6.1 Définition et propriétés

Soit E un espace discret, i.e. E est un espace au plus dénombrable muni de la topologie discrète, où tous les points de sont isolés, et donc de la tribu $\mathcal{E} = P(E)$.

Définition I.2 : Une matrice $P = (P(x, y), x, y \in E)$ est dite matrice stochastique si ses coefficients sont positifs et la somme sur une ligne des coefficients est égale à 1 :

$$P(x, y) \geq 0 \text{ et } \sum_{z \in E} P(x, z) = 1 \text{ pour tous } x, z \in E \quad (I.8)$$

Définition I.3 : Soit P une matrice stochastique sur E . Une suite de variables aléatoires $(X_n, n \in \mathbb{N})$ a valeurs dans E est appelée chaîne de Markov de matrice de transition P si pour tous $n \in \mathbb{N}, x \in E$, on a :

$$\mathbb{P}(X_{n+1} = x \mid X_n, \dots, X_0) = \mathbb{P}(X_{n+1} = x \mid X_n) = P(X_n, x) \quad (I.9)$$

On dit que la chaîne de Markov est issue de μ_0 si la loi de X_0 est μ_0 .

Comme l'espace d'état est discret l'équation (I.9) est équivalente à : pour tous $x_0, \dots, x_n \in E$, tels que $\mathbb{P}(X_n = x_n, \dots, X_0 = x_0) > 0$,

$$\mathbb{P}(X_{n+1} = x \mid X_n, \dots, X_0) = \mathbb{P}(X_{n+1} = x \mid X_n) = P(X_n, x) \quad (I.10)$$

Si $\mathbb{P}(X_0 = x) = 1$, autrement dit μ_0 est la masse de Dirac en x , on dira plus simplement que la chaîne de Markov est issue de x .

La proposition suivante assure que la matrice de transition et la loi initiale caractérisent la loi de la chaîne de Markov.

Proposition I.4 : La loi d'une chaîne de Markov $(X_n, n \in \mathbb{N})$ est entièrement caractérisée par sa matrice de transition, P , et la loi de X_0, μ_0 . De plus, on a, pour tous $n \in \mathbb{N}^*, x_0, \dots, x_n \in E$,



Figure I.12 : Un exemple générique de chaîne de Markov à trois états représentée dans l'espace des états de X .

Le modèle de transition représente les probabilités qui sont associées à chaque arc (non indiquées ici). Or au vu de la simplification de la loi jointe de l'équation I.1, il est également possible de représenter une chaîne de Markov dans le formalisme des réseaux Bayésiens dynamiques comme indiqué sur la Figure I.12.

II.7 MODELES DYNAMIQUES

Dans de nombreux de problèmes réels, le temps peut être une quantité dont il est important de la prendre en compte. Les réseaux Bayésiens dynamiques sont alors à la fois une extension des réseaux Bayésiens dans laquelle l'évolution temporelle des variables est représentée [2], [41]. Les premiers travaux sur l'application des réseaux Bayésiens aux domaines dynamiques [42] ont mené aux formalismes connus sous le nom de Réseaux Bayésiens Temporels (RBT), Réseaux Bayésiens Dynamiques (RBD), Réseau de «dates», et Réseaux de Croyance Temporels Modifiables (RCTM). L'approche commune à toutes ces représentations est la discrétisation de la ligne du temps et l'association d'un nœud à chaque intervalle (ou au un point dans le temps). Les modèles ont été fondamentalement obtenus en générant un réseau Bayésien à l'instant 0 (initial) et

en répétant la même structure à chaque instant sur l'intervalle du temps d'intérêt. Des arcs ont été également ajoutés entre les nœuds appartenant aux différents instants du temps. Cette approche s'appelle génériquement [42], [43] l'approche « time-sliced ».

Une autre approche d'incorporation du temps dans les réseaux Bayésiens a émergé récemment, elle inclut les réseaux Bayésiens aux nœuds temporels (RBNT) [44] et les Réseaux des Événements Irréversibles dans le Temps Discret (REITD) [45]. Dans ces réseaux, un nœud représente un événement qui peut avoir un certain résultat et qui peut avoir lieu à un certain intervalle du temps, l'état du nœud est défini comme étant le résultat des événements et l'intervalle de temps auquel l'événement a eu lieu. Cette approche s'appelle génériquement [42] l'approche basée sur l'évènement. On explicitera dans ce qui suit, les deux approches.

I.7.1 Approche « Time-Sliced »

I.7.1.1 Définition




Figure I.13 : Un diagramme représente le processus d'évolution temporelle instantanée en utilisant l'approche basée sur les tranches de temps (Time-Sliced).

Comme mentionné ci-dessus, les réseaux Bayésien dynamiques sont une façon d'étendre les réseaux Bayésien pour modéliser des distributions de probabilité sur une collection semi-infinie de variables aléatoires Z_1, Z_2, \dots, Z_n , l'ensemble des variables est partitionné en $Z_t = (U_t, X_t, Y_t)$ pour représenter les variables d'entrée, les variables cachées et aussi de sortie. L'indice t est incrémenté par un (1) à chaque nouvelle observation, seulement en prenant en compte les processus stochastiques à temps discret, alors. Le terme dynamique veut dire qu'on modélise des systèmes dynamique et pas que le réseau change à travers le temps (Il est possible de se référer à [2], Section 2.5 pour avoir des informations sur les réseaux Bayésiens dynamiques qui changent leurs structures à travers le temps).




Figure I.14 : Modèle temporel avec des tranches du temps dupliquées.

I.7.1.2 Mécanisme d'inférence des réseaux Bayésiens dynamiques




Figure I.15 : Inférence RBD.

L'algorithme passage en avant :

$\alpha_t(x_t)$: Dénote la distribution de probabilité forward qui décrit la probabilité jointe des observations réunies sur la période t et à l'instant t .

$$\alpha_t(x_t) = \mathbb{P}(Y_0^t | x_t) \quad (\text{I.11})$$

Si on utilise la structure du réseau représenté sur la Figure I.15, ce n'est pas difficile de calculer

$$\alpha_{t+1}(x_{t+1}) = \mathbb{P}(y_t | x_t) \sum \mathbb{P}(x_{t+1} | x_t) \alpha_t(x_t) \quad (\text{I.12})$$

Avec la condition initiale $\alpha_0 = \mathbb{P}(x_0)$

Parmi les résultats intéressants du passage en avant est le terme de vraisemblance des données de séquences d'observation Y_0^t . A partir de la définition du facteur en avant $\alpha_t(x_t)$ de l'équation (I.11) on peut déterminer que:

$$\mathbb{P}(Y_0^{T-1}) = \frac{\alpha_{T-1}(x_{T-1})}{\sum_{x_t} \alpha_t(x_t)} \quad (\text{I.13})$$

L'algorithme passage en arrière :

On commence par $\beta_t(x_t)$, comme étant la distribution de probabilité « en arrière » c.-à-d., la probabilité conditionnelle de l'observation à partir de $t+1$ jusqu'à $T-1$ conditionnée par les valeurs de l'état à l'instant t :

$$\beta_t(x_t) = \mathbb{P}(Y_{t+1}^{T-1} | x_t) \quad (\text{I.14})$$

On peut inférer la prochaine relation à partir de la définition du facteur en avant :

$$\beta_{t-1}(x_{t-1}) = \sum_{x_t} \beta_t(x_t) \mathbb{P}(x_t | x_{t-1}) \mathbb{P}(y_t | x_t) \quad (\text{I.15})$$

Avec $\beta_T(x_{T-1}) = 1$ comme une valeur finale.

Il existe d'autres types d'algorithmes d'inférence des RBDs, le lecteur peut se référer à [2], [46] pour plus des détails.

1.7.2 Approche basé sur l'évènement

1.7.2.1 Définition formelle d'un réseau bayésien temporel d'évènements

Un réseau Bayésien temporel d'évènements (RBTE) [44] est un réseau Bayésien d'évènements du temps discret dans lequel chaque nœud représente un évènement ou un changement d'état d'une variable, et un arc correspond à une relation causale temporelle, cette représentation est basée sur la définition d'un nœud temporel et d'une relation causale temporelle.

Définition 1.4 Définition d'un nœud temporel : *Un nœud temporel est **NT** est un ensemble d'états, chaque état est défini par une paire ordonnée (σ, τ) tel que σ est la valeur d'une variable aléatoire et τ est l'intervalle du temps associé au changement de la valeur de la variable.*

Définition 1.5 Définition d'une relation causale temporelle : *Une relation temporelle entre les intervalles du temps d'un **NT**, elle est défini comme suit:*

*Les relations temporelles possibles entre un nœud temporel **NT**, et un intervalle du temps, T_i , d'un nœud sont: **start (si)**, **during (di)** et **finish (fi)**. La relation temporelle entre chaque paire d'intervalles du temps est **meet (m)**: $T_i \{m\} T_j$.*

D'où la définition d'un réseau Bayésien temporel d'évènements (RBTE) est:

RBTE = (V,E) , où V est l'ensemble des nœuds temporels et E est l'ensembles des arcs.

1.7.2.2 Mécanisme d'inférence dans réseau bayésien temporel d'évènements

Les intervalles temporels de chaque nœud sont relatifs à ses parents. Quand un événement initial est détecté, son instant d'occurrence "fixe" temporellement le réseau. La synchronisation de l'observation est utilisée comme référence temporelle pour les autres événements. Ceci signifie que la synchronisation réelle des événements est représentée dans le réseau dynamique. Pour la définition de mécanisme d'inférence, des paramètres supplémentaires sont à définir [44]:

- **TC** (l'instant de l'occurrence) : est le moment réel où l'événement est détecté. Car le réseau n'en a pas référence temporelle, l'instant de l'occurrence du l'événement initial fixe temporellement le réseau.
- **α** (durée de délai) : est la valeur absolue de la différence des temps de l'occurrence de deux évènements.

Ces paramètres sont employés par le mécanisme d'inférence pour déterminer les intervalles réels de temps de l'occurrence de chaque événement. Le mécanisme se compose de 3 étapes de base :

Etape1 : Détection d'événement et définition d'intervalle de temps

Quand un événement initial est détecté, son instant d'occurrence $TC_{initial}$, sert comme référence temporelle pour tout le réseau. Il y a deux cas possibles, dépendant de la position du nœud initial dans réseau: (a) l'événement initial correspond à un nœud racine, et (b) l'événement initial correspond à un nœud intermédiaire ou de feuille.

- (a) : Dans le premier cas, la valeur réelle du nœud peut être déterminé (les nœuds de racine sont toujours événements instantanés).
- (b) : Pour le deuxième cas, il n'est pas possible de déterminer la valeur de la variable, parce que l'événement a pu être associé n'importe intervalle de temps pour un état. Il est nécessaire d'attendre une deuxième observation pour déterminer l'intervalle. Quand le prochain événement est détecté, son instant d'occurrence $TC_{postérieur}$, est utilisé pour la définition de l'intervalle de temps associé avec la fonction de temps réel d'occurrence, $\alpha = |TC_{initial} -$

$TC_{\text{postérieur}}$ | La valeur de α est utilisée pour mettre l'intervalle de temps de nœud enfant en considérant le nœud parent comme événement initial. Cette étape est appliquée d'une façon récursive aux événements ultérieurs.

Etape 2 : Propagation des évidences

Une fois la valeur d'un nœud est obtenue (l'intervalle de temps et l'état associé), la prochaine étape est de propager l'effet de cette valeur à travers le réseau pour mettre à jour la probabilité d'autres nœuds temporels. N'importe algorithme standard de propagation de probabilité peut être utilisé.

Etape 3: Détermination des événements antérieurs et futurs

Avec les probabilités postérieures, nous pouvons estimer potentiellement, les événements antérieurs et de futur en se basant sur la distribution de probabilité du chaque nœud temporel.

S'il n'y a pas assez d'information, par exemple, il existe un seul événement observé qui correspond à un nœud intermédiaire, le mécanisme traite différents scénarios. Le nœud est instancié à tous les intervalles correspondant à l'état observé, et les probabilités postérieures des autres nœuds sont obtenues pour chaque scénario. Ces scénarios peuvent être utilisés comme un ensemble des alternatives possibles, qui seront réduites quand un autre événement se produit.

I.8 CONCLUSION

Nous avons abordé dans ce chapitre les fondements théoriques, les propriétés et les types, en particulier les modèles dynamiques des réseaux Bayésiens. Ainsi que les méthodes de construction de ces derniers et leur mécanisme d'inférence. Ceci nous a permis de rendre compte des avantages des RBs justifiant l'intérêt grandissant, depuis le milieu des années quatre-vingt dix, dont ont fait preuve les industriels pour les modèles Bayésiens ne fait que croître en particulier grâce à la généralisation de processus d'interaction entre l'homme et la machine pour accélérer les prises de décision.

Les exemples d'application des RBs sont très nombreux et l'on ne saurait en faire une liste exhaustive à savoir : l'évaluation du risque, l'Études de marché,

L'assistance au pilotage, le filtrage du pourriel, l'aide à l'interaction et l'assistance aux handicapés.

Nous nous intéresserons, dans le chapitre suivant, à l'apprentissage des réseaux Bayésiens qui peut s'effectuer à partir de bases de données complètes et incomplètes (i.e. bases pour lesquelles les valeurs prises par certaines variables du domaine sont inconnues pour certaines instances).

CHAPITRE II : APPRENTISSAGE DES RESAUX BAYESIENS

II.1 INTRODUCTION

L'apprentissage d'un réseau Bayésien peut se décomposer en deux phases. Dans un premier temps, la structure du réseau est déterminée, soit par un expert, soit de manière automatique à partir d'une base de cas issus du domaine modélisé, c'est ce qu'on appelle « apprentissage de structure ». Enfin, les paramètres du réseau sont à leur tour déterminés, ici aussi par un expert ou bien par le biais d'un algorithme, appelé phase d'apprentissage de paramètres.

A travers ce chapitre, nous présentons les méthodes les plus usitées dans le cadre de l'apprentissage de paramètres et de la structure d'un réseau Bayésien, les hypothèses sous-jacentes ainsi que les avantages et inconvénients respectifs des différentes méthodes.

II.2 APPRENTISSAGE DES PARAMETRES

L'estimation des paramètres d'un réseau Bayésien consiste à estimer les probabilités conditionnelles Θ correspondant à la structure et la distribution de probabilité \mathbb{P} du graphe orienté sans circuits G à partir d'une base de cas $D = \{C_1, C_2, C_3, \dots, C_n\}$. Si toutes les variables sont connues le calcul des probabilités peut se faire directement. Cependant, si certaines valeurs, pour une instanciation $D^{(l)}$ donnée, ne sont pas connues, on utilise l'algorithme EM.

Auparavant, plusieurs hypothèses doivent être préalablement faites afin de pouvoir effectuer les calculs nécessaires.

- ✓ Indépendance des échantillons: les éléments de la base D sont indépendants, identiquement distribués ;
- ✓ Indépendance des paramètres : pour toute structure G , d'une part les paramètres θ_i associés au nœud X_i sont indépendants des paramètres associés aux autres nœuds et d'autre part, les paramètres θ_{ij} associés à X_i suivant une instanciation π_{ij} des parents de X_i dans G sont indépendants des paramètres associés aux autres instanciations de Π_i ;

- ✓ Modularité paramétrique : si un nœud présente les mêmes parents dans deux structures distinctes G_1 et G_2 , alors la densité de distribution des paramètres de X_i est la même pour les deux modèles définis par G_1 et G_2 ;

Une autre hypothèse, courante, est de supposer que les paramètres de chaque nœud suivent des densités de probabilités admettant des paramètres de *Dirichlet*. Les différents paramètres θ_i admettent alors une densité de probabilité exponentielle de *Dirichlet* d'exposants $\alpha_1, \dots, \alpha_r$ et leur probabilité est égale à :

$$\mathbb{P}(\theta_i | \alpha_1, \dots, \alpha_r) = \frac{\Gamma(\sum_{i=1}^{r_i} \alpha_i)}{\prod_{i=1}^{r_i} \Gamma(\alpha_i)} \times \prod_{i=1}^{r_i} \theta^{\alpha_i - 1} \quad (\text{II.1})^*$$

Cette hypothèse sur la densité de probabilités des paramètres vise à simplifier les calculs des paramètres. La première hypothèse revient en effet à dire que les échantillons de la base D est un échantillon d'une loi multinomiale. Or, la densité de probabilité de Dirichlet est la conjuguée de la loi multinomiale. Ceci permet de conserver à la fois les paramètres et leurs densités dans la même famille de fonctions.

II.2.1 Apprentissage des paramètres à partir d'une base de données complète

Ici, la base d'apprentissage D ne contient pas de cas où viendrait à manquer une ou plusieurs observations. L'apprentissage des paramètres d'un réseau Bayésien peut ici se faire suivant deux approches, l'approche statistique (ou fréquentiste) et l'approche Bayésienne (ou subjective)

Dans les deux cas, l'ensemble Θ des paramètres est estimé à partir de la formule de Bayes:

$$\mathbb{P}(\Theta | D) = \frac{\mathbb{P}(D | \Theta) \times \mathbb{P}(\Theta)}{\mathbb{P}(D)} \quad (\text{II.2})$$

Cette équation peut aussi s'écrire sous la forme :

$$\text{Probabilité } \vartheta \text{ posteriori} = \frac{\text{Vraisemblance} \times \text{Probabilité } \vartheta \text{ priori}}{\text{Vraisemblance marginale}} \quad (\text{II.3})$$

La probabilité a posteriori de l'ensemble des paramètres Θ connaissant la base de cas D est fonction de la vraisemblance de cet ensemble par rapport à D ,

* Γ représente la fonction Gamma d'Euler : $\Gamma(x + 1) = x\Gamma(x)$ et $\Gamma(1) = 1$ dans \mathbb{R}

de la probabilité a priori de Θ (i.e. la connaissance a priori que nous pouvons avoir sur le domaine) et de la vraisemblance de D .

Pour un ensemble de cas $D^{(l)}$, $l \in 1, \dots, N$ indépendants et identiquement distribués, la vraisemblance des données D étant donné les paramètres Θ estimés s'écrit :

$$\mathbb{P}(D|\Theta) = \prod_{l=1}^N \mathbb{P}(D^{(l)}|\Theta) \quad (\text{II. 4})$$

Enfin, reste la valeur de la probabilité a priori $\mathbb{P}(\Theta)$ dont le calcul constitue la principale différence entre l'approche statistique et l'approche Bayésienne, comme nous allons le voir dans la suite.

II.2.1.1 Approche fréquentiste

Les méthodes fréquentistes utilisent dès lors différents estimateurs dont le but est de parvenir à déterminer la meilleure approximation de la valeur des différents paramètres du réseau. Un de ces estimateurs est celui du maximum de vraisemblance. Pour chaque variable X_i , la probabilité d'apparition de l'événement x_i est directement proportionnelle à sa fréquence d'apparition dans la base d'apprentissage.

Soit N_{ijk} le nombre d'occurrences simultanées dans la base de $X_i = x_k$ et $\Pi_i = \pi_{ij}$ où $k \in 1, 2, \dots, r_i$ et $j \in 1, 2, \dots, q_i$. La probabilité estimée est alors notée :

$$\hat{\mathbb{P}}(X_i = x_k | \Pi_i = \pi_{ij}) = \theta_{ijk}^{MV} = \frac{N_{ijk}}{\sum_k N_{ijk}} \quad (\text{II. 5})$$

Le log-vraisemblance (le logarithme de la vraisemblance) est souvent employée pour des raisons pratiques (manipulation de valeurs numériques très faibles).

$$LL((\Theta|D)) = \log \mathbb{P}(D|\Theta) = \sum_{i=1}^N \mathbb{P}(D^i|\Theta) \quad (\text{II. 6})$$

Nous cherchons alors, pour un paramètre $\theta_{ijk} = \mathbb{P}(X_i = x_k | \Pi_i = \pi_{ij})$, la valeur $\hat{\theta}_{ijk}^{MV}$ permettant de maximiser localement la vraisemblance, c'est-à-dire en chaque X_i :

$$\hat{\theta}_{ijk}^{MV} = \arg \text{Max}_{\hat{\theta}_{ijk}} LL(\theta_{ijk}|D) \quad (\text{II. 7})$$

Avec N_{ijk} , le nombre d'occurrences simultanées dans D de $X_i = x_k$ et $\Pi_i = \pi_{ij}$.

II.2.1.2 Approche Bayésienne

Le principe de cette approche revient à traiter le paramètre θ_{ijk} comme une variable aléatoire dotée d'une densité de probabilité sur l'intervalle $[0,1]$.

Si les paramètres θ admettent une densité de probabilité exponentielle de *Dirichlet* et que la distribution de D suit une loi multinomiale, nous pouvons exprimer la probabilité a posteriori des paramètres Θ :

$$P(\theta) \propto \prod_{i=1}^n \prod_{j=1}^{q_i} \prod_{k=1}^{r_i} (\theta_{ijk})^{\alpha_{ijk}-1} \quad (\text{II. 8})$$

Nous savons déjà que :

– la vraisemblance $L(D|\Theta)$ est égale à (équation 3.7) :

$$\prod_{i=1}^n \prod_{j=1}^{q_i} \prod_{k=1}^{r_i} (\theta_{ijk})^{N_{ijk}} \quad (\text{II. 9})$$

– D'autre part:

$$P(\theta|D) = \frac{P(D|\theta)}{P(D)} \quad (\text{II. 10})$$

Nous pouvons dès lors écrire :

$$P(\theta|D) \propto \prod_{i=1}^n \prod_{j=1}^{q_i} \prod_{k=1}^{r_i} (\theta_{ijk})^{N_{ijk} + \alpha_{ijk} - 1} \quad (\text{II. 11})$$

De la même manière que dans le cas du maximum de vraisemblance abordé dans l'approche fréquentiste, nous pouvons alors rechercher les paramètres non plus selon le maximum de vraisemblance mais selon le maximum a posteriori (*MAP*). En effet, dans le cadre de l'approche Bayésienne, le fait d'employer des a priori sur les paramètres du modèle – par l'emploi de coefficients α_{ijk} – sous entend que les données ont déjà été observées. La détermination des paramètres

ne se fait alors plus selon les occurrences des données (*par vraisemblance*) mais conditionnellement à celles-ci (approche *a posteriori*).

$$\theta_{ijk}^{MAP} = P(X_i = x_k | \prod_i i = \pi_{ij}) = \frac{N_{ijk} + \alpha_{ijk} - 1}{\sum_k (N_{ijk} + \alpha_{ijk})} \quad (\text{II.12})$$

Une autre approche consiste à non plus rechercher le maximum *a posteriori* mais son espérance (*EAP*) :

$$\theta_{ijk}^{EAP} = P(X_i = x_k | \prod_i i = \pi_{ij}) = \frac{N_{ijk} + \alpha_{ijk} - 1}{\sum_k (N_{ijk} + \alpha_{ijk})} \quad (\text{II.13})$$

La différence entre ces deux dernières approches consiste essentiellement à définir si l'on souhaite procéder à la sélection d'un modèle – auquel cas on cherche le modèle maximisant la probabilité *a posteriori* – ou bien estimer un modèle le plus informatif possible quant aux différentes hypothèses représentées au sein d'une quantité de données limitée si on désire alors un modèle *prédictif*.

Les partisans de l'approche fréquentiste reprochent généralement à la philosophie Bayésienne d'attribuer des estimations $\mathbb{P}(\theta|D)$ différentes suivant des probabilités a priori $\mathbb{P}(\theta)$ différentes, introduisant par là une subjectivité forte. L'approche fréquentiste considère que l'ensemble Θ des paramètres a une valeur fixe et ne suit pas une distribution de probabilité.

Les méthodes d'apprentissage des paramètres que nous venons de décrire ne sont valables que si l'ensemble des valeurs de la base de données D est observable. Dans le cas contraire, il est nécessaire de faire appel à des méthodes permettant d'estimer les valeurs des observations manquantes. Ce sont ces méthodes que nous allons évoquer dans la section suivante.

II.2.2 Base de données incomplète

Il peut arriver qu'au sein de la base d'apprentissage du modèle, certaines valeurs soient manquantes. Cette situation peut arriver dans le cas où, par exemple, un capteur de données est tombé en panne ou encore lorsque le relevé de valeurs s'avère trop coûteux pour être systématiquement appliqué.

Les approches vues jusqu'ici ne sont plus, alors, applicables directement (à moins de ne considérer pour l'apprentissage que les instances complètes de la base). Si la solution la plus simple consiste à ignorer les instances incomplètes de

la base de données pour l'apprentissage, il est plus courant d'employer une méthode revenant à estimer les données manquantes à partir des données connues. Ce principe est fondé sur celui de l'algorithme EM (Expectation Maximisation ou Espérance Maximisation) proposé dans *DEMPSTER et al* [47] pour être par la suite appliqué à l'apprentissage des paramètres d'un réseau Bayésien dans [48] et [49].

De la même manière que pour l'apprentissage à partir de données complètes, l'algorithme EM peut être appliqué selon une approche fréquentiste ou Bayésienne.

II.2.2.1 Approche fréquentiste

Soit :

- $D_o = \{D_o^{(l)}\}_{l=1, \dots, N}$ L'ensemble des instances de D pour lesquelles l'ensemble des valeurs prises par les variables du domaine sont observées.
- $\Theta^{(t)}$, l'ensemble des paramètres $\{\theta_{ijk}^{(t)}\}$ des paramètres du réseau Bayésien B, à l'itération t.

L'algorithme EM commence par estimer les valeurs des données manquantes (*espérance*) avant de les maximiser de la même manière que dans le cas complet (*maximisation*).

Algorithme 1: Algorithme EM pour l'apprentissage des paramètres d'un réseau Bayésien

1: $t \leftarrow 0$

2: $\theta_{ijk}^{(0)} \leftarrow p > 0$ (*aléatoire*)

3: **Tant que** $|\theta_{ijk}^{(t+1)} - \theta_{ijk}^{(t)}| \geq \varepsilon$ **Faire**

4: 1^{ère} étape : Espérance

$$E(N_{ijk}) = \sum_{t=1}^n p(X_i = x_k / \prod_i = \pi_{ij}, D_o^{(l)}, \theta_{ijk}^{(t)})$$

5: 2^{ème} étape : Maximisation

$$\theta_{ijk}^{(t)} = \frac{E(N_{ijk})}{\sum_k E(N_{ijk})}$$

6: **Fin Tant que**

II.2.2.2 Approche Bayésienne

Dans ce cas, nous employons des a priori de *Dirichlet* sur les paramètres. La différence avec le traitement fréquentiste réside dans la 2^{me} étape de l'algorithme 1 qui devient :

$$\theta_{ijk}^{(t)} = \frac{E(N_{ijk}) + \alpha_{ijk}}{\sum_k E(N_{ijk}) + \alpha_{ijk}} \quad (\text{II.14})$$

II.3 APPRENTISSAGE DE STRUCTURE À PARTIR DES DONNEES

La problématique de l'apprentissage de structure peut être comparée à l'exploration de données, c'est-à-dire à l'extraction d'une connaissance à partir d'une base de données. la connaissance extraite dans ce cas est représentée sous forme d'un graphe orienté sans circuits (DAG) représentant ainsi la structure du réseau Bayésien.

L'apprentissage de structure à partir des données est la tâche de production de la structure c.-à-d, le graphe d'un réseau Bayésien, pour ce faire, il existe plusieurs classes d'algorithmes tels que les algorithmes de recherche et de score "search-and-score Algorithms" et les algorithmes basés sur les contraintes aussi bien que des combinaisons des deux classes [1]. La technique de la première classe, plus intuitif, consiste en la création d'une table d'indépendances conditionnelles entre les différents attributs en effectuant des tests statistiques sur la base d'exemples. La seconde technique d'apprentissage de structure utilise une fonction de score. L'heuristique de recherche consistera alors à optimiser ce score. Les méthodes mixtes ont alors été proposées pour profiter des avantages de chacune de ces méthodologies.

Pour résoudre la problématique de l'apprentissage de structure des réseaux Bayésiens, plusieurs informations peuvent être prises en compte, parmi ces informations on cite [41]:

La nature des données: Les données peuvent être continues ou discrètes, pour la suite des travaux nous n'allons considérer que le cas où celles-ci sont discrètes. Si elles ne le sont pas dans la base d'exemples initiale, cette dernière sera transformée de telle manière que les variables continues soient discrétisées.

L'existence de variable(s) latente(s): Ce type de variable est très particulier. Il s'agit d'attributs pertinents pour la modélisation du système qui ne sont jamais observés. Par exemple, en apprentissage non-supervisé, la variable classe n'est jamais observée, cependant nous comprenons qu'il est indispensable d'introduire un nœud la représentant dans le réseau Bayésien.

Connaissance a priori : De l'information a priori peut être donnée sur le problème à résoudre. Les experts du domaine ou du système à étudier peuvent donner des informations pertinentes concernant ce dernier, il est ensuite possible d'utiliser ces informations pour l'apprentissage de structure, par exemple en décidant de conserver un lien durant toute la phase d'apprentissage.

La nature de la base d'exemples : Les attributs de la base d'exemples peuvent être complètement ou partiellement observés. Par conséquent, on parle de l'apprentissage de structure à partir de base de données complète et incomplète.

II.3.1 Complexité de l'apprentissage de structure

L'apprentissage de structure est un problème très difficile (NP-hard) et dans certains cas NP-complet, en particulier à cause de la taille de l'espace de recherche c.-à-d, le nombre de variables du réseau Bayésien [7], [41]. ROBINSON [7] a montré que le nombre de structures différentes pour n nœuds est donné par la formule de récurrence suivante :

$$f(n) = \sum_{i=1}^n (-1)^{i+1} \binom{n}{i} 2^{i(n-i)} f(n-i), n > 2 = n^{2^{O(n)}} \quad (\text{II. 15})$$

$$f(0)=1$$

$$f(1)=1$$

$f(2)=3$, $f(3)=25$, $f(5)=29\ 000$, $f(10)=4,2 \cdot 10^{18}$, ca montre que l'équation (II. 15) est super-exponentielle. En conséquence, il est difficile d'effectuer un parcours exhaustif de l'espace de recherche en un temps raisonnable dès que le nombre de nœuds dépasse 8. La plupart des méthodes d'apprentissage de structure utilisent alors une heuristique de recherche dans l'espace des graphes dirigés sans circuits (DAG, pour directed acyclic graphs).

L'heuristique de recherche peut principalement être de deux types [41]:

- Soit sur l'espace de recherche lui même, c'est-à-dire en restreignant la recherche à un sous-ensemble de l'espace des DAG,
- Soit sur le parcours de l'espace de recherche, par exemple en utilisant une technique de recherche du type gradient.

Bien sûr, il est possible de mélanger de ces deux types d'heuristiques.

II.3.2 Hypothèses pour l'apprentissage de structure

L'acquisition d'une structure représentative de la distribution de probabilité d'un domaine de variables présuppose certaines conditions (dont la condition locale de Markov, vue dans le chapitre II).

L'application de ces conditions et hypothèses permet de garantir l'existence d'une telle structure (i.e. que la distribution que nous cherchons à modéliser peut l'être par un DAG mais aussi de poser les bases sur lesquelles se fondent les différentes méthodes [50], [41].

Hypothèse de Markov : pour un réseau Bayésien donné, toute variable est indépendante de ses non descendantes sachant ses variables parentes,

Hypothèse de fidélité : un DAG G et une loi de probabilité \mathbb{P} sont supposés fidèles, c'est-à-dire que les relations d'indépendance valides pour \mathbb{P} sont celles données par l'hypothèse de Markov.

Hypothèse de localité paramétrique: si G_1 et G_2 sont deux structures telles que le nœud X_i possède le même ensemble de parents pour chacune, alors :

$$\mathbb{P}(\theta_i/G_1) = \mathbb{P}(\theta_i/G_2) \quad (\text{II.16})$$

Hypothèse de complétude: toutes les variables nécessaires pour modéliser le problème sont connues. En particulier, il n'y a pas de variable autres que celles dont nous avons connaissance.

Comme mentionné ci-dessus, L'apprentissage de structure d'un réseau Bayésien doit s'effectuer en tenant compte de la nature de la base de données fournie pour l'apprentissage. Dans la section suivante, on va s'attacher à la présentation des méthodes d'apprentissage de structure à partir de base données

incomplète. Les méthodes présentées dans ce chapitre, sauf précision contraire, se réfèrent à l'apprentissage de structure dans le cas où :

- ✓ Les variables modélisées prennent leurs valeurs dans un ensemble discret (Si elles ne le sont pas dans la base d'exemples initiale, cette dernière sera transformée de telle manière que les variables continues soient discrétisées).
- ✓ Il n'existe pas de variable latente (hypothèse de suffisance causale).

II.3.3 APPRENTISSAGE DE STRUCTURE À PARTIR DE DONNÉES COMPLÈTES

II.3.3.1 Méthodes basées sur la recherche d'indépendances conditionnelles

Ces méthodes consistent en des procédures de tests sur les indépendances conditionnelles permettant, au final, de retrouver la structure recherchée.

II.3.3.1.1 Méthodes procédant par tests statistiques

Une manière de rechercher une structure adéquate pour un ensemble d'apprentissage est la recherche d'indépendances conditionnelles : la structure du réseau est déterminée pas à pas en établissant les indépendances conditionnelles existant au sein de l'ensemble des variables. Si certains des algorithmes de ce type détectent des variables latentes (cachées), en revanche ils requièrent tous une base complète.

II.3.3.1.1.1 Algorithmes PC et IC

Une des premières méthodes de recherche d'indépendances conditionnelles efficace proposée fût celle de l'algorithme PC (pour Peter and Clark, les prénoms des inventeurs de la méthode). Elle a été introduite par *SPIRITES*, *GLYMOUR* et *SCHEINES* (1993) [50], [41], [1]. Elle utilise un test statistique (X^2 ou G^2 originellement, voir Annexe D) pour évaluer s'il y a indépendance conditionnelle entre deux variables. Il est alors possible de reconstruire la structure du réseau Bayésien à partir de l'ensemble des relations d'indépendances conditionnelles découvertes. En pratique, un graphe complètement connecté sert de point de départ, et lorsqu'une indépendance conditionnelle est détectée à l'aide d'un test statistique, l'arc correspondant est retiré. Les tests statistiques sont effectués

suivant un ordre donné préalablement aux variables. Des études ont montré que cet ordre avait une grande influence sur le résultat rendu par cette méthode [41].

Algorithme 2 : Algorithme PC [50] :

Entrée: Un graphe connexe non orienté $G = \{V, E\}$, $V = \{X_1, X_2, \dots, X_n\}$

- 1:
- 2: **1^{ère} étape : Déterminer les indépendances conditionnelles**
- 3: $k \leftarrow 0$;
- 4: $G \leftarrow$ graphe complètement connecté;
- 5: $SepSet_G(X_i, X_j) \leftarrow \emptyset, \forall (i, j) \in 1, \dots, n$;
- 6: **Tant que** $\exists X_i, X_j \in V^2$ tq $|Adj(X_i)/X_j| \geq k$ **Faire**
- 7: *Détermination des indépendances conditionnelles d'ordre k*
- 8: $\forall (X_i, X_j) \in V^2$ tq $X_i - X_j$ et $|Adj(X_i)/X_j| \geq k$
- 9: Pour tout ensemble de sommets $S_{X_i X_j} \subset Adj(X_i)/X_j$ tel que $|S_{X_i X_j}| = k$
- 10: **Si** $X_i \perp\!\!\!\perp X_j | S_{X_i X_j}$ **Alors**
- 11: $SepSet_G(X_i, X_j) \leftarrow SepSet_G(X_i, X_j) \cup S_{X_i X_j}, \forall (i, j) \in 1, \dots, n$; et supprimer l'arête $X_i - X_j$ dans G .
- 12: **Fin Si**
- 13: $k \leftarrow k + 1$;
- 14: **Fin Tant que**
- 15:
- 16: **2^{ème} étape : Détection des V-structures**
- 17: **Pour** chaque triplet relié de V^3 de la forme $X_i - Z - X_j$ **Faire**
- 18: **Si** $Z \in SepSet_G(X_i, X_j)$ **Alors**
- 19: Orienter : $X_i \leftarrow Z \leftarrow X_j$ dans G
- 20: **Fin Si**
- 21: **Fin Pour**
- 22:
- 23: **3^{ème} étape : Orientation des arêtes restantes**
- 24: **Tant que** \exists d'arête non orientée dans G **Faire**
- 25: $\forall (X_i, X_j) \in V$
- 26: **Si** $X_i - X_j$ et \exists un chemin orienté de X_i vers X_j **Alors**
- 27: orienter l'arête $X_i - X_j$ en $X_i \rightarrow X_j$
- 28: **Sinon**
- 29: **Si** $X_j \in Adj(X_i), \exists Z$ tel que $X_i \rightarrow Z$ et $Z - X_j$ **Alors**
- 30: orienter l'arête $Z - X_j$ en $Z \rightarrow X_j$
- 31: **Fin Si**
- 32: **Fin Si**
- 33: **Fin Tant que**

Le fonctionnement de l'algorithme PC est le suivant : Soit un graphe $\mathbf{G}(\mathbf{V}, E, \Theta)$, deux sommets X_i et X_j de \mathbf{V} et un sous ensemble de sommets $S_{X_i, X_j} \in \mathbf{V} \setminus \{X_i, X_j\}$. Les sommets X_i et X_j sont reliés par un arc dans \mathbf{G} s'il n'existe pas S_{X_i, X_j} tel que $(X_i \perp\!\!\!\perp X_j | S_{X_i, X_j})$.

En pratique, la vérification de l'existence d'une telle indépendance revient à vérifier les différentes indépendances $(X_i \perp\!\!\!\perp_p X_j | S_{X_i, X_j})$ par ordre croissant (ie. selon une taille croissante de l'ensemble S_{X_i, X_j}). À partir d'un graphe non orienté entièrement connecté, la détection d'indépendances permet alors de supprimer les arêtes correspondantes jusqu'à l'obtention du squelette du GOSC recherché. Suivent alors deux phases distinctes visant dans un premier temps à détecter et établir les V-structures du graphe puis à orienter les arêtes restantes.

L'algorithme PC établit les hypothèses suivantes :

- hypothèse de fidélité,
- la base d'apprentissage est complète et suffisamment grande,
- les résultats des tests d'indépendance conditionnelle sont fiables.

Il est courant d'employer le test du X^2 ou bien celui du G^2 (cf. Annexes D).

À noter que l'algorithme PC, décrit dans *l'algorithme 2*, comme tous les algorithmes d'apprentissage de structure employant une base d'exemples, renvoie un graphe orienté appartenant à la classe d'équivalence de Markov du modèle recherché : les orientations des arcs, hormis celles des V-structures détectées, ne correspondent pas forcément aux réels liens de causalité de ce modèle.

Les règles permettant ici d'orienter le graphe non-orienté obtenu à l'issue de la phase de détection des indépendances conditionnelles peuvent être remplacées par toute heuristique permettant l'obtention d'un GOSC à partir d'un tel graphe. Les deux opérations graphiques correspondant dans cette phase de l'algorithme PC à l'ajout d'un arc orienté reviennent simplement à orienter le graphe de manière à :

- ne pas créer de circuit ;
- de ne pas créer de V-structure ;

L'ordre dans lequel les variables sont alors considérées peut éventuellement déboucher sur des GOSC différents mais néanmoins représentant tous les mêmes ensembles d'indépendances conditionnelles.

En revanche, l'ordre d'exécution des tests d'indépendance conditionnelle (i.e. l'ordre suivant lequel les différents sommets de l'ensemble conditionnant sont testés) a une influence sur le résultat final (exception faite du cas où la base d'apprentissage est de taille infinie) [41].

En parallèle à l'algorithme PC, un autre algorithme, nommé IC (pour Inductive Causation). Cet algorithme est similaire à l'algorithme PC mais part d'une structure vide en reliant les couples de variables dès qu'une dépendance conditionnelle est détectée (dans le sens où aucun sous-ensemble conditionnant $S_{X,Y}$ tel que $(X \perp\!\!\!\perp Y | S_{X,Y})$ n'est identifié) et obtient donc une *D-map* minimale là où l'algorithme PC cherche une *I-map* minimale.

L'inconvénient commun aux deux algorithmes est la multiplicité des tests d'indépendance conditionnelle à mener. Lors de la recherche de la structure d'un modèle complexe (nombreuses variables), les deux algorithmes procèdent à des tests exhaustifs sur les différents ensembles conditionnels S_{X_i, X_j} possibles, pour chaque couple de sommets (X_i, X_j) .

II.3.3.1.1.2 Algorithme : BNPC

L'algorithme *BNPC* (pour Bayes Net Power Constructor) utilise une analyse quantitative de l'information mutuelle entre les variables du domaine modélisé afin de construire la structure G recherchée. Les tests d'indépendance conditionnelle reviennent alors à déterminer un seuil pour l'information mutuelle (conditionnelle ou non) entre les couples de variables concernés.

BNPC se décompose en trois phases [50]:

1. Élaboration : Un premier graphe G_1 est créé par le même procédé que celui de l'algorithme MWST.
2. Enrichissement : Des arêtes sont ajoutées à G_1 afin d'obtenir un graphe non-orienté G_2 et ce, par application d'un nombre réduit de tests d'indépendance conditionnelle.

3. Affinement : Une nouvelle série de tests élimine les éventuelles arêtes superflues de G_2 pour obtenir un graphe final, G .

BNPC se décline sous deux variantes (*BNPC-A* et *BNPC-B*) selon que l'utilisateur fournisse ou non un ordre topologiquement compatible avec la structure recherchée. *BNPC-A* prend en entrée un tel ordre peut donc orienter les arêtes détectées à mesure de la construction.

Dans le cas de *BNPC-B*, cet ordre est inconnu et l'algorithme ne procède à l'orientation des différents arcs qu'au terme de son exécution.

La connaissance facultative d'un ordre topologique correct a pour conséquence une différence notable dans la manière dont les deux variantes construisent le graphe G recherché :

- *BNPC-A* peut détecter directement les différentes d-séparations du graphe à chaque étape de sa construction et donc définir précisément quels sont les différents ensembles de sommets conditionnés devant être pris en compte,
- *BNPC-B*, en l'absence d'un ordre topologique correct sur le graphe G , se voit confronté au même problème que les algorithmes PC et IC à savoir la nécessité de tester un nombre exhaustif et donc exponentiel d'ensembles de sommets conditionnés afin de pouvoir déterminer si deux sommets X et Y doivent être ou non reliés par une arête.

Pour réduire sa complexité, *BNPC-B* diminue considérablement le nombre des ensembles de sommets conditionnés par l'intermédiaire d'une analyse quantitative des dépendances régnant au sein du graphe. Pour cela, les auteurs définissent l'hypothèse de la fidélité monotone (Voir Annexe C).

II.3.3.1.1.3 L'algorithme QFCI

Les méthodes précédentes sont très sensibles au bruit et ne sont pas très efficaces lorsqu'il y a peu d'exemples par rapport au nombre de variables. L'algorithme *QFCI* (pour Quantitative Fast Causal Inference) est une amélioration de FCI qui utilise les résultats des tests statistiques pour quantifier la confiance dans les liens découverts. Cette méthode se décompose en cinq phases. Les

quatre premières sont très proches de celles de la méthode FCI. La dernière étape utilise la confiance dans les V-structures pour orienter les arcs [41].

II.3.3.1.1.4 L'algorithme PMMS

Un autre algorithme polynomial a été proposé par *BROWN et al* [51]. Cette méthode s'appelle PMMS pour Polynomial Max-Min Skeleton. Elle utilise une procédure appelée PMMPC pour Polynomial Max-Min Parents and Children qui retrouve des ensembles de voisins pour un noeud. L'algorithme PMMS est une variante polynomiale de l'algorithme MMHC pour Max-Min Hill Climbing introduit par *TSAMARDINOS et al* [52] qui utilisent alors la procédure MMPC qui est une version exacte non polynomiale de PMMPC. Cet algorithme consiste en la découverte de la couverture de Markov des différents nœuds, puis en la construction du squelette de la structure en utilisant cette information. Cette première phase est très proche de la méthode de *CHENG et al* [53], elle utilise également l'information mutuelle. Sa complexité est identique, soit en $O(n_4)$ pour le nombre de tests d'indépendance. Ensuite, pour obtenir une structure orientée, un algorithme glouton est utilisé, mais sa recherche est restreinte en utilisant la couverture de Markov connue.

II.3.3.1.1.5 L'algorithme Recursive Autonomy Identification

Cette méthode, introduite par *YEHEZKEL et al* [54], apprend la structure par l'utilisation récursive de tests d'indépendance conditionnelle d'ordre de plus en plus grand. Comparativement aux autres méthodes qui cherchent à simplifier la structure avant de l'orienter, celle-ci effectue les deux tâches conjointement avec une troisième qui consiste en la séparation hiérarchique en sous-structures. Cette troisième tâche permet de diminuer le nombre de tests avec de grands ensembles de conditionnement tout en améliorant la précision en classification des modèles obtenus d'après *YEHEZKEL et al* [54]. Sa complexité dans le pire des cas reste néanmoins la même que pour la méthode PC.

II.3.3.1.1.6 La recherche de motifs fréquents corrélés

Les méthodes présentées jusqu'à présent ne peuvent pas détecter des situations où des états de plusieurs variables ont une influence conjointe sur un état particulier d'une tierce variable. *AUSSEM et al* [55] proposent alors une

technique basée sur des tests du X^2 pour l'indépendance conditionnelle et des tests de corrélation pour identifier des conjonctions de variables impliquées dans des relations causales en limitant le nombre de tests d'indépendance conditionnelle. Pour ce faire la méthode repose sur l'extraction d'ensembles fréquents corrélés minimaux grâce à un algorithme par niveau dans le treillis des parties de l'ensemble des variables aléatoires considérées.

De manière analogue, *GODENBERG et al* [56] propose une méthode d'apprentissage spécifique au cas où le nombre d'attributs est très élevé. Cette méthode consiste en une adaptation de la découverte des ensembles fréquents, une méthode populaire par ailleurs dans la communauté de la recherche d'information, pour construire un réseau Bayésien lorsque le nombre de nœuds et d'exemples sont tous deux de plusieurs centaines de milliers.

II.3.3.1.1.7 L'algorithme Grow-Shrink

MARGARITIS [57] introduit une méthode nommée the *Grow-Shrink algorithm* pour apprendre la structure d'un réseau Bayésien en utilisant des tests statistiques. Cette méthode consiste en l'identification de la frontière de Markov de chaque nœud, puis en l'utilisation de cette connaissance pour apprendre l'ensemble des parents de chaque nœud. La méthode se termine alors par une phase d'orientation des arêtes non encore orientées.

II.3.3.1.2 Commentaires

Les différents algorithmes procédant par recherche de causalité présentent des points communs. D'une part ces algorithmes présentent l'attrait de proposer une construction graduelle de la structure retournée. La prise en compte de propriétés graphiques locales aux différentes variables ainsi que l'emploi de méthodes statistiques connues rendent ce type d'approche intuitivement séduisante. Cependant, malgré ces traits intéressants, certains défauts demeurent [50] :

- la fiabilité des tests d'indépendance, en particulier en présence d'un nombre de cas insuffisant ;
- le nombre important de tests d'indépendance à effectuer pour couvrir l'ensemble des variables ;

- dans le cas de l'algorithme *BNPC*, le manque de fiabilité de ses fondements théoriques.

Une alternative à l'apprentissage par le biais de tests statistiques est l'emploi d'une mesure d'évaluation de la qualité d'une structure vis-à-vis de la base d'apprentissage en combinaison avec une heuristique de parcours d'un espace de solutions candidates. La section suivante décrit quelques unes de ces méthodes.

II.3.3.2 FONCTION D'ÉVALUATION OU DE SCORE

Les méthodes procédant par exploration et évaluation des solutions potentielles utilisent un score permettant d'évaluer la concordance de la structure courante avec la distribution de probabilité ayant généré les données. De nombreuses fonctions d'évaluation ont été conçues et ce chapitre présente quelques-unes de celles-ci parmi les plus connues.

Certaines propriétés ont été déterminées comme sinon essentielles du moins d'importance pour les métriques employées (voir Annexe C).

II.2.3.2.1 Score Bayésien

Si la dénomination de score Bayésien réfère effectivement à une métrique spécifique que nous allons présenter ici, il s'agit aussi d'un terme plus général dénotant les différentes métriques développées à partir du même principe de base. Lors de l'apprentissage d'un modèle, qu'il s'agisse de sa structure ou de ses paramètres, il existe une incertitude quant à l'identité de ces éléments. L'approche Bayésienne consiste à représenter et quantifier cette incertitude sous une forme subjective. Cet encodage revient alors à déterminer une distribution a priori sur la structure et/ou les paramètres recherchés.

Nous cherchons ici la structure G ayant la probabilité la plus élevée conditionnellement aux données D . Autrement dit, nous cherchons à maximiser la probabilité $P(G|D)$. Cette probabilité est la probabilité a posteriori. La maximisation de cette probabilité passe en premier lieu par sa décomposition ; le théorème de Bayes nous permet la décomposition suivante :

$$P(G|D) = \frac{P(D, G)}{P(D)} = \frac{P(G|D) \times P(G)}{P(D)} \quad (\text{II. 17})$$

Il est important de remarquer que l'élicitation du meilleur modèle se fait à partir de la seule base d'apprentissage D et que nous pouvons alors négliger la probabilité $\mathbb{P}(D)$.

Le plus souvent, pour des raisons de commodité de calculs, l'optimisation de la probabilité a posteriori $\mathbb{P}(D, G)$ passe par l'optimisation de son logarithme :

$$\log \mathbb{P}(G|D) = \log \mathbb{P}(G) + \log \mathbb{P}(D|G) - \log \mathbb{P}(D) \approx \log \mathbb{P}(G) + \log \mathbb{P}(D|G) \quad (\text{II. 18})$$

Nous voyons que la probabilité $\mathbb{P}(G|D)$ se décompose en deux termes :

$\mathbb{P}(G)$: Probabilité a priori de la structure G .

$\mathbb{P}(D|G)$: Vraisemblance marginale.

La probabilité a priori de G , représente la mesure de la confiance (ou a priori) que nous avons en la structure G .

La valeur de la vraisemblance marginale $\mathbb{P}(D|G)$ a été calculée quant à elle, dans le cas de variables discrètes, par *COOPER ET HERSKOVITS [50]*, qui ont proposé le résultat suivant :

Théorème II.1 Soit :

- U , un ensemble de variables aléatoires discrètes, $U = \{X_1, X_2, \dots, X_n\}$;
- $X_i, i \in 1, \dots, n$ variable de U de cardinalité r_i ;
- D , base d'apprentissage formée de N instances de U indépendantes et identiquement distribuées ;
- G une structure d'un réseau Bayésien contenant exactement les n variables de U ;
- r_{ij} , j^e instanciation de $\prod[i, j \in 1 \dots q_i]$;
- N_{ijk} le nombre d'occurrences simultanées de $X_i = x_i^k$ et π_{ij} ;
- soit $N_{ij} = \sum_{k=1}^{r_i} N_{ijk}$

Le score Bayésien, aussi appelé score *BD*, s'écrit alors :

$$\text{Score}_{BD}(G, D) = \mathbb{P}(G, D) = \mathbb{P}(G) \prod_{i=1}^n \prod_{j=1}^{q_i} \frac{(r_i - 1)!}{(N_{ij} + r_i - 1)!} \prod_{k=1}^{r_i} N_{ijk}! \quad (\text{II. 19})$$

Le score Bayésien de l'équation II.19 s'adapte au cas de l'utilisation d'a priori de *Dirichlet* (voir Annexe B) en s'écrivant :

$$\begin{aligned}
Score_{BD}(G, D) &= \mathbb{P}(G, D) \\
&= \mathbb{P}(G) \prod_{i=1}^n \prod_{j=1}^{q_i} \frac{(\alpha_{ij} + r_i - 1)!}{(N_{ij} + \alpha_{ij} + r_i - 1)!} \prod_{k=1}^{r_i} \frac{(\alpha_{ijk} + N_{ijk})!}{\alpha_{ijk}!} \quad (\text{II.20})
\end{aligned}$$

La distribution a priori sur l'espace des structures peut être définie ou calculable grâce à un expert ou bien, cas le plus courant car simplifiant le calcul, être définie comme étant uniforme. Dans ce dernier cas, la maximisation de la probabilité relative a posteriori $\log \mathbb{P}(G, D)$ se ramène alors à la maximisation de la vraisemblance marginale que l'on emploie comme score.

Le score BDe :

Le score Bayésien, présenté précédemment, présente un inconvénient majeur : il n'est pas équivalent. Deux structures présentant les mêmes indépendances conditionnelles obtiennent donc deux évaluations différentes. Une heuristique parcourant l'espace des structures a tout intérêt à employer un score présentant la propriété d'équivalence. À cette fin, les auteurs de [58] ont développé une variante du score *BD*. Cette variante repose sur l'hypothèse d'équivalence de la vraisemblance :

Hypothèse II.1 (Équivalence de vraisemblance) : Soit G_1 et G_2 , deux structures représentant les mêmes indépendances conditionnelles, de probabilités a priori non négatives, alors $\mathbb{P}(\theta \setminus G_1) = \mathbb{P}(\theta \setminus G_2)$.

Soit G_T , le graphe entièrement connecté sur V et N_{est} , un nombre arbitraire de pseudo exemples supplémentaires – i.e. un décompte fictif d'exemples supplémentaires de la base pour lesquels $X_i = x^k, \prod i = \pi_{ij} -$, la contrainte suivante, imposée sur les exposants de *Dirichlet* α_{ijk} des distributions des paramètres du modèle évalué, permet de rendre le score *BD* équivalent :

$$\alpha_{ijk} = N_{est} \times \mathbb{P}(X_i = x, \prod i = \pi_{ij} \setminus G_T) \quad (\text{II.21})$$

L'avantage de fixer un nombre minimal N_{est} d'occurrences pour les différentes configurations possibles est d'empêcher qu'une configuration particulière d'une variable X_i et de son ensemble de variables parents $Pr(X_i)$ ne soit considérée comme impossible par le modèle (et se voit donc attaché une probabilité a posteriori nulle).

La variante, nommée score *BDe* (pour *Bayesian Dirichlet Equivalent*), est alors égale à :

$$S_{BDe}(G \setminus D) = \mathbb{P}(G, D) = \mathbb{P}(G) \prod_{i=1}^n \prod_{j=1}^{q_i} \frac{\Gamma(\alpha_{ij})}{\Gamma(N_{ij} + \alpha_{ij})} \prod_{k=1}^{r_i} \frac{\Gamma(\alpha_{ijk} + N_{ijk})}{\Gamma(\alpha_{ijk})} \quad (\text{II. 22})$$

La fonction gamma Γ étant employée ici du fait que les α_{ijk} ne sont pas nécessairement entiers.

Le score *BDeu* :

Le score *BDeu* est en fait un cas particulier du score *BDe* présenté précédemment. Ici, les distributions de probabilités a priori définies sur les paramètres du modèle évalué sont uniformes (le 'u' de *BDeu* signifiant uniform), i.e.

$$\mathbb{P}\left(X_i = x_k, \prod i = \pi_{ij}/G_T\right) = \frac{1}{r_i \cdot q_i}, \forall i \in 1 \dots N, k \in 1 \dots r_i, j \in 1 \dots q_i \quad (\text{II. 23})$$

GT représentant ici encore le graphe entièrement connecté sur V.

[58] et [59] définissent alors les exposants de *Dirichlet* suivants:

$$\alpha_{ijk} = \frac{N_{est}}{r_i q_i} = \forall i \in 1 \dots r_i, j \in 1 \dots q_i \quad (\text{II. 24})$$

Où N_{est} désigne, ici encore, un nombre arbitrairement fixé.

L'équation II.25 désigne alors le score *BDeu*, qui demeure un score équivalent.

$$S_{BDeu}(G, D) = \mathbb{P}(G) \prod_{i=1}^n \prod_{j=1}^{q_i} \frac{\Gamma\left(\frac{1}{q_i}\right)}{\Gamma\left(\frac{1}{q_i} + N_{ij}\right)} \prod_{k=1}^{r_i} \frac{\Gamma\left(\frac{1}{q_i} + N_{ijk}\right)}{\Gamma\left(\frac{1}{q_i r_i}\right)} \quad (\text{II. 25})$$

Le score *BDeu* est très souvent employé pour l'évaluation de structures. Une de ses caractéristiques est d'être apte à détecter les arcs correspondant à des dépendances conditionnelles de poids faibles. Ce comportement est d'ailleurs d'autant plus prononcé que l'on emploie une valeur élevée pour le paramètre N_{est} de l'équation II.24 [60].

La vraisemblance du modèle évalué par rapport à la base d'apprentissage n'est pas la seule méthode d'évaluation d'une structure. Une autre façon de faire

est d'employer des critères visant non seulement à vérifier cette adéquation mais aussi, dans le cas des fonctions de scores que nous allons présenter, de favoriser les modèles les plus simples.

Le critère AIC :

Le critère *AIC* (*Akaike Information Criterion*) [61] cherche à éviter les problèmes liés à l'apprentissage sur la seule vraisemblance. Dans les évaluations précédentes, la vraisemblance par rapport à la base de données est employée à la fois pour l'apprentissage des paramètres du modèle et pour l'évaluation de la structure, ce qui risque d'introduire un biais. En pénalisant la complexité des structures évaluées, le critère *AIC* vise à éliciter le modèle le plus simple et le plus expressif de la connaissance extraite de la base D .

$$Score_{AIC}(B, D) = -2\log L(D/B, D) = -2\log L(D/B, \theta^{MV}) + 2Dim(B) \quad (II.26)$$

Où θ^{MV} est l'ensemble des paramètres obtenus par maximum de vraisemblance pour le réseau Bayésien B et $Dim(B)$ est la dimension de B .

Soit r_i le nombre de valeurs pouvant être prises par la variable X_i , le nombre de paramètres nécessaires pour représenter $\mathbb{P}(X_i | \prod i = \pi_{ij})$ est égal à $r_i - 1$ et la représentation de $\mathbb{P}(X_i | \prod i)$ nécessite $Dim(X_i, B)$ paramètres avec :

$$Dim(X_i, B) = (r_i - 1) * q_i, \text{ où } q_i = \prod_{X_j \in \prod i} r_j \quad (II.27)$$

La dimension du modèle B devient alors :

$$Dim(B) = \sum_{i=1}^n Dim(X_i, B) \quad (II.28)$$

AIC, bien que décomposable et équivalent, présente cependant un inconvénient : celui de ne pas être consistant avec la dimension. Il faut comprendre par là que le critère *AIC* ne permet pas la sélection du véritable modèle (à supposer qu'il existe) quand la taille de la base d'apprentissage s'accroît. En effet, lorsque la taille de la base croît, le terme de pénalisation tend à devenir négligeable vis-à-vis de la vraisemblance logarithmique. Dès lors, le critère *AIC* va avoir tendance à éliciter le modèle le plus complexe et aboutir ainsi à un sur-apprentissage.

Pour circonvier à ceci, diverses variantes du critère AIC ont été développées parmi lesquelles le critère CAIC (pour Consistent AIC) [62].

$$Score_{AIC}(B, D) = -2\log L(D/B, \theta^{MV}) + Dim(B) * [\log(N) + 1] \quad (II.29)$$

À l'opposé, dans le cas où la taille de la base de données est très limitée, il est généralement préférable d'employer une autre variante du critère AIC : le critère AICC (*Akaike Information Corrected Criterion* [63]. Cette variante inflige une pénalité d'autant moins élevée aux structures complexes que la base est limitée, relâchant la contrainte de parcimonie.

$$Score_{AIC}(B, D) = AIC + \frac{2Dim(B) \times (Dim(B) + 1)}{N - Dim(B) - 1} \quad (II.30)$$

Pour l'équation II.30, on remarque que, lorsque la taille de la base de données devient importante, le dernier terme de l'équation tend vers 0 et on approche la formule du critère AIC.

Le score MDL:

Le critère MDL [64], [65] incorpore un terme pénalisant les structures trop complexes et ne tient pas seulement compte de la complexité même du modèle mais aussi de la complexité du codage des données suivant ce modèle. Il existe différentes variantes du score MDL, dont celle de [66].

$$Score_{MDL}(B, D) = LL(D \setminus \theta^{MV}, B) - |\varepsilon_B| \times \log N - c \cdot Dim(B) \quad (II.31)$$

$|\varepsilon_B|$ représente le nombre d'arcs présents dans le modèle B et c , le nombre de bits nécessaires pour encoder un des paramètres.

Le score BIC:

Le critère BIC (*Bayesian Information Criterion*), proposé dans [67], est certainement le critère le plus employé actuellement dans le cadre de la sélection de modèles. Semblable au critère AIC, il comporte lui aussi une pénalité envers la complexité structurelle.

$$Score_{BIC}(B, D) = \log L(D \setminus B, \theta^{MAP}, B) - \frac{1}{2} Dim(B) \times \log N \quad (II.32)$$

Le terme $-\frac{1}{2}Dim(B) * \log N$ représentant la pénalité envers les structures trop complexes. Si l'on évalue un ensemble $M = \{M_1, M_2, \dots, M_m\}$ de modèles, le meilleur modèle M_i est alors égal à :

$$M = \underset{M_i}{\operatorname{argmax}}(\operatorname{Score}BIC) \quad (II.33)$$

Le score *BIC* présente les trois propriétés présentées en début de section, à savoir l'équivalence, la décomposabilité et la consistance ; ceci, combiné à sa tendance à éliciter les modèles les plus simples [68] en fait une des métriques d'évaluation les plus employées avec le score *BDeu*.

Plusieurs fonctions de score ont été vues dans cette section. Néanmoins, il s'avère, dans la pratique, que la plupart des méthodes actuelles se fondent sur l'emploi du score *BDeu* ou bien du critère *BIC*. Certaines méthodes emploient des versions modifiées des critères pondérés comme *AIC* ou *MDL* [50].

II.3.3.3 METHODES DE RECHERCHE EMPLOYANT UN SCORE

Etant donnée que l'apprentissage de structure à base de recherche exhaustive sur l'espace des DAGs décrits sur l'ensemble des variables modélisée n'étant pas une méthode réalisable en pratique (lorsque le nombre de variables est élevé), il est nécessaire de mettre au point des heuristiques permettant de parcourir efficacement cet espace.

Ces heuristiques parcourent généralement l'espace des DAGs suivant une heuristique afin de restreindre l'espace de recherche, il existe cependant, des heuristiques sur la méthode de recherche.

II.3.3.3.1 Méthodes employant des heuristiques sur l'espace de recherche

Recherche de l'arbre de recouvrement de poids maximal

Une première heuristique peut être adaptée des travaux de *CHOW et al* [69]. Ces derniers ont proposé une méthode dérivée de la recherche de l'arbre de recouvrement de poids maximal (*maximal weight spanning tree* ou *MWST*). Cette méthode s'applique aussi à la recherche de structure d'un réseau Bayésien en fixant un poids à chaque arête potentielle $A \rightarrow B$ de l'arbre. Ce poids peut être par exemple l'information mutuelle entre les variables A et B comme proposé par *CHOW et al* [69], ou encore la variation du score local lorsqu'on choisit B comme

parent de A comme proposé par *HECKERMAN* et al [58]. Une fois cette matrice de poids définie, il suffit d'utiliser un des algorithmes standards de résolution du problème de l'arbre de poids maximal comme l'algorithme de *Kruskal* ou celui de *Prim*. L'arbre non dirigé retourné par cet algorithme doit ensuite être dirigé en choisissant une racine puis en parcourant l'arbre par une recherche en profondeur. La racine peut être choisie soit aléatoirement, soit à l'aide de connaissance a priori, soit en prenant la variable représentant la classe pour des problèmes de classification [50], [41].

L'algorithme K2

Parmi les algorithmes les plus utilisés et qui ont prouvé leur efficacité, on trouve l'algorithme K2 proposé par *COOPER* et *HERSOVITS* en 1992 [41]. L'idée de cet algorithme est de maximiser la probabilité de la structure sachant les données dans l'espace de DAG respectant un ordre d'énumération de variables donné en entrée. La réduction qui découle de cette connaissance permet de limiter la recherche à un espace de $2^{\binom{n}{2}}$ structures. De même, l'espace à explorer est aussi limité en faisant l'hypothèse qu'un nœud ne peut avoir plus d'un certain nombre de parents.

L'algorithme K2 utilise originellement, le score Bayésien de l'équation II., comme il utilise aussi la variante de score Bayésien BDe , et le score BIC . Il est possible qu'il utilise le score MDL et n'importe quel autre score décomposable [50].

La connaissance *a priori* de l'ordre topologique des variables est considéré comme un point fort de l'algorithme K2 et un inconvénient en même temps. En effet la pertinence des résultats obtenus est fortement liée à cet ordre d'énumération des nœuds. La recherche de l'ordre d'énumération correcte est un problème NP-difficile, plusieurs méthodes ont été proposées, tels que les tests d'indépendance conditionnelles, MCMC, les algorithmes génétiques et les algorithmes évolutionnaire [41].

Algorithme K2 [50]:

Entrée: Un ensemble de n nœuds, un ordonnancement sur ces nœuds, une borne supérieure S sur le nombre de parents d'un nœud, une base de données D composée de N cas

```

1: Pour  $i = 1 \dots n$  Faire
2:  $\pi_i \leftarrow \emptyset$ 
3:  $P_{prec} \leftarrow f(X_i, \Pi i)$ 
4: Continuer  $\leftarrow$  VRAI
5: Tant que Continuer et  $|\pi_i| < S$  Faire
6:   Soit  $z$  le nœud de  $Pred(X_i)$  maximisant  $Score_{BD}(X_i, \Pi i \cup \{Z\})$ ;
7:  $P_{nouveau} \leftarrow f(i, \pi_i \cup \{Z\})$ 
8: Si  $P_{prec} > P_{nouveau}$ 
Alors
9:  $P_{prec} \leftarrow P_{nouveau}$ 
10:  $\Pi i \leftarrow \Pi i \cup \{Z\}$ 
11: Sinon
12: Continuer  $\leftarrow$  FAUX
13: Fin Si
14: Fin Tant que
15: Fin Pour

```

L'algorithme K2 teste alors l'ajout de parents de la manière suivante : le premier nœud ne peut pas posséder de parents et pour les nœuds suivants, l'ensemble des parents choisi est le sous-ensemble de nœuds qui augmente le plus le score parmi l'ensemble des nœuds le précédant dans l'ordre d'énumération. L'espace de recherche est ainsi réduit à l'ensemble des DAG respectant cet ordre.

II.3.3.3.2 Méthodes employant des heuristiques sur la méthode de recherche

L'algorithme de recherche gloutonne

L'algorithme de recherche gloutonne (GS, *greedy search*) est très répandu en optimisation. Il part d'un premier graphe, en définit un voisinage, puis associe un score à chaque graphe du voisinage. Le meilleur graphe est alors choisi pour l'itération suivante.

Dans le cas des réseaux Bayésiens, le voisinage d'un DAG est défini par l'ensemble des graphes obtenus en ajoutant, supprimant, ou en retournant un arc du graphe courant.

L'algorithme s'arrête lorsque le graphe obtenu réalise un maximum (local) de la fonction de score. L'espace de recherche est alors l'espace *complet* des DAG contrairement aux méthodes précédentes. Cet algorithme calculant le score de

graphes voisins, il est nécessaire d'utiliser un score décomposable pour n'avoir à calculer que la variation locale du score entraînée par la suppression, l'ajout ou le retournement d'un arc et non les scores globaux de ces deux graphes. Pour les expérimentations, cette méthode utilisera le score *BIC*.

II.3.4 APPRENTISSAGE DE STRUCTURE À PARTIR DES DONNEES INCOMPLETES

II.3.4.1 Fonction de score pour données incomplètes

Soit $V = \{X_1, \dots, X_n\}$ un ensemble des variables aléatoires, D_c une base de m tirages de V indépendants et identiquement distribués.

Supposons par ailleurs que l'on ne possède alors qu'une version incomplète D de la base D_c , celle-ci peut se décomposer en

$$D = \left[\left[X_i^l \right]_{\substack{1 \leq i \leq n \\ 1 \leq l \leq m}} \right] = [O, H] \quad (\text{II. 34})$$

Où O est l'ensemble des variables X_i^l observées et H l'ensemble des variables X_i^l cachées.

Ici nous voudrions évaluer le score Bayésien qui est défini par $BD(G, D) = \mathbb{P}(G, D) = P(G)\mathbb{P}(D|G)$ à partir de bases d'exemples incomplètes. En présence de données incomplètes, nous avons

$$\mathbb{P}(D^l|G) = \mathbb{P}(O^l|G) = \sum_{H^l} \mathbb{P}(O^l, H^l|G) \quad (\text{II. 35})$$

Pour le l -ième exemple de la base. En considérant que les exemples de la base D sont

i.i.d, nous obtenons

$$\mathbb{P}(D|G, \theta) = \prod_{i=1}^m \left(\sum_{H^l} \mathbb{P}(O^l, H^l|G, \theta) \right) \quad (\text{II. 36})$$

Le nombre de terme de l'équation II.36 croît exponentiellement avec le nombre de variables non observées. La complexité de l'évaluation de cette probabilité est donc exponentielle par rapport au nombre de valeurs manquantes

dans la base d'exemples. En pratique, ceci n'est donc pas utilisable, on va donc devoir avoir recours à une méthode d'approximation.

L'approximation de Cheeseman et Stutz :

Cette méthode d'approximation a été introduite par *CHEESEMAN et STUTZ* en 1996 [41]. Elle consiste en l'utilisation d'une complétion D_c de la base incomplète D . Il est alors toujours possible d'écrire l'équation suivante :

$$\mathbb{P}(D|G) = \mathbb{P}(D_c|G) \frac{\mathbb{P}(D|G)}{\mathbb{P}(D_c|G)} \quad (\text{II. 37})$$

Puis, il vient

$$\mathbb{P}(D|G) = \mathbb{P}(D_c|G) \frac{\int \mathbb{P}(D, \theta|G) d\theta}{\int \mathbb{P}(D_c, \theta|G) d\theta} \quad (\text{II. 38})$$

Il reste alors à évaluer l'intégrale $\int \mathbb{P}(D, \theta|G) d\theta$. Celle-ci peut alors être approchée par une méthode de maximum a posteriori.

Approximation de Laplace de Cheeseman et Stutz :

En utilisant la formule II., on peut donner l'approximation suivante pour la formule de *CHEESEMAN et STUTZ*.

$$\begin{aligned} \ln \mathbb{P}(D|G) \simeq \ln \mathbb{P}(D_c|G) - \ln \left(\mathbb{P} \left(D_c, \widehat{\theta}^{MAP} / G \right) \right) + \frac{1}{2} \ln(|\hat{A}|) + \ln \left(\mathbb{P} \left(D_c, \widehat{\theta}^{MAP} / G \right) \right) \\ - \frac{1}{2} \ln(|A|) \end{aligned} \quad (\text{II. 39})$$

Les valeurs $\widehat{\theta}^{MAP}$ et \hat{A} sont évaluées sur la base d'exemples complète D_c tandis que les valeurs θ^{MAP} et A sont évaluées sur la base d'exemples incomplète D .

Approximation BIC-MAP de la formule de Cheeseman et Stutz :

Considérons la base D_c qui est une complétion de D telle que les statistiques suffisantes N_{ijk} de D_c sont égales aux statistiques suffisantes N_{ijk} de D calculées par maximum a posteriori. Soient $\widehat{\Phi}$ les paramètres naturels évalués par maximum a posteriori sur D alors d'après la formule II.39 , nous avons

$$\begin{aligned} \ln\mathbb{P}(D|G) \simeq \ln\mathbb{P}(D_c|G) - \ln\left(\mathbb{P}\left(D_c/G, \widehat{\Phi}\right)\right) + \frac{\dim(G|D_c)}{2}\ln(N) + \ln\left(\mathbb{P}(D/G, \widehat{\Phi})\right) \\ - \frac{\dim(G|D)}{2}\ln(N) \end{aligned} \quad (\text{II. 40})$$

Dans ce cas, *GEIGER et al [70]* ont montré que $\dim(G|D) = \dim(G|\widehat{D})$. De plus, comme les statistiques essentielles des deux bases d'exemples sont égales nous avons $\widehat{\Phi} = \widehat{\Phi}$ donc :

$$\ln\mathbb{P}(D|G) \simeq \ln\mathbb{P}(D_c|G) - \ln\mathbb{P}(D_c|G, \widehat{\Phi}) + \ln\mathbb{P}(D|G, \widehat{\Phi}) \quad (\text{II. 41})$$

Cette méthode permet donc d'évaluer $\mathbb{P}(D|G)$ à partir d'une complétion de la base de cas de manière simple : il suffit juste de s'assurer que les statistiques essentielles de la base incomplète soient conservées dans la base complète.

II.3.4.2 Méthode d'évaluation générique de score à partir d'une base d'exemples incomplète

Pour nos expérimentations, nous utiliserons des scores du type

$$\ln\mathbb{P}(D|G) \simeq BIC(B, C) = \ln\left(\mathbb{P}(D/G, \widehat{\theta}^{MAP})\right) - \frac{1}{2}Dim(B)\log N \quad (\text{II. 42})$$

Il reste cependant à voir comment calculer le terme $\mathbb{P}(D/G, \widehat{\theta}^{MAP})$ lorsque la base D est incomplète. Donnons à présent une méthode générique permettant de calculer un score à partir d'une base d'exemples incomplète.

La méthode

Nous avons vu comment évaluer les paramètres d'un réseau Bayésien à partir d'une base d'exemples incomplète en section II.2. Nous allons maintenant voir comment faire de même pour un critère de score.

Soit $S(M|D_c)$ une fonction de score pour un modèle M en fonction d'une base complète D_c . Alors, il est possible de considérer le score de ce même modèle avec une base de données incomplète D .

$$Q^S(M/D) = \mathbb{E}_{H \sim \mathbb{P}(H)}(S(M/O, H)) \quad (\text{II. 43})$$

Or, nous n'avons pas accès à la loi $\mathbb{P}(H)$. Il faut donc l'approcher à partir d'un modèle de représentation de D .

Supposons, à présent, la donnée d'un modèle M^0 supposé générateur de D , alors il est possible de faire l'approximation suivante :

$$Q^s(M/D) \approx Q^s(M: M^0/D) = \mathbb{E}_{H \sim \mathbb{P}(H/M^0)}(S(M/O, H)) \quad (\text{II. 44})$$

C'est-à-dire

$$Q^s(M: M^0/D) = \sum_H S(M/O, H) \mathbb{P}(H/M^0) \quad (\text{II. 45})$$

Or, maintenant, nous avons accès à $\mathbb{P}(H/M^0)$ puisque M^0 est fixé.

Cette méthode nous permet, à partir d'une fonction de score $S(M/D_c)$ quelconque, de créer une fonction de score $Q^s(M: M^0/D)$ qui donne un résultat (approché car un modèle est rarement exact) sur des bases d'exemples incomplètes. Dans les chapitres suivantes, la base d'exemples sera implicite et la notation simplifiée en $Q^s(M: M^0)$.

Par ailleurs, ce score possède la particularité de conserver les propriétés de décomposabilité (linéarité de l'espérance) et de score équivalence du score S . Le grand avantage de cette méthode est qu'elle s'incorpore parfaitement bien dans un algorithme EM pour lequel l'évaluation du score est de plus en plus fine au fur et à mesure que le modèle est précis.

II.3.4.3 Méthodes à base de score pour données incomplètes

II.3.4.3.1 L'algorithme SEM

Issu initialement des travaux de *FRIEDMAN* en 1997, prolongés dans [76], SEM conjugue la méthodologie d'estimation des données à l'apprentissage par évaluation dans l'espace des DAG pour retourner simultanément la meilleure structure et les paramètres estimés associés.

Les premiers travaux de *FRIEDMAN* dans ce contexte ont utilisé les principes de l'algorithme EM que nous avons vu dans la partie apprentissage de paramètres de chapitre pour effectuer l'apprentissage de structure, ces travaux ont aboutit à la méthode alternative model selection EM (AMS-EM).

Algorithme EM générique pour l'apprentissage de structure [41]:

1: **Init** : $i = 0$

Choix aléatoire ou utilisant une heuristique pour sélectionner le réseau Bayésien Initial (G_0, θ_0)

2: **Répéter**

3: $i = i + 1$

4: $(G^i, \theta^i) = \operatorname{argmax}_{G, \theta} Q(G, \theta: G^{i-1}, \theta^{i-1})$

5: **Jusqu'à** $|Q(G^i, \theta^i: G^{i-1}, \theta^{i-1}) - Q(G^{i-1}, \theta^{i-1}: G^{i-1}, \theta^{i-1})| \leq \varepsilon$

SEM calcule la meilleure estimation des données non observées (et, par la suite, les paramètres calculés à partir de celles-ci) avant d'effectuer une recherche classique telle qu'en présence de données complètes. La fonction de score utilisée est une fonction du type espérance d'un score (*BIC* ou *MDL*).

A chaque itération sur t , l'algorithme SEM sélectionne la structure la mieux évaluée et les paramètres associés. L'algorithme s'appuie sur le fait qu'il essaie d'améliorer le score à chacune de ses itérations. C'est là que se situe le point faible de SEM : pour l'algorithme EM standard, les points de convergence correspondent aux points où la fonction objective est stationnaire ; mais cette notion n'est pas applicable dans l'espace des structures de modèles. Le problème survient quand l'algorithme converge vers un maximum local : ce cas se produit si un modèle génère une distribution assez performante pour faire apparaître les autres solutions comme étant moins performantes, au vu du score espéré. Plus la quantité d'information manquante est importante, plus cela risque de se produire.

Bayesian Structural EM

Friedman [71] à propose une nouvelle version de son algorithme SEM appelé B-SEM pour *Bayesian Structural EM*. Il utilise dans cette version le score Bayésien au lieu d'un score asymptotiquement équivalent (de type *BIC/MDL*), la fonction de score utilisée est celle de la formule de II.. Cette version est aussi basée sur l'idée de complétude des données. Par conséquent, la recherche se fait sur l'espace de structures plutôt que sur l'espace de structures et de paramètres.

Algorithme Bayesian SEM [71]:

1: **Init** : $i = 0$

Choix aléatoire ou utilisant une heuristique pour sélectionner le réseau Bayésien Initial (G_0, θ_0)

2: **Répéter**

3: $i = i + 1$

4: $(G^i, \theta^i) = \operatorname{argmax}_{G, \theta} \varrho(G, \theta: G^{i-1}, \theta^{i-1})$

5: **Jusqu'à** $|\varrho(G^i, \theta^i: G^{i-1}, \theta^{i-1}) - \varrho(G^{i-1}, \theta^{i-1}: G^{i-1}, \theta^{i-1})| \leq \varepsilon$

II.3.4.4 L'APPRENTISSAGE DES RESEAUX BAYESIENS CONTINUES ET HYBRIDES

Les méthodes présentées ci-dessus sont principalement dédiées à l'apprentissage de réseaux Bayésiens pour lesquels tous les nœuds sont supposés discrets. *DAVIES et al [72]* ont proposé une méthode pour effectuer l'apprentissage de réseaux Bayésiens hybrides contenant des nœuds discrets et des nœuds dont les distributions de probabilités sont supposées continues et être de la forme d'un mélange de gaussiennes. Plus récemment, *COBB et al [73]* ont introduit une technique pour apprendre des structures de réseaux Bayésiens avec à la fois des nœuds discrets et des nœuds continus dont les distributions de probabilités sont supposées être de la forme de mélanges d'exponentielles tronquées.

Les méthodes d'apprentissage de structures peuvent elles aussi être adaptées au cas continu, soit par discrétisation de la base d'apprentissage afin d'apprendre un modèle discret, soit bénéficient elles aussi d'adaptation au domaine continu. *COLOT et al [74]* emploient une version modifiée du critère *AIC* afin de discrétiser l'espace des données. Cette pré-discrétisation, appliquée à la base d'apprentissage, servant à l'apprentissage d'un modèle lui-même discret. Les méthodes de discrétisation peuvent elles-mêmes faire partie intégrante de l'apprentissage ; *FRIEDMAN et GOLDSZMIDT [75]* fournissent une méthode de discrétisation à l'aide du critère *MDL*, le modèle appris et les données d'apprentissage discrétisées sont alors alternativement réévaluées afin d'optimiser leur adéquation mutuelle. D'autres méthodes ne discrétisent pas la base d'apprentissage ; ainsi *MARGARITIS [76]* propose une méthode de test d'indépendance conditionnelle entre deux variables continues. Ce test pouvant alors être employé au sein d'un algorithme tel que l'algorithme PC (cf. section 4.2.1). Une description étendue des techniques d'apprentissage de structures dans le cas continu peut être trouvée dans [77].

II.4 APPRENTISSAGE DE RESEAUX BAYESIENS DYNAMIQUES

L'apprentissage de structure de réseaux Bayésiens dynamiques comprend l'apprentissage de connectivité des (*intra_slices*) qui est un graphe orienté sans circuits, et la connectivité des (*iner-slice*) qui est équivalent au problème de la sélection des variables. Pour chaque variable de la tranche t , on doit trouver ses parents dans la tranche $t-1$. Supposant que la structure (la connectivité) des *intra_slices* est figée, l'apprentissage de la structure du réseau Bayésien dynamique se réduit à la sélection des (features) [2].

Si le système est observé d'une façon complète, on peut appliquer les algorithmes standards de la sélection des (features), comme les algorithmes *forward or backwards stepwise selection*, et les algorithmes de *leaps and bounds algorithm*, *Hierarchical priors*, qui peuvent être utilisés à l'intérieur des algorithmes de *MCMC*. Sinon, on utilise souvent l'algorithme SEM adapté aux réseaux Bayésiens dynamiques.

II.5 CONCLUSION

A travers ce chapitre, nous avons étudié les différentes méthodes et algorithmes d'apprentissage de structure et des paramètres des réseaux Bayésiens standard et en particulier les réseaux Bayésiens dynamiques dans les deux cas. Le cas des bases de données complètes et des bases de données incomplètes.

Le prochain chapitre est consacré à l'étude de l'utilisation des réseaux Bayésiens comme modèle d'extraction, de représentation et d'exploitation des connaissances.

CHAPITRE III : LES RESEAUX BAYESIENS POUR L'EXTRACTION, LA REPRESENTATION ET L'EXPLOITATION DE CONNAISSANCES

III.1 INTRODUCTION

L'information et la connaissance sont devenues des atouts déterminants de compétitivité pour les entreprises. Considérer les actifs immatériels comme des facteurs de compétitivité est une démarche nouvelle dans l'évolution de la pensée stratégique. Elle réinterroge en profondeur les principes de base de la stratégie " traditionnelle " issue de l'héritage de la stratégie militaire.

La gestion des connaissances figure actuellement sur le devant de la scène et des initiatives de Knowledge Management (KM) naissent tous les jours dans les entreprises. Objet d'étude et de modélisation depuis une dizaine d'année, les pratiques de KM existent cependant depuis plus longtemps.

Ce chapitre a pour but la présentation et l'étude des réseaux Bayésiens comme étant un outil d'extraction, de représentation et d'exploitation de connaissances. Pour ce faire nous présentons à travers ce chapitre en premier lieu, les généralités et les notons de base de la discipline de gestion de connaissances (Knowledge Management, KM), le processus d'extraction de connaissance (Knowledge Discovery, KDD) et la fouille de données (Data Mining, DM). En deuxième lieu, nous étudions la façon dans laquelle les réseaux Bayésiens sont utilisés en Data Mining. Et en dernier lieu, nous proposons une nouvelle manière d'exploitation des RBs en extraction et exploitation des connaissances.

III.2 GESTION DES CONNAISSANCES

Selon *PRAX* dans [78], le « knowledge management » est « un processus de création, d'enrichissement, de capitalisation et de diffusion des savoirs qui implique tous les acteurs de l'organisation, en tant que consommateurs et producteurs ». L'idée derrière le KM est d'arriver à capitaliser les connaissances

individuelles, ce qui n'est déjà pas une mince tâche, mais également de faire en sorte que la connaissance collective soit supérieure à la somme de ces performances et connaissances individuelles, d'où l'idée d'intelligence collective.

III.2.1 Epistémologie de la connaissance

Le concept de connaissance est une notion qui reste floue, ou qui du moins, n'a pas qu'une seule définition ou acception. De nombreuses disciplines se sont attaquées à sa formalisation, telles que la philosophie, l'économie-gestion, la sociologie ou l'informatique. Nous nous concentrerons sur les points de vue apportés dans le domaine de la gestion (management) et de l'informatique.

Selon [79] « La connaissance est un savoir incarné dans une personne physique. Autrement dit quelque chose qui est su par quelqu'un est une connaissance pour ce quelqu'un. La connaissance renvoie toujours à un possesseur humain à même de mettre en oeuvre, elle est à la base des compétences de tout individu ».

Il existe plusieurs manières de classifier la notion de connaissance [78]. Nous nous concentrerons toutefois sur la classification en connaissance tacite et explicite car c'est cette dernière qui est la plus usitée dans le domaine du « knowledge management ».

III.2.2 La connaissance tacite et explicite

POLANYI a introduit la notion de connaissance tacite [78], c'est-à-dire une connaissance implicite et inarticulée, qui s'inscrit et s'acquiert dans une expérience quotidienne. C'est à partir de son travail qu'a été dérivée la classification de la connaissance en connaissance explicite et connaissance tacite.

Toutefois, *POLANYI* ne fait pas clairement de distinguer entre ces deux notions car selon lui, une part de tacite existe en toute connaissance et donc une connaissance ne peut être complètement explicite. Pour Polanyi, « nous savons plus que nous pouvons exprimer ».

Dans la même lignée, certains chercheurs refusent de clairement scinder la connaissance en tacite/explicite, et identifient une part plus ou moins importante des deux dans chaque connaissance.

Pour ceux qui opèrent une distinction claire entre les deux formes de connaissance, la connaissance explicite est une connaissance codifiée sous une forme formelle telle qu'une procédure, une règle ou un manuel. La connaissance tacite ou implicite n'est, quant à elle, pas directement formalisable et se retrouve ancrée dans certaines actions et certains contextes. Elle existe dans les cerveaux des gens et se manifeste au travers de leurs actions. Le transfert d'un tel type de connaissance n'est donc pas aisé [78].

III.3 PROCESSUS D'EXTRACTION DE CONNAISSANCES

L'extraction de connaissances à partir de données désigne un ensemble de méthodes issues des statistiques, de l'intelligence artificielle et de la reconnaissance de formes dont le but est de valider des éléments de connaissances à partir du traitement des données. Ces méthodes sont appliquées sur les données suivant un processus qui se décompose classiquement en quatre étapes [80] :

- (1) Acquisition et stockage des données ;
- (2) Préparation et transformation des données ;
- (3) Fouille de données (Data Mining) ;
- (4) Interprétation et validation par l'analyste.

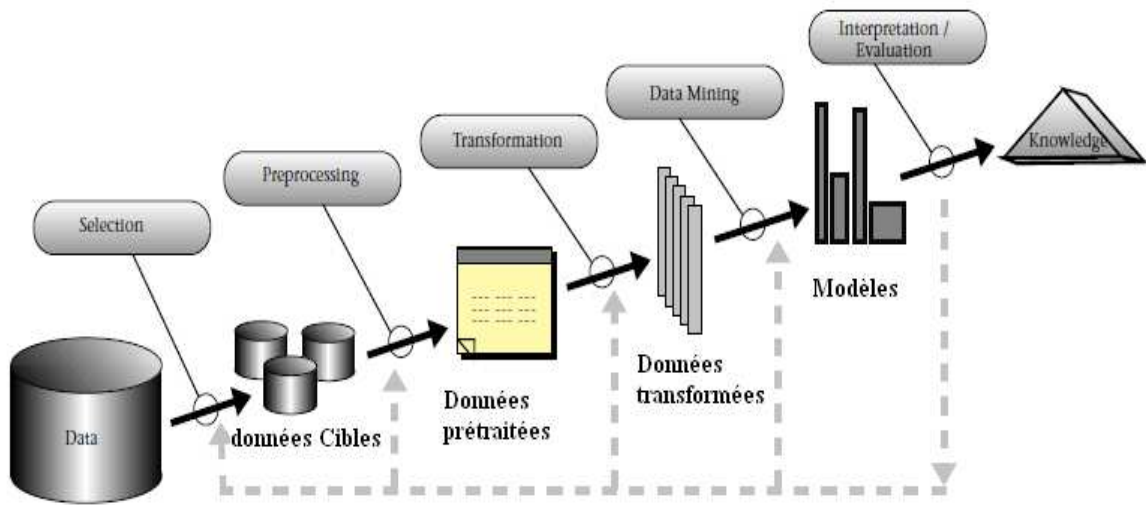


Figure III.1 : Les étapes de processus KDD.

Les techniques d'apprentissage mises en œuvre ont pour but l'induction d'un modèle des données à partir de leur observation. Ce modèle est toujours constitué dans un but particulier, comme par exemple la synthèse d'une grande quantité de données, la décomposition d'un ensemble d'individus en sous-groupes homogènes ou encore la production de connaissances utiles pour un système de résolution de problèmes.

La construction d'un modèle de la réalité par induction à partir d'un ensemble de faits observés est utilisée pour modéliser des phénomènes qui ne se prêtent pas à une modélisation mathématique ou pour lesquels cette modélisation est inconnue. C'est le cas de nombreux phénomènes physiques, mais aussi de tous les phénomènes qui mettent en jeu l'expérience sociale, psychologique ou l'expertise d'un acteur humain. Dans ces situations, la relation « est un modèle de » entre un modèle et la partie de la réalité qu'il représente ne peut être définie que relativement à un observateur donné, et est donc intrinsèquement ternaire [80].

L'extraction de connaissances est donc anthropocentrée et l'analyste humain est partie prenante du processus car il est le seul à même de juger de la qualité du modèle constitué à partir des données. Dans ce cadre, la tâche d'apprentissage peut être vue comme une tâche de formulation d'hypothèses visant à expliquer les faits observés. Ces hypothèses sont proposées à l'analyste humain pour

validation qui les interprète à la lumière de son propre modèle de la partie de réalité étudiée. Lorsqu'une partie du modèle construit à partir des données est jugé pertinente par l'analyste au regard de la tâche d'apprentissage, l'hypothèse correspondante est validée et acquiert le statut de connaissance extraite des données. L'apprentissage inductif peut donc être considéré comme un problème d'acquisition de connaissances [80]. Il peut alors être exprimé comme un processus de modification itérative d'une représentation interne des connaissances, guidé par l'analyste, et réalisé par l'application d'opérateurs, suivant une certaine stratégie de recherche, de façon à améliorer une fonction d'évaluation de la qualité de la représentation.

Comme mentionné ci-dessus le processus de KDD passe par plusieurs étapes. Nous présenterons dans ce qui suit l'ensemble de ces méthodes.

III.3.1 Définition et formulation du problème

Cette première phase est celle où l'on expose le problème et où l'on fait les objectifs, les résultats attendus ainsi que les moyens de mesurer le succès de l'étape de data mining.

Dans cette phase introductive, il est intéressant de recueillir les intuitions et les connaissances des experts afin d'orienter le processus de découverte ou tout simplement pour identifier les variables les plus pertinentes susceptibles d'expliquer les phénomènes analysés. Cette phase se compose de trois étapes essentielles:

- Formulation du problème : consiste à définir le problème et le formuler sous une forme qui peut être traitée par les techniques et les outils de modélisation ;
- Typologie du problème : savoir s'il s'agit d'un problème de structuration (lorsqu'on cherche à classifier des objets en sous-ensembles homogènes) ou alors d'un problème d'affectation (lorsqu'on connaît l'appartenance d'un élément à une ou plusieurs classes) ;
- Les résultats attendus : avant de se lancer dans un processus de data mining, il faut savoir ce que l'on attend et ce que l'on compte faire de la connaissance extraite avec la prise en considération de l'identification

des utilisateurs, des résultats du processus d'extraction des connaissances.

III.3.2 Collection et sélection des données

Il s'agit dans cette phase de localiser un ensemble de données cibles. Les techniques de data mining sont consommatrices de gros volumes de données. Celles-ci sont collectées à partir de différentes sources : documents papiers, supports électroniques, fichiers internes ou externes, bases de données de type data warehouses ou data marts. La recherche d'une sélection optimale de données est le point central d'un processus de KDD. Cette sélection nécessite souvent l'aide d'experts du domaine pour indiquer les variables qui ont une influence sur le problème à résoudre.

III.3.3 Nettoyage des données

Il s'agit de rassembler les données fournies par la phase précédente afin de les rendre plus fiable. Une mauvaise qualité des données peut produire des résultats qui sont peu pertinentes, ce qui impose généralement cette phase de nettoyage de données. Celle-ci a pour objectif de corriger ou de contourner les inexactitudes ou les erreurs qui se sont glissées dans les données. Ces erreurs peuvent être de plusieurs natures :

- ✓ les données ayant des valeurs aberrantes, anormales par rapport leur type ;
- ✓ les erreurs de saisi ;
- ✓ les données ayant des valeurs nulles.

L'existence des valeurs aberrantes ou nulles, ou alors l'absence de certaines valeurs ne convient pas toujours aux outils de data Mining ; il faut donc gérer de manière spécifique ces valeurs selon plusieurs méthodes, parmi lesquelles nous citons :

1. exclure les enregistrements incomplets ; mais l'utilisation de cette méthode risque de réduire la base d'apprentissage.
2. remplacer les champs manquants par la moyenne de tous les champs.

3. remplacer les données manquantes par des valeurs qui sont soit choisie par l'utilisateur (remplacées par la moyenne ou la médiane, par exemple).

III.3.4 Réduction et projection des données

Les données fournies par la phase précédente sont, à ce niveau, pertinentes et fiables. Il faut les transformer pour faciliter leur exploitation par les outils de modélisation. Ces transformations peuvent être de deux types, selon qu'elles modifient une ou plusieurs variables.

III.3.4.1 Transformation mono-variable :

La normalisation sert à aboutir à des ordres de grandeur comparables pour chaque variable. Il existe plusieurs techniques de normalisation, nous citons parmi elles les deux suivantes :

- la première consiste à soustraire de chaque valeur la valeur moyenne sur l'échantillon et à diviser cette différence par l'écart type calculé sur l'échantillon.
- la seconde consiste à effectuer une transformation logarithmique de la variable afin de limiter l'impact de certaines valeurs exceptionnelles.
- La transformation des dates en durées.
- La transformation des données géographiques en coordonnées : cette approche consiste à adjoindre les coordonnées de longitude et de latitude, de façon à intégrer les contraintes de proximité dans le raisonnement.

III.3.4.2 Transformation multi-variable

Lorsque les données brutes sont insuffisantes pour apporter un pouvoir prédictif, on procède par la combinaison de plusieurs variables élémentaires. Parmi les types de transformation multivariable on trouve : les ratios, les fréquences, les tendances, les combinaisons linéaires et non linéaires.

III.3.5 Recherche du modèle

L'étape de recherche du modèle se qu'on appellera aussi phase de modélisation, consiste à extraire la connaissance utile d'un ensemble de données brutes et à la présenter sous une forme synthétique et compréhensible.

Il s'agit de la phase le plus souvent décrite sous le terme « Data Mining » et qui repose, pour partie, sur une recherche exploratoire, c'est-à-dire dépourvue de préjugés concernant les relations entre les données.

III.3.6 Evaluation du résultat

L'évaluation du résultat permet d'estimer la qualité du modèle, afin de déterminer sa capacité ainsi que sa pertinence. Cette évaluation prend généralement une forme qualitative lors de la visualisation de la connaissance extraite sous forme graphique ou textuelle, qui contribue énormément à améliorer la compréhension et l'appréciation des résultats et facilite le partage de la connaissance ; et quantitative lors de la construction d'une base servant pour les tests pouvant ainsi vérifier si le modèle est capable de classer des données qu'il n'a jamais rencontrées auparavant.

III.3.7 Intégration de la connaissance

La connaissance ne sert à rien tant qu'elle n'est pas convertie en décision puis en action. Cette phase d'intégration de la connaissance consiste à implanter le modèle ou ses résultats dans les systèmes informatiques ou alors les processus de l'entreprise. Elle est donc essentielle, puisqu'il s'agit de la transition du domaine des études au domaine opérationnel.

III.4 DATA MINING

La fouille de données est définie comme étant l'extraction non triviale de connaissances implicites, inconnues au préalable, intéressantes, utiles à partir d'informations stockées dans des bases de données. Le processus de la fouille de données passe par les étapes suivantes:

- ♦ *Identifier le problème.*
- ♦ *Préparer les données.*
- ♦ *Explorer des modèles.*
- ♦ *Utiliser le modèle.*
- ♦ *Suivre le modèle.*




Figure III.2 : Positionnement de la discipline du Data Mining.

Le Data Mining se situe à l'intersection des statistiques, de l'apprentissage automatique, et de bases de données.

III.4.1 Classification des techniques de la Fouille de données

Depuis que la fouille de données a commencé de poser beaucoup de problèmes de recherche importants, l'application directe des méthodes développées dans le cadre de l'intelligence artificielle (IA), les statistiques, et des systèmes de base de données ne peuvent pas résoudre ces problèmes, c'est devenu nécessaire de faire des études dédiées à inventer de nouvelles méthodes de la fouille de données ou à développer des méthodes intégrées pour faire une extraction efficace et effective de connaissances, dans ce sens la fouille de données elle-même a formé un nouveau domaine de recherche indépendant.

IL y a eu un avancement rapide dans le développement de la fouille de données, plusieurs techniques et systèmes de fouille de données ont été développés, et plusieurs schémas de classification peuvent être utilisés pour catégoriser les méthodes et les systèmes de fouille de données, basé sur les types de bases de données étudiées, les types de connaissances à découvrir, et les types des techniques utilisées [81] :

- ☒ Types de bases de données étudiées : Un système d'extraction de connaissances peut être classifié selon le type de base de données dont il extrait des connaissances. Base de données relationnelle,

transactionnelle, temporelle, spatiale, multimédia, orienté objets, déductive, hétérogènes... etc.

- ☒ Type de connaissances à extraire : Plusieurs types de connaissances peuvent être découverts par un système d'extraction de connaissances, règles d'association, règles de caractérisation, règles de classification, règles discriminante, clustering, analyse d'évolution et de déviation. De plus, les systèmes d'extraction de connaissances peuvent être classifiés suivant le niveau d'abstraction de connaissances découvertes, connaissances de niveau primitif, connaissances de niveau général, et connaissances multi-niveaux.

- ☒ Technique utilisées : Les systèmes de fouille de données peuvent être classifiés selon les techniques qu'elles les utilisent, par exemple selon "driven method into autonomous knowledge miner", "data-driven miner", "query-driven miner", and interactive data miner. Ils peuvent être catégorisés, aussi selon les approches qu'ils utilisent: fouille de données basée sur la généralisation, fouille de données basée sur des modèles, statistique ou théorie mathématiques, etc.

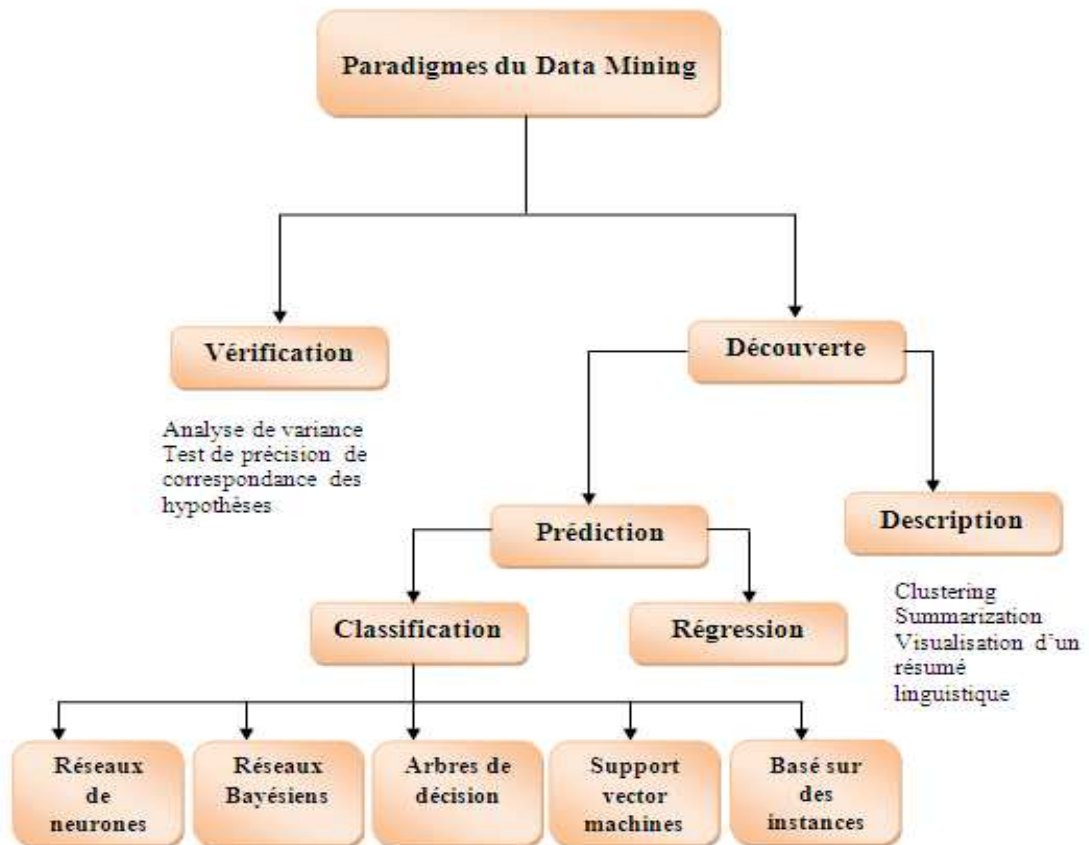


Figure III.3: Taxonomie des méthodes du Data Mining [82].

Parmi les différents schémas de classification, nous allons détailler la classification basée sur le type de connaissances à découvrir, elle présente une image claire des techniques et des conditions de la fouille de données.

Plusieurs méthodes pour extraire différents types de connaissances, règles d'association, règles de caractérisation, classification, groupement (clustering), etc. Pour extraire un type particulier de connaissances, différentes approches sont utilisées, approches de l'IA, approches statistiques, approches issue des bases de données larges.

III.4.1.1 Classification de données

La classification de données est le processus qui trouve les propriétés communes dans un ensemble d'objets dans une base de données, et les classe dans différentes classes. Le processus passe par deux étapes: Premièrement, construire un modèle précis pour chaque classe à partir d'une base de données échantillon (training dataset) ; Ensuite, chaque description d'une

classe est utilisée pour classifier les futures données, ou pour développer une meilleure description (règles de classification) pour chaque classe.

Les applications de la classification de données comprennent:

- ✓ Marketing: comprendre les critères prépondérants dans l'achat d'un produit et segmentation automatique des clients pour le marketing direct.
- ✓ Maintenance: aide et guidage d'un client suite à défauts constatés.
- ✓ Assurance: analyse de risqué.
- ✓ Isolation de populations à risques, médecine.

La classification de données est faite par différents techniques et algorithmes:

- ◆ k-NN.
- ◆ Arbres de décision.
- ◆ Réseaux baysiens.
- ◆ Réseaux de neurones.
- ◆ SVM.
- ◆

III.4.1.2 Groupement (Clustering)

Le processus de grouper des objets physiques ou abstraits dans des classes d'objets similaires est appelé clustering, ou bien une classification non supervisé par ce qu'on ne connaît pas les classes à priori, elles sont à découvrir automatiquement, il est parfois possible d'en fixer le nombre.

Le groupement est une Méthode permettant de découvrir les groupes (clusters) d'individus similaires, dont l'objectif est:

- ◆ Le passage à l'échelle: supporter des bases de données de grande taille.
- ◆ Robustesse: indépendance à l'ordre de parcours de la base et découvrir des groupes de toute forme.
- ◆ Insensibilité aux points isolés (outliers) et insensibilité au bruit.
- ◆ Lisibilité: Donner un sens aux résultats et interpréter les classes.

La notion de similarité, l'appartenance à un groupe et de distance varient selon le domaine.

III.4.1.3 Règles d'association

L'extraction des règles d'associations, la tâche de trouver des corrélations entre les items a reçu une attention considérable, particulièrement depuis la publication de AIS et l'algorithme Apriori, (Agrawal et al. 1993; Agrawal and Srikant 1994) [83]. L'analyse d'extraction de règles d'associations est devenue un champ de recherche mature, les principes fondamentaux de l'extraction de règles associatives sont maintenant bien établis.

Le processus d'extraction de règles d'association passe par deux étapes :

- 1- l'identification des ensembles d'items (*itemsets*) dans l'ensemble de données.
- 2- La dérivation consécutive des règles d'inférence à partir des *itemsets*.

La majorité des travaux de recherches ont été focalisés sur la découverte efficace des *itemsets*, par ce que son niveau de complexité est beaucoup plus grand que celui de la dérivation des règles d'inférence. Pour E items distincts dans un espace de recherche, on a 2^E combinaisons possibles d'*itemsets*, étant donné qu'on travaille sur des bases de données larges, E par conséquent est très grand, et les techniques naïves d'exploration des *itemsets* ne sont pas souvent traitables [84].

Les recherches pertinentes peuvent être organisées en quatre groupes:

- ✓ Construction de l'exploration par le développement, et l'incorporation de mesures d'intérêt (MOI)...
- ✓ Réduction I/O, grâce à la progression du matériels et de techniques comme l'échantillonnage intelligent ont permet au large ensemble de données d'être résident dans la mémoire.
- ✓ Création des structures de données utiles.
- ✓ Produire des ensembles d'inférences condensés pour permettre à la totalité de données d'être inférée à partir d'un ensemble réduit d'inférences, réduction de stockage et facilitation de l'interprétation des utilisateurs.

III.4.2 Domaines d'application du Data Mining

Les domaines d'application de la fouille de données augmentent de plus en plus à cause de:

- explosion des données historisées.
- puissance des machines support.
- nombreux datawarehouses.
- OLAP limité.
- nécessité de mieux comprendre.
- rapports sophistiqués, prédictions.
- aide efficace aux managers.

Parmi les domaines les plus réputés, on peut citer:

- ♦ Analyse de risque (Assurance).
- ♦ Marketing.
- ♦ Grande distribution.
- ♦ Médecine, Pharmacie.
- ♦ Analyse financière.
- ♦ Gestion de stocks.
- ♦ Maintenance.
- ♦ Contrôle de qualité.

Nous avons vu dans la partie précédente de ce chapitre des généralités sur le KM et processus de KDD et le Data Mining, la partie suivante est consacrée au rôle des réseaux Bayésiens dans le processus du KDD et la gestion de connaissances en général.

III.5 ETAT DE L'ART SUR LES RESEAUX BAYESIENS POUR LA GESTION DE CONNAISSANCES

III.5.1 Règle d'association et réseaux Bayésiens

En cas d'existence des données sur le domaine à modéliser, plusieurs travaux [85], [5], [86], [87], [88] exploitent les RBs pour la présentation des règles d'association extraites en utilisant les algorithmes connus dans ce contexte comme le *A Priori*, et pour faciliter l'analyse et la découverte de règles d'association pertinentes. Le mécanisme d'inférence des réseaux Bayésiens a

permis aussi d'évaluer et de valider les règles extraites en calculant leurs taux de cofinance.

L'approche envisagée par les auteurs de [87], [88] repose sur l'estimation de la fréquence des itemsets à partir du RB et la comparaison de cette estimation avec la fréquence constatée sur le jeu de données. Les itemsets dont la fréquence estimée diverge fortement de la fréquence constatée sont considérés comme intéressants.

FAURE et al [85], [5] propose que l'expert explicite les connaissances qui vont lui être utiles pour le processus de fouille de données en utilisant le formalisme des réseaux bayésiens. Ce modèle de connaissance a pour but de faciliter la découverte de motifs pertinents, c'est-à-dire ceux qui ne sont pas pris en compte par le modèle de connaissance, ou ceux qui le contredisent. Plus précisément, ce modèle permet à l'utilisateur de définir -a priori- des dépendances entre des attributs qu'il ne souhaite pas retrouver dans les résultats de l'extraction. Pour cela, ils utilisent les capacités d'inférence du réseau bayésien pour mesurer l'intérêt des règles extraites, en comparant les dépendances déduites du réseau bayésien (construit à partir des connaissances du domaine) et les règles d'association (extraites à partir des données réelles). Une divergence forte indique un motif potentiellement intéressant ; inversement, une convergence entre les données réelles et l'estimation effectuée à partir du réseau Bayésien indique des motifs déjà connus.

III.5.2 Réseaux Bayésien pour la classification (Apprentissage supervisé)

Dans les tâches de classification, une variable précise correspond à la classe qu'il faut « reconnaître » à partir des autres variables (les caractéristiques). Plusieurs méthodes d'apprentissage vont donc proposer des structures où ce nœud classe aura un rôle central [6].

III.5.2.1 Bayes naïve

Pour une problématique de classification, la structure de Bayes naïve a prouvé expérimentalement qu'elle était capable de donner de bons résultats. L'hypothèse de base de ce modèle est de supposer que toutes les observations soient indépendantes les unes des autres conditionnellement à la variable classe,

ce qui revient à une simplification de la loi jointe. Cela mène à la structure type de la Figure III.4. Cette structure, pourtant très simple, donne de très bons résultats dans de nombreuses applications [41].




Figure III.4 : Réseau Bayésien naïf.

III.5.2.2 Bayes naïve augmentée

L'hypothèse simplificatrice utilisée dans le classifieur de Bayes naïf est largement non vérifiée en pratique. Il existe différentes techniques pour assouplir cette hypothèse.

Elles consistent toutes en l'ajout de dépendances conditionnelles entre les observations. Nous obtenons alors une structure dite de Bayes naïve augmentée. Le classifieur de Bayes naïf ne nécessite pas l'hypothèse d'indépendance des attributs pour être optimal pour une fonction de coût en 0-1 et donc que les classifieurs de Bayes naïfs augmentés sont également optimaux dans ce cas.

L'algorithme KDB (pour k-limited Dependence Bayesian classifiers) pour apprendre des classifieurs de Bayes limités dans le fait qu'un nombre maximum de parents par nœud doit être fixé. Cette méthode est basée sur des calculs d'information mutuelle [41].




Figure III.5 : Réseau Bayésien naïf augmenté (par un arbre).

III.5.2.3 Bayes naïve augmentée par un arbre

Il est possible de construire une sous-structure optimale sur les observations en adaptant la méthode de recherche de l'arbre de poids maximal. Pour cela, la fonction de score doit être modifiée de manière à obtenir une fonction de score conditionnellement à la variable classe. Puis en reliant le nœud représentant la classe à tous les sommets de cette structure, nous obtenons la structure de Bayes naïve augmentée par un arbre (TANB pour Tree Augmented Naive Bayes. Cette technique permet d'améliorer les résultats obtenus avec une structure de Bayes naïve classique, mais reste exclusivement réservée aux problématiques de classification [41].

III.5.2.5 Classifieur naïf augmenté par une forêt : FAN Forêt optimale

En ajoutant un critère d'arrêt prématuré en fonction d'une valeur minimum d'augmentation du score dans les algorithmes de recherche de l'arbre couvrant de poids maximal, il est possible de construire une forêt. Ce critère peut par exemple être un pourcentage du score courant jugé significatif, ou encore simplement de choisir seulement des valeurs positives car le score *BIC* d'une arête peut être négatif si l'augmentation de la vraisemblance est plus faible que le terme de pénalité. Le graphe ne sera pas connexe et aura donc une structure de forêt [41].

De même, en utilisant l'algorithme pour trouver une forêt optimale sur l'ensemble des observations et en adaptant la matrice de poids comme dans la section III.5.2.3, nous obtiendrons l'algorithme FAN qui sélectionne le classifieur de Bayes naïf augmenté par une forêt optimale selon le score et le critère qui auront été choisis.

III.5.3 Réseaux Bayésien pour le Clustering (Apprentissage non supervisé)

L'apprentissage des classificateurs de RB des données est généralement effectué d'une façon supervisé, signifiant le jeu de données précédemment classifiés par un expert est employés pour produire le DAG du RB et ses tables de probabilité conditionnelle. Dans la pratique, ceci peut être visualisé en tant qu'ayant une étiquette de classe assignée à chaque exemple (ligne) de l'ensemble de données. Malheureusement, dans beaucoup d'applications industrielles d'apprentissage automatique et du Data Mining, il est difficile d'obtenir des bases

de données larges avec des exemples classifiés. C'est généralement dû au fait qu'un expert humain est nécessaire pour classier manuellement chaque exemple, dont dans beaucoup de cas il peut y avoir des milliers, faisant de cette tâche une tâche longue et consommatrice du temps. A cet effet, il est souhaitable d'avoir une manière alternative de former un classificateur avec les données qui n'ont aucune étiquette de classe assigné à chaque exemple. Cette approche est connue comme étant l'apprentissage ou la classification non supervisée, qui peut être utilisé pour un clustering but. Le but principal du clustering est de trouver les groupements naturels des données.

Bien que les classificateurs des RBs soient devenus un actif axe de recherche dans ces dernières années [89], la plupart des efforts ont été concentrés sur le développement des algorithmes d'apprentissage supervisé. Moins de travail a été fourni dans le cadre de classification non supervisée.

TRUONG PHAM et al [89] présentent une étude détaillée sur les travaux menés dans le contexte de développement des classificateurs de RBs pour la classification non supervisée ou le clustering.

III.5.4 Discussion

Cet état de l'art sur l'utilisation des réseaux Bayésiens dans le cadre du processus KDD montre que Grâce aux capacités de modélisation offertes par les modèles probabilistes dont ils appartiennent les réseaux Bayésiens, ces derniers sont utilisés comme étant un modèle de connaissances que se soit dans le cas de présence ou d'absence des données du domaine à modéliser. En particulier, quand les données sont rares ou leur acquisition revient très chère les RBs peuvent être employés d'une manière similaire au système experts pour modéliser les connaissances a priori sur le domaine et cela en collaboration avec les experts de ce dernier.

Ainsi, en cas de présence des données, les RBs sont utilisés comme un formalisme de présentation de validation et d'interprétation des connaissances extraites souvent sous forme des règles d'association. Les RBs sont aussi exploités dans le cadre de la classification supervisée et non supervisée (clustering) comme une technique du Data mining.

Comme conclusion de cette discussion nous pouvons dire que les RBs sont utilisés comme un outil de représentation d'interprétation, et de validation des connaissances. Ils sont utilisés aussi comme une technique du Data Mining, particulièrement dans la classification supervisée et le clustering mais jamais comme un modèle d'extraction de connaissance à part entière. Ceci est dû à notre avis au fait que le développement d'algorithmes efficaces d'apprentissage des RBs, en particulier l'apprentissage de structure est relativement récent. Dans ce qui suit, nous expliquons comment utiliser les RBs comme un modèle intégré d'extraction de représentation et d'exploitation des connaissances.

III.5.2 Les réseaux Bayésiens un outil intégré pour l'extraction, la représentation et l'exploitation des connaissances

Comme mentionné ci-dessus, plusieurs techniques ont été développées pour extraire des connaissances à partir des données dans le cadre de processus du Data Mining. Ainsi que de nombreux modèles de représentation du Data mining telles que les arbres de décision, les bases de règle et les réseaux de neurones sont disponibles. Pour quoi utilise t-on les réseaux Bayésiens en extraction et représentation des connaissances, qu'est qu'ils offrent de plus ? La réponse de cette question peut être résumée en quatre points importants :

1. Les réseaux Bayésiens peuvent facilement pallier au problème des données incomplètes. Par exemple, considérant un problème de classification ou de régression où deux des variables explicatives ou d'entrée sont fortement corrélés. Cette corrélation n'est pas un problème pour des techniques d'apprentissage supervisé standard, si toutes les entrées sont mesurées dans tous les cas. cependant, quand on n'observe pas un des entrées, beaucoup de modèles produiront une prédiction imprécise, parce qu'ils n'encodent pas la corrélation entre les variables d'entrée. Les réseaux Bayésiens offrent une manière naturelle pour encoder de telles dépendances.
2. Les réseaux Bayésiens nous permettent de faire l'apprentissage des relations causales. L'apprentissage des relations causales est important pour au moins deux raisons. Le processus est utile quand nous essayons de comprendre un domaine de problème, par exemple, pendant l'analyse

exploratoire des données. En outre, la connaissance des relations causales nous permet de faire des prédictions en présence des interventions. Par exemple, un analyste de vente voudrait savoir s'il est intéressant d'augmenter l'exposition d'une publicité particulière afin d'augmenter les ventes d'un produit. Pour répondre à cette question, l'analyste peut déterminer si la publicité est une cause d'augmentation de la vente du produit, et à quel degré. L'utilisation des réseaux Bayésiens aide à répondre à de telles questions même lorsqu'aucune expérience au sujet des effets de l'exposition n'est disponible.

3. Les réseaux Bayésiens en conjonction avec les techniques statistiques Bayésiennes facilitent la combinaison des connaissances sur le domaine et les données. Les connaissances à priori du domaine sont très importantes, particulièrement quand les données sont rares ou chères. Le fait que quelques systèmes commerciaux (c.-à-d., systèmes experts) peuvent être établis de la connaissance antérieure seulement est une preuve de la puissance de la connaissance antérieure. Les réseaux Bayésiens ont une sémantique causale qui rend le codage de la connaissance antérieure causale particulièrement facile et simple. En outre, les réseaux Bayésiens encodent la force de relations causales avec des probabilités. En conséquence, les connaissances antérieures et les données peuvent être combinées par des techniques bien-étudiées des statistiques Bayésiennes.
4. Les méthodes Bayésiennes en conjonction avec les réseaux Bayésiens offrent une approche efficace et solide pour éviter la sur-ajustasse de pertinence des données. De plus, l'utilisation des probabilités permet de prendre en compte l'incertain, en quantifiant les dépendances entre les variables. Ces deux propriétés ont ainsi été à l'origine des premières dénominations des réseaux Bayésiens, "systèmes experts probabilistes", où le graphe était comparé à l'ensemble de règles d'un système expert classique, et les probabilités conditionnelles présentées comme une quantification de l'incertitude sur ces règles.

Toutes ces caractéristiques et ces avantages font des RBs un outil de modélisation très intéressant. Grâce aux méthodes d'apprentissage des RBs, en

particulier, celles d'apprentissage de structure, les RBs sont devenus un outil de découverte de connaissances et pas seulement de représentation celles-ci.

Les RBs peuvent être utilisés comme un outil intégré d'extraction, de représentation et d'exploitation des connaissances comme illustré sur la Figure III.6. Une fois que les données cibles soient choisies. Nous précéderons comme suit pour le reste des phases du processus de KDD :

III.5.2.1 Préparation des données

Dans cette phase les données seront préparées afin qu'elles puissent être utilisées initialement par les algorithmes d'apprentissage de structure des RBs et ensuite par les algorithmes d'apprentissage des paramètres. Le problème principal dans cette phase est la discrétisation des données continue. Malgré que les RB continus peuvent manipuler les variables continues, et les RBs hybrides peuvent contenir des variables continues et discrètes, mais nous n'avons pas encore des algorithmes d'apprentissages de ce genre de RB. Par conséquent il faut choisir une méthode de discrétisation adéquate au problème traité.

Les données incomplètes ne posent pas un problème. Les résultats obtenus par les algorithmes d'apprentissage des RBs à partir des données incomplètes sont généralement satisfaisant.

III.5.2.2 Recherche du modèle

Cette phase consiste à choisir et appliquer une des techniques du Data Mining pour extraire les connaissances. Dans notre cas, nous allons découvrir les connaissances en utilisant l'apprentissage des RBs. Pour ce faire, en premier lieu, il faut définir l'ensemble des variables représentant le domaine à modéliser, parfois nous ne pouvons pas définir d'une façon exhaustive cet ensemble. Ce problème est traité dans le cadre d'apprentissage des RBs avec des variables latentes ou cachées.

En deuxième lieu, il faut choisir le type de RB à employer, réseau Bayésien standard, orienté objet ou temporel.

En dernier lieu, il faut choisir l'algorithme d'apprentissage à utiliser. Ce choix est effectué en prenant en considération le nombre de variables et la taille de base de données.

III.5.2.3 Interprétation et évaluation du résultat

Les connaissances extraites sont directement représentées par le RB obtenu par apprentissage à partir des données. La partie graphique du réseau fournit un outil clair et intuitif d'interprétation des connaissances. Les tables de probabilité conditionnelles permettent d'évaluer celles-ci.

III.5.2.4 Exploitation du résultat

La modélisation du problème par un réseau Bayésien, puis l'utilisation d'algorithmes d'inférence permet de raisonner ou de faire le diagnostic à partir d'informations en particulier dans le cas des informations incomplètes. Quelle est, par exemple, la probabilité qu'un patient soit atteint de telle ou telle maladie, sachant que certains symptômes ont été observés, mais que d'autres informations ne sont pas connues ? Quelle est la configuration des variables représentant l'état de chacun des composants d'un système, sachant que tel ou tel comportement a été remarqué ?

En outre les réseaux Bayésiens modélisent efficacement la loi de probabilité jointe de l'ensemble des variables. Par conséquent ils sont un formalisme privilégié pour l'utilisation de méthodes d'échantillonnage stochastique. Celles-ci permettent de générer à volonté des données simulées. Les réseaux bayésiens sont alors des outils de simulation qui permettent à l'expert d'observer le comportement de son système dans des contextes qu'il n'est pas forcément capable de tester lui même.

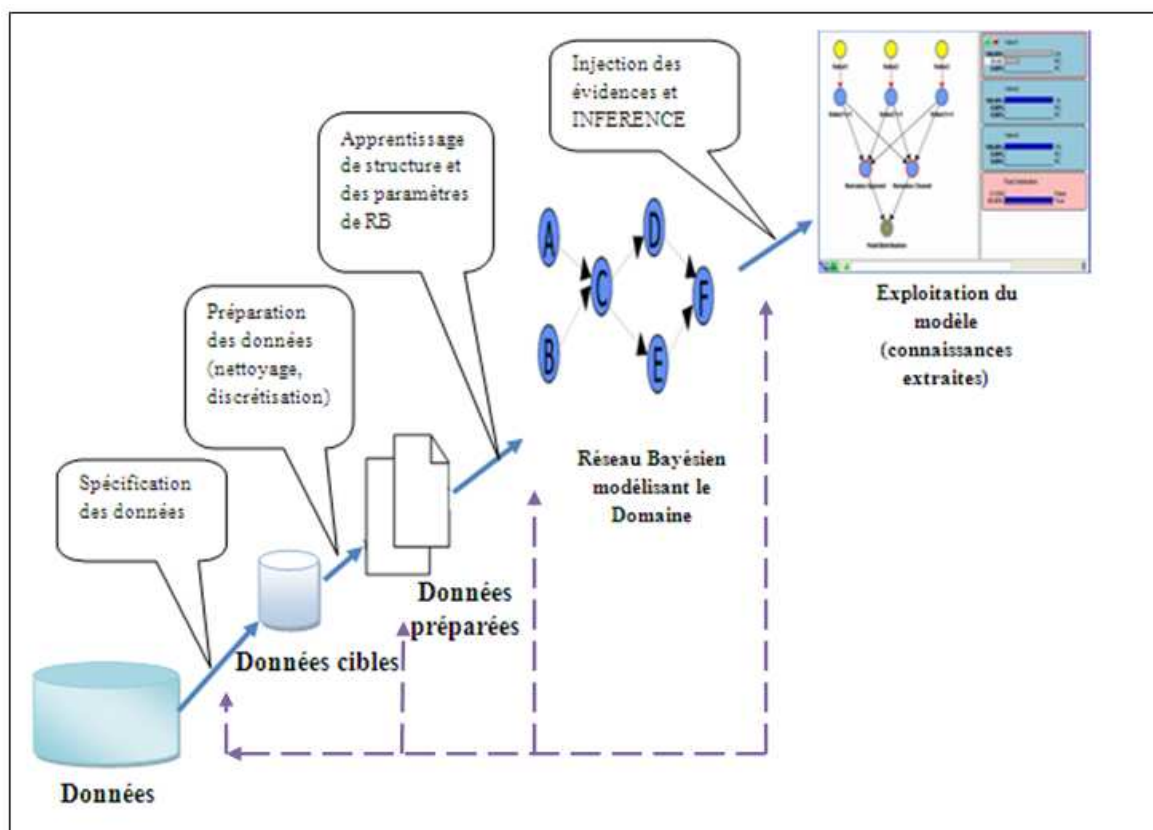


Figure III.6 : Les RBs pour l'extraction et l'exploitation des connaissances.

Comme nous avons mentionné ci-dessus, la sémantique causale d'un réseau Bayésien fournit les moyens par lesquels nous pouvons apprendre des relations causales sur un domaine qui est un aspect très intéressant. Même si le graphe complètement orienté obtenu à partir d'un algorithme d'apprentissage de structure n'est pas nécessairement causal mais ça donne une représentation des indépendances conditionnelles entre les variables du domaine.

La causalité est un champ d'étude très large, qui a motivé de nombreux travaux, de la Biologie à l'Informatique en passant par la Philosophie [5].

Un réseau Bayésien causal est un réseau Bayésien pour lequel tous les arcs représentent des relations de causalité. Leurs premiers avantages sont leur lisibilité et leur facilité d'interprétation pour les utilisateurs. Un autre avantage des réseaux Bayésiens causaux réside dans la possibilité de pouvoir estimer l'influence sur n'importe quelle variable du graphe d'une intervention externe sur une de ces variables. Cette notion importante d'intervention (ou manipulation) a amené PEARL dans [5] à distinguer le concept de mesure d'une variable ($X_A = a$)

à celle de manipulation de la variable X_A grâce à l'opérateur do-calculus. $do(X_A = a)$ signifie ainsi qu'une intervention externe a forcé la variable X_A à prendre la valeur a . Le principe de probabilité conditionnelle $\mathbb{P}(X_A | X_B)$, symétrique grâce au théorème de Bayes, ne permet pas de représenter les relations, asymétriques, de causalité. L'usage de cet opérateur répond à ce problème. Si X_A est la cause de X_B , nous obtenons :

$$\mathbb{P}(X_B = b | do(X_A = a)) = \mathbb{P}(X_B = b | X_A = a) \quad (\text{III. 1})$$

$$\mathbb{P}(X_A = a | do(X_B = b)) = \mathbb{P}(X_A = a) \quad (\text{III. 2})$$

Ces considérations ont débouché sur des travaux très intéressants sur l'idée d'identifiabilité, c'est-à-dire dans quelles conditions il est possible de calculer $\mathbb{P}(X_i | do(X_j))$, X_i et X_j étant n'importe quel nœud du graphe, et sur l'inférence causale, i.e. fournir des algorithmes capables de réaliser efficacement ce calcul lorsqu'il est possible [5].

L'apprentissage et l'inférence des RBs complètement causaux sort du contexte de ce mémoire, néanmoins il faut mentionner que ce type des RBs est très intéressant dans le cadre du data Mining [90] et le processus de KDD en général.

III.6 CONCLUSION

Nous avons vu dans ce chapitre les notions de base de la gestion des connaissances et le processus d'extraction des connaissances ainsi que le rôle des réseaux Bayésiens dans ce processus. Ceci permet de nous rendre compte que les réseaux Bayésiens sont un formalisme unificateur pour différentes modélisations ayant été développées dans la littérature pour des problématiques aussi vastes que la classification, l'extraction d'information, ou encore simplement pour la modélisation.

Parmi les avantages proposés par les réseaux Bayésiens, nous avons mentionné ci-dessus leur capacité, en conjugaison avec les méthodes statistiques dites Bayésiennes (c'est-à-dire prenant en compte un a priori sur la distribution de probabilités modélisée) à conjuguer la connaissance extraite de la base de connaissance avec une connaissance préalable du domaine. Cette

connaissance, subjective, est fréquemment le produit de l'avis d'un expert humain sur le sujet. Cette possibilité est particulièrement intéressante quand le processus de fouille de données ne peut systématiquement retourner l'ensemble des valeurs prises par les différentes composantes du modèle (à cause de capteurs défectueux, par exemple).

Nous vu aussi dans le chapitre précédent, que l'apprentissage des paramètres et de structure des réseaux Bayésiens peut être effectué sur des bases de données incomplètes. Cette propriété est appréciable lorsque l'on sait que dans l'application pratique, l'acquisition de données est non seulement coûteuse en moyens et en temps mais, hélas, débouche souvent sur une base de connaissance de taille réduite.

La partie restante du mémoire sera consacrée à l'étude du domaine d'application qui est la fiabilité des systèmes et les résultats obtenus en utilisant les réseaux Bayésiens comme un modèle intégré d'extraction de représentation et d'exploitation de connaissance pour la modélisation et l'estimation de la fiabilité des systèmes complexes.

CHAPITRE IV : LA FIABILITE DES SYSTEMES

IV.1 INTRODUCTION

Le monde en 21ème siècle est très complexe, socialement économiquement, et technologiquement. Cette complexité est reflétée par les produits et les systèmes qu'on fabrique et on utilise.

Les produits simples tels que les petits appareils électroniques, les petites applications, et les périphériques mécaniques sont destinés à fonctionner sans défaillance. Pour certains produits plus complexes tels que les ordinateurs, les périphériques de communication, les véhicules, peu de défaillances sont tolérés. Et pour certains systèmes très complexes tels que les centrales productrices d'énergies, centrales nucléaires, les systèmes spatiaux, les répercussions de leurs défaillances sont désastreux et terribles et une fiabilité très élevée est requise dans ce cas. Comment peut-on atteindre ce niveau de fiabilité? Il existe plusieurs facteurs affectant la fiabilité d'un système, et plusieurs disciplines sont impliquées, l'ingénierie de modélisation, de matériels, de fabrication, de fonctionnement, et de maintenance.

A travers ce chapitre, nous allons présenter ce qu'est la fiabilité des systèmes, sa définition, ses concepts mathématiques, et un bref historique. Un ensemble des méthodes d'analyse de la fiabilité des systèmes est aussi présentées dans ce chapitre.

IV.2 DEFINITIONS ET CONCEPTS MATHÉMATIQUES

IV.2.1 Définitions

La fiabilité d'un produit ou d'un système signifie dans le langage naturel le bon fonctionnement, la performance, l'absence des pannes et des défaillances, la non fiabilité donne le sens inverse. Plus précisément la fiabilité d'un système et les concepts relatifs à elle sont définis comme suit:

La Fiabilité: la fiabilité d'un produit (système) [91] est la probabilité conditionnelle que le système accomplit sa fonction prévue d'une manière satisfaisante ou sans défaillance avec des limites de performance bien spécifiées pendant une durée déterminée en fonctionnant sous des conditions environnementales et opérationnelles bien définies.

La fiabilité est une probabilité donnée par le rapport du nombre des missions entreprises avec succès sur le nombre total des missions entreprises d'un système [91] :

$$R(t) = \frac{N_S(t)}{N_T(t)} \quad (\text{IV. 1})$$

Où

$N_S(t)$: Nombre des missions entreprises avec succès pendant une durée t .

$N_T(t)$: Nombre total des missions entreprises pendant une durée t .

En réécrivant l'équation (IV.1) on aura :

$$R(t) = \frac{N_T(t) - N_F(t)}{N_T(t)} = 1 - \frac{N_F(t)}{N_T(t)} = 1 - F(t) \quad (\text{IV. 2})$$

Où

$N_F(t)$: Nombre des missions entreprises sans succès pendant une durée t .

$F(t)$: Probabilité de défaillance de la durée t .

Théorie de la fiabilité: consiste à l'utilisation interdisciplinaire de la probabilité, les statistiques, et la modélisation stochastique combinée à la perspicacité d'ingénierie dans la conception, et la compréhension scientifique des mécanismes de panne pour étudier les différents aspects de la fiabilité. Elle inclut plusieurs thèmes, *la modélisation de la fiabilité, l'analyse et l'optimisation de la fiabilité, l'ingénierie de la fiabilité, la science de la fiabilité, la technologie de la fiabilité, et la gestion de la fiabilité* [92].

☒ La modélisation de la fiabilité: consiste à concevoir un modèle pour l'obtention des solutions à un problème de prédiction, d'estimation, et

d'optimisation de performances d'un système non fiable, de l'impacte de la non fiabilité, et les actions à entreprendre pour mitiger cet impacte[92].

- ☒ L'analyse de la fiabilité: elle peut être divisée en deux principales catégories, qualitative et quantitative. En effet dans la première catégorie les différents modes de défaillance et les causes qui contribuent dans la non-fiabilité d'un produit ou d'un système sont analysés. La seconde catégorie utilise des données de défaillance réelles (obtenues à partir d'un programme de test ou d'un champ de fonctionnement) en conjonction avec des modèles mathématiques appropriés pour produire une évaluation quantitative de la fiabilité d'un produit ou d'un système [92].
- ☒ L'ingénierie de la fiabilité: s'intéresse à la modélisation et la construction d'un produit ou d'un système, en prenant en considération la non fiabilité des ses composants et parties. Elle inclut aussi les tests et les programmes pour l'amélioration la fiabilité. Une bonne ingénierie donne des produits plus fiables.
- ☒ La science de la fiabilité: s'intéresse aux propriétés de matériels et aux causes de détérioration qui mènent à la panne des composants. Elle s'intéresse aussi à l'effet de processus de fabrication (moulage, assemblage, ... etc.) sur la fiabilité des composants produits [92].
- ☒ La gestion de la fiabilité: concerne les différents problèmes de gestion, de modélisation et de fabrication et/ou de fonctionnement et de maintenance des systèmes fiables. Ici l'accentuation est de point de vue de busines, de faite que le manque de la fiabilité a des conséquences sur le coût, et dans certains cas sur le bien-être des individus et même sur la sécurité d'une nation [92].

Quelques thèmes dans la liste précédemment cité impliquent d'autres thèmes entre autre : *la prédiction de la fiabilité, l'évaluation et l'optimisation de la fiabilité*, ils sont définis comme suit [92]:

- ❖ Prédiction de la fiabilité: concerne fondamentalement, l'utilisation des modèles de l'historique des produits similaires dont le but de prédire la fiabilité d'un produit dans la phase de la modélisation (conception), le processus peut être mis à jour, pour prédire la fiabilité ultime.
- ❖ L'évaluation de la fiabilité: consiste à estimer la fiabilité en se basant sur les données actuelles et les données de fonctionnement. Elle implique la

modélisation des systèmes, la conformité avec les distributions de probabilité, et les analyses relatives.

- ❖ L'optimisation de la fiabilité: elle couvre plusieurs côtés, et elle concerne la réalisation d'un compromis entre les différents objectifs de concurrence tels que la performance, le coût.
- ❖ Modèle de test de fiabilité: s'intéresse à l'obtention de données valides, fiables et précises, et d'assurer cela d'une manière efficace et effective.
- ❖ L'analyse des données de la fiabilité: consiste à estimer les paramètres, la sélection des distributions et plusieurs d'autres aspects [92].

IV.2.2 Historique de la fiabilité

La première utilisation enregistrée du mot fiabilité remonte à 1800, quoique s'est rapporté à une personne et pas à un système technique. Depuis lors, le concept de la fiabilité est devenu une valeur d'attribut dominante des connotations qualitatives et quantitatives [109]. En particulier, les changements sociaux, culturels et technologiques révolutionnaires qui se sont produits du 1800 au 2000 ont contribué au besoin d'un formalisme rationnel et de traitement quantitatif de la fiabilité des systèmes d'ingénierie. Ceci a mené à l'apparition de l'ingénierie de fiabilité comme une discipline scientifique.

La notion de l'analyse quantitative de la fiabilité est relativement récente, elle date de 1940 [92], [93], dans cette période, des techniques mathématiques, dont plusieurs étaient nouvelles ont été appliquées sur plusieurs stratégies et problèmes pendant la deuxième guerre mondiale. Avant cette période le concept de la fiabilité était qualitatif et subjectif basé sur des notions intuitives. Des méthodes actuarielles ont été utilisées pour estimer la durée de vie des équipements de chemin de fer et dans d'autres applications au début de 20^{ème} [92], la théorie de la valeur extrême a été utilisée pour modéliser la fatigue des matériaux dans les années 30, ce sont ces modèles antérieurs plus des techniques de probabilité et de statistique qui forment la base de la théorie moderne de la fiabilité.

Les besoins des technologies modernes, en particulier les systèmes complexes utilisés dans les programmes militaires et spatiaux ont mené aux approches quantitatives basées sur la modélisation mathématiques et l'analyse.

Une fiabilité très élevée est particulièrement, requise dans les applications spatiales, à cause de la complexité très élevée des systèmes et l'incapacité de les réparer et de les changer une fois qu'ils sont déployés dans une mission dans l'espace. Ce qui a mené au développement rapide de la théorie de la fiabilité. Après le succès des approches quantitatives de la fiabilité utilisées dans les applications spatiales, cette analyse a été appliquée dans plusieurs autres applications, parmi les nouveaux champs d'application, on trouve les équipements biomédicaux, l'aviation, la communication, et le transport.

Depuis l'apparition du livre de *Barlow and Proschan* en 1965 [92], la théorie de la fiabilité a progressé d'une façon très rapide, et cela est illustré par le nombre important des livres et des articles publiés sur ce sujet.

IV.2.3 Métriques de la fiabilité

IV.2.3.1 Fonctions et formules générales de la fiabilité

Tableau IV.1 : Fonctions et formules mathématiques générales de la fiabilité [94].

Mesures	Equivalence	Définitions
$F(t)$	$= 1 - R(t)$	La fonction de distribution de probabilité cumulative (FDC), la probabilité qu'un composant défaille au temps t .
$R(t)$	$= 1 - F(t)$	Fonction de fiabilité , la probabilité que le composant fonctionne au temps t , alternativement, le nombre des unités qui fonctionnent divisé sur le nombre initial des unités.
$f(t)$	$= \frac{dF(t)}{dt}$	Fonction de densité de probabilité , la probabilité de défaillance à un instant (une durée petite d'une façon infinitésimale).
$\lambda_{Cum}(t)$	$= \frac{F(t)}{t}$	Taux de défaillance cumulatif , taux de défaillance cumulatif à l'instant t , expérimentalement, c'est le pourcentage cumulatif à l'instant t divisé par le temps de défaillance observé pour chaque point de défaillance quand on représente

		graphiquement cette fonction.
$\lambda(t)$	$= \frac{f(t)}{R(t)} = -\frac{1}{R(t)} \frac{dR(t)}{dt}$	Taux de défaillance instantané, taux de hasard, taux de défaillance , la probabilité de défaillance dans unité de temps d'un périphérique qui est en court de fonctionnement. Le taux instantané de défaillance des éléments d'une population qui ont fonctionné jusqu' à l'instant t .
MTBF & MTTF	$= \frac{1}{\text{taux de défaillance (constante)}} = \frac{1}{\lambda}$	moyenne des temps entre deux défaillances d'un système réparable, Durée moyenne de bon fonctionnement d'un système avant la première défaillance , la durée prévue pendant laquelle une unité /système sera opérationnel, <i>MTBF</i> est le terme préféré par rapport au <i>MTTF</i> quand des réparations sont impliqués. Les deux sont l'inverse de taux de défaillance quand il est constant.
A	$= \frac{\text{temps de bon fonctionnement}}{\text{temps BF} (*) + \text{Temps de panne}}$	Disponibilité , dans l'état de fonctionnement stable, c'est la probabilité que le système soit opérationnel en fonction du temps, pour la disponibilité inhérente, le temps de bon fonctionnement est le <i>MTBF</i> , et le temps de panne est la durée moyenne de réparation <i>MTTR</i> , la disponibilité non inhérente peut inclure des facteurs complexes tel que, la durée d'attente, durée de logistique, durée d'administration.

Les concepts de taux de défaillance $\lambda(t)$

Le taux de défaillance [94] est la métrique la plus commune de la fiabilité, il peut être dépendant du temps comme il peut être indépendant du temps. Quand on spécifie l'instant dans lequel on a calculé le taux de défaillance, Il est appelé "taux de défaillance instantané" (taux de défaillance de hasard). Et quand le taux de défaillance est donné sur un intervalle de temps, il nous donne un taux de hasard moyen. En plus, le taux de défaillance sur un intervalle bien précis peut être indépendant du temps, quand il ne change pas en fonction de temps, le taux de hasard est constant et il est appelé simplement, un taux de défaillance constant.

Quand le taux de défaillance est constant sa valeur inverse est le **MTTF**. Si le taux de hasard n'est pas constant, le **MTTF** n'est pas identique à la valeur inverse de taux de hasard. Souvent, le terme **MTTF** est généralement utilisé dans le contexte des composants discrets et des systèmes non réparables. Si le système est réparable le terme **MTBF** (intervalle moyen entre défaillances) est utilisé à la place de **MTTF**.

Trois métriques sont utilisées pour le calcul du taux de défaillance:

- ✓ Défaillance par heure.
- ✓ Défaillance par million d'heures (PPM par heure ou année).
- ✓ Défaillance par milliard d'heures (FITs).

Exemple:

Taux de défaillance constant=1/MTTF.

- Si on prend le **MTTF=2** heures.
- Alors $\lambda=1/MTTF=1/2$ (défaillance par heure) =0.5 défaillances / heure.
- Conversion à défaillance par million d'heures (ppm) (multiplier par 1×10^6),
taux de défaillance = 500 000 ppm par heure (multiplier par 8760 pour avoir un ppm par an).
- Conversion à FITs (multiplier par 10^9) $\lambda =500\ 000\ 000$ FITs.

IV.2.3.2 Modèles mathématiques de la fiabilité

Le taux de défaillance $\lambda(t)$ est modélisé, historiquement en utilisant [94] la *courbe baignoire* représentée dans la Figure IV.1 La courbe est modélisée suivant le taux de mortalité humain. La courbe baignoire est divisée en trois régions, la première est associée à la mortalité infantile, la deuxième à la période de stabilité et la troisième au vieillissement.

La période de la mortalité infantile représente une petite portion de la population qui défaille dans la première année, à cause des défauts de fabrication qui n'étaient pas détectés. La période de la stabilité représente la portion de la population qui a un taux de défaillance constant. A la fin de la vie, le vieillissement apparaît quand le taux de défaillance augmente dans le temps, et le reste de la population défaille.

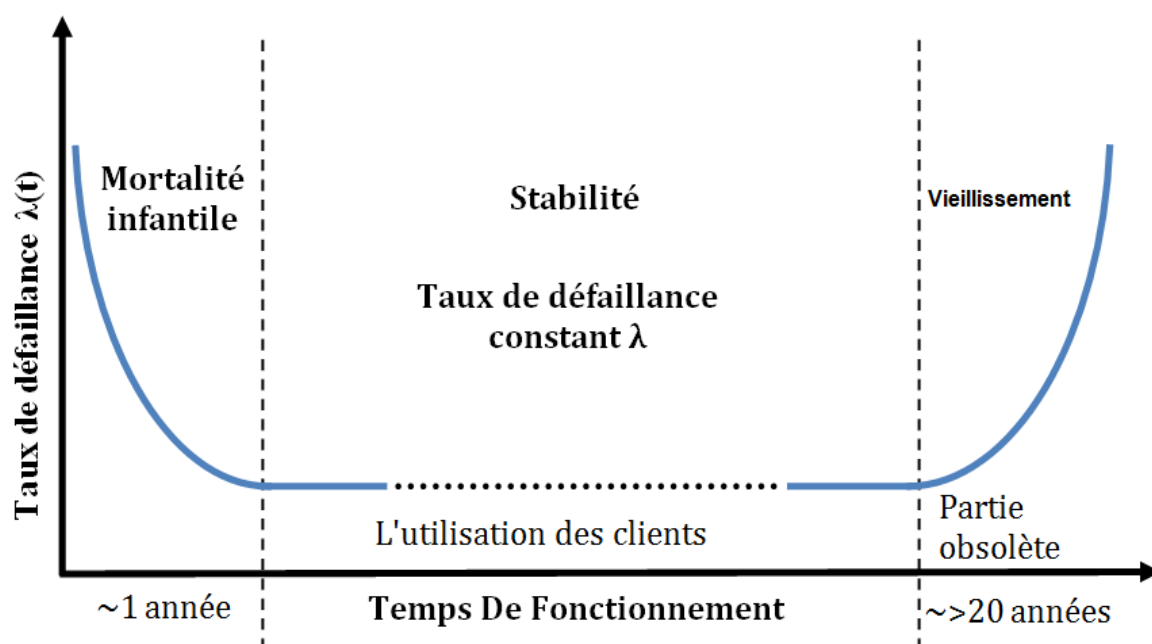


Figure IV.1 : La courbe baignoire [93], [94].

Chaque région de la courbe est modélisée avec une fonction de fiabilité différente, les trois fonctions de distribution principales sont de type: *Weibull*, *Exponentiel*, *Log-Normal*.

$$\lambda(t) = \frac{\beta}{\alpha} \left(\frac{t}{\alpha}\right)^{\beta-1}$$




Figure IV.2 : Différentes parties de la courbe baignoire pour $\beta < 1$, $\beta = 1$, $\beta > 1$.

IV.2.3.2.1 La distribution de Weibull

Cette distribution a été développée par W. WEIBULL dans les années 50, elle peut être utilisée pour représenter plusieurs phénomènes physiques [93]. La distribution de *Weibull* est caractérisée par [94]:

- Elle peut représenter les trois régions de la courbe *baignoire*.
- Elle est très utilisée dans la microélectronique pour modéliser la mortalité infantile.
- Modèle de trois paramètres mais, seulement deux qui sont généralement utilisés (le troisième paramètre représente le changement de temps).

La fonction de densité de probabilité de la distribution de *Weibull* est [93] :

$$f(t) = \frac{\beta}{\alpha^\beta} t^{\beta-1} e^{-\left(\frac{t}{\alpha}\right)^\beta}, \text{ pour } t \geq 0, \alpha > 0, \beta > 0 \quad (\text{IV.3})$$

Où α est le paramètre d'échelle de la distribution et β est le paramètre de forme de la distribution. La fonction de distribution cumulative est l'intégrale de 0 à t de la fonction $f(x)dx$:

$$F(t) = \int_0^t \frac{\beta}{\alpha^\beta} x^{\beta-1} e^{-\left(\frac{x}{\alpha}\right)^\beta} dx = 1 - e^{-\left(\frac{t}{\alpha}\right)^\beta} \quad (\text{IV.4})$$

La distribution *Exponentielle* et la distribution de *Rayleigh* sont des cas particuliers de la distribution de *Weibull* pour respectivement, $\beta = 1$ et 2.

IV.2.3.2.2 La distribution Exponentielle

Cette distribution de probabilité est largement utilisée dans les travaux de maintenance, et de la fiabilité, grâce à deux raisons : elle permet de traiter facilement plusieurs types d'analyses ; et le taux de défaillance constant de plusieurs composants durant leur période d'utilisation, particulièrement les composants électroniques.

La fonction de la densité de distribution de probabilité exponentielle est :

$$f(t) = \lambda e^{-\lambda t}, \quad \text{pour } t \geq 0 \text{ et } \lambda > 0 \quad (\text{IV.5})$$

Où t est le temps, $f(t)$ est la fonction de la densité de distribution de probabilité et λ est le paramètre de la distribution appelé dans le domaine de la fiabilité taux de défaillance constant.

La fonction de la distribution de probabilité cumulative est donnée par la formule suivante :

$$F(t) = \int_0^t \lambda e^{-\lambda x} dx = 1 - \lambda e^{-\lambda t} \quad (\text{IV. 6})$$

IV.2.3.2.3 La distribution de RAYLEIGH

Cette distribution porte le nom de son créateur *John William Strutt Rayleigh* (1842-1919), mathématicien et physicien anglais connu pour sa recherche dans le domaine des phénomènes ondulatoires qui obtint le Prix Nobel de physique en 1904. Elle a été utilisée autrefois dans les études de la fiabilité [93], sa fonction de densité de probabilité est définie par :

$$f(t) = \left(\frac{2}{\alpha^2}\right) t e^{-\left(\frac{t}{\alpha}\right)^2}, \quad \text{pour } t \geq 0 \text{ et } \alpha > 0 \quad (\text{IV. 7})$$

Par conséquent sa fonction de distribution de probabilité cumulative est :

$$F(t) = \int_0^t \left(\frac{2}{\alpha^2}\right) x e^{-\left(\frac{x}{\alpha}\right)^2} dx = 1 - e^{-\left(\frac{t}{\alpha}\right)^2} \quad (\text{IV. 8})$$

IV.2.3.2.4 La distribution Normale

Cette distribution est très utilisée, elle aussi connue par la distribution *Gaussienne* (CARL FRIEDRICH GAUSS (1777–1855)). Sa fonction de densité de probabilité est définie par [93] :

$$f(t) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left[-\frac{(t - \mu)^2}{2\sigma^2}\right], \text{ pour } \infty < t < +\infty \quad (\text{IV. 9})$$

Où μ est le centre et σ l'écart type.

Sa fonction de distribution de probabilité cumulative est :

$$F(t) = \int_{-\infty}^t \frac{1}{\sigma\sqrt{2\pi}} \exp\left[-\frac{(x - \mu)^2}{2\sigma^2}\right] dx = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^t \exp\left[-\frac{(x - \mu)^2}{2\sigma^2}\right] dx \quad (\text{IV. 10})$$

IV.2.3.2.5 La distribution LogNormale

Cette distribution est très utile pour représenter le temps de réparation d'un équipement en panne. La fonction de densité de densité de probabilité de la distribution **LogNormale** est donnée par l'équation suivante [93]:

$$f(t) = \frac{1}{t\alpha\sqrt{2\pi}} \exp\left[-\frac{(\ln t - \mu)^2}{2\alpha^2}\right], \text{ pour } t \geq 0 \quad (\text{IV. 11})$$

Où α et μ sont les paramètres de la distribution.

Sa fonction de distribution de probabilité cumulative est :

$$F(t) = \int_0^t \frac{1}{x\alpha\sqrt{2\pi}} \exp\left[-\frac{(\ln x - \mu)^2}{2\alpha^2}\right] dx = \frac{1}{t\alpha\sqrt{2\pi}} \int_0^t \frac{1}{x} \exp\left[-\frac{(\ln x - \mu)^2}{2\alpha^2}\right] dx \quad (\text{IV. 12})$$

IV.2.3.2.6 La distribution Binomiale

Cette distribution de variables aléatoires discrètes a plusieurs applications dans plusieurs types de problèmes la fiabilité, elle est connue aussi par la distribution de *Bernoulli* après JAKOB BERNOULLI (1654–1705). La fonction de densité de probabilité Binomiale est définie par [93]:

$$f(x) = \left(\frac{n!}{x!(n-x)!}\right) p^x q^{n-x}, \text{ pour } x = 0, 1, 2, \dots, n \quad (\text{IV. 13})$$

x est le nombre total des pannes pour n essai, q est la probabilité de panne pour un seul essai, et p est la probabilité de réussite pour un seul essai. La somme de p et q est égale toujours à 1. Sa fonction de distribution commutative est :

$$F(x) = \sum_{j=0}^x \left(\frac{n!}{j!(n-j)!}\right) p^j q^{n-j} \quad (\text{IV. 14})$$

IV.3 L'INTERET DE L'EVALUATION DE LA FIABILITE

La fiabilité des systèmes d'ingénierie est devenue un sujet très important à cause de la dépendance croissante de notre vie quotidienne au fonctionnement satisfaisant de ces systèmes. Les avions, les trains, les ordinateurs, les satellites dans l'espace, les centrales productrices de l'énergie sont des exemples de ces systèmes. La majorité de ces systèmes sont devenues complexes et sophistiqués, par exemple, un gigantesque *jumbo Boeing 747* est fabriqué en assemblant

approximativement, 4.5 millions de parties. La majorité de ces parties doivent fonctionner correctement pour que l'avion puisse voler [93].

La fiabilité requise des systèmes d'ingénierie est définie dans la spécification de la modélisation. Durant la phase de la modélisation et de la construction, tous les efforts sont fournis pour avoir cette fiabilité. La complexité des systèmes, la concurrence, la pression du public, le coût élevé d'acquisition d'un produit, le nombre croissant des procès judiciaires concernant la fiabilité et la qualité des produits, et la perte du prestige pour les sociétés sont des facteurs qui jouent un rôle très important dans la croissance d'importance accordée à la fiabilité des systèmes [94].

IV.4 LES RESEAUX DE LA FIABILITE

Un système [92] peut former des configurations diverses quand on évalue sa fiabilité. Cette partie concerne l'évaluation de la fiabilité de certaines configurations communes.

IV.4.1 Configuration séquentiel (série)



Figure IV.2: un système de k unités en série.

C'est probablement, la configuration la plus fréquente à apparaître dans les systèmes d'ingénierie et son Bloc-diagramme est représenté dans la Figure IV.2, le diagramme représente un système de k unités, chaque bloc dans le diagramme dénote une unité. Toutes les unités doivent fonctionner correctement pour que le système puisse fonctionner correctement.

L'expression de la fiabilité du système représenté dans la Figure IV.2, est:

$$R_s = P(E_1 E_2 E_3 \dots E_k) \quad (\text{IV. 15})$$

Où E_j dénote le bon fonctionnement de l'unité $j = 1, 2, 3, \dots, k$; R_s est la fiabilité du système et $P(E_1 E_2 E_3 \dots E_k)$ est la probabilité de l'occurrence des événements $E_1 E_2 E_3 \dots$ et E_k

Pour un système avec des unités qui défont d'une façon indépendante l'équation (1.13) devient :

$$R_s = P(E_1)P(E_2)P(E_3) \dots P(E_k) \quad (\text{IV.16})$$

Où $P(E_j)$, $j=1, 2, 3, \dots, k$ est la probabilité de l'occurrence de l'événement E_j .

Si on met $R_j = P(E_j)$ l'équation (1.2) devient:

$$R_s = R_1 R_2 R_3 \dots R_k \quad (\text{IV.17})$$

Où R_j est la fiabilité de l'unité j , $j=1, 2, 3, \dots, k$.

IV.4.2 Configuration parallèle

Dans ce cas, le système est composé de k unités qui fonctionnent simultanément, et au moins une des unités doit fonctionner correctement pour que le système puisse fonctionner. Un Bloc-diagramme de k unités parallèles est montré dans la Figure IV.3.

La probabilité de panne (défaillance) du système parallèle représenté dans la Figure IV.3, est donnée par l'équation suivante:

$$F_{ps} = P(\bar{E}_1 \bar{E}_2 \bar{E}_3 \dots \bar{E}_k) \quad (\text{IV.18})$$

Où F_{ps} est la probabilité de défaillance du système parallèle, \bar{E}_j dénote la défaillance de l'unité j , $j=1, 2, 3, \dots, k$. Et $P(\bar{E}_1 \bar{E}_2 \bar{E}_3 \dots \bar{E}_k)$ est la probabilité de l'occurrence de l'événement $\bar{E}_1 \bar{E}_2 \bar{E}_3 \dots$ et \bar{E}_k .

Pour des unités qui défont indépendamment l'équation (1.16) devient

$$F_{ps} = P(\bar{E}_1)P(\bar{E}_2)P(\bar{E}_3) \dots P(\bar{E}_k) \quad (\text{IV.19})$$




Figure IV.3 : Bloc-diagramme d'un système de k unités parallèles.

Où $P(\bar{E}_j)$, $j = 1, 2, 3 \dots k$ est la probabilité de l'occurrence de l'événement \bar{E}_j . Si on met

$F_j = P(\bar{E}_j)$ l'équation (1.5) devient:

$$F_{ps} = F_1 F_2 F_3 \dots F_k \quad (\text{IV.20})$$

Où F_j est la probabilité de défaillance de l'unité j , $j = 1, 2, 3 \dots k$.

Par soustraction de l'équation (IV.20) de l'unité on aura:

$$R_{ps} = 1 - F_{ps} = 1 - F_1 F_2 F_3 \dots F_k \quad (\text{IV.21})$$

Où R_{ps} est la fiabilité du système parallèle.

IV.4.3 Configuration M-Out-Of-N

Dans ce cas, le système est composé de n unités actives, et au moins m unités doivent fonctionner correctement pour que le système puisse fonctionner. La Figure IV.4, représente un bloc-diagramme d'un système de M-Out-Of-N unités.




Figure IV.4: Bloc-diagramme d'un système de m-out-of-n unités.

Les configurations parallèles et série sont des cas particuliers de la configuration M-Out-Of-N pour respectivement, $m = 1$, $m = n$.

Pour des unités indépendantes et identiques, et en utilisant la distribution *binomiale*, on aura l'expression de la fiabilité suivante pour le diagramme de la Figure IV.4.

$$R_{m/n} = \sum_{j=m}^n \binom{n}{j} R^j (1 - R)^{n-j} \quad (\text{IV.22})$$

Où :
$$\binom{n}{j} = \frac{n!}{(n-j)!j!} \quad (IV.23)$$

Tel que R est la fiabilité de l'unité et $R_{m/n}$ est la fiabilité du système de la configuration M-Out-OF-N.

IV.4. 4 Configuration de réserve (STANDBY)

C'est une autre configuration importante de la fiabilité, dans laquelle une seule unité fonctionne et k unités sont gardées à leur état d'attente. Plus spécifiquement, le système est composé de $k+1$, et dès que l'unité fonctionnelle tombe en panne, le mécanisme de commutation détecte la défaillance et remplace l'unité défaillante par une des unités en attente. La Figure IV.5, montre un bloc-diagramme d'un système de réserve avec une unité fonctionnelle et k unités en attente, chaque bloc dénote une unité.




Figure IV.5: Bloc-diagramme d'un système de réserve avec une unité fonctionnelle et k unités en attente.

En utilisant le diagramme de la Figure IV.5, pour des unités indépendantes et identiques, avec un mécanisme de commutation et une détection de la panne parfaite, et un taux de défaillance en fonction de temps des unités, la fiabilité du système sera donnée est par l'expression suivante:

$$R_{sb}(t) = \sum_{j=0}^k \left[\left[\int_0^t \lambda(t) dt \right]^j e^{-\int_0^t \lambda(t) dt} \right] / j! \quad (IV.24)$$

Tel que $R_{sb}(t)$ est la fiabilité du système de réserve à l'instant t et $\lambda(t)$ est le taux de défaillance dépendant du temps.

Pour un taux de défaillance constant ($\lambda(t) = \lambda$) l'équation (IV.23) devient:

$$R_{sb}(t) = \sum_{j=0}^k (\lambda t)^j e^{-\lambda t} / j! \quad (IV.25)$$

IV.4. 5 Configuration (Bridge)

Parfois un système d'ingénierie peut former une configuration Bridge (série-parallèle), comme c'est montré dans la Figure IV.6. Le diagramme est composé de cinq blocs, chaque bloc représente une unité, tous les blocs sont étiquetés par des chiffres.

Pour des unités indépendantes, la fiabilité du système est donnée par l'équation suivante:

$$R_b = 2R_1 R_2 R_3 R_4 R_5 + R_2 R_3 R_4 + R_1 R_3 R_5 + R_1 R_4 + R_2 R_5 - R_2 R_3 R_4 R_5 - R_1 R_2 R_3 R_4 - R_1 R_2 R_3 R_5 - R_1 R_3 R_4 R_5 - R_1 R_2 R_4 R_5 \quad (IV.26)$$




Figure IV.6 : Une configuration bridge composée de cinq unités non identiques.

Où R_i est la fiabilité des unités pour $i = 1, 2, 3, \dots, k$. R_b est la fiabilité du système.

Pour des unités identiques, l'équation (IV.25) devient:

$$R_b = 2R^5 - 5R^4 + 2R^3 + 2R^2 \quad (IV.27)$$

Pour un taux de défaillance constant des unités, on aura l'équation suivante:

$$R_b(t) = 2e^{-5\lambda t} - 5e^{-4\lambda t} + 2e^{-3\lambda t} + 5e^{-2\lambda t} \quad (IV.28)$$

IV.5 LES METHODES D'EVALUATION ET D'ANALYSE DE LA FIABILITE

L'évaluation de la fiabilité est une activité importante, pour assurer la fiabilité des produits d'ingénierie, elle commence normalement, depuis la phase de la

modélisation conceptuelle du produit. Au fil des années, plusieurs méthodes et techniques d'évaluation de la fiabilité ont été développées.

IV. 5.1 L'ANALYSE DES ARBRES DE DEFAILLANCE

Cette méthode est largement utilisée dans l'industrie pour l'évaluation de la fiabilité des systèmes d'ingénierie, elle était développée dans les années 60 dans le laboratoire de Bell Téléphone, pour analyser la fiabilité et la sécurité de *MINUTEMAN* système de contrôle de lancement [96].

Les arbres de défaillance [96] s'intéressent aux événements de défaillance, un arbre de défaillance peut être décrit comme une représentation logique des événements de défaillance de base ou primaires qui engendrent l'occurrence d'un événement indésirable dit "événement principal" en outre un arbre de défaillance est représenté graphiquement par une structure d'un arbre avec des portes logiques comme la porte "ET" et la porte "OU".

IV.5.1.1 Les étapes de la mise en œuvre d'une analyse d'arbre de défaillance

Une analyse d'arbre de défaillance (AAD) réussie exige la mise en œuvre des étapes suivantes:

- ✓ Identification de l'objectif de l'analyse AAD.
- ✓ Définition de l'événement principal de l'arbre de défaillance AD.
- ✓ Définition du domaine ou l'étendue de l'analyse AAD.
- ✓ Définition de la résolution de l'analyse AAD.
- ✓ Définition des règles de base de l'AAD.
- ✓ Construire l'arbre de défaillance AD.
- ✓ Evaluation de l'arbre de défaillance AD.
- ✓ Interprétation et présentation des résultats.

Les cinq premières étapes concernent la formulation de problème d'une analyse d'arbre de défaillance, le reste des étapes concerne la construction actuelle de l'arbre de défaillance et l'interprétation des résultats de l'arbre de défaillance. Bien que la plupart des étapes soient exécutées d'une manière séquentielle, les étapes 3 à 5 peuvent être réalisées en parallèle, les étapes 4 et 5

sont souvent modifiées durant les étapes 6 et 7. La corrélation des huit étapes est représentée dans la Figure IV.7 [95].

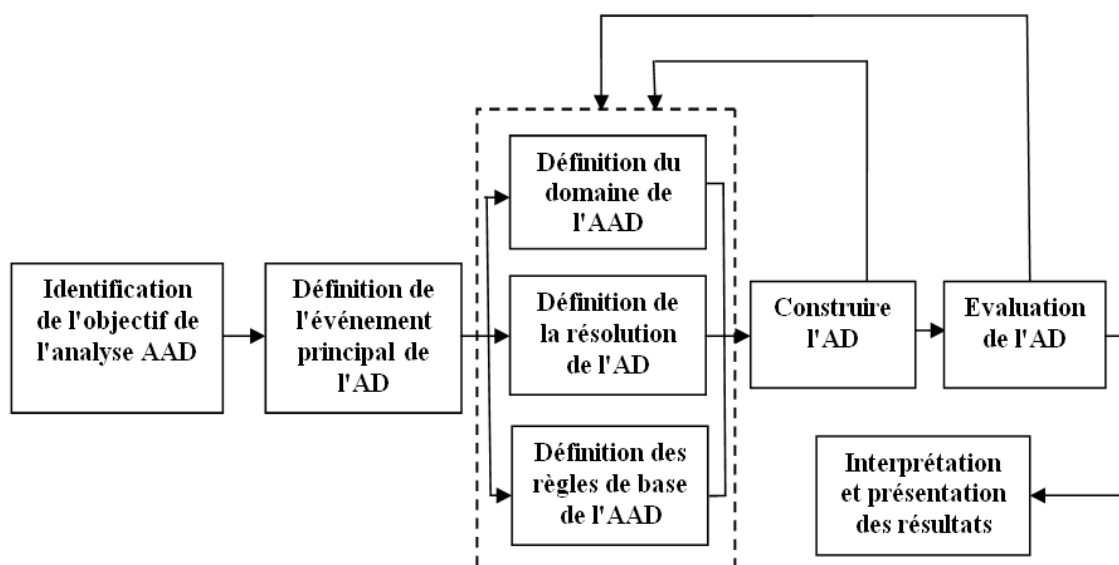


Figure IV.7 : Les étapes de l'analyse d'arbre de défaillance.

IV.5.1.2 Définition des frontières de l'analyse et l'évènement principal de l'AD

Comme n'importe quelle technique de modélisation, les frontières de l'analyse d'arbre de défaillance doivent être définies. Et ceci devrait être accompli avant la construction de l'arbre de défaillance et doit être documenté. La définition des frontières de l'analyse implique la définition de qu'est qui est à l'intérieur de l'analyse et qu'est qui est à l'extérieur. Ce qu'on doit mettre à l'intérieur, ce sont les collaborateurs et les évènements qui ont une relation avec l'évènement principal à analyser. Le reste des collaborateurs qui ne seront analysés, ils sont à l'extérieur.

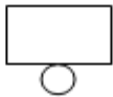
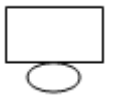
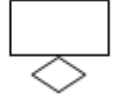
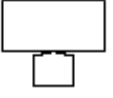
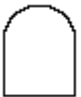
L'évènement principal d'un arbre de défaillance dirige le reste de l'analyse. Si l'évènement principal est défini incorrectement, alors l'analyse de l'arbre de défaillance sera incorrecte ce qui engendre des décisions incorrectes. L'évènement principal peut être défini incorrectement quand l'analyste ne se corrèle pas la définition de l'évènement avec l'objectif du programme et le décideur. Les critères qui mènent à une définition correcte de l'évènement principal d'un arbre de défaillance sont résumés comme suit:


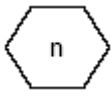


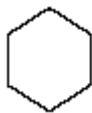


1. Pour définir l'évènement principal, définir le critère de l'occurrence de l'évènement. Pour la panne d'un système, définir d'abord le critère de bon fonctionnement.
2. Assurer que l'évènement principal est compatible avec l'objectif de l'analyse et le problème à résoudre.
3. Si on n'est pas sûr de l'évènement principal, définir des évènements alternatives qui couvre l'évènement principal et évaluer l'applicabilité de chaque un.

La définition de l'évènement principale et les frontières de l'analyse est faite généralement, en se focalisant sur les défaillances (les défauts et les pannes). Cependant, l'analyse peut être faite d'une façon équivalente dans un espace de bon fonctionnement « success space » à la place de l'espace de panne et de défaillance « failure space ».

IV.5.1.3 Symboles utilisés dans la représentation des arbres de défaillance

Tableau IV.2 : Symboles utilisés pour la représentation graphiques des arbres de défaillance [95].

Symbole	Désignation
Symboles des événements primaires	
	Evènement de base: une défaillance de base de lancement qui ne nécessite aucun développement ultérieur.
	Evènement de condition: conditions et restrictions qui sont appliquées sur n'importe quelle porte logique.
	Evènement non développé: un évènement qui n'est pas encore développé à cause de manque d'informations.
	Evènement maison: un évènement qui est normalement, prévu de se produire.
Symboles de portes logiques	
	Porte ET: la défaillance de sortie se produira si toutes les défaillances d'entrée se produisent.

	Porte OU: la défaillance de sortie se produira si une des défaillances d'entrée se produit.
	Porte Combinaison: la défaillance de sortie se produira si <i>n</i> défaillances d'entrée se produisent.
	Porte OU EXCLUSIF: un cas spécial de la porte logique OU, elle a généralement, deux entrées, la défaillance de sortie se produira seulement si une des entrées se produit et pas les deux en même temps.
	Porte Priorité ET: la défaillance de sortie se produira si toutes les défaillances d'entrée se produisent dans un ordre spécifique (l'ordre est représenté par un événement de condition dessiné à droite de la porte).
	Porte INHIBER: la défaillance de sortie se produira si la défaillance unique d'entrée se produit à la présence d'une condition de d'autorisation (la condition d'autorisation est représentée par un événement de condition dessiné à droite de la porte).
Symboles de transfert	
	Transfert in: indique que l'arbre est développé ultérieurement à l'occurrence de symbole de transfert out correspondant.
	Transfert out: indique que cette portion de l'arbre doit être attachée au transfert in correspondant.

IV.5.1.4 Catégories des composants et des défauts de composant

C'est utile que l'analyste [95] classifie les défauts de composants en trois catégories : primaire, secondaire, et de commande. Un défaut primaire est n'importe quelle défaillance de composant qui apparaît dans un environnement dont lequel le composant est qualifié. Un défaut secondaire est n'importe quelle défaillance de composant qui apparaît dans un environnement dont lequel le composant n'était pas qualifié. Les défauts primaires et secondaires sont généralement des défaillances de composant, un défaut de commande implique un fonctionnement correct du composant mais, à un temps incorrect ou dans un lieu incorrect.

Les composants peuvent être actifs ou passifs (aussi appelées quasi-statiques ou dynamiques). Un composant passif contribue d'une manière plus ou moins statique dans le fonctionnement du système. Pour évaluer le fonctionnement d'un composant passif, des tests tels que l'analyse de stress et les études du transfert de la chaleur sont faites. Un composant actif participe d'une manière plus dynamique dans le fonctionnement de son système parent, par la modification du comportement du système d'une certaine façon. Généralement un composant dynamique nécessite un signal d'entrée ou un déclencheur pour son signal de sortie. Il existe une différence importante entre les défaillances d'un composant passif et un composant actif d'un point de vue (aspect) numérique de la fiabilité, c'est la différence dans le taux de fiabilité. La différence de la fiabilité des deux types de composants est exactement égale deux à trois dimensions.

IV.5.1.5 Evaluation qualitative d'un arbre de défaillance

L'évaluation qualitative d'un arbre de défaillance comprend l'application de l'algèbre relationnelle afin d'obtenir les équations des différentes portes logiques d'un arbre de défaillance, et les méthodologies d'obtention de l'ensemble de coupes minimales d'un arbre de défaillance. Les diagrammes de décision binaires sont une approche alternative pour l'évaluation qualitative des arbres de défaillance [95].

IV.5.1.5.1 Les ensembles de coupe minimale et l'algèbre relationnelle

La détermination des ensembles de coupe minimale est une étape très importante pour l'analyse qualitative et quantitative d'un arbre de défaillance. L'algèbre booléenne est un outil puissant qui sert à effectuer cette tâche. En effet un arbre de défaillance peut être considéré comme une représentation graphique des relations booléennes qui se trouvent entre ses événements provoquant ainsi l'apparition de l'évènement principal. Il est possible, de convertir entièrement un arbre de défaillance en un ensemble d'expressions booléennes équivalentes en utilisant les règles de l'algèbre de Boole, pour avoir plus de détails sur le sujet avec des exemples, le lecteur peut se référer à [95], [97].

Un ensemble de coupe [97] est un ensemble de composants dont les défaillances causent la panne du système entier. Un ensemble de coupe minimale est la plus petite combinaison de composants dont la défaillance collective provoque la panne du système. L'ensemble de coupe minimale représente la plus petite collection de composants dont les défaillances sont nécessaires et suffisantes pour causer la panne du système. Si un de ces composants est enlevé de la collection, elle deviendrait plus un ensemble de coupe minimale.

IV.5.1.5.2 Les diagrammes de décision binaires

Les développements récents de la logique digitale [95] a produit une procédure alternative d'analyse des arbres de défaillance. Cette approche est basée sur les digrammes de décision binaires qui travaille directement avec les expressions logiques au lieu des ensembles de coupe.

En 1992, J.-C. Coudert et O. Madre d'un coté, A. Rauzy d'un autre, ont proposé un codage efficace des arbres de défaillance. Un arbre de défaillance est équivalent à une formule binaire. En effet, un arbre est constitué d'évènements $E = \{e_1, e_2, \dots, e_n\}$ et de portes logiques $P = \{et, ou, \dots\}$. Chaque évènement est transformé en une variable booléenne x_i qui vaut 1 si l'évènement s'est produit et 0 sinon. Les portes logiques sont directement traduites en connecteurs logiques.

Tableau IV.3 : Transformation un évènement en une variable booléenne.

Evènement e_j	Variable booléenne x_j
Se produit	1
Ne se produit pas	0

La traduction en formule booléenne de l'arbre de défaillance de la Figure IV.8 est $E_i = x_i$, $F = x_1 \vee (x_2 \wedge x_3)$.




Figure IV.8 : Un exemple d'un arbre de défaillance.

Les diagrammes de décision binaires (BDD pour Binary Decision Diagram) sont une structure de données qui permet de représenter de façon compacte les relations entre variables booléennes. Ils ont été introduits par *Randal E. Bryant* et sont devenus incontournables pour les outils de vérification.




Figure IV.9 : Diagramme de décision binaire de $x \rightarrow y$.

Voici un petit programme qui vérifie pour trois variables booléennes x , y et z si la formule $x \rightarrow y$ est vraie :

Implique(x,y,z)=

If x then

If y then true


else false

else true

On déduit le codage des arbres de défaillance:

Tableau IV.4 : Codage des portes logiques d'un arbre de défaillance par les diagrammes de décision binaires.

Arbre de défaillance	Diagrammes de décision binaire



On peut ensuite appliquer des règles de simplification quand une variable apparaît Plusieurs fois dans une même branche. Considérons l'exemple ci-dessous :




Figure IV.10 : Exemple d'un arbre de défaillance et son diagramme de décision binaire équivalent.

Le BDD peut se simplifier en E_1 dans les deux branches et on obtient :

Grâce à cette représentation sous forme de diagramme de décision binaire, on trouve rapidement les coupes minimales d'un arbre, il s'agit en effet d'une branche menant à un 1. Dans l'exemple, il y a deux coupes minimales $E1.E2$ ou $E1.E3$.




Figure IV.11 : Coupe minimale de l'exemple.

IV.5.1.6 Evaluation quantitative d'un arbre de défaillance

L'évaluation quantitative d'un arbre de défaillance implique le calcul de la probabilité de l'évènement principal de l'arbre de défaillance, pour ce faire les probabilités des évènements de base doivent être fournies au préalable. Les probabilités des évènements de base de l'arbre de défaillance se propagent d'une façon ascendante vers l'évènement principal en utilisant les relations booléennes. Ceci est réalisé en utilisant les digrammes de décision binaires qui représentent un arbre de défaillance. Alternativement, les ensembles de coupe minimale peuvent être générés à partir de l'arbre de défaillance et utilisés ensuite pour calculer la probabilité de l'évènement principal.

Etant donné que l'évènement principal (EP) d'un arbre de défaillance est exprimé sous forme de l'union des ensembles de coupe minimale, sa probabilité peut être rapprochée par la somme des probabilités de coupe minimale individuelle [95]. Et comme, une coupe minimale (CM) [95] est l'intersection des évènements de base (EB), la probabilité d'une coupe minimale est simplement le produit des probabilités des évènements de base. Par conséquent, la probabilité de l'évènement principal est la somme des produits des évènements de base individuels.

En termes de symboles l'expression de la somme des produits est donnée par les formules suivantes [95]:

$$P(EP) = \sum_i P(CM_i) \quad (IV.29)$$

Alors,

$$P(CM) = \prod_{i=1}^n P(EB_i) \quad (IV.30)$$

IV.5.1.7 Extension des arbres de défaillance (les arbres de défaillance dynamiques)

Les arbres de défaillance dynamiques (ADD) étendent les arbres de défaillance traditionnels en définissant des portes logiques spéciales pour capturer les composants séquentiels et les dépendances fonctionnelles. Pour l'analyse, le modèle d'un arbre de défaillance dynamique est automatiquement converti en Chaîne de Markov [97]. GALILEE [92] définit six types de portes logiques dynamiques en plus des trois portes logiques statiques (ET, OU, K/M):

- La porte logique de dépendance fonctionnelle (*FDEP*).
- Les portes logiques, pièces de rechange froid, chaud, et frais (*CSP*, *HSP*, *WSP*).
- La porte logique, ET avec ordre de priorité (*PAND*).
- La porte logique, ordre imposé (*SEQ*).

Un arbre de défaillance peut comporter des portes logiques statiques et dynamiques.

La porte logique *FDEP* :

Cette porte est composée d'un événement déclencheur et d'un ensemble des composants dépendants. Quand l'événement déclencheur se produit, les composants dépendant deviennent inaccessible ou inutilisable, la Figure IV.12 fournit une description de la porte logique *FDEP*.




Figure IV.12 : Représentation graphique de la porte logique FDEP.

La porte logique (CSP, HSP ou WSP) :

La porte CSP a une entrée primaire unique et une ou plusieurs entrées alternatives. Toutes les entrées sont des événements de base (ou des composants). L'entrée primaire est initialement mise sous tension et quand elle tombe en panne, elle est remplacée par une entrée alternative. La sortie de la porte de CSP est vraie quand l'entrée primaire et toutes les entrées alternatives tombent en panne. La Figure IV.13 décrit la porte de CSP.

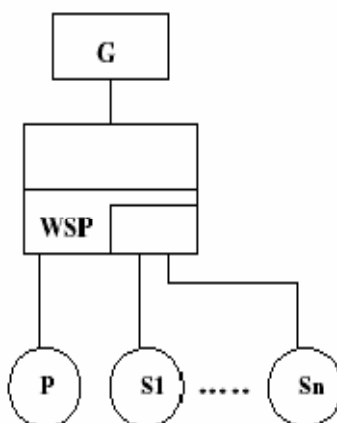


Figure IV.13: Représentation graphique de la porte logique WSP.

La porte logique PAND :

Cette porte a deux entrées, A et B. la sortie de la porte est vraie quand A et B tombe en panne et A tombe en panne avant (ou au même temps que) B. Figure IV.14 montre la porte PAND.




Figure IV.14 : Représentation graphique de la porte logique PAND.

Le principal inconvénient des arbres de défaillance est que le développement est sensible aux erreurs à différentes étapes. En effet, l'arbre construit est aussi bon seulement avec le modèle mental de son créateur. Pour exécuter un diagnostic correct à partir des arbres de défaillance, ceux-ci doivent largement représenter toute les relations causales du processus, c'est-à-dire qu'ils doivent être capable d'expliquer tous les scénarios de défauts possibles. De plus, l'emploi de cette méthode se révèle difficile pour les systèmes fortement dépendant du temps. En fin, il n'y a pas des méthodes formelles pour vérifier l'exactitude de l'arbre développé.

IV.5.2 L'AMDEC (Analyse des Modes des Défaillances et leurs effets et Criticités)

Cette méthode est très utilisée dans les études de la fiabilité et de sûreté de fonctionnement lors de la conception des systèmes d'ingénierie, elle est indispensable pour garantir que les paramètres de fiabilité, de maintenabilité, de disponibilité et de sécurité sont conformes aux spécifications. Elle peut être simplement décrite comme une approche qui prend en compte toutes les défaillances plausibles et analyse les conséquences sur les missions et les fonctions des systèmes, ce qui permet l'identification des matériels sensibles ces derniers devront éventuellement faire l'objet d'un changement de conception ou bien d'une redondance matérielle au stade de la réalisation. Pour des installations déjà opérationnelles, il est également possible de faire ces analyses à posteriori pour identifier les « matériels dont la fiabilité » est insuffisante et pour lesquels il sera indispensable d'entreprendre des actions de surveillance particulière [95]. Quand AMDE est étendu pour classer par catégorie l'effet de chaque panne

potentielle selon sa sévérité (Criticité), la méthode est appelée [95] l'Analyse des Modes des Défaillances et leurs Effets et Criticité (AMDEC).

La réalisation d'une AMDE / AMDEC est souvent basée sur des informations telles que :

- La décomposition d'un système en éléments matériels ou fonctionnels ;
- La représentation graphique de la structure fonctionnelle du système par exemple à l'aide d'un Bloc diagramme matério-fonctionnel ou bien d'un arbre fonctionnel ;
- La définition précise des modes de défaillances associés à chaque niveau de décomposition fonctionnelle ;
- La notion de criticité pour la réalisation des AMDEC.

IV.5.2.1 L'analyse fonctionnelle

La méthode AMDEC est basée sur les techniques de modélisation issue l'analyse fonctionnelle des systèmes. Le principe des méthodes de modélisations des défaillances fonctionnelles et d'établir a priori et de manière formelle et exhaustive les liens entre les causes initiales des défaillances et de leurs effets mesurables par les opérateurs ou les systèmes de traitement de l'information. Les méthodes d'analyse fonctionnelles permettent :

Une description du besoin de l'utilisateur en termes de fonctions indépendamment des solutions matérielles. A chaque fonction, prise au sens «d'actions d'un produit ou de l'un des ses constituants, exprimé exclusivement en terme de finalité», on attribue des critères d'appréciations et de leur niveau. La non satisfaction des critères conduit à conclure à la non-satisfaction du besoin ;

- Une description des choix technologiques que l'on impose au concepteur en termes de contraintes. Les contraintes peuvent être de nature technique ou imposée par le client
- Une vérification pour chaque fonction de l'adéquation des objectives et de ça stabilité dans le temps ;
- Une description du produit envisagé comme solution, en termes de fonctions de services (satisfaction du besoin) et en termes de fonction technique (solution technique retenus pour la réalisation) ;

- Une optimisation du besoin aussi bien au plan économique qu’au plan technique (disponibilité, sûreté et fiabilité).
- La mise en œuvre de l’analyse fonctionnelle se déroule en trois grandes phases :
- L’analyse fonctionnelle externe qui a pour objectives de formaliser de valider l’analyse du besoin en considère le produit comme une « une boîte noire » recevant des entrées et fournissant des sorties.
- L’analyse fonctionnelle interne identifier de façon précise les fonctions techniques et les solutions technologiques préconisées pour réaliser la boîte noire.
- La vérification de l’optimisation technico-économique du couple besoin produit.

IV.5.2.2 Rédaction des tableaux AMDEC

La rédaction d’un dossier d’AMDEC nécessite dans la première phase industrielle en nombre des niveaux jugés nécessaire pour la remise au point d’un programme de maintenance basée sur la fiabilité. A l’aide de ces études il sert possible de déterminer les fonctions, les défaillances fonctionnelles. Ensuite par une utilisation du retour d’expérience on pourra déterminer la fréquence, la gravité, la criticité de chacun des modes de défaillance.

Pour les autres informations sur les méthodes de détection, les moyens de prévention ou les actions correctrices, il est indispensable de faire appel aux constructeurs, aux personnels d’exploitation de maintenance, de maintenabilité ou du soutien logistique.

La réalisation des dossiers d’analyse d’AMDEC nécessite des compétences multidisciplinaires. La figure suivante représente la compétence des rédacteurs et utilisateurs des dossiers AMDEC.

La réalisation d’une analyse AMDE nécessite tout d’abord la détermination du niveau de décomposition à partir duquel l’analyse est effectuée. Un système pourra faire l’objet d’une décomposition hiérarchique en autant de niveau qu’il sera nécessaire. Le dernier niveau correspondant en général au dernier composant remplaçable. Le niveau de décomposition doit être compatible avec la connaissance de tous les modes de défaillances et de leurs effets. Le résultat de

ces analyses est ensuite regroupé dans un tableau qui résume les effets des défaillances premières des composants sur les fonctions assurées par les éléments du système. Le contenu de ces tableaux varie suivant les secteurs industriels et contient en général les informations suivantes :

- Le nom de l'élément matériel ou fonctionnel du système analysé.
- La fonction remplie par cet élément.
- Le repère d'identification.
- Les modes de défaillances.
- Les causes de défaillances.
- Les effets des défaillances.
- Les méthodes de détection ou de découverte.
- La criticité de la défaillance pour les AMDEC.
- La probabilité d'apparition de la défaillance première.
- Une colonne «remarques ou observations»

La réalisation des dossiers d'AMDEC représente la partie la plus visible de « l'iceberg » du dossier d'analyse. Les informations portées dans les colonnes doivent faire impérativement l'objet de description détaillée et de justification rationnelle dans des paragraphes bien identifiés du dossier pendant toutes ces phases d'élaboration. Sinon, leur vérification par des auditeurs externes sera rendue difficile, et les utilisateurs, non-rédacteurs, ne leur approchent qu'un crédit très limité. Ci-dessous la majorité des éléments communs des tableaux AMDEC :

Numéro ou nom de l'élément

Correspond en général à celui défini pendant la décomposition matérielle ou fonctionnelle de l'installation.

Repère fonctionnel ou nomenclature

- Le repère fonctionnel est spécifique et interne à l'entreprise et il correspond au découpage fonctionnel adopté.
- Le numéro de nomenclature de l'élément reprend par souci de cohérence celui utilisé par les services achats, approvisionnements ou de gestion des stocks.

Fonction remplie par l'élément

Pour le niveau de décomposition fonctionnel analysé, on doit trouver sous cette rubrique la fonction remplie par l'élément en respectant les règles sémantiques. La fonction d'un moteur électrique sera énoncée ainsi : convertir une énergie électrique en énergie mécanique.

Modes de défaillance

Comme chaque élément peut posséder plusieurs modes de défaillance, cette rubrique définira chacun de ces modes. Ainsi pour un moteur électrique, les modes de défaillance peuvent être extraits de la liste non exhaustive tel que : S'arrête de fonctionner, ne démarre pas, ne s'arrête pas.

Causes de défaillance

Cette rubrique est délicate à remplir si l'on ne tient pas compte de niveau de décomposition qu'il lui est associé. Suivant les cas une cause sera la défaillance de l'élément fonctionnel ou matériel de rang immédiatement inférieur ou bien la cause première physique de la défaillance (érosion, corrosion, fatigue,...). C'est ce point qui introduit souvent des malentendus entre les rédacteurs des dossiers AMDEC et leurs utilisateurs.

Effets des défaillances

Les effets à reporter dans cette colonne peuvent appartenir aux catégories suivantes :

- Effet local effet au niveau immédiatement supérieur de la décomposition.
- Effet final sur le procédé.

Méthode de détection

Les informations répertoriées sous cette rubrique doivent décrire avec quels moyens physiques il sera possible d'assurer la détection de la défaillance. Pour la Maintenance basé sur la fiabilité, cela permettra de classer la défaillance comme évidente ou cachée.

Action corrective

Dans cette colonne sont listées les actions que doivent entreprendre les personnels qui conduisent ou de la maintenance. Pour compenser les effets d'une défaillance.

Remarque :

Dans le cas où il existerait des particularités dans l'analyse du système elle doit être consignée dans cette colonne.

Fréquence

La fréquence ou la probabilité d'occurrence de la défaillance doit être estimée soit à l'aide de retour d'expérience prenant d'industrie similaire ou par jugement d'expert. Suivant les secteurs industriels des échelles des fréquences comportant de 5 à plus de 10 niveaux à valeur numérique ou symbolique ont été établis. En générale pour un indice numérique en la note F.

Tableau IV.5 : Exemple de hiérarchisation de probabilité de défaillance.

Très improbable	1 fois tous les 1000 ans
Improbable	1 fois tous les 100 ans
Occasionnelle	1 fois tous les 10 ans
Probable	1 fois par ans
Fréquente	1 fois par mois ou plus.

Gravité

La gravité des conséquences de défaillance est souvent évaluée à l'aide d'un indice de gravité également spécifique à chaque secteur industriel. Pour la maintenance basée sur la fiabilité, il sert à établir, en conjonction avec d'autres paramètres, la nature critique ou non critique d'une fonction ou d'un matériel.

L'indice est noté souvent par convection G. le Tableau IV.5 représente respectivement le tableau de gravité recommandé par la norme MIL-STD 1629.

Tableau IV.6 : Tableau de gravité.

Catégorie	Explications
IV	Catastrophique : défaillance qui peut conduire à la mort de personnes ou la perte de système d'armes.
III	Critique : défaillance qui peut conduire à la blessure de personnes. A des dommages sur les bâtiments ou sur les systèmes d'armes qui peuvent conduire à la perte de la mission.
II	Majeure : défaillance qui peut conduire à la blessure de personnes, à des dommages sur les bâtiments ou sur les systèmes d'armes qui peuvent conduire à des retards ou perte de disponibilité ou la dégradation de la mission.
I	Mineure : défaillance pas assez sérieuse pour causer des blessures de personnes, des dommages sur les bâtiments ou sur les systèmes d'armes mais qui peuvent conduire à des taches.

Indice de non-détection

L'indice de détection D est un jugement qualitatif destiné à quantifier la probabilité que la défaillance soit détectée par l'utilisateur final. Cette information est utile dans l'élaboration d'un programme de la maintenance basé sur la fiabilité pour séparer les défaillances évidentes des défaillances cachées. La figure ci-dessous donne un exemple de tableau de détection (ou non-détection) à quatre niveaux.

Tableau IV.6 : Indice de détection.

Niveau	Description
1	Signes (bruit, vibration, échauffement) avant coureur de défaillance que les exploitants pourront éviter par une action préventive.
2	Il existe un signe avant coureur de la défaillance, mais il y a risque qu'il ne soit pas perçu par les exploitants.
3	Il existe un petit signe avant coureur de la défaillance, il y a un grand risque qu'il ne soit pas perçu par les exploitants.
4	Il n'existe aucun signe avant coureur de la défaillance.

IV.5.2.3 Indice de criticité ou de sévérité

Les indices de fréquences, gravité et détection peuvent être utilisés seuls ou en même temps pour établir la sévérité des conséquences d'une défaillance. Plusieurs méthodes ont été élaborées pour juger de la sévérité ou de la criticité des défaillances.

La première méthode consiste à remplir le produit FGD, à condition évidemment que toutes les valeurs F, G, D soient numériques. Dans les industries à risques écologiques ou humains, ce mode de calcul n'est pas très adapté car on est amené à calculer la valeur $0 \times \infty$.

La valeur 0 correspond à une probabilité très faible et ∞ , la valeur associée aux conséquences d'une défaillance. Pour cette raison. On préfère garder un plan où les axes retenus sont les probabilités d'apparition et la gravité de la défaillance. On peut alors utiliser directement ce plan pour situer la criticité de la défaillance (montré sur la Figure IV.15).




Figure IV.15: Indice de criticité.

IV.5.3 LA METHODE DE REDUCTION DE RESEAU

C'est une méthode simple et utile pour l'estimation de la fiabilité des systèmes qui se composent de sous-systèmes série et parallèle indépendants, cette méthode réduit d'une manière séquentielle les configurations série et parallèle à des unités équivalentes, jusqu'à ce que le système global devienne une

seule unité hypothétique. L'avantage principal de cette méthode est sa simplicité à comprendre et à utiliser [93].

IV.5.4 METHODE D'ANALYSE DE LA CAUSE DE DEFAILLANCE COMMUNE

Il existe plusieurs instances dans l'industrie où des unités multiples qui tombent en panne suite à une seule cause. On citera dans ce qui suit l'ensemble des paramètres qui provoquent l'occurrence de la cause commune de défaillance [96]:

- Un modèle pauvre.
- Un environnement opérationnel commun (ex: humidité, vibration, chaleur).
- Événements catastrophiques externes (ex: inondation, séisme, feu, tornade).
- Des erreurs de maintenance.
- Insuffisance fonctionnelle.
- Des fabricants communs de certaines parties.
- Des sources d'énergie externe communes.

Les causes communes de défaillances sont des facteurs importants dans l'analyse de fiabilité des systèmes d'ingénierie. Leurs occurrences doivent être prises en compte dans la prédiction de la fiabilité d'un système, autrement la fiabilité prédit ne reflètera pas le système réel. Plusieurs méthodes et modèles ont été développés pour prendre en considération la cause-commune de défaillances dans l'évaluation de la fiabilité des systèmes. Une des ces méthodes est basé sur l'hypothèse que toutes les causes communes de défaillances associées à un système redondant peuvent être représenté par une seule unité hypothétique. Cette unité est mise en série avec le système redondant.

Quelques exemples de ce système redondant sont le réseau parallèle, le système de k -out- n unités, et la configuration (bridge). Néanmoins, cette méthode est démontrée ici, pour le système redondant étant un réseau parallèle représenté sur la Figure IV.15. Chaque bloc dans la figure dénote une unité et les symboles n et C_f dénotent respectivement, le nombre d'unités en parallèle et l'unité hypothétique représentant toute les défaillances de cause commune liées au réseau parallèle.

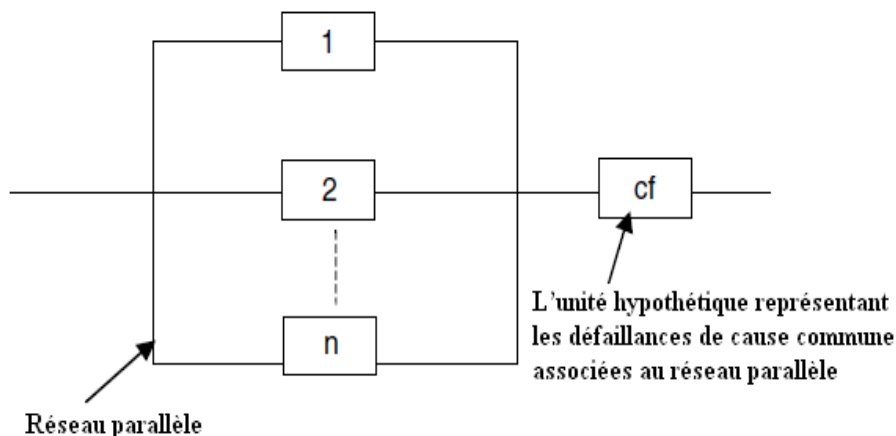


Figure IV.16: Bloc-diagramme d'un système parallèle aux défaillances de cause commune.

$$R_{pc} = [1 - (1 - R)^n]R_{cf} \quad (\text{IV. 31})$$

Où R_{pc} : la fiabilité d'un système parallèle avec des défaillances de cause commune.

N : Nombre total des unités indépendantes et identiques en parallèle.

R : La fiabilité de l'unité.

R_{cf} : La fiabilité de l'unité hypothétique représentant les défaillances de cause commune associées au réseau parallèle.

Pour les distributions exponentielles et le temps de défaillances de cause commune, le taux de défaillance total d'une unité est exprimé par la formule suivante :

$$\lambda_T = \lambda + \lambda_{cf} \quad (\text{IV. 32})$$

Où

λ_T : Le taux de défaillance total d'une unité.

λ : Unité de mode indépendant (c a d, taux de défaillance de cause non commune).

λ_{cf} : Le taux de défaillance de l'unité (l'unité qui représente toutes les défaillances de cause commune associées au réseau parallèle).

D'où,

$$\gamma = \frac{\lambda_{cf}}{\lambda_T} \quad (IV.33)$$

Par conséquent

$$\lambda_{cf} = \gamma \lambda_T \quad (IV.34)$$

En substituant la formule (6.25) à la formule 6.23, on aura la formule suivante :

$$\lambda = (1 - \gamma) \lambda_T \quad (IV.35)$$

La formule générale de la fiabilité d'une unité est :

$$R(t) = e^{-\int_0^t \lambda(x) dx} \quad (IV.36)$$

Où $R(t)$ est la fiabilité de l'unité à temps t et $\lambda(t)$ est le taux de défaillance de l'unité,

Ainsi en utilisant l'équation et l'équation dans l'équation, on aura l'équation suivante :

$$R_{cf}(t) = e^{-\gamma \lambda_T t} \quad (IV.37)$$

et

$$R(t) = e^{-(1-\gamma) \lambda_T t} \quad (IV.38)$$

Où $R_{cf}(t)$ est la fiabilité de l'unité hypothétique représentant les défaillances de cause commune associées au réseau parallèle à l'instant t et $R(t)$ est la fiabilité de l'unité.

En substituant l'équation (IV.38) à l'équation IV.31, on aura la formule suivante :

$$R_{pc} = \left[1 - (1 - e^{-(1-\gamma) \lambda_T t})^n \right] e^{-\gamma \lambda_T t} \quad (IV.39)$$

Où R_{pc} est la fiabilité du système parallèle aux défaillances de cause commune à l'instant t . La durée moyenne de bon fonctionnement du système parallèle avant la première défaillance est exprimée par formule suivante :

$$MTTF_{pc} = \int_0^{\infty} R_{pc}(t) dt = \sum_{i=0}^n (-1)^{i+1} \binom{n}{i} / \lambda \{i - (i-1)\gamma\} \quad (IV.40)$$

Où $MTTF_{pc}$ est la durée moyenne de bon fonctionnement du système parallèle aux défaillances de cause commune avant la première défaillance.

$$\binom{n}{i} = \frac{n!}{i!(n-i)!} \quad (\text{IV.41})$$

IV.5.5 LA METHODE DE MARKOV

Cette méthode est la méthode la plus largement utilisée pour l'analyse de la fiabilité, elle a pris son nom d'un mathématicien russe appelé *ANDREI ANDREYEVICH MARKOV* (1856–1922). Cette méthode est très utile pour la modélisation des systèmes avec des défaillances dépendantes. Elle est basée sur les suppositions suivantes [97]:

- ✓ La probabilité de transition du système d'un état à un autre dans un intervalle du temps fini Δt est $\alpha \Delta t$, tel que : α est le taux de transition d'un état du système à un autre.
- ✓ La probabilité que plus qu'une transition dans l'intervalle du temps Δt à partir d'un état à l'état suivante est négligeable.
- ✓ Les occurrences sont indépendantes les unes des autres.




Figure IV.17 : Diagramme de l'espace d'état d'un système.

IV.5.6 LES CHAINES DE MARKOV POUR LA FIABILITE

La représentation de la défaillance (panne) d'un système d'une manière probabiliste est intéressante parce qu'elle intègre naturellement l'incertitude et l'ambiguïté. Pour effectuer une telle représentation, le comportement d'un processus est considéré comme étant un ensemble de variables aléatoires qui prennent leurs valeurs dans un espace fini d'états correspondant aux états possibles de processus. Les Chaines de Markov permettent de modéliser le dynamisme (dynamique) d'un système à travers ces états.

IV.5.6.1 Chaines de Markov

Soit X une variable aléatoire discrète utilisée pour modéliser un processus avec un nombre fini des états, mutuellement exclusifs $\{s_1, \dots, s_M\}$. Le vecteur π , dénote alors, une distribution de probabilité sur de ces états [99]:

$$\pi = [\pi(s_1), \dots, \pi(s_m), \dots, \pi(s_M)], \quad \pi(s_m) \geq 0 \quad (\text{VI. 42})$$

Avec,

$$\mathbb{P}(s_m) = \mathbb{P}(X = s_m) \text{ et } \sum_{m=1}^M \pi(s_m) = 1 \quad (\text{VI. 43})$$

En admettant que le système évolue à travers les états, où l'occurrence d'un événement marque la transition d'un état (k) à l'état futur ($k+1$), puis le processus produit la séquence $\{\pi_0, \pi_1, \dots, \pi_{k-1}, \pi_k\}$ qui peut être modélisé par une Chaîne de Markov (CM) discrète si:

$$\pi_k(s_m) = \mathbb{P}(X_k = s_m | \pi_0, \pi_1, \dots, \pi_{k-1}, \pi_k) = \mathbb{P}(X_k = s_m | \pi_{k-1}) \quad (\text{VI. 44})$$

La propriété de Markov permet de spécifier les relations statistiques entre les états comme étant une matrice de probabilité de transition \mathbb{P}_{MC} , si les probabilités de transition $\mathbb{P}(X_k = s_j | X_{k-1} = s_i)$ sont indépendants du temps, la CM est dite homogène.

$$\mathbb{P}(X_k | X_{k-1}) = \begin{bmatrix} \mathbb{P}_{11} & \mathbb{P}_{12} & \dots & \mathbb{P}_{1M} \\ \mathbb{P}_{21} & \mathbb{P}_{22} & \dots & \mathbb{P}_{2M} \\ \dots & \dots & \dots & \dots \\ \mathbb{P}_{M1} & \mathbb{P}_{M2} & \dots & \mathbb{P}_{MM} \end{bmatrix} \quad (\text{VI. 45})$$

La séquence de la distribution de probabilité est estimé par :

$$\pi_k = \pi_0 (\mathbb{P}_{MC})^k \quad (\text{VI. 46})$$

IV.5.6.2 Le processus Markovien discret indépendant du temps

La détérioration peut être modélisée par un processus stochastique discret indépendant du temps $X_k, k \geq 0$, où X_k est une quantité aléatoire pour tout $k \geq 0$. La fiabilité des systèmes est généralement supposée être un processus Markovien.

Le processus Markovien est un processus stochastique qui évolue sous la propriété de Markov (voir l'équation VI.3). En donnant la valeur de X_k , les valeurs

de X_{k+i} où $i > 0$ sont indépendants des valeurs de X_{k-j} où $j > 0$. Dans le cas d'un espace d'état fini ou comptable, les processus de Markov peuvent être représentés par les chaînes de Markov [100].

Les chaînes de Markov homogènes sont utilisées dans le cas des systèmes ayant des taux de défaillance constants parce que les probabilités de transition sont stationnaires. Dans ce genre de modèle, les probabilités de transition sont invariables dans le temps et dépendent seulement aux valeurs des états (voir l'équation VI.18). Dans une chaîne de Markov homogène à temps discret, la matrice \mathbb{P}_{CM} de transition entre les états est définie par les paramètres de taux de défaillance.

La fiabilité des systèmes ou des composants est classiquement modélisé par les CM. Cette méthode mène à une représentation graphique [98]. Néanmoins la complexité du modèle dépend des prétentions faites pour rapprocher le processus stochastique. Malheureusement, la complexité de modélisation augmente considérablement, si on veut être du comportement réel de la fiabilité de système. En effet, l'espace d'état décrivant le système est le produit cartésien des états des composants.




Figure IV.18 : Une Chaîne de Markov modélisant la fiabilité d'un composant.

Considérons la fiabilité d'un composant. Il est modélisé par une variable aléatoire discrète X avec les états $\{o, f\}$, dans lesquels (o) indique un état opérationnel et (f) indique un état de panne. Pour modéliser la fiabilité, la matrice \mathbb{P}_{CM} entre les états $\{o, f\}$ est défini comme suit:

$$\mathbb{P}(X_k | X_{k-1}) = \mathbb{P}_{CM} = \begin{bmatrix} 1 - \lambda & \lambda \\ 0 & 1 \end{bmatrix} \quad (\text{VI.47})$$

Où λ est le taux constant de défaillance.

$$\lambda(t) = \frac{f(t)}{R(t)} = \frac{1}{MTTF} \quad (\text{VI. 48})$$

La fonction de densité du temps de défaillance est $f(t)$:

$$f(t) = \frac{dR(t)}{dt} \quad (\text{VI. 49})$$

IV.5.6.3 Le processus Markovien discret dépendant du temps

Les modèles markoviens à temps discret se basent sur l'hypothèse que le temps dans chaque état est géométriquement distribué. Par conséquent, sous cette hypothèse le taux de défaillance d'un composant est considérée comme indépendant du temps. Malheureusement, la distribution géométrique ne convient pas à la majorité de problèmes d'ingénierie parce qu'elle ne reflète pas le fait que la plupart des composants détériorent d'une façon continue à cause de l'utilisation, de l'usure ou de l'âge. Pour tenir compte de ce problème, la matrice définie dans l'équation VI.48 devient temps-dépendante et la CM n'est plus homogène.

$$\mathbb{P}_{\text{CM}} = \begin{bmatrix} 1 - \lambda(k) & \lambda(k) \\ 0 & 1 \end{bmatrix} \quad (\text{VI. 50})$$

L'approximation du processus initial par une chaîne de Markov équivalente indépendante du temps Une solution pour modéliser un processus de Markov dépendant du temps **[100]**.

IV.5.7 METHODE DE DECOMPOSITION

Cette méthode **[96]** est utilisée pour évaluer la fiabilité des systèmes complexes. Elle décompose le système complexe en des sous systèmes plus simple en appliquant la théorie de la probabilité. A la fin la fiabilité du système est obtenue en combinant les mesures de la fiabilité des sous systèmes.

La méthode commence premièrement par la sélection de l'élément ou l'unité clé utilisée pour la décomposition du système/réseau. Le mauvais choix de cet élément clé mène à une mauvaise efficacité du système de calcul de la fiabilité. Néanmoins, l'expérience joue un rôle instrumental dans le bon choix de cet élément clé.

Premièrement, la méthode suppose que l'élément/unité clé appelé x , est remplacé par un autre élément qui ne défaille jamais (fiable à 100%), et ensuite elle suppose que l'élément clé est complètement non fiable (enlevé complètement du système). Sous ce scénario la fiabilité du système globale est donnée par [96]:

$$R_s = P(x)P(\text{système en bon état}/x \text{ en bon état}) + P(\bar{x})P(\text{système en bon état}/x \text{ défectueux}) \quad (\text{IV.51})$$

Où :

R_s : La fiabilité du système.

$P(\text{système en bon état}/x \text{ en bon état})$: La fiabilité du système quand x est 100% fiable.

$P(\text{système en bon état}/x \text{ défectueux})$: La fiabilité du système quand x est 100% non fiable.

$P(x)$: La fiabilité de l'élément clé.

$P(\bar{x})$: La non-fiabilité de l'élément clé.

De la même manière, le taux de défaillance global du système est :

$$F_s = P(x)P(\text{système défectueux}/x \text{ en bon état}) + P(\bar{x})P(\text{système défectueux}/x \text{ défectueux}) \quad (\text{IV.52})$$

F_s : La probabilité de défaillance du système.

$P(\text{système défectueux}/x \text{ en bon état})$: La probabilité de défaillance du système quand x est 100% fiable.

$P(\text{système défectueux}/x \text{ défectueux})$: La probabilité de défaillance du système quand x est 100% non fiable.

IV.6 CONCLUSION

Nous avons abordé dans ce chapitre les aspects théoriques fondamentaux de la fiabilité des systèmes, et les méthodes d'analyse de la fiabilité.

Le chapitre suivant présente un état de l'art sur l'utilisation des réseaux Bayésiens pour l'analyse et l'estimation de la fiabilité des systèmes.

CHAPITRE V : LES RESEAUX BAYESIENS POUR LA FIABILITE : ETAT DE L'ART

V.1 INTRODUCTION

L'estimation de la fiabilité des systèmes en utilisant les réseaux Bayésiens remonte à 1988, où l'idée a été présentée pour la première fois par *BARLOW* [101], [102]. La proposition d'utiliser les réseaux Bayésiens comme un formalisme pour l'analyse et l'évaluation de la fiabilité provient d'une tendance de recherches qui a comparé les formalismes classiques de la fiabilité (tels que les arbres de défaillances (AD) et les blocs-diagrammes) aux réseaux Bayésiens, et qui a montré que les réseaux Bayésiens ont des avantages significatifs par rapport aux formalismes traditionnels.

La première vraie tentative de fusionner les efforts des deux communautés, la communauté de l'intelligence artificielle, dont les réseaux Bayésiens proviennent et celle de la fiabilité des systèmes est probablement le travail de *ALMOND* [101], où il a proposé l'utilisation de l'outil « réseau de croyance » pour calculer la fiabilité d'un système d'injection de liquide réfrigérant à basse pression pour un réacteur nucléaire.

Ce chapitre présente un état de l'art sur l'utilisation des réseaux Bayésiens et leurs modèles dynamiques pour l'estimation et l'analyse de la fiabilité des systèmes.

V.2 APERCU GENERAL SUR L'UTILISATION DES RESEAUX BAYESIENS POUR LA MODELISATION ET L'ANALYSE DE LA FIABILITE DES SYSTEMES

La fiabilité d'un système peut être définie comme étant la probabilité que le système accomplisse sa fonction prévue pour une durée déterminée sous des conditions bien définies [101]. L'estimation de la fiabilité des systèmes est un problème très important et un challenge pour les ingénieurs des systèmes. Il est important parce que la réputation des compagnies, la satisfaction des clients et les coûts du modèle du système peuvent être directement liés aux défaillances de ce

dernier. Il est aussi stimulant vu que les techniques actuelles d'estimation de la fiabilité nécessitent un niveau élevé de background dans l'analyse de la fiabilité, ainsi que la familiarité avec le système à étudier.

Traditionnellement, la fiabilité d'un système est évaluée en étudiant la façon dans laquelle, les composants interagissent entre eux pour garantir le bon fonctionnement du système, à la base de cette étude un modèle graphique (généralement, sous forme d'arbre de défaillance, un bloque-diagramme, ou un graphe de réseau) est élaboré. Une fois le modèle graphique est obtenu, différentes méthodes d'analyse [101], [102], [103] (Coupe minimale, les digrammes de décision binaires (DDB)) peuvent être utilisées pour la représentation quantitative de la fiabilité du système étudié. Finalement les caractéristiques de la fiabilité des composants sont introduites dans la représentation mathématique pour obtenir le niveau de fiabilité du système.

Cette approche est valide quand le comportement du système est bien compris. Cependant, pour les nouveaux systèmes complexes, que ce soit dans la phase de conception ou de déploiement, la compréhension de l'interaction des composants devient un problème difficile qui nécessite l'intervention des experts du domaine. Par conséquent, Les anciens problèmes de l'évaluation de la fiabilité des systèmes se sont développés en nouveaux challenges, dans le contexte des systèmes modernes complexes.

Les principaux caractéristiques à modéliser pour évaluer et analyser la fiabilité d'un système moderne [103], [104] sont :

- La représentation et la modélisation du système (La complexité et la taille du système, L'aspect temporel, La dépendance entre les évènements tels que les défaillances, La nature des composants (Multi-Etats)).
- La quantification du modèle du système (L'intégration des informations qualitative avec des connaissances quantitatives à des différent niveaux d'abstraction).
- La représentation, la propagation et la quantification de l'incertitude dans le comportement du système (l'incertitude sur l'estimation des paramètres).

La modélisation de ces caractéristiques pose beaucoup de problèmes. Pour résoudre ces problèmes, les réseaux Bayésiens ont été proposés comme une alternative aux approches traditionnelle d'analyse et d'estimation de la fiabilité [101]. Les réseaux Bayésiens ont été choisis principalement, puisqu'ils sont faciles à utiliser et à comprendre par les experts du domaine. Les réseaux Bayésiens sont particulièrement appropriés pour la collecte et la représentation des connaissances sur des domaines incertains mais également ils permettent de faire des calculs probabilistes et des analyses statistiques d'une façon efficace.

Dans la littérature récente, on observe un intérêt croissant focalisé sur les réseaux Bayésiens. Cette méthode de modélisation n'est pas la solution à tous les problèmes, mais elle semble être très appropriée et prometteuse dans le contexte des systèmes complexes [101], [103]. Le journal de RESS (*Reliability Engineering and System Safety*), très connu dans le secteur de la fiabilité des systèmes, montre un taux d'incrément de 100% des travaux publiés dans la période de 1999-2009 [103]. Les travaux de recherches menés sur l'application des réseaux bayésiens dans l'analyse de la fiabilité et de risque et de maintenance ont montré une tendance croissante significative depuis l'année 2000, particulièrement dans la fiabilité des systèmes. Récemment, environ 30 articles sont publiés par année avec une augmentation de 800% du nombre des publications entre 2000 et 2008.




Figure V.1 : Tendance des publications dans le domaine de l'estimation de la fiabilité des systèmes à base de réseaux Bayésiens [103].

Les chercheurs ont focalisé leurs travaux, en premier temps sur les réseaux Bayésiens statiques, les premières principales contributions [103] étaient sur l'estimation de la fiabilité (avec la possibilité d'avoir une dépendance des défaillances) et la modélisation des systèmes complexes. Le modèle de réseau Bayésien représentant le système à étudier est construit en collaboration avec les experts [105] ou en convertissant l'arbre de défaillance standard d'un système en un réseau Bayésien équivalent [107]. Les chercheurs ont travaillé aussi sur l'estimation de la fiabilité des systèmes complexes en utilisant les réseaux Bayésiens pour l'intégration des informations [107] et la manipulation des données discrètes multi-niveau [108] (Multilevel discret data).

Dans le contexte de l'imperfection des données de la fiabilité et l'incohérence entre le modèle de la fiabilité et le système modélisé, *SIMON et al* [109], [110] ont constaté que la théorie d'évidence est le modèle le plus adaptée pour manipuler cette incertitude épistémique. Et ils ont proposé d'adapter le modèle du réseau Bayésien de la fiabilité pour intégrer la théorie d'évidence et de produire par la suite un réseau d'évidence.

Certaines phénomènes dans le domaine de la fiabilité des systèmes doivent être prise en charge (dans un modèle) avec une nature continue, tels que les variables d'environnement et de fonctionnement, l'utilisation des variables continues avec des variables discrètes dans le même réseaux engendre ce qu'on appelle les réseaux Bayésiens hybrides, par conséquent, L'inférence des réseaux Bayésiens hybrides et la discrétisation des données continues de la fiabilité ont attirer l'intention des chercheurs [111], [112], [113].




Figure V.2 : La distribution des références sur les thèmes : Les RBD pour la fiabilité dynamique et les RBs pour la fiabilité.

Les méthodologies dynamiques (les arbres de défaillance dynamique, les arbres d'évènements dynamiques discrets, les chaînes de Markov) tentent à intégrer les processus dynamiques et stochastiques pour capturer la réponse dynamique d'un système (hardware /software) durant un scénario d'accident [104]. Les réseaux Bayésiens, plus précisément, leurs modèles dynamiques ont été aussi proposés pour l'estimation de la fiabilité dynamique [114], les réseaux Bayésiens dynamiques ont été utilisés pour estimer la fiabilité dynamique en intégrant l'aspect temporel dans plusieurs travaux [42], [102], [115-121].

La Figure V.2 montre que 31% des thèmes traités dans la littérature relative à l'application des réseaux Bayésiens dans le domaine de l'estimation de la fiabilité des systèmes concernent l'utilisation des réseaux Bayésiens dynamiques pour la modélisation de la fiabilité des systèmes dynamiques. L'étude statistique est faite sur environ 100 articles (qui représentent les contributions principales) publiés dans les journaux : RESS (*Reliability Engineering and System Safety*), IEEE (*Transactions On Reliability*), et QREI (*Quality And Reliability Engineering International*). Cette étude montre aussi que sur une période de 20 ans (de 1990 jusqu'au 2012), les chercheurs ont commencé à s'intéresser aux modèles dynamiques des RBs et leurs application dans l'estimation de la fiabilité dynamique au début des dix dernières années (à partir de 2003). L'intérêt se continue jusqu'à présent (début de l'année 2012, voir la Figure V.3).




Figure V.3 : Tendence des publications dans le domaine de l'estimation de la fiabilité des systèmes à base de réseaux Bayésiens statiques et dynamiques.

A la fin de cet aperçu général sur l'estimation de la fiabilité à base des réseaux bayésiens, nous pouvons tirer comme conclusion qu'il ya deux thèmes généraux à traiter dans ce domaine :

- L'estimation de la fiabilité en utilisant les réseaux bayésiens statistiques et leurs différentes variantes pour traiter les divers aspects de fiabilité.
- L'utilisation des réseaux Bayésiens dynamiques pour l'analyse de la fiabilité dynamique et l'intégration des facteurs exogènes influençant la fiabilité d'un système.

Par conséquent, le reste de ce chapitre est divisé en deux parties consacrées à l'étude du premier et deuxième thème respectivement.

V.3 LES MODELES STATIQUES DES RESEAUX BAYESIENS POUR MODELISER LA FIABILITE DES SYSTEMES

V.3.1 Construction directe des modèles de RB pour l'estimation de la fiabilité

La construction d'un modèle de RB modélisant un certain système en utilisant les connaissances des experts est une tâche difficile et consommatrice du temps. La collaboration d'un groupe de spécialistes est nécessaire. Un expert en matière de RB guide le processus de construction du modèle, il pose les questions appropriées au experts de domaine, et expliquent les hypothèses qui sont encodées dans le modèle au reste du groupe. D'autre part, les experts de domaine, fournissent leurs connaissances à l'expert en matière de RB d'une façon structurée. La familiarité des deux catégories des experts, chacun avec le domaine des autres est essentielle pour l'efficacité de la procédure de construction. L'expert en matière de RB devrait étudier le système à modéliser, et les analystes de fiabilité doivent avoir les connaissances de base sur les RBs. Dès que ceci sera établi, la construction de modèle procédera par un certain nombre de phases (illustrées sur la Figure V.4).

SIGURDSSON et al [105] montrent que les réseaux Bayésiens sont appropriés à la structuration, la gestion et la représentation des connaissances des experts et leurs jugements (avis) modélisant la fiabilité d'un système. Cependant, malgré les avantages des réseaux Bayésiens dans ce contexte, leur

utilisation directe implique que les analystes de fiabilité doivent se familiariser avec les RBs et abandonner les méthodes classiques de fiabilité. En outre, parmi les inconvénients des réseaux Bayésiens est qu'il n'y a pas sémantique qui guide le processus de construction du modèle, c'est un processus purement subjectif et nécessite l'intervention des spécialistes en science cognitive.

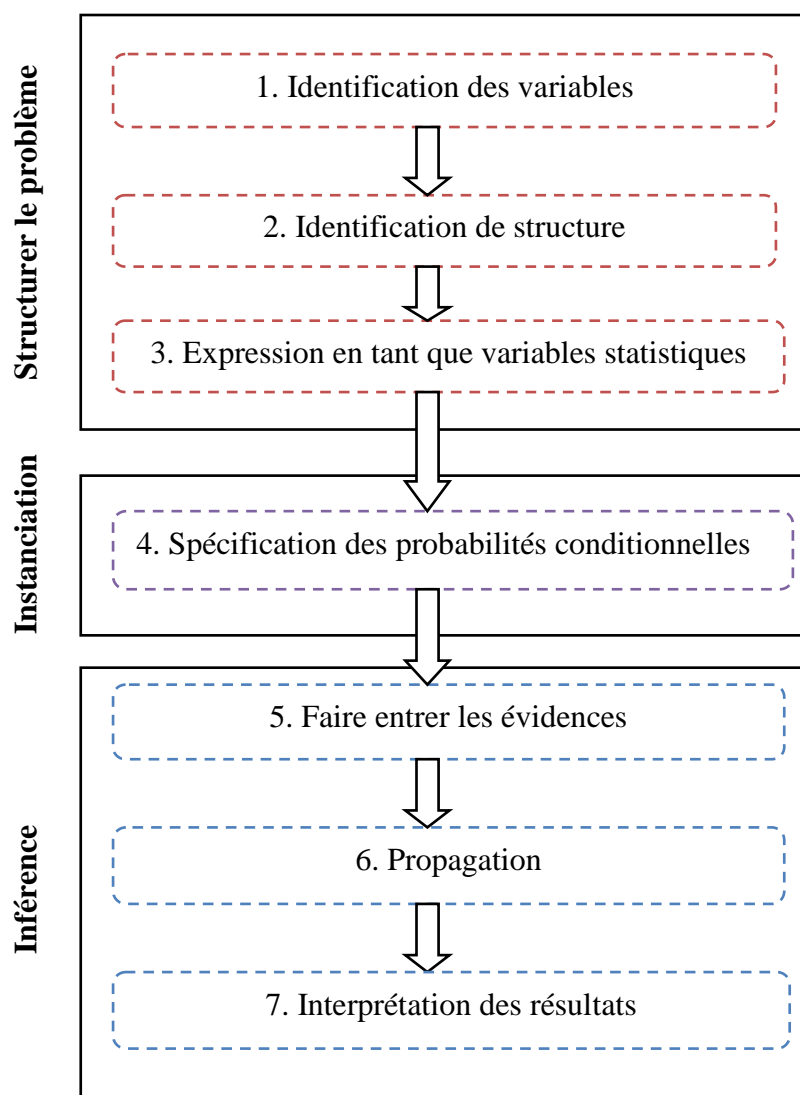


Figure V.4 : Les étapes de construction et d'utilisation d'un modèle de RB.

Pour se bénéficier des avantages des RBs dans l'estimation de la fiabilité sans passer par la procédure difficile de construction des modèles de RB, les chercheurs ont proposé deux solutions alternatives :

- ✓ la première solution consiste à développer des outils de conversion des modèles élaborés par les méthodes conventionnelles d'analyse

de fiabilité en des modèles de réseau Bayésien équivalents[101] , [106], [109], [110].

- ✓ La deuxième et la plus récente, elle n'est pas encore bien élaborée, consiste à trouver de nouvelles méthodes de construction telles que l'apprentissage automatique de modèle de RB représentant un système [102].

Dans ce qui suit, on présentera une étude synthétisée des travaux représentant les fondements de la première solution.

V.3.2 Construction des modèles de réseau Bayésien basée sur les méthodes classiques d'analyse de fiabilité

Dans cette partie, nous allons présenter les travaux de recherche les plus intéressants concernant l'utilisation des méthodes classiques d'analyse de fiabilité pour la construction d'un modèle de réseau Bayésien équivalent. Le réseau Bayésien généré est utilisé ensuite pour estimer la fiabilité du système modélisé.

V.3.2.1 Construction d'un modèle de réseau Bayésien pour l'analyse de fiabilité à base des arbres de défaillance

L'analyse des arbres de défaillance est une des techniques les plus populaires au milieu des ingénieurs de la fiabilité [101], [106]. Cette technique est basée sur l'identification d'un évènement indésirable particulier pour l'analyser (Par exemple la panne du système), cet évènement est appelé *évènement principal (EP)*. La construction de l'arbre de défaillance se fait par le mode haut/bas (Top/Down), de l'évènement à ses causes de défaillance jusqu'à l'obtention des défaillances des composants de base. Cette méthodologie est basée sur les hypothèses suivantes:

- Les évènements sont binaires (marche/ ne marche pas).
- Les évènements sont statistiquement indépendants.
- Les relations entre les évènements et les causes sont représentées par des portes logiques.
- La racine de l'arbre de défaillance est l'évènement indésirable à étudier.

L'analyse d'arbre de défaillance est réalisée en deux étapes, une étape qualitative dans laquelle une expression logique de l'évènement principal est dérivée en termes de d'ensembles de coupe minimale, et une étape quantitative dans laquelle, en se basant sur les probabilités de défaillance attribuée aux composants de base, la probabilité de l'occurrence de l'évènement principal et (les évènements internes correspondant à un sous système logique) est calculée [106].

Les réseaux Bayésiens peuvent améliorer la modélisation des systèmes faite traditionnellement, par les arbres de défaillance. En donnant un arbre de défaillance standard, il est tout à fait simple de le convertir en un RB équivalent avec des nœuds (variables) discrets, et toute analyse qui peut être faite en utilisant le formalisme de l'AD peut être également faite par l'inférence des RBs [101], [109], [110], [106].

V.3.2.1.1 Convertir un arbre de défaillance en un réseau Bayésien

Bobbio et al [106] proposent de convertir l'arbre de défaillance standard d'un système en un réseau Bayésien équivalent afin d'améliorer l'analyse de la fiabilité des systèmes. Pour ce faire, un algorithme de conversion a été proposé.




Figure V.5 : Arbre de défaillance : Porte logique OU.




Figure V.6 : Modèle de RB équivalent de la porte logique OU.

Un arbre de défaillance décrit le mécanisme de propagation de la panne dans un système. La fiabilité d'un système ou sa disponibilité est modélisée selon l'hypothèse de l'indépendance entre les événements affectant les entités. Considérant un modèle classique de la structure parallèle basé sur un arbre de défaillance (Porte logique OU), comme c'est représenté sur la Figure V.5, son modèle avec un réseau Bayésien est réalisé avec une «structure V» simple comme c'est représenté sur la Figure V.6 [106].

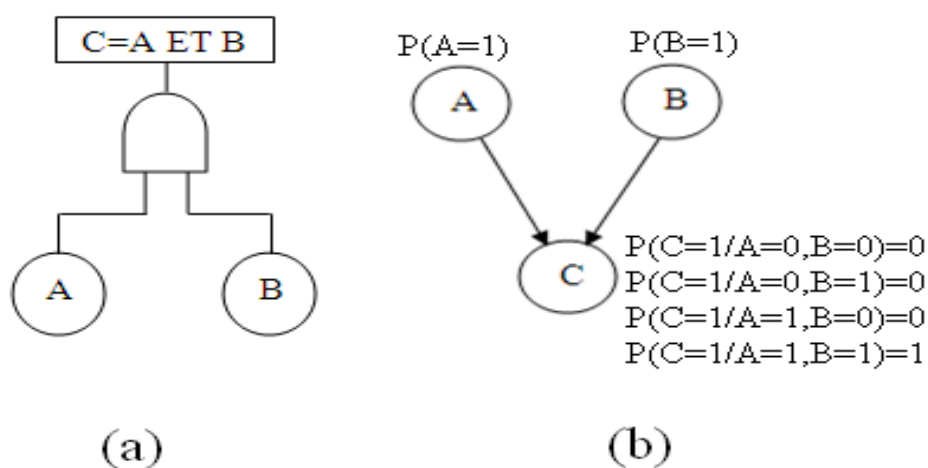


Figure V.7 : La porte logique ET d'un arbre de défaillance (a) et son modèle de RB équivalent (b).

La configuration séquentielle (Porte logique ET) est aussi modélisée par une structure V. les deux configurations séquentielle et parallèle sont modélisées par la même structure mais chacune d'elles a une table de probabilité conditionnelle différente. La porte logique K/N est modélisée par le même principe : les arcs vont des nœuds feuilles représentant les évènements de base au nœud qui représente la porte logique, la Figure V.8 montre un exemple de la porte logique K/N, où $K = 2$ et $N = 3$ et son modèle de RB équivalent.

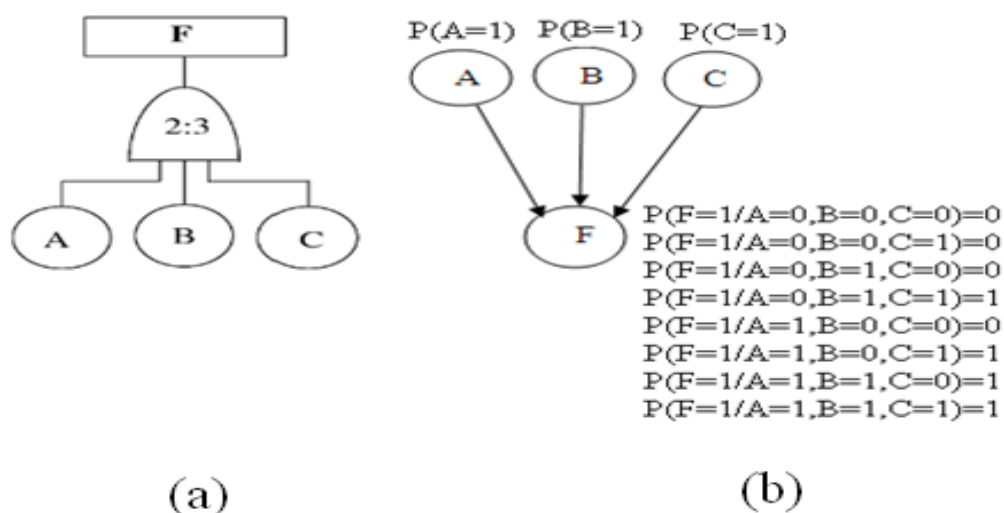


Figure V.8 : La porte logique K/N (2:3) d'un arbre de défaillance (a) et son modèle de RB équivalent (b).

Selon les règles de conversion des portes logiques de base d'un arbre de défaillance, ce dernier peut être converti directement en un RB binaire, c.-à-d. un RB avec des variables ayant deux valeurs valables: la valeur Faux (0), correspondant à un état de fonctionnement normal ou la valeur vraie (1) correspondant à u arrêt du fonctionnement ou un dysfonctionnement. L'algorithme de conversion procède le long des étapes suivantes [106]:

- Pour chaque nœud feuille de l'arbre de défaillance (un évènement primaire ou un composant du système), créer un nœud racine dans le réseau Bayésien équivalent. Cependant si plusieurs feuilles de l'AD représentent le même évènement de base (même composant du système), créer un seul nœud dans le RB.
- Attribuer aux nœuds racine dans le RB la même probabilité à priori (préalable) correspondante dans l'AD (calculée en donnant le durée de mission).
- Pour chaque porte logique créer un nœud correspondant dans le RB.
- Etiqueter la porte logique dont sa sortie est l'évènement principal de l'AD comme étant le nœud qui représente la défaillance du système.
- Connecter les nœuds de RB de la même façon dans laquelle, les portes logiques de l'AD sont connectées.

- Pour chaque nœud qui représente une porte dans le RB (OU, ET, K/N), Donner sa table de probabilité conditionnelle. (comme c'est montré dans les Figures V.5, V.6 et V.7, et V.8).

V. 3.2.1.2 Les portes Probabilistes pour modéliser les causes communes de défaillance

Contrairement aux arbres de défaillance, les relations d'indépendance entre les variables d'un réseau Bayésien ne sont pas déterministes. Ce qui donne la possibilité de modéliser l'incertitude dans le comportement des portes logiques, par la spécification adéquate des tables de probabilité conditionnelle. Les portes logiques probabilistes peuvent refléter une connaissance imparfaite du comportement du système, ou éviter la construction d'un modèle plus détaillé et raffiné. Un exemple typique est l'incorporation des causes communes de défaillance (CCD). Les causes communes de défaillance sont habituellement, modélisées par l'AD en ajoutant une porte logique 'OU', connectée directement à l'évènement principal, dans laquelle une des entrées est la panne du système et l'autre est la feuille CCD dont une probabilité de défaillance causée par des causes communes est attribuée. Dans le formalisme des réseaux Bayésiens une construction additionnelle de ce genre n'est pas nécessaire grâce aux dépendances probabilistes incluses dans les tables de probabilité conditionnelle. La Figure V.7 montre une porte 'ET' avec CCD et La Figure V.8 montre le RB correspondant. La valeur de L_{CCD} est la probabilité de panne du système dû à des causes communes quand un ou tous les deux composants sont en marche.




Figure V.9 : Arbre de défaillance : Porte logique K/N.




Figure V.10 : Modèle de réseau Bayésien équivalent de la porte logique K/N.

V.3.2.2 Les réseaux Bayésiens et la théorie d'évidence pour modéliser la fiabilité des systèmes complexes

Afin de traiter le problème de l'incertitude des données de fiabilité *SIMON et al* [109], [110] proposent d'adapter le formalisme des réseaux bayésiens en intégrant la théorie d'évidence. Le formalisme généré est appelé réseaux d'évidence.

V.3.2.2.1 Le formalisme de la théorie d'évidence

La théorie d'évidence, parfois appelée la théorie de la fonction de croyance, a été initiée par *Dempster* avec ses travaux sur les limites supérieures et inférieures d'une famille d'une distribution de probabilité et ils ont été renforcés par *Shafer*.

Sur certain aspect, la théorie d'évidence peut être vue proche de la théorie des probabilités. D'ailleurs, Le théorème Bayésien généralisé peut être trouvé dans la théorie d'évidence. Ce théorème présente un intérêt important pour les applications de la théorie de *Dempster-Shafer* par les algorithmes des réseaux bayésiens [109]. Dans ce cadre formel, il y a un processus d'allocation d'une quantité (la masse de croyance) s'étendant entre 0 et 1 aux différentes propositions (affectation de base de croyance). Ce procédé d'allocation est plutôt proche du cadre probabiliste, mais il est différent grâce à la possibilité d'assigner une quantité à tous les tuples de propositions [110].

V.3.2.2.2 Affectation de croyance de base

Le procédé d'allocation dans le cadre de la probabilité suit l'équation suivante:

$P: 2^\Omega \rightarrow [0,1]$ Tel que: (V.1)

$$P(\emptyset) = 0$$

$$\sum_{s_i^X \in \Omega} P(X = s_i^X) = 1$$

Où Ω se compose de chacune des propositions disjointes S_i^X (États établis dans l'étude de fiabilité) et \emptyset . Cette trame sert à élaborer les probabilités à priori sur les états des composants et les probabilités postérieures sur les états d'un sous-système. Dans la théorie d'évidence, l'attribution de croyance de base est faite par la fonction (V.1).

Si on considère par exemple, que les variables sont binaires alors :

$$\Omega = \{\text{en marche, en panne}\}$$

$$2^\Omega = \{\emptyset ; \text{en marche, en panne} ; \{\text{en marche, en panne}\}\}$$

Ainsi, la possibilité d'assigner une quantité à la proposition $\{\text{en marche, en panne}\}$ assouplit le cadre de probabilité. Le rôle de cette modalité de raisonnement est de caractériser notre ignorance sur l'état réel du composant. Il signifie que le composant peut être à l'état *en marche* ou *en panne*. Naturellement, il ne devrait pas être considéré que le composant peut être dans les deux états simultanément. Cette ignorance caractérise l'incertitude et $\{\text{en marche, en panne}\}$ est l'état épistémique.

V.3.2.2.3 Les réseaux d'évidences pour modéliser la fiabilité

Le formalisme de réseaux d'évidence proposé par *SIMON et al* [109] est basé comme mentionné ci-dessus, sur les réseaux Bayésiens. La partie qualitative (le graphe) du réseau est construit à partir de l'arbre de défaillance du système à modéliser. Ils considèrent les composants ou les fonctions avec des états binaires et les mêmes hypothèses de base des arbres de défaillance. Cependant les tables de probabilités conditionnelles et les probabilités à priori doivent être adaptées pour utiliser les outils des réseaux Bayésiens avec la théorie d'évidence.

A. Tables de masses conditionnelles

Cette adaptation consiste à transformer les tables de probabilité conditionnelle en tables de masse conditionnelle afin d'intégrer l'attribution de croyance de base et de décrire le mécanisme de propagation des défaillances. Les Tableaux V.11, V.12, et V.13 représentent les tables de masse conditionnelle pour respectivement, les portes ET, OU, et K/N (2/3).

La probabilité conditionnelle pour les modalités $\{En\ marche\}$ et $\{En\ panne\}$ peuvent être utilisées directement. La modalité $\{En\ marche, En\ panne\}$ caractérise notre ignorance de l'état du composant. Et comme un composant peut prendre seulement deux états définis, les masses conditionnelles de $\{En\ marche, En\ panne\}$ dans les tables de masse conditionnelle sont définies par la logique booléenne.

Par exemple, considérons la porte logique ET. Si le composant 1 est dans l'état $\{En\ marche\}$ et le composant 2 est dans l'état $\{En\ panne\}$ alors la sortie S3 est dans l'état $\{En\ marche\}$ mais si le composant 2 est dans l'état $\{En\ panne\}$ la sortie S3 est dans l'état $\{En\ panne\}$. Imaginons que l'état du composant 2 est dans l'état épistémique et peut être ainsi $\{En\ marche\}$ ou $\{En\ panne\}$, la sortie S3 peut être également dans les deux états $\{En\ marche\}$ ou $\{En\ panne\}$, on exprime cette ignorance de l'état de S3 en affectant une masse conditionnelle à l'état épistémique $\{En\ marche, En\ panne\}$. La table de masse conditionnelle pour la porte ET est établie et décrite dans le Tableau V.1.




Figure V.11: Réseau d'évidence de la porte logique ET.

Tableau V.1: La table de masse conditionnelle de la porte logique ET.

		S3		
C1	C2	{En marche}	{En panne}	{En marche, En panne}

{En marche}	{En marche}	1	0	0
	{En panne}	0	1	0
	{En marche, En panne}	0	0	1
{En panne}	{En marche}	0	1	0
	{En panne}	0	1	0
	{En marche, En panne}	0	1	0
{En marche, En panne}	{En marche}	0	0	1
	{En panne}	0	1	0
	{En marche, En panne}	0	0	1

Le même raisonnement a été effectué pour la construction de la table de masse conditionnelle de la porte logique OU (voir le Tableau V.2).




Figure V.12: Réseau d'évidence de la porte logique OU.

Tableau V.2: La table de masse conditionnelle de la porte logique OU.

C1	C2	S3		
		{En marche}	{En panne}	{En marche, En panne}
{En marche}	{En marche}	1	0	0
	{En panne}	1	0	0
	{En marche, En panne}	1	0	0
{En panne}	{En marche}	1	0	0

	{En panne}	0	1	0
	{En marche, En panne}	0	0	1
{En marche, En panne}	{En marche}	1	0	0
	{En panne}	0	0	1
	{En marche, En panne}	0	0	1

Comme le cas des portes logiques ET/OU, la table de probabilité conditionnelle de la porte logique K/N doit être convertie en une table de masse conditionnelle. La modalité *{En marche, En panne}* est introduite pour chaque état du composant et également la sortie. Par exemple, considérons une porte 2/3. Quand deux composants des trois sont dans le même état, la sortie est dans l'état de la majorité des composants. En outre, si deux composants parmi les trois sont dans des états opposés *{En marche}* et *{En panne}* l'état du troisième composant donne l'état de la sortie. Ainsi, si l'état de ce dernier composant est incertain, la sortie est également incertaine. Le tableau suivant montre la table de masse conditionnelle d'une porte logique **2/3**.




Figure V.13: Réseau d'évidence de la porte logique 2/3.

Tableau V.3: La table de masse conditionnelle de la porte logique 2/3.

			S3		
C1	C2	C3	{En marche}	{En panne}	{En marche, En panne}
{En marche}	{En marche}	{En marche}	1	0	0
		{En panne}	1	0	0
		{En marche,	1	0	0

		En panne}			
	{En panne}	{En marche}	1	0	0
		En panne}	0	1	0
		{En marche, En panne}	0	0	1
	{En marche, En panne}	{En marche}	1	0	0
		{En panne}	0	0	1
		{En marche, En panne}	0	0	1
{En panne}	{En marche}	{En marche}	1	0	0
		{En panne}	0	1	0
		{En marche, En panne}	0	0	1
	{En panne}	{En marche}	0	1	0
		{En panne}	0	1	0
		{En marche, En panne}	0	1	0
	{En marche, En panne}	{En marche}	0	0	1
		{En panne}	0	1	0
		{En marche, En panne}	0	0	1
{En marche, En panne}	{En marche}	{En marche}	1	0	0
		{En panne}	0	0	1
		{En marche, En panne}	0	0	1
	{En panne}	{En marche}	0	0	1
		{En panne}	0	1	0
		{En marche, En panne}	0	0	1
	{En marche, En panne}	{En marche}	0	0	1
		{En panne}	0	0	1
		{En marche, En panne}	0	0	1

Le développement de ces tables de masse conditionnelle rend possible la modélisation de la propagation de la panne dans le modèle de la fiabilité du système et également la façon dont l'incertitude est propagée sur la connaissance de l'état des composants. Ces propagations vont prendre lieu à partir des nœuds de parent ou des nœuds racines du réseau jusqu'aux nœuds enfants à travers le réseau afin de caractériser la fiabilité du système complet.

B. Fonctions de plausibilité et de crédibilité

Pour implémenter le calcul de la fonction de croyance et de la plausibilité dans l'outil de simulation des réseaux Bayésien, on sépare leur calcul dans deux

différents nœuds (**bel**, **pls**). Cette solution permet de libérer la contrainte additive inhérente à l'algorithme de réseaux Bayésiens qui n'existe pas en général dans le cadre de la théorie d'évidence. La table de masse conditionnelle (Tableau V.4) convertit la relation V.2 en réseau Bayésien pour calculer la plausibilité que le système est dans l'état $\{Up\}$, En outre, la modalité *NotBelieve* est introduite pour permettre au nœud de réseau Bayésien de respecter la contrainte additive.

$$Bel(X = s_i^X) = \sum_{s_j^X / s_j^X \in s_i^X} (X = s_j^X) \quad (V.2)$$

Tableau V.4 : Table de masse conditionnelle de la fonction de crédibilité **Bel**(Etat du système=En marche).

	Etat du système	{En marche}	{En panne}	En marche, En panne}
Bel (Etat du système=En marche)	<i>Crédibilité</i>	1	0	0
	<i>NonCrédibilité</i>	0	1	1

De la même façon, la table de masse conditionnelle (Tableau V.5) est définie pour calculer la fonction de plausibilité du système (relation 8) et présenter la modalité *NonPlausibilité* pour permettre au nœud de réseau Bayésien de respecter la contrainte additive.

$$Pls(X = s_i^X) = \sum_{s_j^X / s_i^X \cap s_j^X \neq \emptyset} (X = s_j^X) \quad (V.3)$$

Tableau V.5: Table de masse conditionnelle de la fonction de plausibilité **Pls**(Etat du système=En marche).

	Etat du système	{En marche}	{En panne}	En marche, En panne}
Pls (Etat du système=En marche)	<i>Plausibilité</i>	1	0	0
	<i>NonPlausibilité</i>	0	1	1

En outre, ces tables peuvent être utilisées pour calculer les fonctions de plausibilité et de crédibilité de chaque composant ou nœud du réseau afin de

fournir l'information sur les bornes de probabilité qui limitent la valeur réelle de la probabilité des sous-systèmes.

V.3.3 DISCUSSION

Comme résumé, on peut dire que le principe des approches de conversion des modèles élaborés par les méthodes conventionnelles d'analyse de fiabilité (Arbres de défaillance) en modèles de réseaux Bayésiens est le même dans toutes les différentes travaux illustrées dans la partie précédente, il consiste que les variables du réseau (nœuds) représentent les composants du système et les portes logiques reliant ces derniers, les liens (arcs) représentent les relations de dépendance entre les composants. Pour la partie quantitative les tables de probabilité conditionnelle représentent le degré (le niveau de force) des relations (liens).

Cependant, les capacités de modélisation des RBs sont plus larges. Ce qui permet d'intégrer plusieurs aspects de fiabilité traités difficilement et d'une manière insuffisante et insatisfaisante par les méthodes traditionnelles de fiabilité. En particulier, les RBs peuvent inclure des aspects comme :

- L'incertitude concernant les dépendances locales (c.-à-d. portes probabilistes).
- Variables Multi-état (c.-à-d., modes et comportements multiples).
- L'incertitude sur les paramètres des modèles.
- La dépendance entre les composants (par exemple, représenté par un environnement commun).

Toute analyse faite par les méthodes classiques d'analyse de fiabilité peut être faite par les modèles des RBs générés. Néanmoins, le mécanisme d'inférence des réseaux Bayésiens permet de faire une analyse meilleure, dans les deux sens diagnostique [107], et pronostic grâce aux algorithmes d'inférence.

V.3.3.1 Les variables Multi-Valeurs

L'utilisation des variables (Multi-états) ou n-vecteur variables peut être très utiles pour plusieurs applications [106]. Où il n'est pas suffisant de restreindre le comportement d'un composant à la dichotomie (En marche/En panne). Voici

quelques scénarios (typiques) ou c'a nécessite l'incorporation des composants multi-états :

- La présence possible des modes de défaillance divers;
- les différents effets des modes de défaillance sur le fonctionnement du système (panne dangereuse vs panne sans danger) ;
- ou bien divers niveaux de performance entre le fonctionnement normal et la panne du composant.

En utilisant des variables qui ont plusieurs modalités, les réseaux Bayésiens permettent de représenter des composants qui peuvent être dans des états multiples.

V.3.3.2 Les réseaux Bayésiens pour modéliser les modes de défaillance dépendants et la propagation de l'incertitude

Les réseaux Bayésiens fournissent un formalisme mathématique puissant pour modéliser les processus stochastiques complexes. En effet, cette méthode de modélisation est basée sur un modèle de graphe orienté sans circuits et pas un arbre. Donc, l'hypothèse de l'indépendance entre les événements (les défaillances) dans l'arbre de défaillance n'est pas nécessaire. En outre, le réseau Bayésien permet de calculer l'influence exacte des variables dépendantes sur la fiabilité du système. D'ailleurs, grâce aux tables de probabilité conditionnelle (TPC), les réseaux Bayésiens fournissent un modèle de la propagation de plusieurs modes de défaillance dans le système (les composants multi-états).

Les variables ne sont pas nécessairement booléennes, donc, il est possible de représenter un système composé de quelques entités avec plusieurs modes de défaillance sous une forme factorisée. La méthode d'analyse des modes de défaillance et leurs effets (AMDE) [108] permettent de déterminer les modes de défaillance liés à un composant. Il est également possible de présenter l'incertitude en plaçant les probabilités conditionnelles dans un intervalle de valeurs [0, 1].

Tableau V.5 : Tableau comparatif.

<u>Aspects de la fiabilité à traiter</u>	<u>Capacités des réseaux Bayésiens</u>	<u>Limites théoriques</u>	<u>Limites en pratique</u>
les composants de nature multi-états.	les nœuds (variables) dans un réseau Bayésien peuvent prendre plusieurs modalités représentant ainsi les composants dits multi-états.	/	L'augmentation de la taille des tables de probabilité conditionnelles proportionnellement au nombre des variables et le nombre des modalités de chaque variable (systèmes complexes) influence les résultats de calcul de fiabilité (les algorithmes d'inférence, problème NP-Difficile et parfois).
L'intégration des informations qualitatives et quantitatives.	Un réseau Bayésien peut contenir des nœuds (variables) discrètes et continues. Ce type de réseaux est appelé réseau Bayésien hybride	Les algorithmes d'inférence des réseaux bayésiens hybrides ne sont pas efficaces et la discrétisation des données continues de fiabilité pose des problèmes de précision des résultats obtenus par les algorithmes d'inférence.	/

La complexité des systèmes et le nombre important de leurs composants.	Les réseaux Bayésiens orienté objet ont été proposé pour manipuler ce genre de problèmes par conséquent ils sont très appropriés à la modélisation des systèmes complexe	/	
l'incertitude sur l'estimation des paramètres	Les tables de probabilité conditionnelle/ou les fonctions de densité de probabilité.	/	/

L'aspect temporel est un des aspects les plus importants de la fiabilité des systèmes. La compréhension, la modélisation et la représentation du comportement dynamique des systèmes est un challenge dans le cadre des systèmes modernes complexes. La partie restante de ce chapitre est consacrée à la présentation, l'étude et la discussion des travaux de recherche publiés traitant ce point en utilisant les réseaux Bayésiens et plus précisément leurs modèles dynamiques.

V.4 LES MODELES DYNAMIQUES DES RESEAUX BAYESIENS POUR MODELISER LA FIABILITE DYNAMIQUE

Les méthodes conventionnelles d'analyse de fiabilité statiques sont inadéquates pour la modélisation des interactions dynamiques entre les composants d'un système. Diverses techniques telles que les arbres de défaillance dynamiques, les chaînes Markov, et les blocs-diagramme dynamiques ont été proposées pour modéliser les systèmes dynamiques basés sur l'amélioration des méthodes de modélisation conventionnelles.



Figure V.14: Tendence des publications dans le domaine de l'estimation de la fiabilité dynamique à base de réseaux Bayésiens dynamiques.

Récemment, Les réseaux Bayésiens et plus précisément, leurs modèles dynamiques ont été proposés pour modéliser la fiabilité dynamique. Nous exposons dans cette section les travaux les plus intéressants et qui constituent les bases fondamentales de cette nouvelle méthode d'estimation de la fiabilité dynamique.

V.4.1 Construction des modèles de réseau Bayésien à base d'arbres de défaillance dynamiques pour modéliser la fiabilité dynamique

MONTANI et al [118] ont développé leur travail présenté en [106] explicité dans la section V.3.2.1.1 de ce chapitre en utilisant les réseaux Bayésiens dynamiques pour modéliser les portes logiques dynamiques des arbres de défaillance dynamiques.

Les arbres de défaillance dynamiques sont une amélioration des arbres de défaillance classiques, ils introduisent quatre (04) nouvelles portes logiques pour capturer des types complexes de dépendances appelées portes logiques dynamiques qui sont :

- La porte logique de dépendance fonctionnelle (FDEP)(The functional dependency gate).
- Les portes logiques cold, hot, and warm spare (CSP, HSP, WSP).
- La porte logique ET prioritaire (PAND)(priority AND gate).
- La porte logique (SEQ) (The sequence enforcing gate).

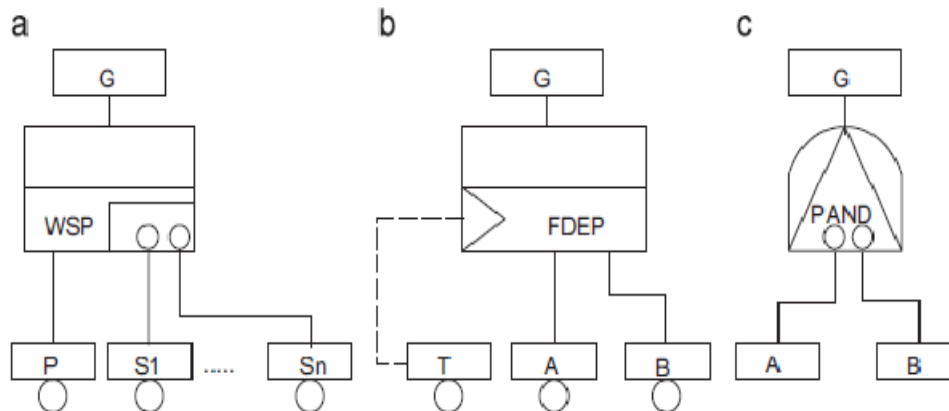


Figure V.15: Représentation graphique des portes logiques dynamiques WSP (a), FDEP (b) et PAND (c).

Ils ont utilisé un modèle particulier (spécifique) des réseaux Bayésiens dynamiques, le 2TBN (two time-slice bayes net) avec une représentation particulière appelée la forme canonique [121]. Les réseaux Bayésiens dynamiques modélisant les portes logiques dynamiques WSP, FDEP et PAND sont illustrés respectivement, sur les Figure V.16, V.17 et V.18.




Figure V.16: Le RBD représentant la porte logique WSP (a) [118].




Figure V.17: Le RBD représentant la porte logique PDEF (b) [118].




Figure V.18: Le RBD représentant la porte logique PAND (c) [118].

Les mêmes chercheurs présentent en [119] *RADYBAN* (Reliability Analysis with Dynamic Bayesian Networks), Un logiciel de conversion automatique d'un arbre de défaillance dynamique en un réseau Bayésien dynamique, un ensemble

d'algorithmes d'inférence des RBDs a été implémenté dans ce logiciel pour l'estimation de la fiabilité.

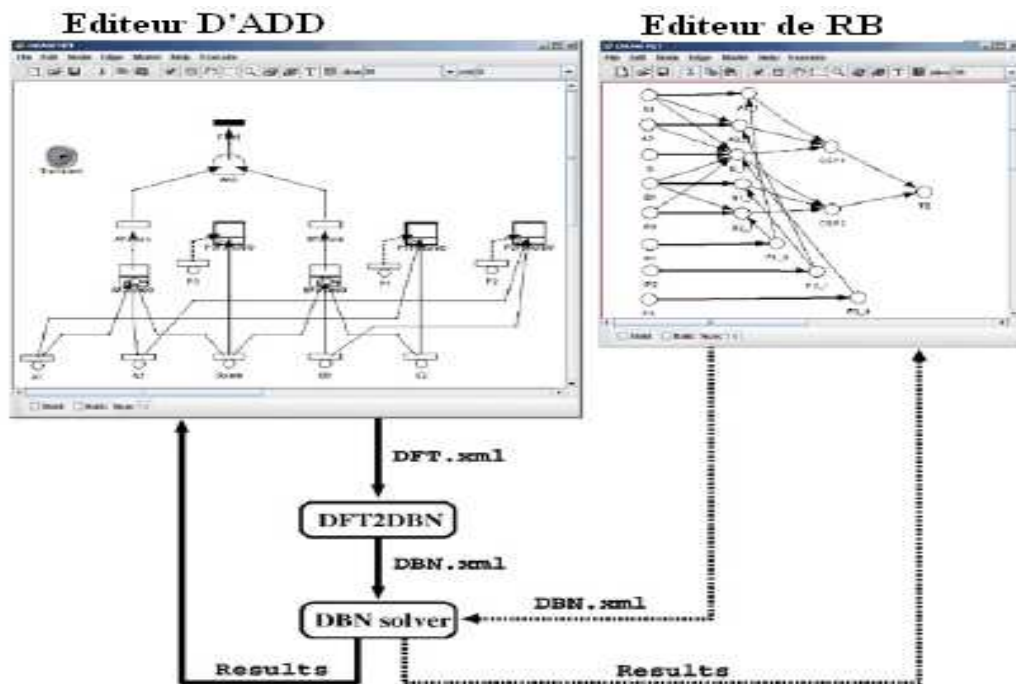


Figure V.20: Architecture du logiciel RADYBAN.

PORTINALE et al [120] présentent deux extensions importantes des ADDs, appelées: les portes logiques de dépendance probabiliste (Probabilistic Dependency Gates PDGs); Et les boîtes de réparation (Repair Boxes RBoxes). En particulier le processus de réparation est un aspect très important dans l'analyse de fiabilité.




Figure V.21: Représentation graphique des portes logiques PDG et RBoxes [120].

Les possibilités de modélisation offertes par les RBs ont permis de modéliser ces nouvelles portes logiques des ADDs, et d'exploiter la puissance des RBDs dans l'estimation et l'analyse de fiabilité. La conversion des portes logiques (PDG, Repair Boxes) en modèle de RBD est implémentée et intégrée dans le processus de compilation de *RADYBAN*, le logiciel développé en [119].

V.4.2 Réseau Bayésien Temporel Discret pour modéliser la fiabilité des systèmes dynamiques

BOUDALI et DUGAN [42], [116] ont développé un formalisme de Réseau Bayésien Temporel Discret (RBTD) pour modéliser la fiabilité des systèmes dynamiques, ils ont utilisé l'approche basée sur l'évènement pour la représentation de l'aspect temporel des réseaux Bayésiens, appelée réseau Bayésien Temporal d'Evènements [44].

Dans ce formalisme, chaque nœud (ou variable) représente un composant du système. Un composant du système peut être un composant de base ou un sous-système décrivant l'interaction entre une collection de composants. Dans un arbre de défaillance dynamique, un composant de base est un événement de base et un sous-système est représenté par une porte logique décrivant l'interaction entre ses entrées et sa sortie. Les variables sont discrètes et binaires, leurs états représentent la panne ou le bon fonctionnement du composant à un point dans le temps. Le réseau Bayésien équivalent (généré à partir de l'ADD) a un seul nœud feuille qui représente la panne globale du système.

Initialement, l'ADD est converti en un RB temporel discret équivalent, chaque événement de base de l'ADD est représenté par un nœud racine. Dans certains cas, quand des dépendances existent entre les événements de base (par exemple exclusion mutuelle), un événement de base n'est plus un nœud racine alors il possède des portes logiques et une TPC (Table de probabilité conditionnelle). Toutes les portes logiques (y compris la porte supérieure qui représente la panne du système) dans l'ADD sont des nœuds intermédiaires dans le RB possédant une TPC.

La traduction de l'ADD par un RBD est juste une première étape pour la définition de ce formalisme. Étendre l'ensemble des portes logiques de l'ADD pour inclure d'autres concepts (constructions) est la seconde étape. Les concepts

(constructions) sont essentiellement une manière de définir de nouveaux types de comportements et de dépendances entre les composants. Certaines de ces extensions incluent l'assurance imparfaite, exclusivité mutuelle, le délai.

V.4.2.1 Représentation de l'aspect temporel

Dans le RBD, un nœud X représente un composant de base du système ou la sortie d'une porte logique, X est en état x signifie que le composant de base ou la porte logique tombe en panne dans l'intervalle x de temps.

La ligne de temps est divisée en $n+1$ intervalles. Chaque nœud variable a un nombre fini de $n+1$ états. Les n premiers états divisent l'intervalle du temps $]0, T]$ (T est le temps de mission) en n intervalles (probablement) égaux, et le dernier état $n+1$ représente l'intervalle du temps $]T, +\infty[$. X est à l'état $n+1$ signifie que le composant de base correspondant ou la sortie de porte logique correspondante n'a pas tombé en panne pendant le temps de mission. n est un paramètre important pour l'exactitude de la solution et le temps d'exécution.

A. La Porte logique OU

Dans le cas des portes statiques (ET, OU, et K/M), les composants de base ont une probabilité de panne fixe, n est mis à un (1) et la solution est exacte. La valeur $P1$ de A (respectivement B) est égale à la probabilité de panne de A (respectivement B) durant le temps de mission T et $P2 = 1 - P1$. La TPC du nœud OU définit la probabilité de la sortie de la porte logique OU pour être à un certain état en donnant les états de A et de B .

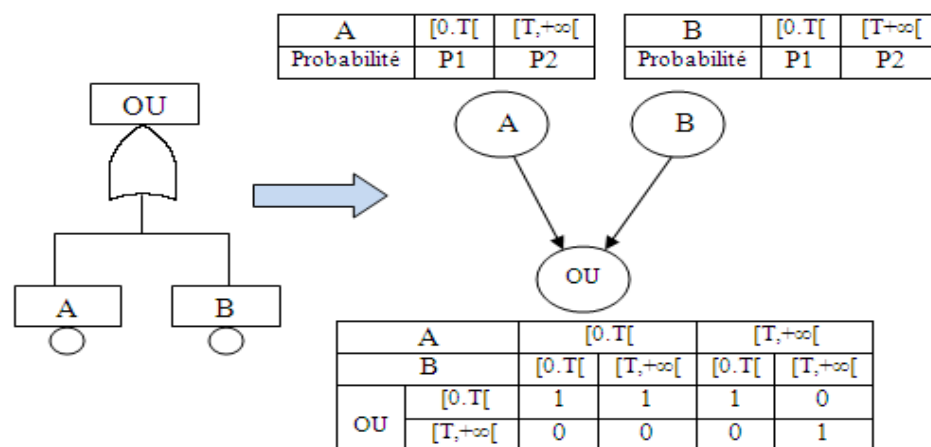


Figure V.22: La porte logique OU et son RBD équivalent.

B. La porte logique de CSP

Pour la clarté, $n=2$.

P1, P2, et P3 sont les probabilités que le composant primaire de base A tombe en panne dans respectivement les intervalles 1, 2, et 3 (3 étant A ne tombe pas en panne pendant le durée de mission).

Les entrées qui ont la valeur zéro de la TPC de nœud B signifie que le composant de réserve B ne peut pas tomber en panne avant, ou au même temps que le composant primaire A. La TPC de la sortie de porte logique CSP signifie que La sortie de CSP tombe en panne avec une probabilité égale à 1 quand le B de réserve tombe en panne.

Les TPCs peuvent être visualisé en tant que tables multidimensionnelles. Comme une règle générale la dimension d de la table est égale au nombre d'arcs entrants (c.-à-d. nombre des parents) plus un; c.-à-d $d = 1 + \{\text{Nombre des arcs entrants}\}$. En fait, il n'existe pas une seule structure de RB pour une porte logique donnée; et le but est de minimiser la dimension d des TPCs.

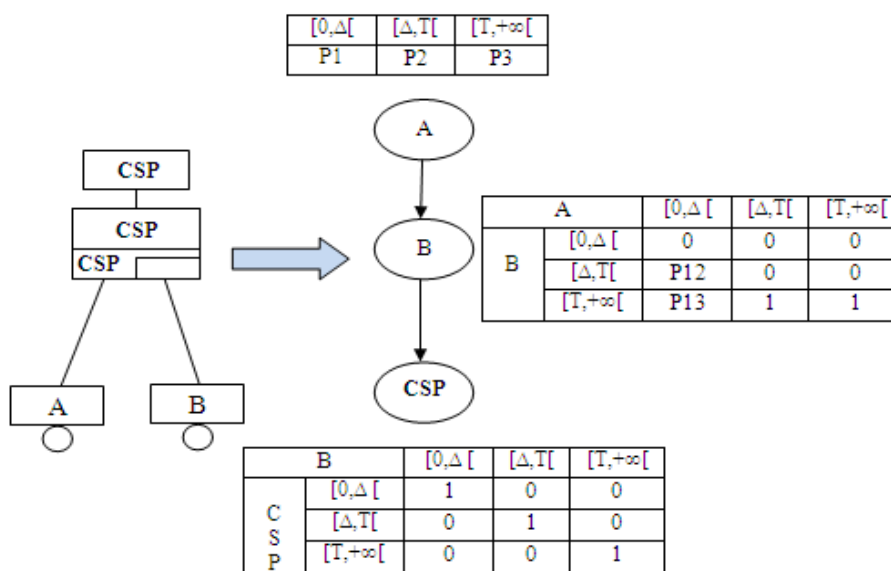


Figure V.23 : La porte logique CSP et son RBTD équivalent.

V.4.2.2 La table des probabilités à priori

En principe, les probabilités se sont associées à chaque intervalle de temps peuvent prendre n'importe quelle valeur indiquée. La seule condition est que la

somme des probabilités, de tous les intervalles, doit être égale à un (1). Cependant, dans la plupart des cas, l'utilisateur indique une distribution particulière de probabilité de panne.

En supposant que le composant A a un taux de panne fixe λ c.-à-d. une fonction de fiabilité exponentielle.

Par exemple, considérant le cas où la fonction de fiabilité du composant de base est exponentielle, $R(t) = e^{-\lambda t}$ (la distribution cumulative de panne, la fonction $F(t) = 1 - R(t) = e^{-\lambda t}$), et définissant $\Delta = T/N$ la longueur d'un intervalle de temps dans l'intervalle de temps de mission. La probabilité que le composant A tombe en panne dans l'intervalle de temps x est :

$$\begin{aligned} P\{A \text{ tombe en panne pendant } [(x-1)\Delta, x\Delta]\} &= \int_{(x-1)\Delta}^{x\Delta} F(t) dt = \int_{(x-1)\Delta}^{x\Delta} \frac{dF(t)}{dt} dt \\ &= \lambda \int_{(x-1)\Delta}^{x\Delta} e^{-\lambda t} dt = [e^{\lambda\Delta} - 1]e^{-\lambda x\Delta} \end{aligned}$$

Comme application numérique, regardons la probabilité que A, dans l'exemple de la porte logique CSP, tombe en panne dans divers intervalles de temps:

Assumer $T=1$, $n=2$, et $I \geq 1$, donc $\lambda=1/2$. Les intervalles de temps sont :] 0, Δ],

] Δ , 2 $\Delta = T$], et] T , $+\infty$ [. puis:

P {A tombe en panne dans le 1^{er} intervalle} est : $\left[e^{-\frac{\lambda}{2}} - 1 \right] e^{-\frac{\lambda}{2}} = 0.393$

P {A tombe en panne dans le 2^{eme} intervalle} est : $\left[e^{-\frac{\lambda}{2}} - 1 \right] e^{-\lambda} = 0.239$

P {A tombe en panne dans le 3^{eme} intervalle} est : $e^{-\lambda T} = 0.368$

V.4.2.3 Tables de probabilités conditionnelles TPCs

Les probabilités qui doivent être données dans la TPC d'un nœud intermédiaire dépendent de la sémantique définie par le nœud. Considérons l'exemple ci-dessus de la porte logique CSP. Pour le nœud B, la probabilité

conditionnelle de B tombe en panne dans l'intervalle y de temps étant donné que A a tombé en panne dans l'intervalle de temps x ($y > x$) doit être indiqué:

$P \{B \text{ tombe en panne dans } y / A \text{ a tombé en panne dans } x\}$ est :

$$= \frac{\int_{(x-1)\Delta}^{x\Delta} \int_{(y-1)\Delta}^{y\Delta} \lambda e^{-(b-a)} \lambda e^{-\lambda a} da db}{\int_{(x-1)\Delta}^x e^{-\lambda a} da} = \frac{\lambda \Delta \int_{(y-1)\Delta}^y e^{-\lambda b} db}{\int_{(x-1)\Delta}^x e^{-\lambda a} da} = \lambda \Delta e^{\lambda x \Delta} e^{-\lambda x \Delta}$$

Une fois la structure de RB est connue et toutes les tables de probabilité sont remplies, le calcul des probabilités résultantes que chaque variable de nœud peut être directement effectué. En particulier, la probabilité de la variable de nœud feuille, qui représente l'état global de système (c.-à-d. la porte supérieure dans l'arbre de défaillance).

V.4.3 Réseau Bayésien temporel continu pour modéliser la fiabilité des systèmes dynamiques

Le travail de *BOUDALI et DUGAN [117]* est une extension de leur formalisme (RBTD) développé en [42], [116]. La structure du réseau est la même, la différence est que, les variables dans le RBTD sont discrètes, tandis que dans le nouveau formalisme appelé Réseau Bayésien Temporal Continu (RBTC) sont continues. Par conséquent, Les probabilités conditionnelles deviennent des fonctions de densité de probabilité et la distribution de probabilité jointe devienne une fonction de densité de probabilité jointe.

V.4.4 Réseau Bayésien orienté objets dynamique pour modéliser la fiabilité des systèmes dynamiques complexe

La modélisation des systèmes contenant un nombre important de variables par les réseaux Bayésiens mène généralement à des modèles complexes. Pour éviter ce phénomène, *KOLLER et al [4]* ont défini une classe particulière des RBs, les Réseaux Bayésiens Orientés Objet (RBOO). Leur Modèle est basé sur la décomposition du réseau global à des niveaux hiérarchiques. Cette méthode de représentation permet de décentraliser et de structurer la connaissance dans les RBs avec une taille réduite. Les RBOOs sont alors très adaptée à la modélisation des systèmes industriels complexes.

La modélisation des systèmes complexes nécessite une méthodologie qui aide à spécifier la structure du réseau Bayésien et les états de ses variables. Des méthodes comme la technique de conception et d'analyse structurée (TCAS) et l'analyse des modes de défaillances et leurs effets (AMDE), ont été traditionnellement, utilisés dans la pratique pour analyser la fiabilité, *WEBER et al [115]*, ont essayé de formaliser un modèle de réseaux Bayésien en combinant les connaissances générés par ces méthodes.

V.4.4.1 Unification de système de la connaissance fonctionnement et dysfonctionnement

Le modèle est élaboré avant la mise en place du système, à ce moment-là, les choix technologiques principaux sont faits. Mais il est encore nécessaire de définir la logistique de maintenance, qui contribue à étendre les buts en termes de performance.

Le modèle de RB est conçu en utilisant deux méthodes : l'analyse fonctionnelle (TCAS) et l'analyse des défaillances du système (AMDE). La définition de l'environnement, les ressources externes, et les modes de défaillance sont formalisés au niveau de la fonction principale et la fonction élémentaire (FE). La description des défaillances et la fiabilité des composants est faite au niveau du composant (CMP).

L'approche de modélisation consiste à analyser le fonctionnement systémique du système en utilisant la représentation graphique de la méthode (TCAS). Et à représenter le dysfonctionnement (défauts de fonctionnement) en utilisant la méthode (AMDE) et puis à formaliser et unifier ces deux résultats dans un seul modèle grâce au RBOO.

Le fonctionnement et le dysfonctionnement du système sont duals et doivent être étudié ensemble pour contrôler chaque variable du système. Premièrement, se focaliser sur le fonctionnant du système en relation à son environnement et à ses ressources interne et externe. Cette action peut être faite en utilisant la représentation graphique TCAS. Cette modélisation est basée sur le principe de la décomposition fonctionnelle des composants, à partir des fonctions et des sous-fonctions aux fonctions élémentaires.

V.4.4.2 Modélisation de la fiabilité en utilisant les RBOO

La représentation de réseau Bayésien est basée sur la décomposition fonctionnelle du système. Les flux sont représentés par des variables aléatoires discrètes qui sont représentées à leur tour par les nœuds de RB. Cette représentation est structurée comme un arbre (voir la Figure V.24). Sa racine est un RBOO représentant le niveau d'abstraction le plus haut. Les fonctions élémentaires représentent les niveaux fonctionnels les plus bas modélisés par les RBs. Les connexions entre les sous fonctions sont modélisées par des fonctions logiques.

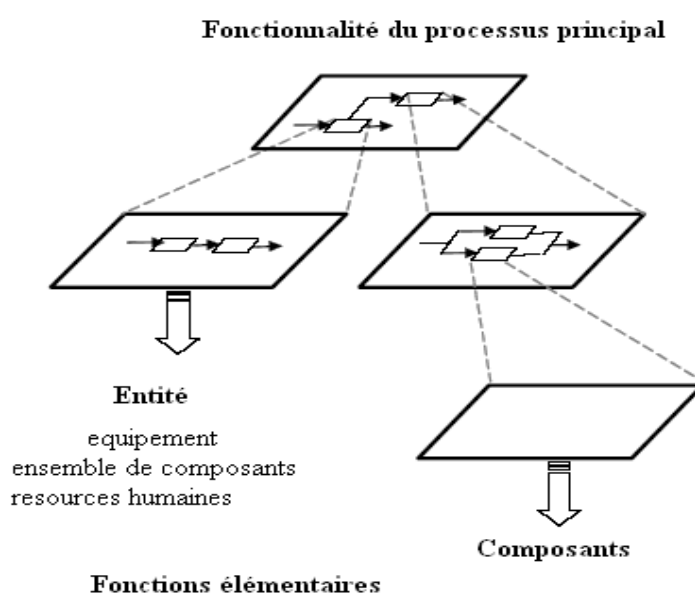


Figure V.24: Décomposition fonctionnelle [115].

Les RBOOs se composent des sous-fonctions génériques dans le haut niveau fonctionnel du modèle. Puis, une représentation unifiée peut être obtenue par la construction directe de RBOO à partir de l'analyse duale Fonctionnel/Dysfonctionnel. Pour garder le concept de la fonction générique, les entrées sont modélisées par des nœuds d'entrée définissant des variables aléatoires associées aux flux, AD, HD. La fonction générique représentée dans le formalisme de RB est donnée dans la Figure V.25.




Figure V.25: L'entrée générique de RB et la structure des nœuds de sortie [115].

Pour modéliser les niveaux fonctionnels élevés, Les RBOOs se composent des sous fonctions génériques qui sont structurées comme c'est montré dans Figure V.25. Quand la fonction mène à plusieurs missions, il est possible de reproduire plusieurs nœuds d'entrées ou de sorties (AD, HD...). D'ailleurs, il est également possible de modéliser des sous-fonctions en parallèle ou en série (Figure V.26).

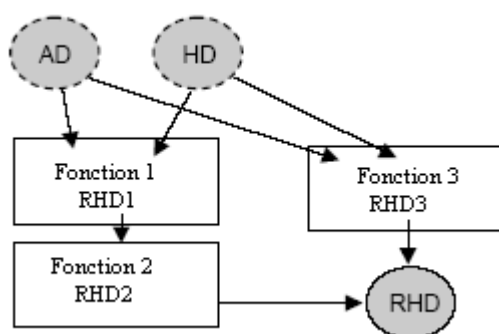


Figure V.26: Le niveau haut de la décomposition fonctionnelle [115].

Dans la Figure V.26, et comme les sous-fonctions génériques F1 et F2 sont en ligne, l'état RHD1 est transféré au F2 par l'entrée de flux HD. Comme les fonctions F2 et F3 forment une structure de V , le nœud RHD est lié à RHD2 et à RHD3 afin de calculer le RHD de la fonction globale. Les connexions entre les fonctions sont définies comme une TPC qui représente la propagation logique des modes de défaillance.

Les RBOO permet de décrire les systèmes grâce à l'architecture en série ou en parallèle des composantes. Cependant, les TPCs plutôt que les structures de RBOO constituent les relations des architectures séquentielles ou parallèles.

Ainsi, la même relation entre les fonctions peut être représentée par les deux structures différentes représentées dans les Figure V.27 et Figure V.28 Cette différence structurale n'a aucun impact sur le calcul de la fiabilité si le TPC est défini comme suit, où * est un opérateur logique représentant la relation entre les fonctions F 1 et F 2.

- Figure V.27: La TPC du nœud F3 a défini $\mathbb{P}(F3/F1, F2) = \mathbb{P}(F1) * \mathbb{P}(F2)$.
- Figure V.28: La TPC modélise la transformation $\mathbb{P}(X/F1, F2) = \mathbb{P}(F1) * \mathbb{P}(F2)$ et la TPC associé à F3 ($\mathbb{P}(X/F3)$) correspond à l'opérateur d'identité (c.-à-d. La diagonale de TPCs est égale à 1, toutes les autres probabilités étant égal à 0).

Ces deux structures sont alors équivalentes. Le choix d'une structure plutôt qu'une autre dépend de la spécificité du problème.




Figure V.27: RB : structure V.

Le modèle de RBOO offre la possibilité pour calculer la fiabilité de système. Cependant, l'équivalence entre les ADs et les RBs est vérifié seulement si les variables de système sont binaires. Cette hypothèse restrictive ne s'applique pas au RBs puisque ils permettent de considérer des variables discrètes aléatoires définies en fonction d'un ensemble d'états sans restriction. En bref, un RB peut toujours être transformé en un AD équivalent, mais l'inverse est faux. Par conséquent, modéliser les modes de défaillance par RBOO représente une augmentation de la précision en ce qui concerne le modèle de fiabilité.




Figure V.28: RB structure série.

V.4.5 DISCUSSION

Les Chaines de Markov Discret et Continues (CMD et CMC) sont très adaptées à la l'analyse de la fiabilité des systèmes dynamiques, néanmoins, leur inconvénient principal est l'explosion combinatoire du nombre des états, ce qui implique un temps de calcul exponentiel, D'où parmi les avantages principaux d'utilisation des réseaux Bayésiens dynamiques, quelle que soit l'approche utilisée est d'éviter ce problème, en outre les avantages des capacités de modélisation offertes par les modèles probabilistes graphiques cités dans la discussion de la première partie de ce chapitre.

Sans oublier que l'analyse de fiabilité peut être faite dans les deux sens [122], diagnostic et pronostic grâce aux algorithmes d'inférence. Ces avantages sont communs à toutes les approches présentées précédemment. Quoique chaque approches à ses avantages et ses inconvénient particuliers.

Tableau V. : Tableau comparatif des avantages et des inconvénients des méthodes : RBD, CM&ADD dans l'analyse de fiabilité.

<u>RBD</u>	<u>ADD&CM</u>
<ul style="list-style-type: none"> ils ont l'avantage de fournir un cadre unifié, dans lequel les composants statiques et dynamiques peuvent être 	<ul style="list-style-type: none"> Evénements binaires (deux états seulement : en marche/en panne).

<p>analysés.</p> <ul style="list-style-type: none"> • Exploiter toutes les capacités de modélisation des modèles graphiques probabilistes • Variables (Composants) multi-Etats • les dépendances locales entre les différentes composantes. • Modéliser l'interaction probabiliste entre le comportement des composants. • Mécanisme d'inférence générale, combinant la prédiction ainsi que le diagnostic peut être naturellement effectué sur un RBD. • Incertitude 	<ul style="list-style-type: none"> • L'hypothèse de l'indépendance entre les composants/ Evènements • Interaction déterministe entre les comportements des composants (Portes logiques ET/OU). • Analyse prédictive/ adductive implémenté difficilement dans l'analyse des ADD. • Explosion combinatoire du nombre des états modélisant un système.
-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------	-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

Les travaux de *BOBBIO et al [118]*, *MONTANI et al [119]* et *PORTINALE et al [120]* concrétisés par le logiciel *RADYBAN* ont permis aux experts de la fiabilité qui ne sont pas familiarisés avec les réseaux Bayésiens dynamiques d'exploiter (se bénéficier) la puissance et les avantages des RBD dans l'estimation et l'analyse de la fiabilité, sans qu'ils renoncent (abandonner) aux approches classiques (AD, ADD). Cependant, l'intervalle de l'étape de discrétisation influence les résultats de calcul de la fiabilité. Donc, les résultats obtenus en utilisant les RBD ne sont pas exactement identiques aux résultats obtenus en utilisant les CMC (la méthode adoptée habituellement pour l'analyse de la fiabilité des ADDs), en fait (as fact as matter, in fact) les deux méthodes ne sont pas exactement équivalentes. (trade-off) c'est un compromis entre l'approximation fournie par la discrétisation et l'effort nécessaire pour l'analyse: plus petite est l'étape de discrétisation, plus précise sont les résultats obtenus, et plus proche du calcul continu de cas. Le type des RBDs utilisé dans ces travaux est restreint (limité) aux systèmes markoviens.

L'utilisation de l'approche basée sur l'événement pour la représentation de l'aspect temporel dans les RBDs dans le formalisme de *Boudali et Dugan [116]*, *[117]* a permis d'éviter la complexité inutile de l'utilisation de l'approche Time-

Sliced, et d'appliquer ce formalisme à tous les systèmes et pas seulement aux systèmes Markoviens. Dans ce formalisme, La conversion d'un ADD en RB peut être automatisé, les TPCs et les tables de probabilité à priori sont définies selon la distribution de probabilité de la panne des composants de base et le type des portes les attachant. Il n'y a aucun besoin d'experts en matière de RB, la structure de RB et les tables de probabilité TPCs à priori peuvent être toutes, automatiquement dérivées du l'ADD. Néanmoins Ces travaux concernent seulement les systèmes non réparables, l'extension de ces travaux aux systèmes réparables reste une perspective.

Le travail *Weber et Jouffe [115]* présente un formalisme très intéressant pour la modélisation de la fiabilité des systèmes complexes, cependant un ensemble important de méthodes d'analyse de la fiabilité des systèmes tels que (AMDEC, SADT) est utilisé pour construire le modèle de réseau Bayésien, ce qui nécessite l'intervention de plusieurs experts du domaine de la fiabilité.

V. 5 CONCLUSION

A la fin de cet état de l'art sur les travaux de recherche menés sur l'utilisation des réseaux Bayésiens pour l'estimation et l'analyse de la fiabilité des systèmes statiques et dynamiques, on peut constater qu'il y a deux grands axes de recherche dans ce domaine. Le premier consiste à convertir le modèle conçu par une méthode classique d'analyse de fiabilité tels que les arbres de défaillance statiques et dynamiques (la méthode la plus utilisée) en un réseau Bayésien ou un réseau Bayésien dynamique équivalent, ce qui conduit à un modèle cohérent, mais limité par les contraintes imposées par les méthodes traditionnelles et ne permet pas d'exploiter tous les avantages de modélisation offerts par les réseaux Bayésiens et les réseaux Bayésiens dynamiques. Le deuxième axe consiste à trouver de nouvelles méthodes de construction de modèle de réseau Bayésien représentant le système à étudier, ce qui pose par la suite des problèmes de validation du modèle conçu.

CHAPITRE VI : RESEAUX BAYESIENS : UN MODELE DE GESTION DE CONNAISSANCES, APPLICATION A LA FIABILITE DES SYSTEMES

VI.1 INTRODUCTION

L'utilisation des réseaux Bayésiens pour la modélisation de systèmes complexes passe obligatoirement par la définition de la structure et des paramètres d'un RB. Depuis 1990, les travaux de recherche dans le domaine des RBs se sont essentiellement intéressés à l'apprentissage des réseaux Bayésiens lorsque toutes les variables sont connues (pas de variables latentes), et lorsque ces variables sont complètement observées (pas de données manquantes), problème lui aussi NP-Difficile.

La prise en compte de données incomplètes, comme la découverte de variables latentes, posent encore de sérieux défis en terme de complexité. La découverte de réseaux Bayésiens complètement causaux à partir de données est une question qui a été abordée plus récemment. Les travaux sur le sujet s'accordent sur le fait qu'il est impossible de travailler à partir de données d'observations uniquement. Les plans d'expériences, c'est à dire la façon dont les données ont été obtenues, sont des informations essentielles pour capturer la notion de causalité.

Nous présentons dans ce chapitre, notre approche basée sur les réseaux Bayésiens dynamiques proposée pour l'analyse et l'évaluation de la fiabilité dynamique. Des exemples pris de la littérature ont été utilisé pour valider l'approche proposée. Nous terminons ce chapitre par une discussion concernant l'apport apporté, les avantages et les inconvénients de l'approche proposée, tout en justifiant le choix des différents outils utilisés.

VI.2 UNE METHODE GENERIQUE POUR L'ANALYSE ET L'ESTIMATION DE LA FIABILITE A BASE DE RESEAUX BAYESIENS DYNAMIQUES

Les systèmes industriels modernes sont caractérisés par un ensemble de dépendances. Ces dépendances existent entre les composants du système et au même temps entre les composants et l'environnement de fonctionnement du système. L'influence du temps sur la dégradation ou la défaillance d'un système, en d'autre terme sur la fiabilité du système est un aspect très important pour l'analyse du risque de ce dernier, sa durée de vie et la planification des maintenances. Les méthodes classiques de la fiabilité intégrant cet aspect, telle que l'analyse des arbres de défaillance dynamiques ne traitent pas d'une façon efficaces cet aspect et elles ont beaucoup d'insuffisances.

Les chaînes de Markov sont appropriées à prendre en charge l'évolution temporelle d'un système d'une manière satisfaisante. Or, l'explosion combinatoire du nombre des états d'une chaîne de Markov représentant un système complexe moderne, rend cette méthode NP-Difficile impliquant un temps d'exécution exponentielle. Comme alternative, les réseaux Bayésiens dynamiques ont été proposés, comme vu dans le chapitre précédant, pour prendre en compte efficacement l'influence du temps sur la fiabilité d'un système et au même temps l'incertitude.

Les approches actuelles d'estimation de fiabilité à base de réseau bayésien utilisent un réseau Bayésien spéciale pour un système spécifique. La construction de modèle de réseau Bayésien fait appelle aux experts. Soit elle est effectuée directement en collaboration avec les experts du domaine et les experts des réseaux Bayésiens, les tables de probabilité conditionnelle sont données par les experts du domaine ; Soit la structure du réseau est données par l'expert du domaine en utilisant une méthode classique d'analyse de fiabilité, la méthode qui est souvent utilisée est l'analyse des arbres de défaillance, l'arbre de défaillance est converti ensuite en un réseau Bayésien et peut être enrichie par les avis des experts du domaine, les tables de probabilité conditionnelle à priori sont également données par les experts.

VI.2.1 Principe

Les méthodes proposées dans le cadre de l'apprentissage de structure ont transformé les réseaux bayésiens non seulement en outil de représentation des connaissances, mais aussi en outil de découverte de celles-ci.

Ainsi, nous proposons une méthode générique pour l'analyse et l'estimation de la fiabilité des systèmes. En exploitant les données de test ou de retour d'expérience (historical data) pour construire le modèle de réseau Bayésien dynamique. En d'autre terme la construction de réseau Bayésien qui modélise le système à étudier par apprentissage automatique et l'exploitation du modèle généré pour l'estimation de la fiabilité en utilisant le mécanisme d'inférence des RBDs.

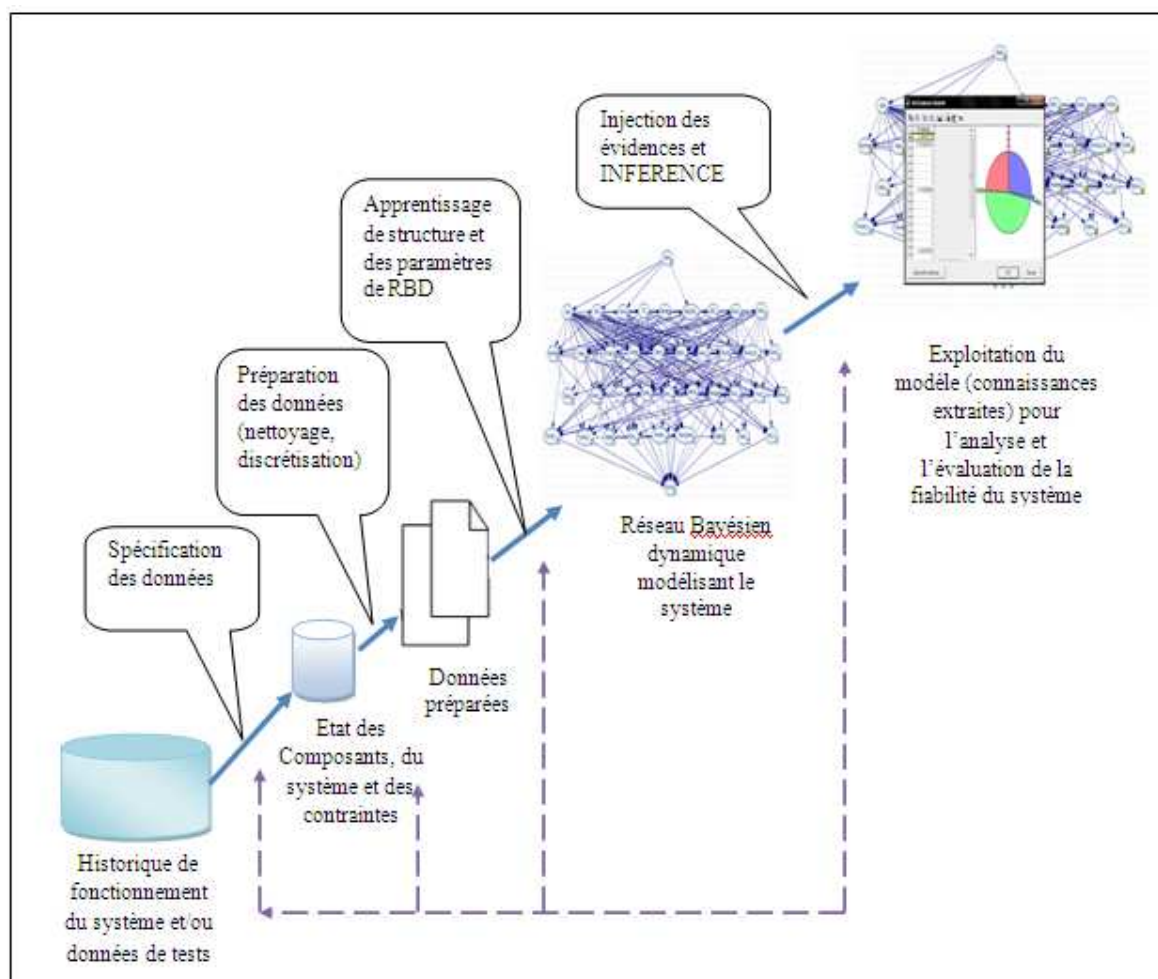


Figure VI.1 : Processus de découverte et d'exploitation des connaissances modélisant la fiabilité d'un système en utilisant les RBs.

VI.2.2 Construction et exploitation d'un modèle de RBD pour modéliser la fiabilité d'un système

Pour réaliser le processus d'extraction et d'exploitation de connaissances nécessaires à la modélisation de la fiabilité d'un système sous forme d'un réseau Bayésien dynamique, nous devons passer par les phases suivantes :

Phase N°1 : La première phase consiste à sélectionner les données dont l'exploitation permet de répondre à notre problématique « la modélisation de la fiabilité des systèmes ».

	B	C		D	E	F	G	H
2	N°	DATE ET HEURE		PUISS.	ENERGIE	CAUSE	COMMENTAIR	
3	GR	DEBUT	FIN	PERDUE	PERDUE			
5	1	31/déc/96 21:49	02/janv/97 00:47	168,00	4163,60	POSTE D'EAU	Fuite importante tuyauterie condensat réchauffeur H	
6	3	01/janv/97 00:27	01/janv/97 02:36	168,00	361,20	CHAUDIERE	Dt. groupe suite Dt. chaudière par niveau très bas b	
7	4	02/janv/97 08:00	02/janv/97 17:00	98,00	882,00	POSTE D'EAU	Indisponibilité des pompes alimentaires n°43 et n°42	
8	5	02/janv/97 07:30	02/janv/97 15:45	84,00	693,00	POSTE D'EAU	Indisponibilité des pompes alimentaires (n°53 pour le	
9	5	03/janv/97 02:40	03/janv/97 15:15	168,00	2114,00	CHAUDIERE	Dt. groupe suite niveau très très bas ballon chaud.	
10	3	05/janv/97 13:42	05/janv/97 14:59	168,00	215,60	MOD. ESSAI	Dt. groupe pendant essai contrôle vibratoire par équ	
11	3	07/janv/97 05:25	07/janv/97 19:19	168,00	2335,20	POSTE D'EAU	Reprise fuite importante par le clapet pompe alimente	
12	4	08/janv/97 15:20	08/janv/97 18:25	98,00	302,17	POSTE D'EAU	Indisponibilité des pompes alimentaires n°43 et n°42	
13	5	08/janv/97 07:00	08/janv/97 10:05	84,00	259,00	POSTE D'EAU	Indisponibilité des pompes alimentaires (n°53 pour le	
14	2	09/janv/97 16:16	09/janv/97 21:41	168,00	910,00	CHAUDIERE	Dt. groupe suite Dt. chaudière par perte alimentateu	
15	2	11/janv/97 18:00	12/janv/97 12:00	23,00	414,00	CHAUDIERE	Brûleur n°9 indisponible	
16	3	11/janv/97 22:31	12/janv/97 00:10	168,00	277,20	CHAUDIERE	Dt. groupe suite arrêt des 02 ventilateurs de soufflag	
17	4	11/janv/97 13:00	11/janv/97 17:00	68,00	272,00	CHAUDIERE	Recherche défaut s extinction des brûleurs 7,8 et 9	
18	4	11/janv/97 18:00	12/janv/97 18:00	84,00	2016,00	POSTE D'EAU	Indisponibilité des pompes alimentaires n°43 et n°42	
19	2	13/janv/97 19:07	13/janv/97 22:35	168,00	582,40	CHAUDIERE	Dt. groupe suite Dt. chaudière par pression gaz très	
20	2	13/janv/97 23:00	14/janv/97 10:00	28,00	308,00	CHAUDIERE	Perturbation combustible chaudière (transmetteur dé	
21	2	14/janv/97 22:41	16/janv/97 09:25	168,00	5835,20	CHAUDIERE	Reprise fuite importante de vapeur sur le débit neutre	
22	3	14/janv/97 12:28	14/janv/97 13:40	168,00	201,60	TURBINE	Dt. groupe suite défaut alimentation régulation turbin	
23	4	20/janv/97 07:00	20/janv/97 17:00	84,00	840,00	POSTE D'EAU	Travaux sur la soupape de débit nul PA n°42.	
24	1	26/janv/97 23:02	27/janv/97 23:02	168,00	4032,00	POSTE D'EAU	Reprise fuite importante condensat réchauffage. HP	
25	1	29/janv/97 10:00	29/janv/97 11:45	78,00	136,50	EAU DE MER	Reprise fuite eau de mer sur tuyauterie de charge 1/2	
26								

Figure VI.2 : Exemple des données prise de l'historique de fonctionnement d'une centrale thermique productrice d'énergie électrique.

Spécification des données : comme mentionné ci-dessus, les données collectées au long des années d'exploitation d'un système représentant ainsi l'historique de fonctionnement de ce dernier sont de différents formats. Chaque organisme

stocke ces données d'une manière différentes. Ces données contiennent essentiellement, les paramètres de fonctionnement des composants (tels que : la température, vibration ..., etc.), les pannes du système rencontrées, leurs causes et leurs durée ainsi que les maintenances faites et les problèmes détectés lors d'une maintenance programmée ou préventive (c.-a.-d, une maintenance effectuée périodiquement même si le système est en état de fonctionnement normal). Les systèmes complexes modernes sont équipés d'une commande numérique et des IHMs (Interface Homme Machine) qui permettent de gérer le système et connaître l'état de ses composants, représenté par leurs paramètres de fonctionnement via des capteurs. Par conséquent, toutes ces différentes informations sont stockées automatiquement.

Système	Sous système 1			Sous système 2			...	Sous système N		
Unité	Comp ₁₁	...	Comp _{1n}	Comp ₂₁	...	Comp _{2j}	...	Comp _{1N}	...	Comp _{nN}
T ₁	X ₁₁₁	...	X _{1n1}	X ₁₁₂	...	X _{1j2}	...	X _{11N}	...	X _{1nN}
T ₂	X ₂₁₁	...	X _{2n1}	X ₂₁₂	...	X _{2j2}	...	X _{21N}	...	X _{2nN}
⋮	⋮			⋮			⋮	⋮		
T _r	X _{T11}	...	X _{Tn1}	X _{T12}	...	X _{Tj2}	...	X _{T1N}	...	X _{TnN}

Figure VI.2 : Structure de données.

Afin de modéliser la fiabilité dynamique d'un système, nous avons besoins de l'état du système ainsi que l'état de ses composants à chaque instant t pendant une durée de fonctionnement T (Voir Figure VI.2), l'état du système et de ses composants peut se résumer à {en marche / en panne}, comme il peut prendre d'autres modalités, par exemple, un composant de réserve peut être en panne, en marche ou en attente. Nous pouvons rajouter aussi des variables qui représentent des contraintes exogènes telles que la température ambiante (facteur environnemental).

Spécification de méthodes du data Mining

Cette étape permet de définir la ou les familles de méthodes de data Mining qui peuvent être exécutées dans le processus de découverte de connaissances, telles que : les méthodes de classification, les méthodes de segmentation, les méthodes de règles d'association etc.

Nous allons employer une des méthodes d'apprentissage des réseaux Bayésiens dynamiques comme une technique de Data Mining. Par conséquent, l'apprentissage d'un RBD est utilisé comme un modèle de d'extraction de connaissances. La construction d'un modèle de réseau Bayésien par apprentissage peut être comparée à la discipline du Data Mining. L'apprentissage des réseaux Bayésiens est un outil de Data Mining et cet aspect peut être par conséquent d'un grand intérêt pour les chercheurs et les utilisateurs.

Représentation des résultats du data mining

Ceci réfère à la forme sous laquelle le résultat du data mining sera présenté. On peut choisir différentes techniques de visualisation (graphe, tableau, cube, etc.). Dans notre système les connaissances extraites seront représentées sous forme d'un réseau Bayésien dynamique. Ainsi, la partie graphique du réseau Bayésien indique les dépendances (ou indépendances) entre les variables et donne un outil visuel de représentation des connaissances, outil plus facilement appréhendable par ses utilisateurs. De plus, l'utilisation de probabilités permet de prendre en compte l'incertain, en quantifiant les dépendances entre les variables. En effet, nous avons utilisé le RBD comme un modèle de représentation de connaissances.

Phase N° 2: La seconde phase concerne la préparation des données sélectionnées lors de la phase précédente afin qu'elles soient facilement exploitées par les méthodes du data Mining.

Jusqu'à présent, il n'existe pas des algorithmes efficaces d'apprentissage des réseaux Bayésiens hybrides et en particulier les RBDs. Par conséquent, les données de nature continue doivent être discrétisées dans notre cas.

Les données incomplètes sont prises en compte par les algorithmes d'apprentissage des RBs. De ce fait, nous garderons les observations partielles du système. Ce problème est traité en utilisant l'algorithme d'apprentissage approprié. Or les résultats obtenus dans ce cas seront discuté ultérieurement.

Phase N° 3 : la troisième phase consiste en application d'une ou des techniques du data Mining sur les données traitées dans la phase précédente. Cette phase est le cœur du processus de découverte de connaissance.

Dans notre cas, nous allons utiliser une des méthodes d'apprentissage des réseaux bayésiens dynamiques. Le choix de type des réseaux bayésien dynamiques à employer, la méthode de construction de structure du réseau et la méthode d'apprentissage des paramètres sera explicitée ultérieurement. Néanmoins, nous rappelons que nous n'allons pas utiliser les réseaux Bayésiens en tant qu'un outil de découverte des règles d'associations (la méthode du Data Mining la plus approprié à nos besoins), mais en tant qu'un modèle d'extraction et de représentation de connaissances à part entière.

Avant d'entamer la phase de construction du modèle de réseau Bayésien dynamique modélisant la fiabilité d'un système. Il fallait tout d'abord, choisir entre l'approche basée sur l'évènement et l'approche basée sur les tranches du temps qui intègrent la dimension temporelle dans un réseau Bayésien. Chaque approche présente des avantages et des inconvénients dans le contexte de la modélisation de fiabilité.

L'approche basée sur les tranches du temps « time-sliced » à été choisie en se basant sur deux points très importants:

- Nous ne pouvons pas modéliser les systèmes réparables en utilisant l'approche basée sur l'évènement, c.-à-d., on ne peut pas étendre ce travail pour l'analyse du risque et la planification des maintenances.
- Le mécanisme d'inférence de l'approche basée sur l'évènement n'est pas bien développé, et le plus important, le mécanisme d'apprentissage de structure et des paramètres du réseau est complètement absent.

Les nœuds (variables) dans le modèle de réseau Bayésien dynamique proposé représentent les composants du système à étudier, les liens (arcs)

représentent les relations de dépendance entre les composants et les relations temporelles représentant le dynamisme du système. Des nœuds représentant les contraintes exogènes (de l'environnement et les conditions de fonctionnement du système) peuvent être rajoutés. Les arcs reliant ainsi les variables exogènes aux variables endogènes (les composants du système) indiquent avec précision l'impact (influence) de l'environnement et des conditions de fonctionnement sur la fiabilité du système.

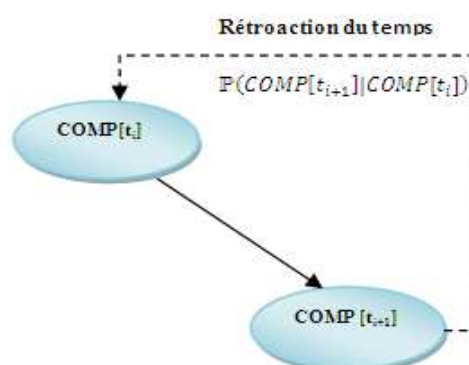


Figure VI.3: Modélisation la dégradation d'un composant à travers le temps (fiabilité) en utilisant le 2TBN.

Le modèle des réseaux Bayésiens dynamiques utilisé est le Two (2) slice Temporal Bayes Net (2TBN). Le 2TBN [2] est défini pour être une paire, (B_0, B_{\rightarrow}) où B_0 est un réseau Bayésien qui définit la distribution de probabilité antérieure $\mathbb{P}(X[0])$, et B_{\rightarrow} est un Réseau Bayésien Temporel à deux Tranche qui définit $\mathbb{P}(X[t]|X[t-1])$ par un DAG comme suit:

$$\mathbb{P}(X[t]|X[t-1]) = \prod_{i=1}^N \mathbb{P}(X_i[t] | Pa(X_i[t])) \quad (\text{VI.1})$$

Où $X_i[t]$ le $i^{\text{ème}}$ nœud à l'instant t , et $Pa(X_i[t])$ sont les parents de X_t^i dans le graphe. Les nœuds dans la première tranche d'un 2TBN n'ont pas de paramètres, mais chaque nœud dans la deuxième tranche du 2TBN a une distribution de probabilité conditionnelle associée (DPC), qui définit $\mathbb{P}(X_i[t] | Pa(X_i[t]))$ pour tout $t > 0$.

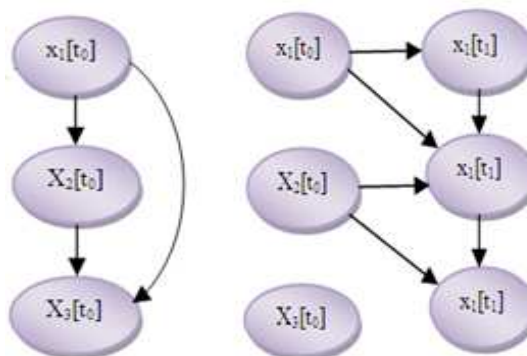


Figure VI.4: Un réseau à priori et un réseau de transition définissant un réseau Bayésien dynamique pour les attributs X_1, X_2, X_3 .

Les parents d'un nœud $Pa(X_i[t])$, peuvent être dans la même tranche du temps ou dans la tranche précédente, c.-à-d., nous supposons que le modèle est de Markov de premier ordre. Cependant, la plupart du temps c'est pour la simplicité d'écriture: il n'y a aucune raison fondamentale pour laquelle nous ne pouvons pas permettre à des arcs de sauter à travers des tranches. Les arcs entre les tranches sont de gauche à droite, reflétant l'écoulement causal du temps. S'il y a un arc de $X_i[t - 1]$ à $X_i[t]$, ce nœud s'appelle persistant. Les arcs dans une tranche sont arbitraires, à condition que le réseau Bayésien dynamique global soit un GOSC. Intuitivement, les arcs orientés dans une tranche représentent la causation "instantanée".




Figure VI.5: Le réseau Bayésien dynamique "déroulé" correspondant au réseau Bayésien de la Figure VI.4.

Nous assumons que les paramètres des distributions de probabilité conditionnelles sont constants c.-à-d., invariant dans le temps « time-invariant »

donc, le modèle est homogène dans le temps «time-homogeneous». Si les paramètres peuvent changer, on peut les rajouter à l'espace des états [2].

La sémantique d'un réseau Bayésien dynamique peut être définie "en déroulant" le 2TBN jusqu'à ce que nous ayons T tranches du temps. La distribution de probabilité jointe résultante est alors donnée par la formule suivante [2], [43]:

$$\mathbb{P}(X[0], \dots, X[T]) = \prod_{t=0}^T \prod_{i=1}^N \mathbb{P}(X_i[t] | Pa(X_i[t])) \quad (\text{VI. 2})$$

Le 2TBN est similaire au modèle markovien avec des variables dynamiques indépendantes. Il signifie qu'en calculant les variables à l'étape $(i+1)$, l'étape qui précède l'étape (i) , c.-à-d, l'étape $(i-1)$ est oubliée grâce à la propriété de Markov, qui dit que l'état future ne dépend que du présent.

VI.3.2 Construction du modèle de réseau Bayésien dynamique

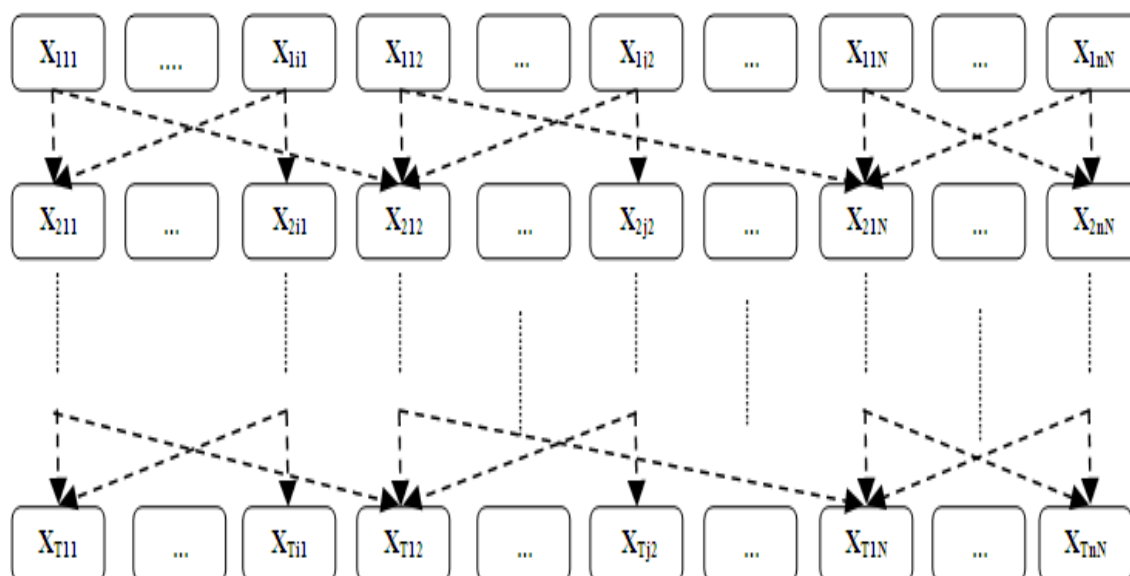


Figure VI.6: Les liens temporels et les états de transition dans un système complexe.

Nous supposons que nous avons une base de données D contenant N cas complètement observés sur I séquences du temps chaque séquence contient N_i cas. Tel que :

$$N = \sum_l N_l \quad (\text{VI.3})$$

Le système à modéliser contient n_c composants, et nous avons aussi, n_{ex} variables exogènes à représenter par conséquent, nous aurons n variables (nœuds).

Où, $n = n_c + n_{ex}$

Nous rajoutons une autre variable qui représente l'état du système en entier, donc le nombre total des variables est : $n + 1$.

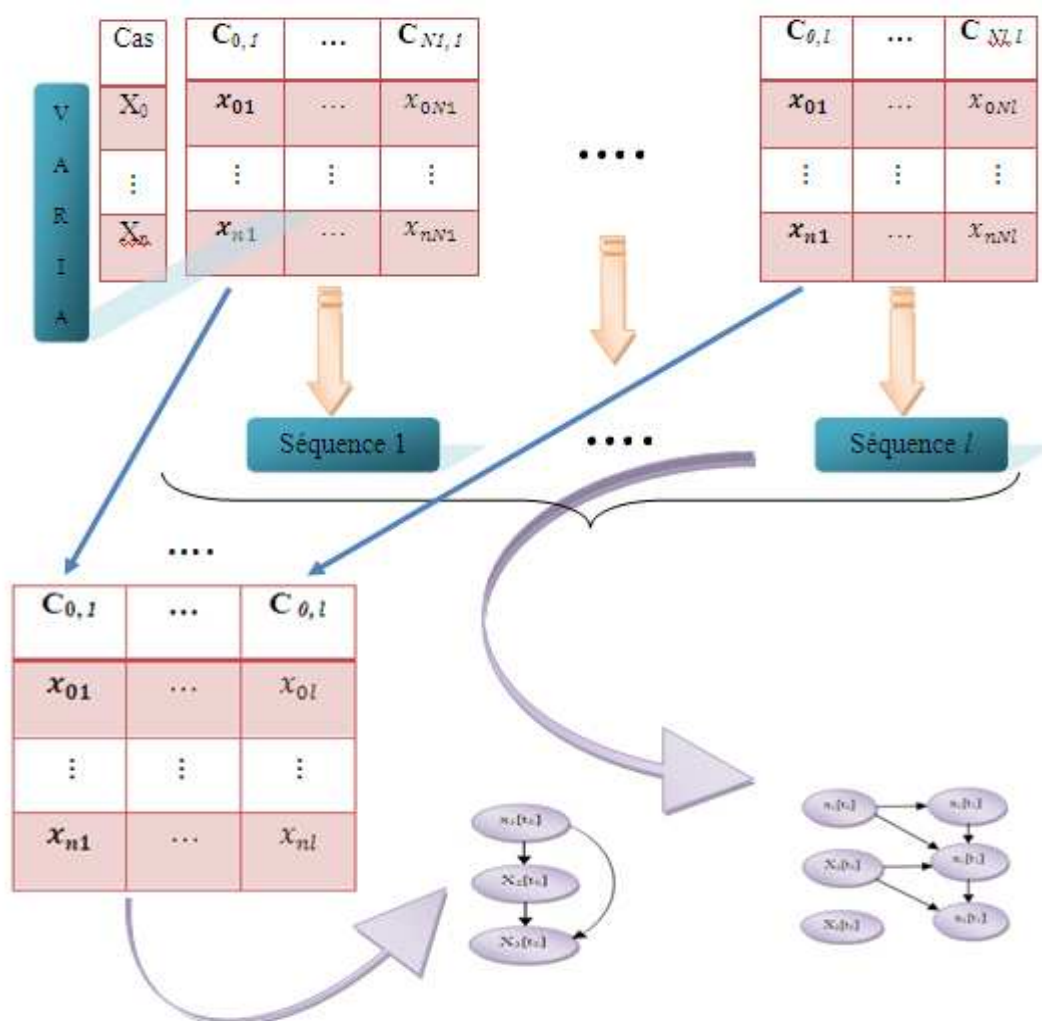


Figure VI.7: Schéma représentant l'apprentissage de structure du modèle à partir d'une base de cas.

VI.3.2.1 Apprentissage de structure du modèle

La structure initiale B_0 (celle de la première tranche du temps) est tirée de l'ensemble de données constitué du premier cas de chaque séquence. Alors, nous avons N_0 instances pour construire la structure du réseau à priori (initial), qui est construit indépendamment du réseau de transition, et en utilisant un des algorithmes d'apprentissage de structure des réseaux Bayésiens standards.

Nous avons aussi, N Instances de transitions à partir desquelles on peut tirer la structure du réseau de transition B_{\rightarrow} . Les relations de dépendance temporelles sont représentées dans ce réseau. La paire (B_0, B_{\rightarrow}) représente le réseau bayésien dynamique.

Il est à noter que pas nécessairement dans tout les cas, la structure de B_0 est différente de la structure qui se répète dans le reste des tranches du temps (c.-a-d, la partie statique du réseau de transition).

Comme mentionné ci-dessus, le lème séquence est de taille N_l et spécifie les valeurs des variables $\mathbf{X}^l[0], \dots, \mathbf{X}^l[N_l]$, où \mathbf{X} est le vecteur des variables.

FRIEDMAN et al ont décrit en [43] le score BIC et BDe dans le cas des réseaux Bayésiens dynamiques et ils ont montré que les résultats obtenus reflètent les résultats obtenus avec les réseaux probabilistes standards.

$$\theta_{i,j_i,\hat{k}_i}^{(0)} = \mathbb{P}(X_i[0] = \hat{k}_i | Pa(X_i[0]) = j_i) \quad (\text{VI. 4})$$

Et de la même manière

$$\theta_{i,j_i,k_i}^{\rightarrow} = \mathbb{P}(X_i[t] = k_i | Pa(X_i[t]) = j_i) \quad (\text{VI. 5})$$

Pour $t = 1, \dots, T$

$$N_{i,j_i,\hat{k}_i}^{(0)} = \sum_l I(X_i[0] = \hat{k}_i, Pa(X_i[0]) = j_i; \mathbf{X}^l) \quad (\text{VI. 6})$$

$$N_{i,j_i,k_i}^{\rightarrow} = \sum_l \sum_t I(X_i[t] = k_i, Pa(X_i[t]) = j_i; \mathbf{X}^l) \quad (\text{VI. 7})$$

Où $I(\cdot; X^l)$ est une fonction qui prend la valeur (1) si l'évènement . Apparaît dans la séquence X^l et elle prend la valeur (0) sinon.

La fonction de vraisemblance se décompose en fonction de la structure du réseau Bayésien dynamique exactement comme avec un réseau Bayésien statique.

$$\mathbb{P}(D|G, \theta_G) = \prod_i \prod_{j_i} \prod_{\hat{k}_i} (\theta_{i,j_i,\hat{k}_i}^{(0)})^{N_{i,j_i,\hat{k}_i}^{(0)}} \times \prod_i \prod_{j_i} \prod_{k_i} (\theta_{i,j_i,k_i}^{\rightarrow})^{N_{i,j_i,k_i}^{\rightarrow}} \quad (\text{VI.8})$$

D'où le log de vraisemblance est :

$$L(B: D) = \sum_i \sum_{j_i} \sum_{\hat{k}_i} N_{i,j_i,\hat{k}_i}^{(0)} \log \theta_{i,j_i,\hat{k}_i}^{(0)} + \sum_i \sum_{j_i} \sum_{k_i} N_{i,j_i,k_i}^{\rightarrow} \log \theta_{i,j_i,k_i}^{\rightarrow} \quad (\text{VI.9})$$

Cette décomposition facilite le calcul du score *BIC* et du score *BDe*. Premièrement, la vraisemblance est exprimée sous forme d'une somme de termes, où chaque terme dépend seulement à la probabilité conditionnelle d'une variable sachant ses parents. Donc si on veut calculer les paramètres de maximum de vraisemblance, on peut maximiser chaque famille indépendamment. Deuxièmement, la décomposition permet qu'on puisse trouver B_0 indépendamment de B_{\rightarrow} . et finalement, On peut faire l'apprentissage de B_{\rightarrow} de la même manière que l'apprentissage des réseaux Bayésien statiques.

Score BIC pour les réseaux probabilistes dynamiques :

En utilisant l'estimateur standard de maximum de vraisemblance pour les distributions multi-nominales, on aura l'expression de $\hat{\theta}_G$ suivante :

Le Score *BIC* est donné par la formule suivante :

$$BIC(G: D) = BIC_0 + BIC_{\rightarrow} \quad (\text{VI.10})$$

Où

$$BIC_0 = \sum_i \sum_{j_i} \sum_{\hat{k}_i} N_{i,j_i,\hat{k}_i}^{(0)} \log \hat{\theta}_{i,j_i,\hat{k}_i}^{(0)} - \frac{\log N_{seq}}{2} \#G_0 \quad (\text{VI.11})$$

et

$$BIC_{\rightarrow} = \sum_i \sum_{j_i} \sum_{k_i} N_{i,j_i,k_i}^{\rightarrow} \log \hat{\theta}_{i,j_i,k_i}^{\rightarrow} - \frac{\log N_{seq}}{2} \#G_{\rightarrow} \quad (\text{VI.12})$$

Score BDe pour les réseaux probabilistes dynamiques :

$$\mathbb{P}(D|G) = \int \sum_x \theta_x^N \mathbb{P}(\theta_x|G) d\theta_x = \frac{\mathbb{J}(\sum_x \hat{N}_x)}{\mathbb{J}(\sum_x (\hat{N}_x + N(x)))} \times \prod_x \frac{\mathbb{J}(\hat{N}_x + N(x))}{\mathbb{J}(\hat{N}_x)} \quad (\text{VI. 13})$$

$$\mathbb{P}(D|G) = \prod_i \prod_{j_i} \frac{\mathbb{J}(\sum_{\hat{k}_i} \hat{N}_{i,j_i,\hat{k}_i}^{(0)})}{\mathbb{J}(\sum_{\hat{k}_i} \hat{N}_{i,j_i,\hat{k}_i}^{(0)} + \hat{N}_{i,j_i,k_i}^{\rightarrow})} \times \prod_{\hat{k}_i} \frac{\mathbb{J}(\hat{N}_{i,j_i,\hat{k}_i}^{(0)} + N_{i,j_i,\hat{k}_i}^{(0)})}{\mathbb{J}(\hat{N}_{i,j_i,\hat{k}_i}^{(0)})} \quad (\text{VI. 14})$$

$$\text{Où } \hat{N}_{i,j_i,\hat{k}_i}^{(0)} = \hat{N}^{(0)} \times \mathbb{P}_{\hat{B}_0}(X_i[O] = \hat{k}_i | Pa(X_i[O]) = j_i) \quad (\text{VI. 15})$$

$$\text{Et } \hat{N}_{i,j_i,k_i}^{\rightarrow} = \hat{N}^{\rightarrow} \times \mathbb{P}_{\hat{B}^{\rightarrow}}(X_i[O] = k_i | Pa(X_i[O]) = j_i) \quad (\text{VI. 16})$$

VI.3.2.2 Apprentissage des paramètres du modèle

Une fois la structure du modèle de RBD est construit, la prochaine étape consiste à trouver les valeurs des paramètres du réseau (c.-a.-d, la table de probabilité conditionnelle de chaque nœud qui maximise la vraisemblance de la base de données d'apprentissage). Comme mentionné ci-dessus, la base de données d'apprentissage contient I séquences indépendantes. Les paramètres du modèle sont estimés en suivant la méthode utilisée en [51], [123].

L'avantage principal de faire l'apprentissage des paramètres à partir des données dans le cas de la fiabilité des systèmes est que nous n'avons pas obligé de chercher quelle distribution de probabilité (Exponentielle, Normale, Lognormal ...etc) représente le mieux la panne des composants du système et de calculer le taux de défaillance de chaque composant. L'ensemble des tables de probabilité conditionnelle représente d'une façon implicite la distribution de la fiabilité du système.

Phase N° 5 : Cette phase est la dernière phase, elle concerne l'interprétation et l'exploitation des connaissances extraites.

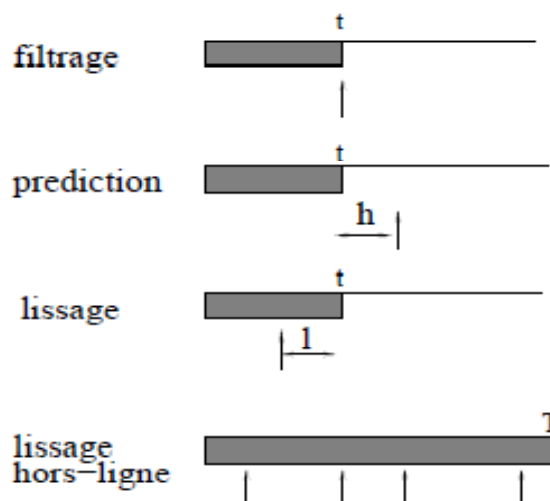


Figure VI.7 : Types d'inférence utilisés pour l'analyse et l'évaluation de fiabilité.

L'exploitation du modèle généré pour l'analyse de la fiabilité est faite via les algorithmes d'inférence qui offrent la possibilité de faire une analyse prédictive (cas d'algorithmes d'inférence de type prédiction), inductive et adductive du système modélisé (voir Figure VI.7).

- Filtrage : Calculer $\mathbb{P}(X_t | e_{1:t})$.
- Prédiction : Calculer $\mathbb{P}(X_{t+h} | e_{1:t})$ avec $h > 0$.
- Lissage : Calculer $\mathbb{P}(X_{t-l} | e_{1:t})$ avec $0 \leq l \leq t$.
- Lissage hors-ligne : Calculer $\mathbb{P}(X | e_{1:T})$ avec $\forall X \subseteq \prod_{t=0}^T X_t$.

Pour évaluer la fiabilité du système en utilisant le modèle généré, il suffit de calculer la probabilité de la variable S qui représente l'état global du système sachant que nous avons observé tous les composants ou une partie ou même dans le cas d'aucune observation.

VI.3 OPTIMISATION DU MODELE PROPOSE

VI.3.1 Métaheuristiques

La majorité des problèmes d'extraction de connaissances peuvent s'exprimer comme des problèmes d'optimisation combinatoire. Or, de nombreux problèmes d'optimisation combinatoire sont NP-difficiles et ne pourront donc pas être résolus de manière exacte dans un temps "raisonnable" puisque la capacité de calcul des machines évolue linéairement alors que le temps nécessaire à la résolution de ces

problèmes évolue exponentiellement. Lorsqu'on s'attaque à des problèmes réels, il faut se résoudre à un compromis entre la qualité des solutions obtenues et le temps de calcul utilisé.

Au milieu des années 1970 sont apparues des méthodes qui supervisent l'évolution de solutions fournies par des heuristiques [124]. Ces méthodes assurent un compromis entre diversification – quand il est possible de déterminer que la recherche se concentre sur de mauvaises zones de l'espace de recherche – et intensification – on recherche les meilleures solutions dans la région de l'espace de recherche en cours d'analyse. Ces algorithmes ont été appelés «Métaheuristiques» et ont pour objectif de trouver des solutions dont la qualité est au-delà de ce qu'il aurait été possible de réaliser avec une simple heuristique.

Nous introduisons dans cette section différentes méthodes classiques d'optimisation (Métaheuristiques) classées en deux groupes : les méthodes à solution unique et les méthodes à population de solutions. Nous verrons, pour chaque méthode, ses différentes applications dans l'extraction de connaissances en insistant sur: la fonction d'évaluation, la représentation des solutions, les opérateurs.

VI.3.1.1 Les métaheuristiques à solution unique

Les méthodes itératives à solution unique sont toutes basées sur un algorithme de recherche de voisinage qui commence avec une solution initiale, puis l'améliore pas à pas en choisissant une nouvelle solution dans son voisinage [124].

VI.3.1.1.1 Les méthodes de descente (Hill Climbing)

Les méthodes de descente sont assez anciennes et doivent leur succès à leur rapidité et leur simplicité [125]. A chaque pas de la recherche, cette méthode progresse vers une solution voisine de meilleure qualité. La descente s'arrête quand tous les voisins candidats sont moins bons que la solution courante ; c'est-à-dire lorsqu'un optimum local est atteint.

On distingue différents types de descente en fonction de la stratégie de génération de la solution de départ et du parcours du voisinage : la descente déterministe, la descente stochastique et la descente vers le premier meilleur.

Algorithme : Méthode de descente générique [124].

Procédure : φ fonction de coût

Variable locale : solution courante S

Choix d'une solution initiale S_0

Solution courante $S \leftarrow S_0$

(a.) Génération des candidats par voisinage ;

Choix du meilleur candidat C

IF $\varphi(C) < \varphi(S)$ THEN

$S \leftarrow C$;

Aller en (a.) ;

END IF

RETURN S

VI.3.1.1.2 Le recuit simulé (Simulated Annealing)

Le recuit simulé est une technique d'optimisation de type Monte-Carlo généralisé à laquelle on introduit un paramètre de température qui sera ajusté pendant la recherche [126]. Elle s'inspire des méthodes de simulation de Metropolis (années 50) en mécanique statistique. L'analogie historique s'inspire du recuit des métaux en métallurgie : un métal refroidi trop vite présente de nombreux défauts microscopiques, c'est l'équivalent d'un optimum local pour un problème d'optimisation combinatoire. Si on le refroidit lentement, les atomes se réarrangent, les défauts disparaissent, et le métal a alors une structure très ordonnée, équivalente à un optimum global.

La méthode du recuit simulé, appliquée aux problèmes d'optimisation, considère une solution initiale et recherche dans son voisinage une autre solution de façon aléatoire. L'originalité de cette méthode est qu'il est possible de se diriger vers une solution voisine de moins bonne qualité avec une probabilité non nulle. Ceci permet d'échapper aux optima locaux. Au début de l'algorithme, un paramètre T , apparenté à la température, est déterminé et décroît tout au long de l'algorithme pour tendre vers 0. De la valeur de ce paramètre va dépendre la probabilité d'acceptation des solutions détériorantes (plus la température T est élevée, plus cette probabilité sera forte).

La performance du recuit simulé dépend, entre autres, de la règle de refroidissement (c'est à dire la décroissance du paramètre T) que l'on utilise. Un refroidissement trop rapide mènerait vers un optimum local pouvant être de très mauvaise qualité. Un refroidissement trop lent serait très coûteux en temps de calcul. Le réglage des différents paramètres (température initiale, nombre d'itérations par palier de température, décroissance de la température, ...) peut être long et difficile.

Algorithme : Méthode générique de recuit simulé [124].

Procédure : φ Fonction de coût \mathbb{P} affectation selon une probabilité \mathbb{P}

Variable locale : S solution courante, T température courante, M meilleure solution, K palier de température T_i , suite de température

Choix d'une solution initiale S_0

Solution courante $S \leftarrow S_0$

Meilleure solution $M \leftarrow S$

Température courante $T \leftarrow T_0$

while Suivant $(T, T_i) \neq NULL$

 Itération de palier $I \leftarrow 1$

while $I < K$ **do**

 Génération d'un candidat C par opération de voisinage

$\Delta = \varphi(C) - \varphi(S)$

if $\Delta < 0$

$S \leftarrow C$

if $\varphi(C) < \varphi(M)$

$M \leftarrow S$

end if

else

 Mise à jour probabilité $\mathbb{P} \leftarrow e^{-\frac{\Delta}{KT}}$

$S \stackrel{\mathbb{P}}{\leftarrow} C$

end if

$I \leftarrow I + 1$

$T \leftarrow \text{suivant}(T + T_i)$

end while

end while

Return S

Le recuit simulé a également été utilisé dans des hybridations avec des méthodes Tabou (voir paragraphe suivant). L'intérêt de ces méthodes est qu'il existe une preuve de la convergence asymptotique. Ainsi, lorsque certaines conditions sont vérifiées (schéma de décroissance particulier), on a la garantie d'obtenir la solution optimale. Malheureusement, le paramétrage recommandé par

la théorie n'est pas réaliste et il faut beaucoup de temps pour arriver à paramétrer ces méthodes.

VI.3.1.1.3 La recherche Tabou (Tabu search)

La recherche Tabou a été introduite par *GLOVER* [127] et a montré sa performance sur de nombreux problèmes d'optimisation. Les idées de bases de la recherche Tabou se retrouvent également dans le travail de *HANSEN* [128]. Elle n'a aucun caractère stochastique et utilise la notion de mémoire pour éviter de tomber dans un optimum local. Le principe de l'algorithme est le suivant : à chaque itération, le voisinage (complet ou sous ensemble de voisinage) de la solution courante est examiné et la meilleure solution est sélectionnée.

En appliquant ce principe, la méthode autorise de remonter vers des solutions qui semblent moins intéressantes mais qui ont peut être un meilleur voisinage. Le risque est de cycler entre deux solutions. Pour éviter les phénomènes de cyclage, la méthode a l'interdiction de visiter une solution récemment visitée. Pour cela, une liste taboue contenant les attributs des dernières solutions visitées est tenue à jour. Chaque nouvelle solution considérée enlève de cette liste la solution la plus anciennement visitée. Ainsi, la recherche de la solution courante suivante se fait dans le voisinage de la solution courante actuelle sans considérer les solutions appartenant à la liste taboue.

Cette méthode ne s'arrête pas d'elle-même et il faut déterminer un critère d'arrêt en fonction du temps de recherche que l'on s'octroie. Ce critère peut être, par exemple, l'exécution d'un certain nombre d'itérations ou la non-amélioration de la meilleure solution pendant un certain nombre d'itérations. Ainsi, tout au long de l'algorithme, la meilleure solution doit être conservée car l'arrêt se fait rarement sur la meilleure solution.

Il existe de nombreuses variantes de recherches Tabou impliquant des techniques plus ou moins sophistiquées pour intensifier ou diversifier la recherche.

Algorithme : Méthode générique de Tabou [124].

Procédure : φ fonction de coût

Variables locales: S solution courante, liste tabou L , Meilleure solution M , itération courante, nombre d'itération N .

Paramétrages : Taille de la liste Tabou, Critère d'aspiration
 Choix d'une solution initiale S_0
 Solution courante $S \leftarrow S_0$
 Meilleure solution $M \leftarrow S_0$
 $K \leftarrow 0$
while $S < S_0$ **do**
 $K \leftarrow K + 1$
 Mise à jour de L
 Génération des candidats E par opération de voisinage
 $C \leftarrow best(E)$
 if $(\varphi(S) < \varphi(M))$ OU C n'est pas tabou OU C vérifie l'aspiration **then**
 $S \leftarrow C$
 else
 $E \leftarrow E / C$
 end if
end while
Return S

VI.3.1.2 Les métaheuristiques à population de solutions

Les méthodes d'optimisation à population de solutions améliorent, au fur et à mesure des itérations, une population de solutions. L'intérêt de ces méthodes est d'utiliser la population comme facteur de diversité.

VI.3.1.2.1 Les algorithmes génétiques (Genetic Algorithms)

Il existe de nombreux algorithmes évolutionnaires et nous ne pouvons pas parler des algorithmes génétiques sans mentionner les méthodes de programmation évolutionnaire développée par *FOGEL* [129] et les stratégies évolutionnaires développées indépendamment par *RECHENBERG* [130] et *SCHWEFEL* [131]. Ils ont contribué énormément à l'intérêt porté aux algorithmes évolutionnaires.

Les algorithmes génétiques sont des méthodes basées sur les mécanismes biologiques tels que les lois de Mendel et sur le principe fondamental (sélection) de Charles Darwin. *HOLLAND* exposa les principes de ces algorithmes pour permettre aux ordinateurs "d'imiter les êtres vivants en évoluant" pour rechercher la solution à un problème [131]. Il expliqua d'abord comment ajouter de l'intelligence dans un programme informatique avec les croisements (échange du matériel génétique) et la mutation (source de la diversité génétique).

Il formalisa ensuite les principes fondamentaux des algorithmes génétiques:

- La capacité de représentations élémentaires, comme les chaînes de bits, à coder des structures complexes.
- Le pouvoir de transformations élémentaires à améliorer de telles structures.
- Plus récemment, Goldberg enrichit la théorie des algorithmes génétiques en s'appuyant sur le parallèle suivant :
 - Un individu est lié à un environnement par son code d'ADN,
 - Une solution est liée à un problème par son indice de qualité,
 - Une "bonne" solution à un problème donné peut être vue comme un individu susceptible de survivre dans un environnement donné.
- Les algorithmes génétiques simulent le processus d'évolution d'une population. A partir d'une population de solutions du problème représentant des individus, on applique des opérateurs simulant les interventions sur le génome tel que le croisement (cross-over) ou la mutation pour arriver à une population de solutions de mieux en mieux adaptée au problème. Cette adaptation est évaluée grâce à une fonction coût.

VI.3.1.2.2 Programmation génétique (Genetic Programming)

Récemment, un nouveau paradigme génétique fait son apparition, c'est la Programmation Génétique. L'idée sous-jacente à cette approche est qu'il n'est pas nécessaire d'utiliser des codages linéaires (les simples vecteurs de l'algorithme génétique traditionnel) pour soumettre des programmes à une évolution génétique. Le principal promoteur de ce paradigme est KOZA [132].

L'algorithme consiste à faire évoluer une population constituée d'un grand nombre de programmes. La plupart des algorithmes de programmation génétique travaille avec une population modélisée sous forme d'arbres. Lors de la recherche, la profondeur de ces arbres peut augmenter fortement en taille. Au départ, la population est constituée de programmes créés aléatoirement. Chaque programme est évalué selon une méthode propre au problème posé. A chaque itération (génération), on classe les programmes en fonction des notes qu'ils ont obtenues, et on crée une nouvelle population, où les meilleurs programmes auront une plus grande chance de survivre ou d'avoir des enfants que les autres. Ce principe est le même qu'en algorithmique génétique classique, mais les

opérateurs de croisement et de mutation sont différents. En effet, ils travaillent directement sur la structure d'arbre du programme.

VI.3.1.2.3 Algorithmes à essaim de particules (Particle Swarm Optimiser)

Les algorithmes d'optimisation par essaim de particules (PSO) ont été introduits en 1995 par *KENNEDY* et *EBERHART* comme une alternative aux algorithmes génétiques standards [133]. Ces algorithmes sont inspirés des essaims d'insectes (ou des bancs de poissons ou des nuées d'oiseaux) et de leurs mouvements coordonnés. En effet, tout comme ces animaux se déplacent en groupe pour trouver de la nourriture ou éviter les prédateurs, les algorithmes à essaim de particules recherchent des solutions pour un problème d'optimisation. Les individus de l'algorithme sont appelés particules et la population est appelée essaim.

Dans cet algorithme, une particule décide de son prochain mouvement en fonction de sa propre expérience, qui est dans ce cas la mémoire de la meilleure position qu'elle a rencontrée, et en fonction de son meilleur voisin. Ce voisinage peut être défini spatialement en prenant par exemple la distance euclidienne entre les positions de deux particules ou sociométriquement (position dans l'essaim de l'individu). Les nouvelles, vitesse et direction de la particule seront définies en fonction de trois tendances : la propension à suivre son propre chemin, sa tendance à revenir vers sa meilleure position atteinte et sa tendance à aller vers son meilleur voisin. Les algorithmes à essaim de particules peuvent s'appliquer aussi bien à des données discrètes qu'à des données continues.

VI.3.1.2.4 Systèmes immunitaires artificiels (Artificial Immune Systems)

Les systèmes immunitaires artificiels (AIS) sont apparus dans les années 90 et sont inspirés du fonctionnement du système immunitaire humain qui est un mécanisme de défense capable d'apprendre. Beaucoup de propriétés des systèmes immunitaires ont un grand intérêt pour les informaticiens par exemple :

- chaque individu possède son propre système immunitaire avec ses forces et vulnérabilités,
- les molécules qui n'appartiennent pas à l'individu sont reconnues et éliminées,

- le système immunitaire peut détecter et réagir aux pathogènes (appelés antigène Ag) que le corps n'a jamais rencontrés,
- etc ...

Un des types de réponse immunitaire est la sécrétion d'anticorps. Les anticorps sont des molécules réceptrices permettant de reconnaître l'antigène et de le bloquer. Cette métaphore est utilisée par les AIS où un anticorps va représenter une solution potentielle au problème [124].

VI. 3.1.2.5 Algorithmes à Estimation de Distribution (Estimation of Distribution Algorithms)

Récemment, une nouvelle classe d'algorithmes a fait son apparition : les algorithmes à estimation de distribution (EDA). Ces algorithmes ont été pour la première fois introduits en 1994 par Baluja dans ses travaux sur Population Based Incremental Learning (PBIL) [134], [135] puis en 1996 par MÜHLENBEIN et PAASS [140]. Les stratégies évolutionnaires mettent en œuvre des opérateurs de mutation et de croisement mais il est difficile pour un utilisateur inexpérimenté de choisir l'opérateur approprié à son problème.

Les algorithmes à estimation de distribution reprennent les principes des algorithmes à population mais utilisent des modèles probabilistes à la place d'opérateurs de mutation et de croisement pour construire de nouveaux individus. Le modèle de fonctionnement de l'algorithme est le suivant [137] :

1. Génération de la population initiale.
2. Sélection des individus prometteurs.
3. Estimation de la distribution de ces individus (construction d'un modèle probabiliste).
4. Génération de nouvelles solutions à partir du modèle probabiliste.
5. Retour en 2 jusqu'à ce que le critère d'arrêt soit satisfait.

Les EDA peuvent être appliqués aussi bien sur un domaine discret que sur un domaine continu [124], [139]. Il existe de nombreux algorithmes à estimation de distribution qui peuvent être classés selon le modèle utilisé pour la construction des nouveaux individus : compact GA (produit de distribution de Bernouilli), Population Based Incremental Learning (règle de Hebian), Univariate Marginal

Distribution Algorithm, extended compact GA (produit de distribution marginale), Bayesian Optimization Algorithm (réseau bayésien) [137].

VI.3.1.2.6 Les colonies de fourmis (Ants System)

Initialement proposé par *DORIGO et al* [141] dans les années 90, pour la recherche de chemins optimaux dans un graphe, le premier algorithme s'inspire du comportement des fourmis recherchant un chemin entre leur colonie et une source de nourriture. L'idée originale s'est depuis diversifiée pour résoudre une classe plus large de problèmes et plusieurs algorithmes ont vu le jour, s'inspirant de divers aspects du comportement des fourmis.

Le déplacement des fourmis du nid à la source de nourriture et vice-versa (ce qui, dans un premier temps, se fait essentiellement d'une façon aléatoire), les fourmis déposent au passage sur le sol une substance odorante appelée phéromone, ce qui a pour effet de créer une piste chimique. Les fourmis peuvent sentir ces phéromones qui ont un rôle de marqueur de chemin : quand les fourmis choisissent leur chemin, elles ont tendance à choisir la piste qui porte la plus forte concentration de phéromones. Cela leur permet de retrouver le chemin vers leur nid lors du retour. D'autre part, les odeurs peuvent être utilisées par d'autres fourmis pour retrouver les sources de nourriture détectées par leurs consœurs.

Il a été démontré expérimentalement que ce comportement permet l'émergence des chemins les plus courts entre le nid et la nourriture, à condition que les pistes de phéromones soient utilisées par une colonie entière de fourmis.




Figure VI.8 : Les fourmis et le plus court chemin.

Le système de fourmis (Ants System - AS) est une méthode d'optimisation basée sur ces observations proposées par *DORIGO* [141], [142], [143], [144]. Le système de fourmis a été employé avec succès sur de nombreux problèmes (voyageur de commerce, affectation quadratique, ...) mais les auteurs ont remarqué que l'AS n'a pas un comportement très exploratoire ce qui a conduit les auteurs à utiliser des hybridations du système de fourmis avec des recherches locales. Les colonies de fourmis ont été utilisées en extraction de connaissances [145].

VI.3.2 Optimisation par colonie de fourmis (OCF) pour l'apprentissage de structure des réseaux Bayésiens

Vue la taille super-exponentielle de l'espace des réseaux Bayésiens, une solution logique est d'utiliser des méthodes d'optimisation simples pour parcourir cet espace moins brutalement que les méthodes de type K2, sans toutefois parcourir tout l'espace. Les principales différences entre les méthodes proposées résident dans la façon de parcourir l'espace, c'est-à-dire dans le choix des opérateurs générant le voisinage d'un graphe, et l'utilisation d'heuristiques supplémentaires pour simplifier le voisinage obtenu.

L'algorithme de recherche gloutonne est connu pour converger vers un optimum local et souvent de mauvaise qualité. Une façon simple d'éviter de tomber dans cet optimum local est de répéter plusieurs fois la recherche gloutonne à partir d'initialisations tirées aléatoirement. Cette méthode connue sous le nom de iterated hill climbing ou random restart permet de découvrir plusieurs optima, et a donc plus de chances de converger vers la solution optimale si la fonction de score n'est pas trop « bruitée ».

Dans le même esprit, d'autres techniques d'optimisation sont utilisées, comme le recuit simulé (Simulated Annealing), la recherche Tabou (Tabu search), et les algorithmes génétiques pour parcourir l'espace des DAGs [5].

Malgré que l'optimisation par colonie de fourmis a été appliquée à beaucoup de problèmes dans le domaine de l'optimisation combinatoire, mais, les recherches menées sur l'utilisation de cette technique d'optimisation pour l'apprentissage de structure des RBs sont récents.

Deux approches principales d'utilisation de la technique d'optimisation par colonie de fourmis pour l'apprentissage de structure des réseaux Bayésiens ont été définies par de *CAMPOS et al* [146] et de *DALY et al* [147]. La première effectue une recherche dans l'espace des orderings des DAGs, tandis que la seconde recherche dans les classes d'équivalence.

DALY et al [147] ont effectué une étude comparative de leur algorithme d'apprentissage de structure à base d'optimisation par colonie de fourmis par rapport à tous les algorithmes intégrant des métaheuristiques connus dans la littérature. Cette étude a montré que l'optimisation par colonie de fourmis est très prometteuse. Par conséquent nous avons choisi l'optimisation par colonie de fourmis pour optimiser l'apprentissage de structure du modèle proposé. En s'inspirant de ce travail nous allons étendre ce principe pour l'apprentissage de structure d'un 2TBN.

VI.3.3 L'apprentissage de structure du modèle proposé à base d'optimisation par colonie de fourmis

L'optimisation par colonie de fourmis est inspirée du comportement de fourmis réelles. Au lieu des fourmis réelles, des fourmis artificielles sont conçues comme des unités de calcul. Au lieu des pistes, ces fourmis traversent un graphe de construction. Les chemins que les fourmis prennent dans le graphe sont des solutions au problème. L'idée est de renforcer la phéromone sur les meilleures solutions. Cependant, l'idée fondamentale de déposer la phéromone est gardée. Les fourmis déposent la phéromone sur les arcs pendant qu'elles les traversent d'un nœud à un autre. En outre, les fourmis sont programmées à suivre les arcs avec une phéromone plus forte. Les fourmis artificielles peuvent être plus utiles que les fourmis réelles du fait, elles peuvent être dotées d'une mémoire. Ceci peut arrêter les fourmis faisant une boucle et aider à étendre la phéromone sur l'itinéraire de retour. En outre elles peuvent être programmées pour utiliser l'heuristique dépendante de problème, qui peut guider la recherche vers de meilleures solutions.

VI.3.3.1 Métaheuristique d'optimisation par colonie de fourmis

Dans la Métaheuristique OCF, un problème est représenté par le triple (S, f, Ω) , où S est un ensemble de solutions candidates, $f: S \times T$ est un objectif ou une fonction de score qui mesure la qualité des solutions à un temps particulier $t \in T$ et $\Omega: T$ un ensemble de contraintes à temps $t \in T$, utilisé dans une construction de solutions. L'intervalle de f et de Ω dépend de l'exemple particulier de la Métaheuristique. Dans l'essai de modéliser un problème d'optimisation combinatoire sur cette représentation, le formalisme de modélisation suivant est utilisé [147] :

- Il devrait y avoir un ensemble fini de solution components $C = \{c_1, c_2, \dots, c_{N_c}\}$. Ce sont les modules des solutions candidats.
- Les états de problème sont représentés par des séquences des composants de solution $X = \langle c_i, c_j, \dots \rangle$. L'ensemble de toutes les séquences possibles est indiqué comme X .
- S – l'ensemble de solutions candidats comme mentionné ci-dessus, – est un sous-ensemble de X , c.-à-d. $S \subseteq X$.
- Il y a un ensemble d'états faisables \check{X} , où $\check{X} \subseteq X$. un état faisable $x \in \check{X}$ est un état où il est possible d'ajouter des composants de C à x pour créer une solution satisfaisant les contraintes Ω .
- Chaque solution candidate $s \in S$ a un coût $g(s, t)$. Normalement $g(s, t) \equiv f(s, t), \forall s \in \check{S}$ et $\check{S} = S \cap \check{X}$, est l'ensemble de solutions faisables candidates. Cependant, ceci ne pourrait pas toujours être le cas; parfois, il pourrait être plus facile de calculer g la fonction qui est largement semblable à f et qui peut être utilisée dans la génération des solutions.
- L'ensemble S^* de solutions optimales devrait être non vide, avec $S^* \subseteq \check{S}$.
- Parfois il peut également être possible d'associer un coût $J(x, t)$ à un état $x \in X$ qui n'est pas une solution candidate.

En utilisant ce formalisme, les solutions au problème (S, f, Ω) peuvent être générées en ayant des fourmis artificielles exécutent une *promenade aléatoire* sur le graphe complet G définie sur les composants de C . Ce graphe G est connu par le nom *graphe de construction*. Une promenade aléatoire sur un graphe est une série de mouvements d'un nœud de graphe à un autre, où chaque mouvement

est aléatoire à un certain degré. Si la promenade est markovienne, alors le prochain mouvement est toujours complètement aléatoire; si non alors le prochain mouvement est influencé par les mouvements précédents. Par conséquent, l'utilisation de cette terminologie OCF est non-Markovien.

La promenade faite par une fourmi est généralement polarisée par deux choses. Une valeur d'heuristique η (η_i si l'heuristique est associé aux différents noeuds de G , η_{ij} s'il est associé aux arêtes de G) et d'un τ piste de phéromone (encore, τ_i si la phéromone est associé aux différents noeuds de G , τ_{ij} si la phéromone est associé aux arêtes de G). En général, η l'heuristique est une mesure de la qualité de prendre un mouvement particulier sur le *graphique de construction* comme défini par une certaine mesure locale. τ la phéromone est une mesure de la qualité de prendre un mouvement particulier comme défini par le comportement global des fourmis choisissant ce mouvement et la qualité des solutions que ces fourmis génèrent. Chaque fourmi artificielle k a les propriétés suivantes afin d'indiquer entièrement comment la promenade aléatoire procédera:

Mémoire : chaque fourmi k a une mémoire M^k qui stocke des informations sur les chemins qu'elle a jusqu'ici pris.

Etat de début : chaque fourmi k a un x_s^k d'état de début et un ensemble non vide de e^k d'états d'arrêt.

Critère d'arrêt: quand une fourmi est à l'état x , elle vérifie si un des critères d'arrêt e^k est satisfait. Sinon, elle se déplace à un noeud $j \in N^k(x)$. N^k est une fonction qui renvoie le voisinage d'un noeud X , c.-à-d. tous les noeuds sur le graphe de construction G qui peut être atteint de l'état actuel, donné les contraintes Ω .

Règle de décision: une fourmi choisit le noeud j selon une règle de décision probabiliste, en fonction de phéromone τ et de l'heuristique η . La spécification de ces règles est un problème dépendant. Mais, habituellement est un choix aléatoire qui favorise les mouvements avec une valeur plus élevée d'heuristique et de phéromone.

Mise à jour de phéromone : la phéromone d'un chemin peut être modifié par une fourmi pendant qu'elle le traverse, ou sur l'itinéraire de retour, quand elle revient

au début. C'est un problème dépendant, mais la formulation standard est d'augmenter la quantité de phéromone des bonnes solutions et diminuer la quantité de phéromone des mauvaises solutions, bonne et mauvaises étant donné par une formulation particulière.

En termes d'actions algorithmiques, un algorithme d'OCF peut normalement être décomposé en trois parts:

Construire les solutions des fourmis : cette partie de l'algorithme concerne l'envoi des fourmis sur le *graphe de construction* selon les règles données ci-dessus.

Mise à jour de phéromone : cette partie consiste à changer les valeurs des quantités de phéromone, par dépôt et évaporation. Des parties de cette tâche pourraient être exécutées pendant le passage des fourmis sur le graphe, quand le passage des fourmis est terminés ou après une itération de tous les passages des fourmis.

Actions Daemon : la présente partie de l'algorithme accomplit des tâches qui ne sont pas directement liées aux fourmis. Par exemple une procédure locale de recherche pourrait être exécutée après chaque fin de passage de fourmi.

Etant donné le cadre ci-dessus, plusieurs fourmis artificielles font une promenade aléatoire. Ce procédé est répété un certain nombre de fois, avec une quantité de phéromone augmentant graduellement sur les meilleures parties de la solution.

VI.4.3.2 Application à l'apprentissage de structure d'un réseau Bayésien

VERMA et *PEARL* dans [5] ont démontré que tous les DAGs équivalents possèdent le même squelette (graphe non dirigé) et les mêmes V-structures. Une classe d'équivalence, c'est-à-dire un ensemble de réseaux bayésiens qui sont tous équivalents, peut donc être représentée par le graphe sans circuit partiellement dirigé (PDAG) qui a la même structure que tous les réseaux équivalents, mais pour lequel les arcs réversibles (n'appartenant pas à des V-structures, ou dont l'inversion ne génère pas de V-structure) sont remplacés par des arêtes (non orientées).

Le DAG partiellement dirigé ainsi obtenu est dit complété (CPDAG) ou graphe essentiel. La Figure VI.9 nous donne le graphe asia et son CPDAG représentant dans l'espace des classes d'équivalence de Markov. Ce CPDAG possède bien le même squelette que le DAG initial ainsi que ses deux V-structures. De plus, l'arc $O \rightarrow X$ est obligatoirement orienté dans ce sens pour ne pas créer de V-structure supplémentaire.

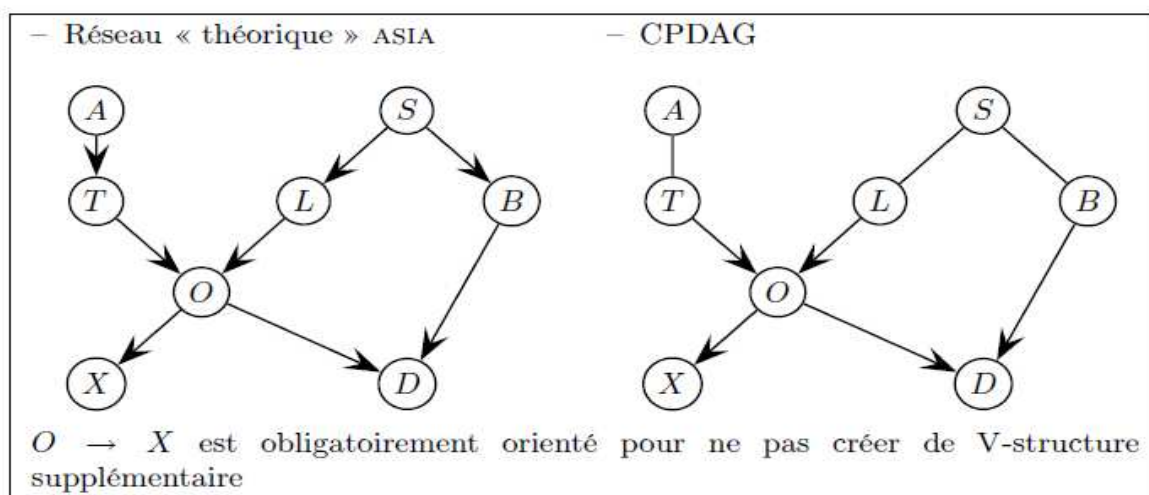


Figure VI.9 : Exemple de réseau bayésien et son représentant dans l'espace des classes d'équivalence de Markov [5].

Le problème d'apprentissage de structure des RBs peut être modélisé par le triple (S, f, Ω) où :

- S , l'ensemble de toutes les solutions candidate, est l'ensemble de tout les CPDAGs sur les nœuds du RB. Cet ensemble a une cardinalité massive, super-exponentielle dans le nombre de nœuds.
- f , la fonction objective est la fonction employée pour marquer un DAG candidat. Cette fonction serait généralement un des critères du score mentionnés dans la section précédente.
- Ω , l'ensemble de contraintes qui assure que seulement les PDAGs à extension cohérente sont générés comme solutions. Dans cette présentation, les contraintes sont implicites dans les opérateurs qui seront utilisés pour se déplacer d'un état à un autre.

GRAPHE DE CONSTRUCTION

Le graphe de construction d'un algorithme d'OCF décrit le mécanisme par lequel les solutions peuvent être assemblées. C'est un graphe complet sur les composants de solution. En tant que tels, ces composants jouent un rôle crucial dans la viabilité de l'algorithme. Dans l'algorithme ACO-E, les composants C du graphe de construction sont les divers déplacements qui peuvent être entrepris, c.-à-d. chaque mouvement est une instanciation d'un opérateur fourni.

Les états du problème sont les séquences de déplacements. Cependant, parce que chaque état peut être une solution candidate, $S = X$ dans le cadre de la métaheuristique d'OCF. Ceci n'implique pas que tous les états sont des solutions candidates faisables, mais seulement que les solutions candidates peuvent être de n'importe quelle longueur. Ceci signifie également que $\check{S} = \check{X}$. Une autre façon de visualiser l'état d'une fourmi est de considérer le graphe vide P (l'état initial) et l'état actuel comme une séquence de déplacements (composants). L'application de chaque $c \in X \setminus P$ du mouvement c donnera un CPDAG qui est une autre représentation de l'état actuel.

Il convient de noter que les contraintes sont implicitement prises en compte par les opérateurs, c.-à-d. les essais de validité sur les opérateurs satisfont la contrainte que chaque état est un PDAG valide. On devrait également affirmer que la définition habituelle de

$$g(x, t) = f(x, t), \forall s \in \check{S} \quad (\text{VI. 17})$$

S'applique, il n'y a aucune fonction $J(x, t)$, puisque tout x sont des solutions candidates et ajouter un composant de solution peut diminuer le coût.

PROBLEME DE L'EURISTIQUE

L'heuristique dans un algorithme d'OCF, est employée pour guider la recherche à de bonnes solutions. Ceci est fait souvent implicitement en termes de coût lié à choisir un composant particulier pour l'ajouter à l'état actuel; ajouter un composant avec le moindre coût est souvent un moyen utile de la démarche à suivre en construisant une solution. Dans ACO-E, l'heuristique est utilisée de la même manière, avec la possibilité que le coût pour ajouter un composant peut

être négatif, c.-à-d. ajouter un composant à l'état actuel peut améliorer la fonction de coût g . l'heuristique est dynamique parce qu'elle dépend de l'état actuel de la fourmi. En outre, il est associé à chaque $c \in C$ par opposition aux arcs $c_i - c_j$ entre les composants.

La valeur η_i de l'heuristique est indiquée par le gain pour chaque déplacement $c_i \in C$ qui est possible à l'état actuel. Essentiellement elle correspond au changement de score en effectuant un mouvement particulier sur le CPDAG actuel. Pour les opérateurs étant utilisés en cet article.

PROBLEME DE PHEROMONE

La phéromone dans un algorithme d'OCF guide la recherche en se basant sur les résultats de recherches précédentes. Dans beaucoup variantes, il est associé aux arcs de graphe de construction, mais dans ACO-E [147] il est associé aux nœuds du graphe de construction. Ceci donne les valeurs τ_i de phéromone pour chaque $c_i \in C$. La phéromone pour chaque τ_i est initialisé à une valeur τ_0 donnée par :

$$\tau_0 \leftarrow \frac{1}{n|\text{Score}(P^+)|} \quad (\text{VI. 18})$$

Dans cette formule, n est le nombre de variables qui sont dans les données, SCORE est la fonction objective f , définie dans la section précédente et P^+ est la meilleure solution trouvée jusqu'au là. Au début de l'algorithme, ceci est initialisé à cela trouvé par une recherche gloutonne à partir d'un graphe vide. Pour que la phéromone puisse changer pour refléter les itinéraires effectués les fourmis, des règles de mise à jour de phéromone sont données. Une règle locale d'évaporation, par laquelle la phéromone est retirée d'une piste ou d'un chemin pendant qu'une fourmi le traverse.

$$\tau_m \leftarrow (1 - P)\tau_m + P\tau_0 \quad (\text{VI. 19})$$

Ceci montre l'effet du paramètre P , qui est le taux d'évaporation et de dépôt de phéromone. Avec cette formule, les limites implicites sur la façon dont on peut augmenter et baisser la quantité de phéromone à chaque composant peuvent être obtenues. La règle globale de mise à jour de phéromone qui dépose la nouvelle quantité de phéromone sur la meilleure piste trouvée jusqu'à présent est :

$$\tau_m \leftarrow \frac{(1 - P)\tau_m + P}{|\text{Score}(P^+)|} \quad (\text{VI. 20})$$

Ceci se produit après un passage des fourmis. Le SCORE et le P^+ sont définis comme dans l'équation VI.20. En outre, cette formule implémente des limites implicites sur les valeurs que la phéromone peut prendre.

LA REGLE DE TRANSITION PROBABILISTE

Afin de choisir quel composant à visiter étant donné un état particulier, l'algorithme d'OCF utilise une règle de transition probabiliste. Cette règle utilise des valeurs données par l'heuristique et la phéromone pour informer le choix de nœud à sélectionner. Le choix réel est aléatoire et basé sur une distribution donnée par l'heuristique et la phéromone de chaque choix possible. Dans ACO-E, la règle du choix probabiliste est donnée par une pseudo-règle de choix proportionnelle aléatoire. Une fourmi choisit le composant c_m , où m est donnée par :

$$m \leftarrow \begin{cases} \text{Arg max}_{m \in N(x)} \tau_m [\eta_m]^\beta, & \text{if } q < q_0 \\ \text{proportionnelle aléatoire,} & \text{sinon} \end{cases} \quad (\text{VI. 21})$$

Dans cette formule, $N(x)$ est l'ensemble de composants aux lesquels une fourmi à l'état x peut se déplacer, étant donné les contraintes du problème Ω . La règle est proportionnelle pseudo-aléatoire, parce qu'elle se comporte parfois en quelque sorte qui n'est pas aléatoire. Un nombre aléatoire q est uniformément dans l'intervalle $[0, 1]$. Si ce nombre est inférieur ou égal à un paramètre q_0 , alors la règle se comporte gloutonnement « GREEDILY »; le meilleur déplacement possible est pris par rapport la valeur de $\tau_m [\eta_m]^\beta$ pour chaque composant c_m . τ_m et η_m sont la phéromone et l'heuristiques comme expliqué précédemment et le β est un paramètre qui représente le taux de favorisation de l'heuristique par rapport au phéromone.

Si le nombre q est plus grand que q_0 , alors une règle proportionnelle aléatoire est utilisée pour choisir quel composant à visiter ultérieurement. La probabilité que la fourmi visitera le composant c_m est donnée par p_m , où

$$p_m = \frac{\tau_m[\eta_m]^\beta}{\sum_{u \in N(x)} \tau_u[\eta_u]^\beta}, \forall m \in N(x) \quad (\text{VI. 22})$$

On peut remarquer que la probabilité qu'une fourmi se déplace au composant c_m est directement donnée par $\tau_m[\eta_m]^\beta$, normalisé par rapport les autres déplacements possibles afin qu'il soit dans l'intervalle [0 1].

PROPRIETES DES FOURMIS

En termes de fourmis employées pour construire des solutions, les propriétés suivantes de la fourmi k devraient être notées:

- La mémoire M^k peut être égalisée à l'état actuel du problème donné par la fourmi k . de ceci, le CPDAG courant peut être construit afin de mettre en application les contraintes Ω , calculer η la valeurs de l'heuristique, évaluer la solution courante et étendre la phéromone en excursion. Dans la pratique, le CPDAG courant est normalement gardé afin d'éviter de le recalculer à chaque étape.
- L'état initial x_s^k est donné par la séquence vide $\langle \rangle$, c.-à-d. par le CPDAG vide.
- La simple condition d'arrêt e^k , doit arrêter l'excursion quand aucune amélioration de score n'est possible.
- Le voisinage $N^k(x)$ est l'ensemble de tous les déplacements possibles étant donné le CPDAG courant.

PROCEDURE DE RECHERCHE LOCALE

L'algorithme peut utiliser une procédure de recherche locale aux points intermédiaires durant et à la fin de l'exécution de l'algorithme. Cette procédure de recherche locale peut être utilisée pour accélérer la génération d'une solution à un maximum local. Avec l'heuristique actuelle et la recherche locale standard, la procédure de recherche qui sera utilisée est la recherche gloutonne « GREEDY-SEARCH » avec les opérateurs mentionnés dans [147], appelé GREEDY-E-recherche locale ne fournirait aucun avantage supplémentaire par rapport la solution trouvée par une fourmi. Néanmoins, la recherche locale a été mise dans l'algorithme dans le cas où le problème de l'heuristique a été implémenté différemment.

Algorithme ACO-E [147]

Input : les opérateurs, $O, t_{max}, t_{min}, m, p, q_0, \beta, n$.

Output: PDAG P^+

$(P^+, path^+) \leftarrow$ GREEDY-E ($P^{empty}, path^{empty}$)

$\tau_0 \leftarrow \frac{1}{n|Score(P^+)|}$

for each $o \in O$ **do**

for each possible move m in o on P^{empty} **do**

$\tau_m \leftarrow \tau_0$

end for

end for

for $t \leftarrow 1$ to t_{max} **do**

for $k \leftarrow 1$ to m **do**

$(P^k, path^k) \leftarrow$ ANT-E (O, p, q_0, β, τ_0)

if ($t \bmod t_{step} = 0$) **then**

$(P^+, path^+) \leftarrow$ GREEDY-E ($P^{empty}, path^{empty}$)

end if

end for

$b \leftarrow \text{Arg max}_{k=1}^m \text{Score}(P^k)$ **then**

$P^+ \leftarrow P^b$

if $\text{Score}(P^b) > \text{Score}(P^+)$

$path^+ \leftarrow path^b$

end if

for each move m in $path^+$ **do**

$\tau_m \leftarrow \frac{(1 - P)\tau_m + P}{|Score(P^+)|}$

end for

end for

return P^+

Algorithme ANT-E [147]

Input : Opérateurs O, p, q_0, β

Output : PDAG P , Path $Path$, Empty PDAG P , Empty path $Path$

While true **do**

$M \leftarrow$ All possible moves from P using O

if $|M| = 0$ $\max_{l \in M} \text{TOTAL} - \text{SCORE}(l, \beta) \leq 0$ **then**

 return ($P, Path$)

end if

$q \leftarrow$ random number in $[0, 1]$

if $q < q_0$ **then**

$l \leftarrow \text{Arg max}_{l \in M} \text{TOTAL} - \text{SCORE}(l)$

```

else
   $l \leftarrow \text{random according to Equation 3}$ 
end if
 $\tau_m \leftarrow (1 - p)\tau_l + p\tau_0$ 
 $P \leftarrow \text{apply } l \text{ to } P$ 
 $\text{Path} \leftarrow \text{append } l \text{ to path}$ 
end while

```

Algorithme TOTAL-SCORE

Input : Move l , β

Output: Score s

return s such that $s = \begin{cases} \tau_l(\eta_l)^\beta & \text{if } \eta_l > 0 \\ 0 & \text{sinon} \end{cases}$

La plupart des algorithmes d'apprentissage de structure de réseau Bayésien sont conçus pour apprendre la structure des RBs statiques. Tandis que les réseaux bayésiens dynamiques sont très similaires aux RBs statiques. Le 2TBN utilisé dans notre modèle comprend deux réseaux comme mentionné ci-dessus le réseau initial (a priori) et le réseau de transition, nous nous concentrerons sur l'apprentissage du réseau de transition; le réseau antérieur est exactement identique à un réseau Bayésien standard.

Dans un réseau de transition, les nœuds sont regroupés dans des couches représentant des points sur l'axe du temps. Les arcs ne peuvent jamais retourner dans le temps et la tête de n'importe quel arc est seulement dans une seule couche.

Afin d'appliquer ce principe pour l'apprentissage de structure d'un 2TBN, il est suffisant d'ajouter une contrainte supplémentaire à l'algorithme d'apprentissage, qui est : la tête d'un arc doit toujours être dans la couche de temps t .

VI.4 CAS DES BASE DE DONNEES INCOMPLETE

Nous allons étudier dans cette partie le cas des données incomplètes. L'apprentissage des réseaux Bayésiens à partir de données incomplètes est très intéressant, car dans la plupart des situations réelles les données ne sont pas complètement observées. La difficulté principale de l'apprentissage à partir des

observations partielles est que nous n'avons plus les propriétés de décomposition de la fonction de Score (voir Annexe C). Ceci signifie que le choix optimal de paramètre dans une partie du réseau dépend des choix de paramètre dans d'autres parties du réseau.

La méthode la plus généralement utilisée pour pallier à ce problème est l'algorithme d'Expectation-Maximisation (EM). L'algorithme EM a été proposé dans le cadre de l'apprentissage des paramètres dans le cas des données incomplètes, une autre version a été proposée pour l'apprentissage de structure appelée SEM (voir Chapitre II). Des extensions de cet algorithme ont été proposées dans le cas des réseaux Bayésiens dynamiques, en particulier le 2TBN.

VI.5 TESTS ET VALIDATION

Afin de valider l'approche proposée, nous avons simulé le comportement de quelques exemples de systèmes pris de la littérature. La simulation est faite en utilisant l'arbre de défaillance dynamique de chaque un d'eux. L'ADD décrit le mécanisme de propagation de panne dans un système à travers le temps. Le travail de *GUILLAUME et al* [150] permet de modéliser mathématiquement (modélisation algébrique) les différentes portes logiques, et plus particulièrement, les portes logiques dynamiques d'un ADD. En s'inspirant de ce travail nous avons implémenté le module de génération des données qui représente l'historique de fonctionnement de ces exemples dans le cas de plusieurs scénarios:

- Le cas où il n'y'a pas un mécanisme de réparation (de maintenance) ;
- Le cas d'une maintenance programmée, ou préventive.

La simulation commence par un état de fonctionnement normal de tous les composants (donc un système en marche à l'instant t_0), les prochains états des composants, ceux de l'instant t_1 sont complètement aléatoires (panne d'un ou plusieurs composants ou même rester dans les mêmes états de t_0). A partir de cette itération les états qui suit sont relativement aléatoire, parce qu'on prend en considération l'état précédent. Le passage d'un état à l'autre est effectué suivant des règles qui prennent comme entrée l'état de chaque composant à l'instant t .

Si nous arrivons à l'état d'arrêt du système et il n'y a pas un mécanisme de réparation, la simulation atteint ses fins. Sinon nous poursuivons la simulation

avec une des états de bon fonctionnement du système. La structure des données générées de la simulation est illustrée sur le Tableau VI.1.

Tableau VI.1 : Structure de base de données générée.

Variables	t=0	t=1	t=3	t=T
X_0	0	0	0	1
X_2	0	0	1		1
X_3	0	0	0		0
\vdots	\vdots				0
X_{n+1}	0	0	1		1

Il y a, en général, trois méthodes différentes employées dans l'apprentissage de structure d'un réseau bayésien à partir des données. La première consiste à trouver des indépendances conditionnelles dans les données et puis employer ces indépendances conditionnelles pour produire la structure. Les algorithmes les plus connus qui utilisent cette méthode sont probablement l'algorithme *PC* et les algorithmes *CI* et de *FCI*. La seconde utilise la programmation dynamique et optionnellement le clustering pour construire un DAG. La troisième méthode définit une recherche sur l'espace des réseaux Bayésiens. Cette méthode utilise une fonction de score qui indique relativement comment un réseau est meilleur comparé à d'autres.

Bien que les méthodes d'apprentissage des réseaux Bayésiens soient classifiées en trois catégories comme mentionné ci-dessus, il est utile de différencier leur applicabilité, les bornes entre elles ne sont pas souvent aussi claires qu'elles peuvent paraître. Par exemple, l'approche de recherche et de score et l'approche de programmation dynamique sont semblables du fait qu'elles utilisent des fonctions de score.

Nous avons implémenté l'algorithme d'apprentissage de structure de 2TBN en utilisant la programmation dynamique qui se base sur la notion de récursivité. En s'inspirant des travaux [152-154] dans le cas des réseaux Bayésiens standard.

Quand il s'agit de modéliser la fiabilité d'un système, la partie statique de structure de réseau B_0 de la tranche initiale du temps est la même dans le réseau de transition B_{-} . Parce que les relations de dépendances entre les composants ne vont pas changer.

VI.5.1 Exemple N°1 : Le système « AHRS »

Le premier exemple est pris de [119], il représente un système actif de rejet de chaleur (Active Heat Rejection system), la Figure VI.9 représente le schéma bloqué de ce système. Le temps de panne de chaque composant est une variable aléatoire représentée par une distribution exponentielle négative, les taux de défaillance des différents composants sont donnés sur la Figure VI.12. Les données générées de ce système (dans le cas où il n'y a pas un mécanisme de réparation) sont représentées par la Figure VI.10. La Figure VI.11 montre le RBD obtenu en utilisant la programmation (Dynamic Programming) pour construire la structure du RBD à partir des données, dans le cas d'une base de données complète (pas de valeurs manquante ni variable cachées).

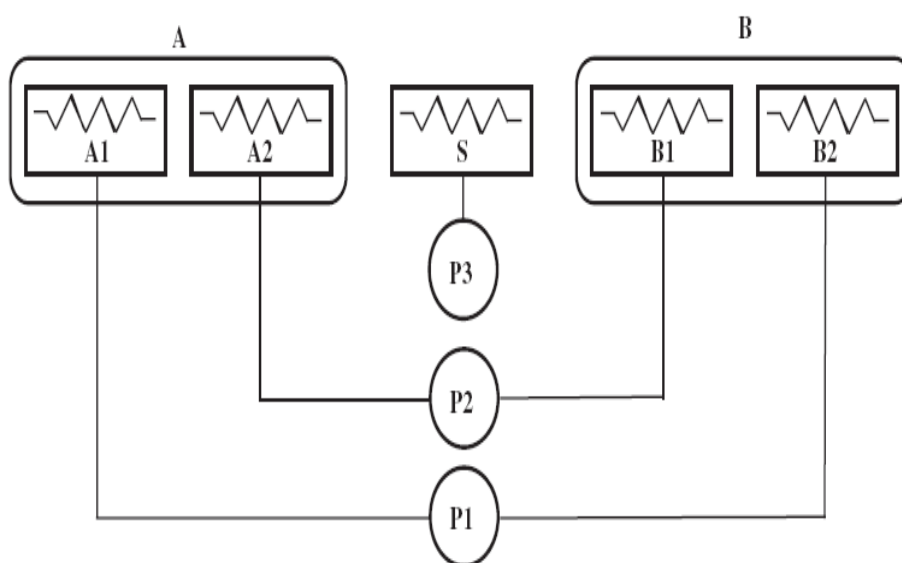


Figure VI.9 : Le schéma bloqué de l'architecture de AHRS.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19
P1	2	1	1	2	2	2	2	1	1	2	1	1	1	2	1	1	2	2	1
P2	1	1	1	1	1	2	2	1	2	2	1	2	2	1	2	2	2	2	2
P3	1	1	1	1	2	2	1	2	2	1	1	1	1	1	2	1	1	2	1
A1	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
A2	1	2	2	2	2	2	2	1	1	2	1	2	2	1	1	2	2	2	2
S	2	1	1	2	2	2	2	2	2	1	2	2	2	2	2	2	1	2	2
B1	1	2	2	2	2	2	2	2	1	2	2	2	2	2	2	2	2	2	2
B2	2	2	2	2	1	2	2	1	2	2	2	2	2	2	2	2	2	2	2
TE	1	1	1	2	2	2	2	1	1	1	2	2	2	2	2	2	1	2	2

Figure VI.10: Les données générées pour l'exemple AHRS.

Les variables de réseau représentent les composants, plus une variable qui représente l'état du système à chaque séquence du temps. Les variables sont discrètes et binaires ('1' représente l'état en marche et '2' représente l'état en panne à chaque instant t).

A1 : Composant principal de la première unité de rejection thermique.

A2 : Composant de réserve de la première unité de rejection thermique.

B1 : Composant principal de la deuxième unité de rejection thermique.

B2 : Composant de réserve de la deuxième unité de rejection thermique.

P1 : Composant d'alimentation de A1 et B2, il se comporte comme un déclencheur.

P2 : Composant d'alimentation de A2 et B1, il se comporte comme un déclencheur.

P3 : Composant d'alimentation de S, il se comporte comme un déclencheur.

S : Composant de réserve partagé entre la première et la deuxième unité de rejection thermique.

TE : Le système.

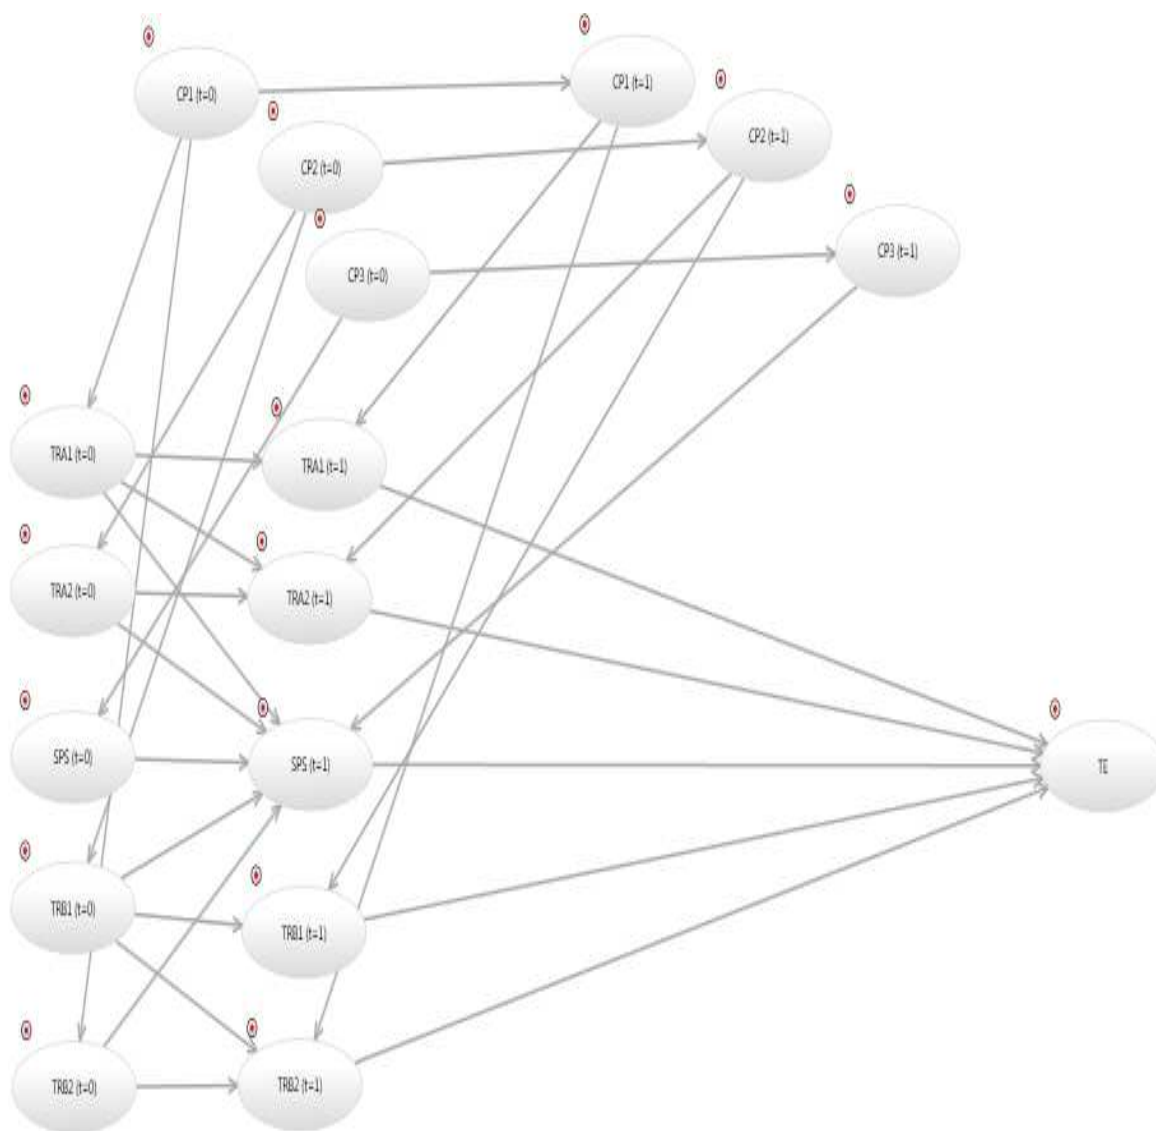


Figure VI.11 : Le RBD de AHRS construit à partir des données générées (cas où il n'y a pas un mécanisme de réparation ou de maintenance).

Composant	Taux de défaillance (λ) (h^{-1})
A1	0.001
A2	0.005
B1	0.002
B2	0.0035
S	0.005
P1, P2, P3	0.003

Figure VI.12 : Les taux de défaillances des composants de système AHRS.

En utilisant les algorithmes d'inférence des RBD on peut maintenant calculer la fiabilité du système globale ou de chaque combinaison de composant qu'on veut, pour faire le diagnostic. On peut faire des prédictions sur l'état prochaine du

système pour une durée de mission T . Les résultats obtenus pour une durée de mission $T=60$ h. avec une étape de discrétisation $\Delta t = 0,05$ h sont montrés dans la figure Tableau VI.2, en comparant nos résultats aux résultats obtenus en [119] on peut dire que les deux résultats sont très proches. Pour effectuer l'inférence nous avons utilisé le package développé par *MURPHY* [2].

Tableau VI.2 : Les résultats obtenus pour l'exemple AHRS.

t	RADYBAN [119]	Notre approche
10	1	1
20	1	1
30	0,999264	0,998995
40	0,997882	0,996985
50	0,995695	0,994995
60	0	0

VI.5.1 Exemple N°2 : Le système « CPU »

Le deuxième exemple est pris de [118], c'est une partie d'un système réel 'un appareil d'assistance cardiaque', cette partie est l'unité centrale de traitement 'CPU' qui gère le reste des composants. Elle est composée de Primary CPU (P), Backup CPU, Crossbar Switch (C), System Supervisor (S). La variable (CPU) représente l'état du système.

	1011	1012	1013	1014	1015	1016	1017	1018	1019	1020	1021	1022	1023	1024	1025	1026	1027	1028	1029
0	2	1	2	1	1	1	2	1	1	2	2	2	2	2	1	1	1	2	2
1	1	2	2	2	2	2	1	2	2	1	2	2	2	1	2	2	2	1	1
P	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
B	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
CPU	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2

Figure VI.13 : Les données générées pour l'exemple "CPU".

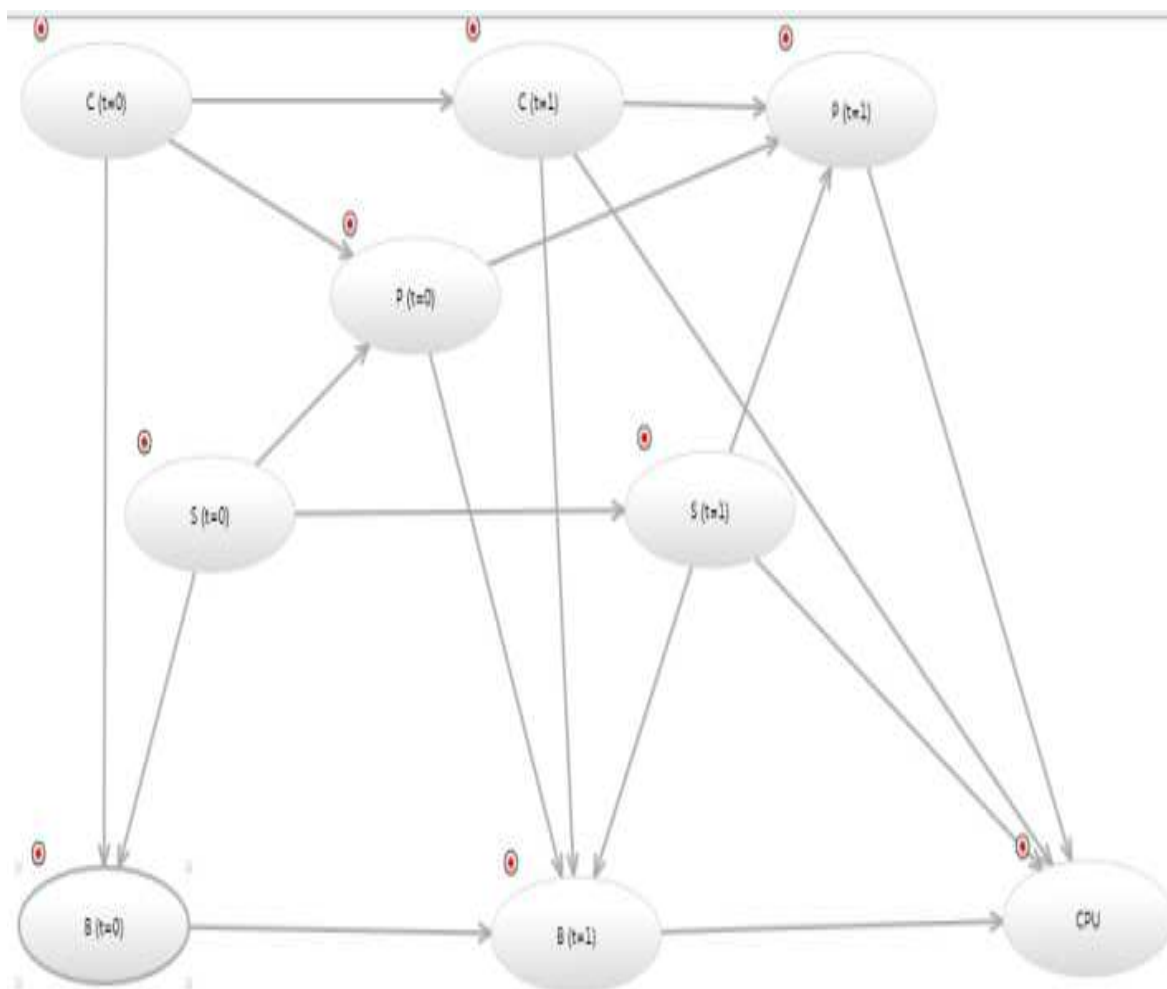


Figure VI.14 : Le RBD de CPU construit à partir les données générées (cas où il n'y a pas un mécanisme de réparation ou de maintenance).

Composant	Taux de défaillance	h^{-1}
Crossbar Switch	0.00002	
System Supervisor	0.00009	
Primary CPU	0.00006	
Backup CPU	0.00006	

Figure VI.15 : Les taux de défaillances des composants de CPU.

Le Tableau VI.3 montre les résultats obtenus pour l'exemple CPU avec un temps de mission $T=1000$ h et une étape de discrétisation $\Delta t = 100$ h.

Tableau VI.3: Les résultats obtenus pour l'exemple CPU.

t	Résultats en [118]	Notre approche
100	0.048	0.43
200	0.095	0.11
300	0.13	0.128
400	0.19	0.188
500	0.21	0.209
600	0.29	0.289
700	0.32	0.319
800	0.38	0.378
900	0.42	0.417
100	0.47	0.469

L'approche a été aussi, testée en utilisant des données réelles, prise de l'historique de pannes d'une centrale thermique productrice de l'énergie électrique, plusieurs valeurs sont absentes, pour cela on a utilisé une version amélioré de l'algorithme SEM [151] pour construire le RBD. La centrale est composée de 4 blocs, les blocs sont similaires et ils contiennent les mêmes unités, on a travaillé sur le niveau d'abstraction le plus haut c.à.d. sur les unités et pas sur les composants, parce que on n'avait pas des informations sur les composants.

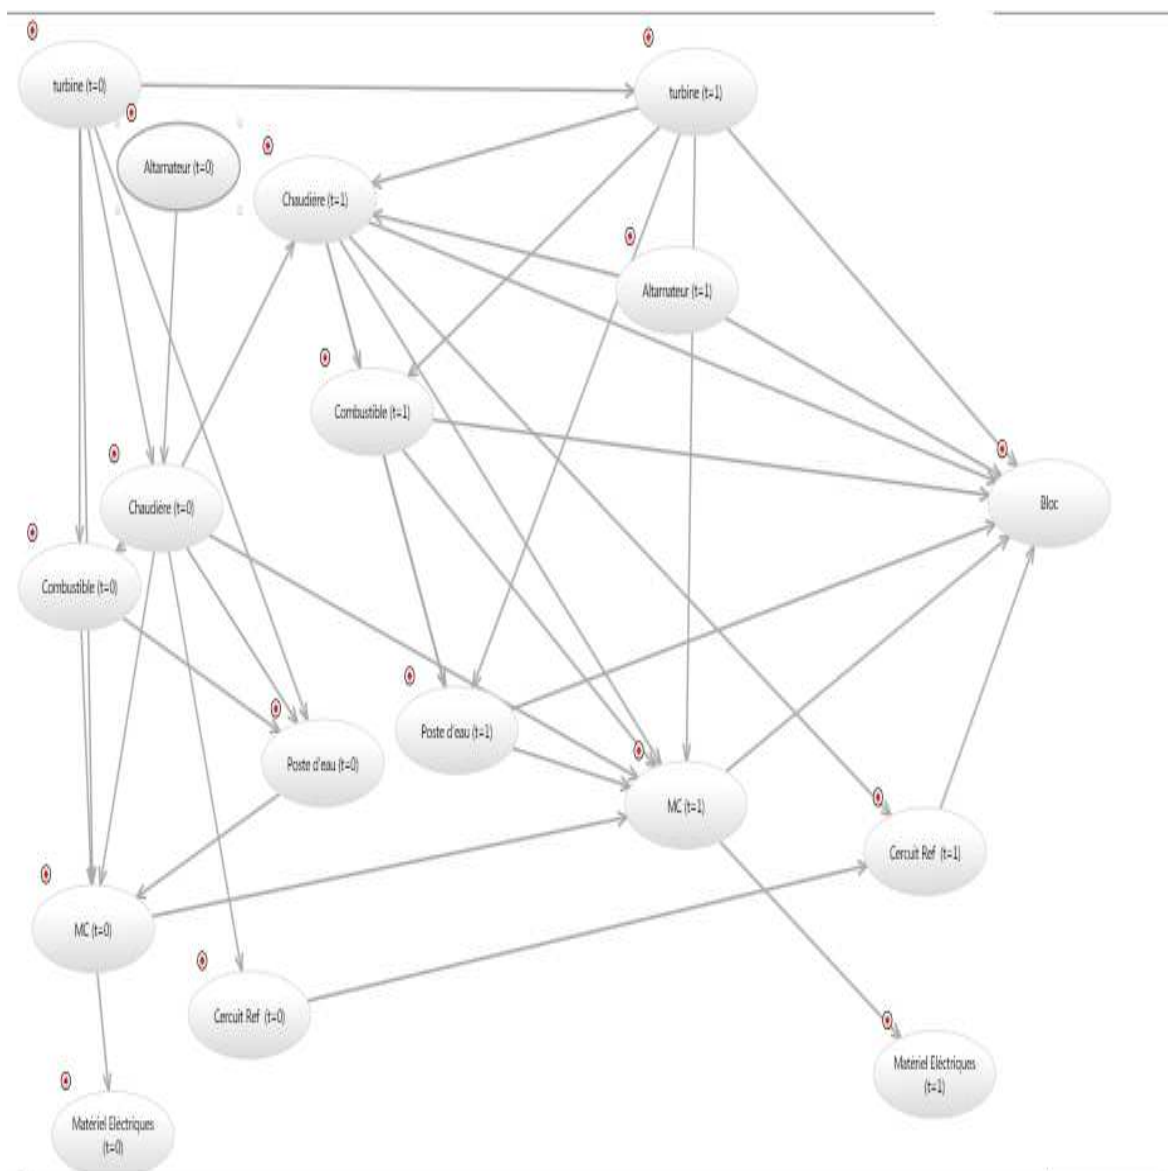


Figure VI.15: Le RBD du Bloc N°1 de la centrale thermique.

Les blocs sont composés de 8 unités qui sont représentées par les variables du réseau : la turbine (turbine à vapeur), l'alternateur, la chaudière, le combustible, le poste d'eau, le circuit de réfrigération, les matériels électriques et on ajoute une variable qui représente le système. Le réseau produit sera validé par les experts du domaine.

VI.6 DISCUSSION

Comme n'importe quel modèle de construction, l'apprentissage est soumis à un ensemble de compromis, on doit laisser les données gouverner le modèle. Les données doivent être soumises à un prétraitement, plusieurs techniques de

discrétisation des données et algorithmes d'apprentissage peuvent être appliqués. D'où ils y'a plusieurs degrés de liberté quand le modèle est conçu à partir des données.

L'avantage principal est que les relations de dépendances entre les variables de l'ensemble des données deviennent apparentes et ceci révèle de nouvelle connaissance sur le système. De plus la force (puissance) des relations de dépendance entre les variables est calculée pour établir un modèle prédictif, il est basé sur des principes statistiques solides bien que n'importe quel degré de connaissance du domaine puisse être appliqué.

Puisque la dimension de l'espace des états est égale au nombre des variables, l'estimation des probabilités nécessite une grande quantité des données pour produire un modèle fiable. Un compromis est mis ici ; la quantité importante des données augmente la fiabilité du modèle généré mais aussi, augmente le temps d'exécution de la procédure d'apprentissage et l'inverse diminue le temps d'exécution et il diminue aussi la fiabilité du modèle prédit.

Nous avons testé l'approche proposée, la construction automatique de modèles de Réseau Bayésien Dynamique pour le calcul de la fiabilité sur des données générées à partir des exemples de systèmes pris de la littérature. En ce qui concerne les résultats obtenus à partir des exemples pris de la littérature sont très satisfaisants et très proche (avec un pourcentage de 99,8%) aux résultats obtenus dans les articles dont on a pris les exemples, on peut dire que cette approche permet de calculer la fiabilité des systèmes dynamiques. Quoiqu'il ne faut pas éliminer le rôle de l'expert qui peut rajouté et enrichie le modèle.

Les résultats obtenus en utilisant l'optimisation par colonies fourmis sont similaires aux résultats obtenus par programmation dynamique par ce que le nombre des variables n'est pas important. Dans le cas l'implémentation par programmation dynamique, si nous dépassons 9 variables, le temps d'exécution augmente d'une façon considérable. L'optimisation par colonie de fourmi à palier a ce problème mais le modèle généré, il n'est pas aussi pertinent que par programmation dynamique.

Enfin nous pouvons dire que les réseaux Bayésien présente un outil intégré d'extraction et de représentation et aussi d'exploitation des connaissances. Il

existe cependant quelques spécifications relatives à la nature du problème à résoudre qui font des réseaux Bayésiens l'outil le plus adéquat pour modéliser ce problème.

VI.7 CONCLUSION

Nous avons présenté dans ce chapitre notre approche d'utilisation des réseaux Bayésiens dynamique comme un modèle d'extraction, de représentation et d'exploitation de connaissances appliquée à la modélisation de la fiabilité des systèmes. Cette approche a été validée par des exemples pris de la littérature.

CONCLUSION ET PERSPECTIVES

Le domaine de la gestion des connaissances qui connaît un intérêt croissant est un domaine d'application potentiel pour les réseaux Bayésiens. Dans la mesure où ceux-ci offrent un formalisme riche et intuitif d'extraction et de représentation de connaissance. La fiabilité des systèmes est également un domaine d'application des réseaux Bayésiens. Notre travail se situe au chevauchement des ces deux domaines d'application des RBs.

L'utilisation des réseaux Bayésiens en tant qu'un modèle intégré d'extraction, de représentation et d'exploitation des connaissances nous a permis de proposer une méthode générique d'estimation et d'analyse de la fiabilité des systèmes et l'application ce principe d'extraction et de découverte de connaissances dans le domaine de la fiabilité des systèmes a permis par conséquent de le valider.

Afin d'étudier et de comprendre les capacités de modélisation des réseaux Bayésiens, nous avons vu dans le premier chapitre la définition, les types, les règles de calcul, et le mécanisme d'inférence d'un réseau Bayésien.

L'extraction des connaissances en utilisant les réseaux Bayésiens passe inévitablement par la détermination de la structure et des paramètres du réseau. Par conséquent nous avons vu dans le deuxième chapitre comment construire ce modèle à partir d'expertises, ou de données, qu'elles soient complètes ou non. De multiples méthodes existent, mais beaucoup de problèmes restent encore à résoudre concernant la prise en compte de données incomplètes, par exemple, ou l'apprentissage de modèles, en particulier, les réseaux Bayésiens temporels.

Le rôle des réseaux Bayésiens dans le processus de KDD et de KM en général à été étudié en détail dans le troisième chapitre. Dans ce chapitre, nous avons aussi justifié le choix des réseaux Bayésiens comme un modèle d'extraction de connaissances et illustré notre vision d'utilisation des réseaux Bayésiens comme un outil intégré d'extraction de représentation et d'exploitation des connaissances.

La modélisation de la fiabilité des systèmes complexes en utilisant les réseaux Bayésiens est la source de motivation de notre travail et elle présente le domaine d'application de notre étude. Par conséquent, le quatrième chapitre a été consacré pour la définition des différentes notions mathématiques nécessaires à la compréhension de cette discipline et l'étude des méthodes classiques utilisées pour l'estimation et l'analyse de la fiabilité des systèmes.

L'utilisation des réseaux Bayésiens pour la modélisation de la fiabilité des systèmes est un champ de recherche récent et très actif. Le cinquième chapitre, présente un état de l'art détaillé et une étude comparative sur les travaux qui ont été publiés jusqu'à présent sur ce thème.

L'étude des réseaux Bayésiens et leur rôle dans l'extraction des connaissances dans une première partie et dans une deuxième partie leurs capacités dans la modélisation de la fiabilité ont aboutit à la proposition d'une méthode générique pour l'estimation et l'analyse de la fiabilité des systèmes. Cette approche a été illustrée et validé dans le dernier chapitre.

1. CONTRIBUTIONS

Ce travail de thèse se positionne comme une contribution d'une part au développement des modèles de gestion de connaissances et d'une autre au développement de méthodes génériques pour l'estimation et l'analyse de la fiabilité des systèmes complexes en utilisant les réseaux Bayésiens.

Notre contribution se situe premièrement dans la proposition d'utiliser les réseaux Bayésiens comme un outil intégré d'extraction, de représentation et d'exploitation des connaissances, et deuxièmement dans la construction de modèle de réseau Bayésien dynamique modélisant un système par apprentissage automatique et l'utilisation du modèle généré dans l'analyse de fiabilité. Et cela en exploitant les données de tests ou bien les données prise de l'historique de fonctionnement du système (retour d'expériences).

Ceci a permis aussi de prouver que les réseaux Bayésiens peuvent être employés comme un modèle d'extraction de connaissances en utilisant principalement les algorithmes d'apprentissage de structure et de paramètres de ces derniers, les connaissances extraites sont représentées directement par le

réseaux Bayésien générés et facilement interprétés et exploités via le mécanisme d'inférence des réseaux Bayésiens.

Nous avons appliqué ce principe pour la gestion des connaissances médicales, plus spécifiquement dans l'orientation des patients vers les différents services d'un hôpital. Les résultats obtenus sont très satisfaisants (Voir l'annexe D pour plus de détails).

Concernant le domaine d'application étudié dans ce mémoire, qui est la fiabilité des systèmes, nous avons focalisé nos recherches sur les modèles dynamiques des réseaux Bayésiens qui semblent très appropriés à la modélisation des systèmes complexes et l'intégration des contraintes exogènes dans l'analyse de la fiabilité dite dynamique. Ceci est montré dans un ensemble de travaux de recherche menés dans ce contexte. Sans oublier que la modélisation par les réseaux bayésiens dynamiques englobe la partie statique du système. Par conséquent, les réseaux bayésiens dynamiques représentent un formalisme général pour la modélisation statique et dynamique d'un système.

Notre travail qui consiste en construction de modèle de réseau Bayésien dynamique par apprentissage automatique est au niveau général un problème d'extraction de connaissance. L'apprentissage d'un réseau bayésien consiste à identifier sa structure qui est un graphe orienté sans circuit et ses paramètres constituant l'ensemble des tables de probabilité conditionnelles. Pour ce faire :

Premièrement, nous avons choisi le type des réseaux Bayésiens dynamiques à utiliser dans le modèle proposé, qui est le 2TBN. Ce choix a été fait après une étude qui a été effectuée à travers les chapitres suivants:

- Réseaux Bayésiens, où nous avons vu les différents types des modèles dynamiques des réseaux Bayésiens, en particulier leurs propriétés et leur mécanisme d'inférence.
- Apprentissage des réseaux Bayésiens, où nous avons vu les méthodes et les algorithmes d'apprentissage de structure et des paramètres des différentes approches d'intégration de la dimension temporelle dans les réseaux Bayésiens.

- Réseaux bayésiens pour la fiabilité: Etat de l'art, où nous avons étudié un ensemble de travaux qui ont utilisé différentes variantes des réseaux bayésiens pour l'analyse de la fiabilité des systèmes.

Deuxièmement, nous avons défini comment appliquer la méthode d'apprentissage de structure et des paramètres de réseau bayésien dynamique choisie pour modéliser la fiabilité d'un système (définition des variables, la nature des variables, structure de la base d'apprentissage).

Troisièmement, nous avons implémenté et réalisé ce module de construction automatique de modèle de réseau bayésien dynamique modélisant la fiabilité des systèmes en utilisant la programmation dynamique.

Quatrièmement, sachant que l'apprentissage des réseaux Bayésiens est un problème NP-Difficile. En particulier, les réseaux bayésiens dynamiques (dans notre cas le 2TBN), le nombre des variables est doublé parce que dans un réseau de transition, chaque variable possède deux copies une dans la tranche du temps t , et une autre dans la tranche $t-1$. Par conséquent, le problème d'optimisation du temps de calcul s'impose. Pour résoudre ce problème, nous avons effectué une recherche sur les Métaheuristiques d'optimisation. Après étude nous avons choisie l'optimisation par colonie de fourmis et proposé ensuite une nouvelle approche d'apprentissage de structure des 2TBN en intégrant cette Métaheuristique.

Cinquièmement, nous avons défini comment exploiter les modèles conçus pour l'analyse et l'estimation de fiabilité.

L'aspect qui a motivé initialement ce travail était de répondre à cette question : « est que le modèle de réseaux Bayésien dynamique généré par apprentissage automatique modélisant un système peut être pratiquement utilisé pour l'analyse de la fiabilité de ce dernier ».

Théoriquement, l'idée de construire des modèles de RBD modélisant la fiabilité des systèmes par apprentissage automatique en utilisant les données de test ou de l'historique de fonctionnement de ces derniers, tel qu'il est montré dans le formalisme proposée semble très prometteuse. La validation empirique de

l'approche à prouver qu'on peut pratiquement utiliser ce formalisme générique pour l'analyse de la fiabilité.

2. PERSPECTIVES

Le travail mené dans ce mémoire a permis de pouvoir confronter les caractéristiques d'une problématique d'intérêt – l'apprentissage des réseaux Bayésiens et l'extraction des connaissances – à celle d'analyse de la fiabilité des systèmes. Il offre plusieurs perspectives de recherche :

- Le développement d'algorithmes d'apprentissage de structure de réseaux bayésiens, et plus particulièrement des réseaux bayésiens dynamiques qui "passent à l'échelle", applicables lorsque le nombre de variables est très grand (cas des systèmes complexes).
- Le développement d'algorithmes d'inférence des réseaux bayésiens dynamiques plus performants et plus rapide, le pas de discrétisation Δt influence les résultats de calcul de fiabilité obtenus, plus le Δt est petit plus les résultats seront précis, mais ça demande un temps d'exécution plus important.
- Les réseaux Bayésiens orienté objet offre un cadre très intéressant pour la modélisation de la fiabilité des systèmes complexes, l'apprentissage des RBOO est aussi un champ d'étude intéressant pour l'application de notre approche.
- Les variables représentant les contraintes exogènes peuvent être de nature continue, par conséquent le développement des algorithmes d'apprentissage et d'inférence des réseaux Bayésiens dynamiques hybrides et des techniques de discrétisation efficaces et une piste de recherche très intéressant.
- Appliquer le formalisme proposé en utilisant l'approche basée sur l'évènement des réseaux Bayésiens pour modéliser la fiabilité est très intéressant parce qu'il permet de modéliser les systèmes non markoviens, néanmoins le développement des méthodes d'apprentissage de structure et des paramètres de ce genre des réseaux Bayésiens dynamiques est nécessaire.

- Etendre ces travaux pour modéliser la procédure de la planification des maintenances et l'analyse de risque.
- Intégrer dans un seul modèle de réseaux Bayésien, les aspects techniques, organisationnels, informationnels, décisionnels et humains et leurs impacts sur le fonctionnement du système.
- Cas des bases de données incomplètes, c'est le cas de la plupart des applications réelles est aussi un axe de recherche très intéressant.
- La découverte de structures causales sans variables latentes est une première étape, pas encore complètement résolue, mais elle n'est pas suffisante. Rares sont les problèmes où les variables pertinentes sont toutes connues, et l'oublier peut aboutir à la découverte de relations causales erronées. Il faut donc à présent continuer à explorer la piste des réseaux bayésiens causaux avec variables latentes.

ANNEXE A

LISTE DES SYMBOLES ET ABREVIATIONS

GENERALE

RB : Réseau Bayésien.

RBD : Réseau Bayésien Dynamique.

DAG : Direct Acyclic Graph.

GOSC : Graphe Orienté sans Circuits.

AD : Arbre de défaillance.

AAD : Analyse d'arbres de défaillance.

FT : Fault Trees.

ADD : Arbre de Défaillance Dynamique.

DFT : Dynamic Fault Trees.

CM : Chaine de Markov.

CMD : Chaine de Markov Discrète.

CMC : Chaine de Markov Continue.

OCF : Optimisation par Colonie de Fourmis.

VARIABLES ALEATOIRES

X_1, \dots, X_n : Variables aléatoires génériques et noms de nœuds génériques d'un graphe.

X, Y, Z vecteurs aléatoires formés d'éléments de X_1, \dots, X_n et sous ensembles de nœuds de $\{X_1, \dots, X_n\}$.

$x, \{X = x\}$ événement.

X_i^l : Variable aléatoire représentant la valeur de l'i-ième attribut dans le l-ième exemple de la base D .

PROBABILITES ET INDEPENDANCES

\mathbb{P} : Mesure de probabilité.

$\mathbb{P}(\cdot|\cdot)$: Probabilité conditionnelle ($\mathbb{P}(X|Z)$).

$\cdot \perp \cdot$: Indépendance marginale.

$\cdot \perp \cdot | \cdot$: Indépendance conditionnelle ($X \perp Y | Z$).

GRAPHES ET SEPARATION

G : Graphe sur l'ensemble de nœuds $X = \{X_1, \dots, X_n\}$.

$\perp \cdot \mid \cdot$: Critère de séparation dans les graphes.

$\perp_d \cdot \mid \cdot$: Critère de d-séparation dans les graphes ($X \perp_d Y \mid Z$) .

ε : Application de $X \times X$ vers $\{0, 1\}$ codant l'existence d'arcs et d'arêtes.

$Pa(X_i)$: vecteur aléatoire de l'ensemble des variables parentes du i-ième nœud.

$En f(X_i)$: variable aléatoire de l'ensemble des variables parentes filles du i-ième nœud.

$Desc(X_i)$: variable aléatoire de l'ensemble des variables descendantes du i-ième nœud.

$F(X_i)$: frontière de Markov du nœud X_i .

$M(X_i)$: couverture de Markov du nœud X_i .

PARAMETRES

Θ : caractère générique pour représenter l'ensemble des paramètres d'un réseau Bayésien $\Theta = \{\mathbb{P}(X_i = k \mid \mathbb{P}\mathbb{Q}(X_i) = j)\}_{i,j,k}$.

$\hat{\Theta}$: Caractère générique pour représenter l'ensemble des paramètres d'un réseau Bayésien évalué par maximum de vraisemblance ou maximum a posteriori.

θ_i : Tableau à trois dimensions représentant l'ensemble des paramètres pour le nœud x_i .

θ_{ij} : Matrice de paramètres pour le nœud X_i lorsque ses parents sont dans leur j-ième configuration.

θ_{ijk} : Paramètre pour le nœud X_i lorsque ses parents sont dans leur j-ième configuration et qu'il est dans sa k-ième état $\theta_{ijk} = \{\mathbb{P}(X_i = k \mid \mathbb{P}\mathbb{Q}(X_i) = j)\}_{i,j,k}$.

DONNEES ET INSTANTIATIONS

D_c : Base d'exemples complète.

D : Base d'exemples incomplète.

O : Partie observée de D , sous ensemble de $\{X_i^l\}$.

H : Partie non-observée de D , sous ensemble de $\{X_i^l\}$, complémentaire de O .

n : Nombre d'attributs dans la base D .

N : Nombre d'exemples dans la base D .

q_i : Nombre de configurations du vecteur aléatoire de l'ensemble des variables parentes du nœud X_i .

r_i : Nombre de configurations de la variable aléatoire discrète X_i .

N_i : Histogramme de la variable X_i pour la base D .

N_j : Nombre d'exemples où le vecteur aléatoire $Pa(X_i)$ prend sa j-ième valeur dans la base D .

N_{ijk} : Nombre d'exemples où le vecteur aléatoire $Pa(X_i)$ prend sa j-ième valeur tandis que la variable X_i prend sa k-ième valeur dans la base D .

x_i^l : Observation du i-ième attribut dans le l-ième exemple de la base D .

$pa(X_i)^l$: l-ième observation dans D de la variable $Pa(X_i)$.

$enf(X_i)^l$: l-ième observation dans D de la variable $enf(X_i)$.

$desc(X_i)^l$: l-ième observation dans D de la variable $Desc(X_i)$

ANNEXE B

PROBABILITE ET STATISTIQUE

Définition B.1 (tribu des événements)

Soit A , un sous ensemble des parties de Ω , A a une structure de tribu s'il satisfait :

- si $A \in \Omega$ alors son complémentaire $A^c = \Omega \setminus A$ est aussi dans A .
 - Soit une suite A_1, A_2, \dots, A_n finie et dénombrable d'éléments de A , leur réunion $\bigcup_{n \geq 1} A_n$ est aussi dans A .
 - L'ensemble vide \emptyset est dans A .
- On appelle événements les éléments de A .

Définition B.2 (probabilité) Soit un espace Ω d'observables et une tribu d'événements A formée de sous-ensembles de Ω , on appelle probabilité une fonction \mathbb{P} de A dans $[0, 1]$ telle que :

- L'événement certain est de probabilité 1 : $\mathbb{P}(\Omega) = 1$.
- Toute suite A_1, A_2, \dots, A_n d'événements de A , deux à deux disjoints alors la série

$$\sum_{i=1}^{\infty} \mathbb{P}(A_i) \quad (B.1)$$

Converge et a pour somme $\mathbb{P}(\bigcup_{n \geq 1} A_i)$.

On appelle alors espace de probabilités ou espace probabilisé le triplet (Ω, A, \mathbb{P}) .

Définition B.3 (Variable aléatoire) Soit (Ω, A, \mathbb{P}) , un espace probabilisé et \mathbf{B} la tribu des boréliens de \mathbb{R} .

Une application :

$$\begin{cases} (\Omega, A) \rightarrow \mathbb{R} & \mathbf{B}(\mathbb{R}) \\ w \rightarrow X(w) \end{cases} \quad (B.2)$$

est appelée variable aléatoire (ou v.a.) sur (Ω, A) si :

$$\forall B \in \mathbf{B}(\mathbb{R}), (X \in B) \text{ implique } X^{-1}(B) \in A \quad (B.3)$$

Dans le cadre de notre étude, l'espace de définition des variables est dénombrable et fini ; par conséquent, nous travaillerons par la suite avec des variables aléatoires discrètes.

Définition B.4 (loi d'une variable aléatoire discrète X)

$$p(x) = \mathbb{P}(\omega \in \Omega | X(\omega) = x) \quad (B.3)$$

Propriété 1

$$- 0 \leq p(x) \leq 1 \quad \forall x \in \Omega$$

$$- \sum_{x \in \Omega} p(x) = 1$$

$$\mathbb{P}(X(A)) = \sum_{x \in A} p(x)$$

Définition B.5 (probabilité jointe)

Soient X et Y deux variables aléatoires définies sur le même espace d'événements. On définit la probabilité jointe P_{AB} de ces deux v.a. par :

$$\mathbb{P}_{AB} \left| \begin{array}{l} (\Omega, \mathbf{A}) \times (\Omega, \mathbf{B}) \rightarrow [0,1] \\ (a, b) \rightarrow \mathbb{P}_{AB}(a, b) = \mathbb{P}(\{\omega \in \Omega | A(\omega) = a \text{ ET } B(\omega) = b\}) \end{array} \right. \quad (B.4)$$

Ce qui peut se généraliser à un ensemble $X = \{X_1, X_2, \dots, X_n\}$ de n v.a.:

$$\mathbb{P}_x : \left| \begin{array}{l} (\Omega, \mathbf{A}_{X_i}) \rightarrow [0,1] \\ x = (x_1, x_2, \dots, x_n) \rightarrow \mathbb{P}_x(x) = \mathbb{P}(\{\omega \in \Omega | \text{ET}_{i \in \{1, \dots, n\}} X_i(\omega)\}) \end{array} \right. \quad (B.5)$$

B.1 PROBABILITES CONDITIONNELLESDéfinition B.6 (Probabilité conditionnelle)

Soit un espace probabilisé $(\Omega, \mathbf{A}, \mathbb{P})$, la probabilité conditionnelle $P(A|B)$ d'un événement A conditionnellement

à un événement B tel que $P(B) > 0$ est définie par :

$$\mathbb{P}(A|B) = \frac{\mathbb{P}(A \cap B)}{\mathbb{P}(B)} \quad (B.6)$$

Si $P(B) = 0$ alors $P(A|B)$ n'est pas définie.

Proposition B.1 (Règle d'inversion de Bayes)

Soit un espace probabilisé $(\Omega, \mathbf{A}, \mathbb{P})$, et A et B deux événements de \mathbf{A} tels que $\mathbb{P}(A) > 0$ et $\mathbb{P}(B) > 0$ alors :

$$\mathbb{P}(A|B) = \frac{\mathbb{P}(A|B) \mathbb{P}(B)}{\mathbb{P}(B)} \quad (B.7)$$

Cette propriété est à la base du procédé d'inférence. En effet, si nous cherchons à mesurer notre incertitude quant à une hypothèse H en connaissant à partir d'une observation (ou ensemble de données) o , nous pouvons écrire :

$$\mathbb{P}(H|o) = \frac{\mathbb{P}(o|H)\mathbb{P}(H)}{\mathbb{P}(o)} \quad (B.8)$$

- $\mathbb{P}(o|H)$ est la probabilité a posteriori ;
- $\mathbb{P}(H)$ est la probabilité a priori ;
- $\mathbb{P}(H|o)$ est la vraisemblance de l'observation ;
- $\mathbb{P}(o)$ est une constante telle que : $\sum_h \mathbb{P}(H = h|o) = 1$ soit $\mathbb{P}(o) = \sum_h \mathbb{P}(o|h)\mathbb{P}(o)$

B.2 Indépendances conditionnelles : définitions et mesures

Le calcul d'une probabilité jointe sur un ensemble conséquent de variables aléatoires, même binaires, requiert un nombre exponentiel de calculs. Il convient alors de simplifier la démarche et pour cela, exploiter les indépendances conditionnelles sous-jacentes au domaine.

Définition B.6 (Indépendance conditionnelle)

Soit un univers Ω et un ensemble X de variables aléatoires. Soient les sous ensembles X, Y et $Z \subseteq X$. X est indépendant de Y conditionnellement à Z (ou $(X \perp Y|Z)$) si et seulement si X, Y et Z vérifient :

$$(X \perp Y) \leftrightarrow \begin{cases} \mathbb{P}(X|Y, Z) = \mathbb{P}(X|Z) \\ \text{et } \mathbb{P}(Y|X, Z) = \mathbb{P}(Y|Z) \end{cases} \quad (B.8)$$

Définition B.7 (Indépendance marginale)

Soit un univers Ω et un ensemble X de variables aléatoires. Soient les sous ensembles X et $Y \subseteq X$ tels que $(X \perp Y|Z)$:

B.3 Formules et notions liés à l'indépendance conditionnelle

Test du χ^2

Le test du χ^2 a plusieurs emplois possibles :

- Test d'adéquation ;
- Test d'homogénéité ;
- Test d'indépendance.

Nous nous intéressons à son emploi afin de déterminer si deux variables aléatoires sont indépendantes.

Soient deux variables aléatoires discrètes X_A et X_B . Soient r_A et r_B , leurs cardinalités respectives. Soient N_{ab} le nombre d'occurrences observées dans la base d'exemples D , constituée de N cas, de $\{X_A = a \wedge X_B = b\}$. N_a et N_b le nombre d'occurrences observées de $\{X_A = a\}$ et $\{X_B = b\}$, respectivement. E_{ab} représente l'effectif théorique des occurrences de $\{X_A = a \wedge X_B = b\}$.

Deux hypothèses :

H_0 : les deux variables X_A et X_B sont indépendantes et $\mathbb{P}(X_A \wedge X_B) = \mathbb{P}(X_A) \times \mathbb{P}(X_B)$.

H_1 : X_A et X_B ne sont pas indépendantes.

Le test quantifie la distance entre la fréquence observable des événements considérés et la fréquence hypothétique. Un seuil limite fait office de critère de validation de l'hypothèse H_0 (en l'occurrence les variables sont indépendantes).

$$\chi^2 = \sum_{a,b} \frac{(N_{ab} - E_{ab})^2}{E_{ab}} \quad (B.9)$$

Dans le cadre de l'établissement non plus d'une indépendance entre deux variables mais d'une indépendance conditionnelle faisant intervenir une troisième variable aléatoire X_C , les hypothèses à vérifier deviennent :

H_0 : les deux variables X_A et X_B sont indépendantes conditionnellement à X_C .

H_1 : X_A et X_B ne sont pas indépendantes conditionnellement à X_C .

Et la formule précédente se réécrit :

$$X^2 = \sum_{a,b,c} \frac{(N_{abc} - E_{abc})^2}{E_{abc}} \quad (B.10)$$

Avec N_{abc} le nombre d'occurrences observées de $\{X_A = a \wedge X_B = b \wedge X_C = c\}$. N_{ac} et N_{bc} le nombre d'occurrences observées de $\{X_A = a \wedge X_C = c\}$ et $\{X_B = b \wedge X_C = c\}$, respectivement.

Entropie

Pour une variable aléatoire X_A dotée d'une distribution de probabilité $P(X_A)$, l'entropie de X_A s'exprime par :

$$H(X_A) = \sum_{x_a} \mathbb{P}(X_A) \log(\mathbb{P}(X_A)) = E(-\log \mathbb{P}(X_A)) \quad (B.11)$$

L'entropie conditionnelle d'une variable aléatoire X_A étant donné la valeur prise par une variable aléatoire X_B exprime la quantité d'information nécessaire pour inférer X_A à partir d' X_B .

Entropie Croisée Soit E_C , l'entropie croisée de X_A et X_B étant donné X_A, X_B et X_C trois variables aléatoires.

$$E_C(X_A, X_B | X_C) = \sum_{x_c} (\mathbb{P}(X_C) \sum_{x_a, x_b} \mathbb{P}(X_A, X_B | X_C) \log \left(\frac{\mathbb{P}(X_A, X_B | X_C)}{\mathbb{P}(X_A | X_C) \mathbb{P}(X_B | X_C)} \right) \quad (B.12)$$

L'entropie est bien entendu nulle quand il n'y a pas d'incertitude.

Ceci vérifie $E_C(X_A, X_B | X_C) = H(X_A | X_C) - H(X_A | X_B, X_C)$ et est aussi connu sous le nom d'Information Mutuelle : $I_m(X_A, X_B)$.

Démonstration C.3: Dans le cas de trois variables aléatoires, X_A , X_B et X_C , nous avons :

$$H(X_A | X_C) = - \sum_{x_a} \sum_{x_b} \sum_{x_c} \mathbb{P}(X_A, X_B, X_C) \log(\mathbb{P}(X_A | X_C)) \quad (B.13)$$

$$H(X_A | X_B, X_C) = - \sum_{x_a} \sum_{x_b} \sum_{x_c} \mathbb{P}(X_A, X_B, X_C) \log(\mathbb{P}(X_A | X_B, X_C)) \quad (B.14)$$

$$I_m(X_A, X_B | X_C) = \sum_{x_a} \sum_{x_b} \sum_{x_c} \mathbb{P}(X_A, X_B, X_C) \log \left(\frac{\mathbb{P}(X_A | X_B, X_C)}{\mathbb{P}(X_A | X_C)} \right) \quad (B.15)$$

Or,

$$\mathbb{P}(X_A|X_B, X_C) = \frac{\mathbb{P}(x_i, y_j, z_k)}{\mathbb{P}(y_j, z_k)} = \frac{\mathbb{P}(x_i, y_j|z_k)\mathbb{P}(z_k)}{\mathbb{P}(y_j|z_k)\mathbb{P}(z_k)} = \frac{\mathbb{P}(x_i, y_j|z_k)}{\mathbb{P}(y_j|z_k)} \quad (B.16)$$

D'où

$$I_m(X, Y|Z) = \sum_n \sum_m \sum_l \mathbb{P}(x_i, y_j, z_k) \log \left(\frac{\mathbb{P}(X_A|X_B|X_C)}{\mathbb{P}(X_A|X_C)\mathbb{P}(X_B|X_C)} \right) \quad (B.17)$$

$$= \sum_{x_a} \mathbb{P}(X_C) \sum_{x_b} \sum_{x_c} \mathbb{P}(X_A, X_B, X_C) \log \left(\frac{\mathbb{P}(X_A|X_B|X_C)}{\mathbb{P}(X_A|X_C)\mathbb{P}(X_B|X_C)} \right) \quad (B.18)$$

Pour deux variables aléatoires X_A et X_B , l'information mutuelle dépend à la fois de X_A et de X_B . Nous quantifions (conceptuellement) la quantité d'information sur X_B contenue dans X_A (et inversement, l'information étant symétrique, la quantité d'information sur X_A contenue dans X_B).

Cette mesure permet de définir une sorte de distance entre la probabilité jointe $\mathbb{P}(X_A, X_B)$ et le produit de probabilités marginales $\mathbb{P}(X_A) \times \mathbb{P}(X_B)$.

Si X_A et X_B sont indépendantes, alors $\mathbb{P}(X_A, X_B) = \mathbb{P}(X_A) \times \mathbb{P}(X_B)$ et l'information mutuelle est nulle. Dans notre cas, nous nous intéressons à $I(X_A, X_B|X_C)$. Cette expression n'est nulle que si X_A et X_B sont conditionnellement indépendantes, connaissant X_C .

Rapport de vraisemblance

En lieu et place du test du X^2 , on peut souhaiter employer le test du rapport de vraisemblance aussi connu sous le nom de test du G^2 .

$$G^2(X_A, X_B) = \sum_{a,b} N_{ab} \times \log \left(\frac{N_{ab} \times N}{N_a \times N_b} \right) \quad (B.19)$$

Nous voyons ici que la valeur de G^2 est proportionnelle à celle de l'entropie croisée :

$$G^2(X_A, X_B) = 2 \times E_C(X_A, X_B) \quad (B.20)$$

G^2 suit alors une loi de distribution du X^2 à $(r_a - 1)(r_b - 1) \prod_{c \in C} r_c$ degrés de libertés.

Test de Mann-Whitney

Il s'agit, à la base, d'un test statistique non-paramétré permettant de déterminer, avec un certain degré confiance, s'il existe une différence significative entre deux échantillons supposément indépendants (on dit aussi que ce test est un test d'identité permettant de déterminer si les deux échantillons sont issus d'une même distribution). Typiquement, on va chercher à déterminer si les valeurs d'un échantillon sont significativement plus petites que celle d'un deuxième échantillon.

Le test de Mann-Whitney repose sur la mesure d'un paramètre U , calculé en fonction des rangs des différentes valeurs des deux ensembles, les unes par rapport aux autres. La distribution de U sous l'hypothèse H_0 est connue (H_0 : les deux échantillons ne sont pas homogènes).

Il existe plusieurs manières de calculer U mais nous n'en détaillerons qu'une seule, simple. Nous nous limitons au cas d'échantillons de taille modeste, bien que des techniques d'approximation permettent de traiter le cas d'échantillons de très grande taille.

Le calcul de U s'effectue comme suit :

Soit E_{1c} le premier échantillon, de taille n_1 dont on cherche à déterminer si ses valeurs sont significativement plus petites que celles contenues dans le deuxième échantillon, E_{2c} , de taille n_2 :

Commencer par regrouper les valeurs issues des deux échantillons dans un seul ensemble, E_c . Ordonner les valeurs de E_c (sans perdre leur origine) puis calculer R, la somme des rangs occupés par les valeurs issues de E_{1c}

$$U = n_1 n_2 + \frac{n_1(n_2 + 1)}{2} - R \quad (B.21)$$

La lecture de tables appropriées permet alors, à partir de la valeur de U de déterminer la validité ou non de l'hypothèse nulle H_0 .

B.4 MESURES DE DIVERGENCE ENTRE DEUX DISTRIBUTIONS DE PROBABILITES

Il peut être utile de pouvoir définir une notion de distance entre deux distributions de probabilités définies sur un même domaine. C'est ce que permettent les mesures introduites dans cette section : les divergences de Kullback-Leibler et celle de Jensen-Shannon.

B.4.1 Divergence de Kullback-Leibler

Soit X_i une variable aléatoire.

P et Q deux distributions de probabilités.

La divergence de Kullback-Leibler entre deux lois de distributions respectives P et Q est définie par :

$$KL(\mathbb{P}||Q) = \sum_{x_i} \mathbb{P}(X_i) \log\left(\frac{\mathbb{P}(X_i)}{Q(X_i)}\right) \quad (B.22)$$

Les propriétés de cette divergence sont les suivantes :

- Non symétrique
- égale à zéro si et seulement si $\mathbb{P} = Q$
- Si $\exists x_i$ tel que $p(x_i) > 0$ et $q(x_i) = 0$, alors la divergence est infinie
- L'entropie de P vaut $\log(r) - D(P||U)$ avec m, le nombre de cas contenus dans D et U, la distribution uniforme. la non-symétrie de la divergence de Kullback-Leibler ainsi que sa convergence vers +1 si il existe x_i tel que $p(x_i) > 0$ et $q(x_i) = 0$ rendent

son emploi en tant que mesure de dissimilarité problématique. On préfère souvent employer une extension de la divergence [41]:

$$D_\lambda(\mathbb{P}||Q) = \lambda KL(\mathbb{P}||\lambda\mathbb{P} + (1 - \lambda)Q) + (1 - \lambda)KL(Q||\lambda\mathbb{P} + (1 - \lambda)Q) \quad (B.23)$$

B.4.2 Divergence de Jensen-Shannon

Soit X_i une variable aléatoire.

\mathbb{P} et Q deux distributions de probabilités.

La divergence de Jensen-Shannon entre deux lois de distributions respectives \mathbb{P} et Q est définie par:

$$JS(\mathbb{P}||Q) = \frac{1}{2} \left[\sum_{x_i} \mathbb{P}(X_i) \log \left(\frac{2\mathbb{P}(X_i)}{\mathbb{P}(X_i) + Q(X_i)} \right) + \sum_{x_i} Q(X_i) \log \left(\frac{2Q(X_i)}{\mathbb{P}(X_i) + Q(X_i)} \right) \right] \quad (B.24)$$

B.5 GRAPHE MORAL

Définition B.2 (graphe moral): Si $G = (X, E)$ est un GSCO, alors $G_0 = (X, E_0)$ est un graphe moral associé à G si G_0 est un graphe non orienté tel que $E_0 \supseteq E$ et si $[E(X_{i1}, X_j) = 1 \text{ et } E(X_{i2}, X_j) = 1] \text{ alors } E_0(X_{i1}, X_{i2}) = 1$.

La moralisation est une réécriture de $\mathbb{P}(X_1, \dots, X_n) = \prod_i \mathbb{P}(X_i, Pa(X_i))$ par $\mathbb{P}(X_1, \dots, X_n) = \prod_i fct(X_i, Pa(X_i))$ telle qu'il est toujours possible de retrouver la première expression. Après avoir retiré les orientations, nous pourrions croire que de l'information a été perdue, mais cela n'est pas le cas.

Définition B.3 (graphe triangulé): Soit $G = (X, E)$ est un graphe moral, un graphe triangulé pour G est un graphe cordal qui est également une carte d'indépendance pour la loi sous-jacente à G .

Remarquons qu'un graphe triangulé associé à un graphe moral n'est pas unique.

B.6 Distribution de Dirichlet

La loi de Dirichlet, souvent notée $Dir(\alpha)$, est une famille de lois de probabilité continues pour des variables aléatoires multinomiales. Cette loi (ou encore *distribution*) est paramétrée par le vecteur α de nombres réels positifs et tire son nom de Johann Peter Gustav Lejeune Dirichlet. Elle est vue comme la généralisation multinomiale de la loi bêta.

La loi de Dirichlet d'ordre $K \geq 2$ de paramètres $\alpha_1, \dots, \alpha_K > 0$ possède pour densité de probabilité :

$$f(x_1, \dots, x_k, \alpha_1, \dots, \alpha_k) = \frac{1}{\beta(\alpha)} \prod_{i=1}^k x_i^{\alpha_i - 1} \quad (B.25)$$

Pour tous les $x_1, \dots, x_K > 0$ vérifiant $x_1 + \dots + x_{K-1} < 1$, où x_K est une abréviation pour $1 - x_1 - \dots - x_{K-1}$. La densité est nulle en dehors de ce simplexe ouvert de dimension $(K - 1)$. La constante de normalisation est la fonction bêta multinomiale, qui s'exprime à l'aide de la fonction gamma :

$$\beta(\alpha) = \frac{\prod_{i=1}^k \Gamma(\alpha_i)}{\Gamma(\sum_{i=1}^K \alpha_i)}, \alpha = (\alpha_1, \dots, \alpha_k) \quad (B.26)$$

ANNEXE C

NOTIONS UTILES POUR L'APPRENTISSAGE DES RESEAUX BAYESIENS

C.1 DIMENSION D'UN RESEAU BAYESIEN

$X = (X_1, \dots, X_n)$ est un vecteur aléatoire composé de n variables aléatoires discrètes. Si r_i est la modalité de la variable X_i , alors le nombre de paramètres nécessaires pour représenter la distribution de probabilité $P(X_i/Pa(X_i) = pa(x_i))$ est égal à $r_i - 1$.

Pour représenter $P(X_i/Pa(X_i))$, il faut alors $Dim(X_i, B)$ paramètres avec

$$Dim(X_i, B) = (r_i - 1) \cdot q_i \quad (C.1)$$

Où q_i est le nombre de configurations possibles pour les parents de X_i , c'est-à-dire

Définition C.1: La dimension d'un réseau Bayésien B est définie par :

$$Dim(X_i) = \sum_{i=1}^n Dim(X_i, B) \quad (C.2)$$

La dimension d'un réseau Bayésien est une grandeur qui sera utile pour les fonctions de score qui font intervenir un terme de pénalité. Cette grandeur représente le nombre de paramètres indépendants que possède le réseau. Il est judicieux de pénaliser les réseaux trop complexes. Ceux-ci peuvent alors encoder de nombreuses distributions de probabilité, cependant, ils sont difficilement interprétables quand ils sont fortement connectés. Dans ce cas, que dire de plus quand toute variable dépend de presque toutes les autres ? Un tel réseau permet donc de modéliser de nombreuses dépendances, par contre, il possède un grand nombre de paramètres. Donc, si la base ne contient pas beaucoup d'exemples, l'apprentissage des paramètres ne sera alors pas très précis : il n'y aura alors que très peu d'exemples pour chaque configuration d'un nœud et de l'ensemble de ses nombreux parents. Il faut alors trouver un bon compromis expressivité/complexité du réseau. Pour cela, il est possible de se conformer au principe du rasoir d'*Occam*.

C.2 PRINCIPE DU RASOIR D'OCCAM

Le rasoir de William d'Ockham (Guillaume d'Occam étant la variante latine de ce nom, 1285-1349) est un principe attribué au moine écrivain et théologien franciscain. Penseur du XIV^e siècle, il est né à Occam, un village du comté de Surrey. Ses enseignements furent parmi les premiers à être en rupture avec ceux des philosophes médiévaux le précédant, y compris le réalisme aristotélicien de Thomas D'Aquin. William luttait contre la pratique habituelle (toujours d'actualité)

de décrire la nature en ayant recours à des abstractions non testables, tentant d'être aussi proche de la réalité physique que possible quelque soit le domaine étudié.

Ce principe a été énoncé comme suit :

"Pluralitas non est ponenda sine neccesitate"

"Frustra fit per plura quod potest fieri per pauciora"

"Non sunt multiplicanda entia praeter necessitatem"

Ce texte peut se traduire en : "La pluralité ne devrait pas être posée sans nécessité", "C'est en vain que l'on fait avec beaucoup ce qui peut être fait avec un petit nombre", "les entités ne doivent pas être multipliées sans nécessité". De tels points de vue ont été partagés par de nombreux auteurs dont Aristote en 350 avant notre ère qui a déclaré : "la nature prend toujours le chemin le plus court possible", ou encore : "le plus limité, s'il est adéquat, est toujours préférable". De nombreux savants ont adopté ou réinventé le rasoir d'Occam, par exemple, en voici une variante moderne : "Ce qui peut être fait avec peu d'hypothèses sera fait en vain avec plus", ou encore, Isaac Newton, qui énonça la règle :

"Nous n'avons pas à accepter plus de causes des choses naturelles que celles qui sont à la fois vraies et suffisantes pour expliquer ces choses". De même, plus récemment, Einstein disait : "Tout devrait être fait le plus simplement possible, ce qui ne veut pas dire de façon simplette". Ce principe est également appelé «principe de simplicité», «principe de parcimonie », ou encore «principe d'économie». Le principe du rasoir d'Occam consiste à ne pas multiplier les hypothèses au-delà du nécessaire, et en d'autres termes, à *privilégier l'hypothèse la plus simple* tant que cela reste compatible avec les observations.

Dans le cadre des réseaux Bayésiens, nous privilégierons le modèle le moins complexe, c'est à dire, celui possédant le moins de paramètres.

C.3 SCORE DECOMPOSABLE

En supposant que nous disposions d'une méthode qui parcourt l'espace des DAG en effectuant des opérations du type ajout ou suppression d'arcs, il est nécessaire de réduire le nombre de calculs utilisés pour l'évaluation du score. Pour cela, posséder un score calculable localement, permet de n'estimer que la variation de ce score entre deux structures voisines, au lieu de le recalculer entièrement pour la nouvelle structure.

Définition C.2: *Un score S est dit décomposable (ou local) s'il peut être écrit comme une somme ou un produit de mesures dont chacune n'est fonction seulement que d'un nœud et de l'ensemble de ses parents. En clair, si n est le nombre de nœuds du graphe, le score doit avoir une des formes suivantes :*

Tous les scores que nous allons introduire par la suite peuvent se décomposer localement. Cette dernière assertion est en fait héritée d'un élève de William d'Occam.

C.3.1 SCORE EQUIVALENT

Un score qui associe une même valeur à deux graphes équivalents est dit équivalent. Certains scores ne sont pas équivalents comme par exemple le score BD qui est issu de la vraisemblance marginale $\mathbb{P}(D|G)$. Par contre, la vraisemblance $\mathbb{P}(D|G)$ est score équivalente mais ne respecte pas le principe de parcimonie.

Définition C.3 (Score décomposable): *Une fonction de score S est dite décomposable si, étant donné la structure G d'un réseau Bayésien B , $S(B)$ peut être exprimé sous la forme d'un produit (ou d'une somme, dans l'espace logarithmique) de scores locaux ne concernant qu'un sommet et ses parents.*

$$S(B) = \sum_{i=1}^n s(X_i, \pi_i) \text{ ou bien } S(B) = \prod_{i=1}^n s(X_i, \pi_i) \quad (C.3)$$

Où n représente le nombre de sommets du graphe G .

Cette propriété permet de réduire considérablement les coûts de calcul d'une heuristique de parcours de l'espace des GOSC.

ÉQUIVALENCE : Deux GOSC différents peuvent encoder une même décomposition de la loi jointe sur le domaine modélisé. Les deux structures sont alors dites équivalentes au sens de Markov. Il en résulte que plusieurs GOSC peuvent représenter le même ensemble d'indépendances conditionnelles et, par conséquent, présenter la même pertinence en termes de représentation de connaissance (dans le cas d'un graphe non-causal).

Définition C.4 (Score équivalent): *Une fonction de score S est dite équivalente si, étant donné deux réseaux Bayésiens B et B_0 équivalents au sens de Markov, S associe une même valeur aux structures de B et B_0 .*

L'emploi d'un score équivalent permet donc de pouvoir distinguer des structures qui ne sont pas statistiquement équivalentes (et réciproquement, de regrouper les structures qui le sont). Dans le meilleur cas, nous devrions pouvoir ainsi déterminer une seule structure G statistiquement équivalente au graphe G^2 recherché. Il nous reste à assurer l'existence de G^2 , ce qui est le rôle de la propriété de consistance.

CONSISTANCE : Il est important de pouvoir garantir que la structure obtenant la meilleure évaluation soit celle du réseau à l'origine de la base de cas. Cette propriété est connue sous le nom de consistance du score employé.

Définition C.5 (Score consistant): *Une fonction de score S est dite consistante si, lorsque la taille de la base d'apprentissage D tend vers l'infini, la structure G^* correspondant au modèle sous-jacent à D obtient le meilleur score avec une probabilité approchant 1.*

Par structure correspondant au modèle, nous entendons ici la structure qui est une carte d'indépendance minimale du modèle sous-jacent à D .

C.4 L'INFORMATION MUTUELLE

Le critère d'information mutuelle IM , qui peut simplement être exprimé à l'aide de la distance de Kullback-Leibler par [41] :

$$IM(X; Y) = KL(P(X, Y) || P(X)P(Y)) = \sum_x \sum_y \mathbb{P}(x, y) \log \frac{\mathbb{P}(x, y)}{\mathbb{P}(x)\mathbb{P}(y)} \quad (C.4)$$

$$IM(X; Y) = \sum_{i=1}^{s_1} \sum_{j=1}^{s_2} \frac{O_{ij}}{N} \log \left(\frac{O_{ij}N}{E_{ij}} \right) \quad (C.5)$$

Où O_{ij} représente le nombre de fois où la configuration $x = i$ et $y = j$ apparaît dans la base d'exemples, $E_{ij} = N_i \times N_j$ et N est le nombre de cas dans la base.

L'information mutuelle représente alors le nombre de *nats* que deux variables ont en commun. Cette mesure permet donc de décider, s'il est avantageux de connecter deux variables plutôt que de les conserver indépendantes.

C.5. L'INFORMATION MUTUELLE MOYENNE CONDITIONNELLE

Il est possible de définir une Information mutuelle conditionnelle simplement en utilisant la définition de l'information mutuelle et en remplaçant les probabilités par des probabilités conditionnelles. L'information mutuelle (moyenne) conditionnelle est alors définie par :

$$IM(X; Y) = \sum_x \sum_y \sum_z \mathbb{P}(x, y, z) \log \left(\frac{\mathbb{P}(x, y, z)\mathbb{P}(z)}{\mathbb{P}(x, z)\mathbb{P}(y, z)} \right) \quad (C.6)$$

ANNEXE D

EXTRACTION ET EXPLOITATION DES CONNAISSANCES MEDICALES EN UTILISANT LES RESEAUX BAYESIENS POUR L'ORIENTATION DES PATIENTS



Figure D.1 : Fenêtre principale de l'application « Orientation des patients ».

D.1 Data Mart « consultation »

La construction de la vue « consultation » présentée dans la figure 1. Dans cette vue nous avons considéré une centaine d'attributs avec 10379 enregistrements.

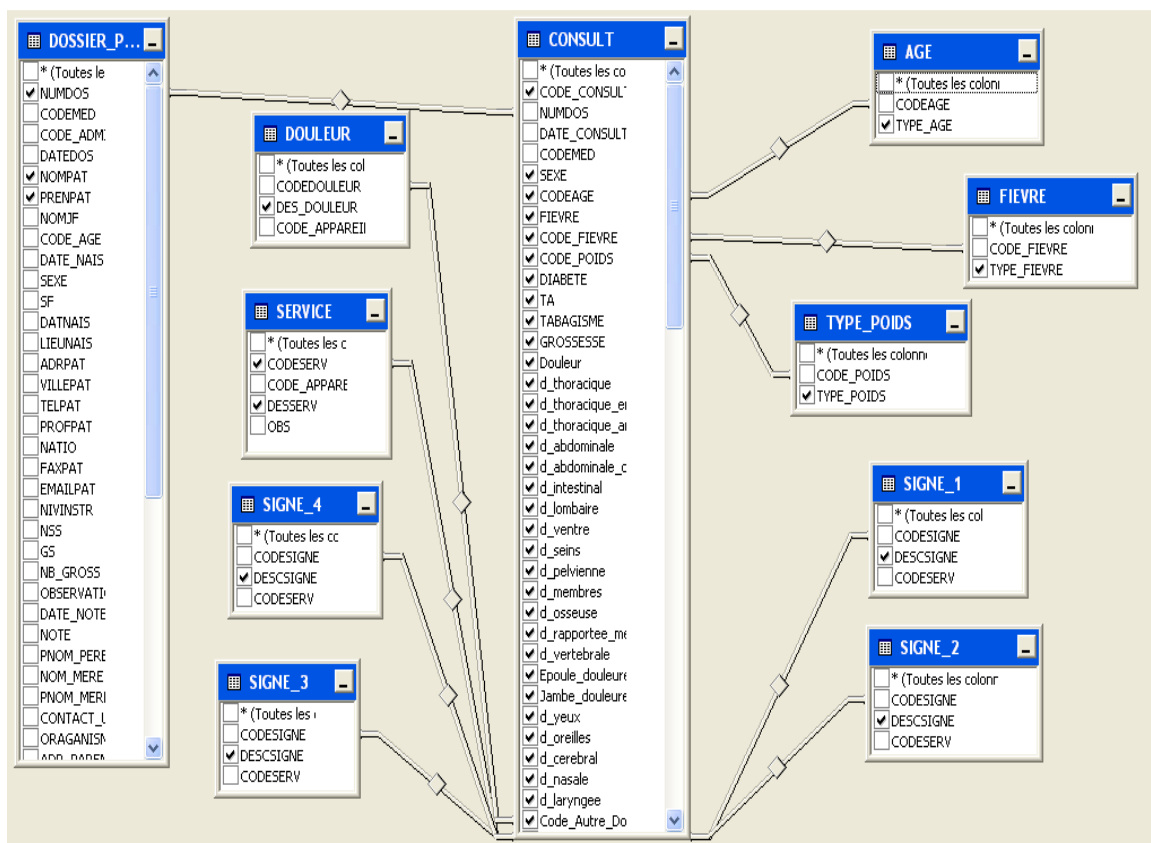


Figure D.2 : vue « consultation ».

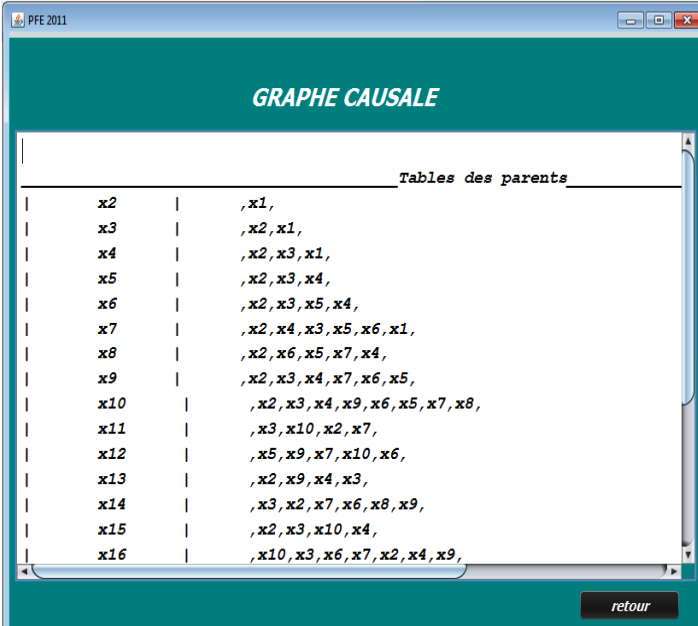
D.2 Extraction des connaissances à partir des données(ECD)

Dans ce module, nous avons développé la partie de l'extraction des connaissances à partir de données. Nous avons commencé par apprentissage de structure. Puis la construction des tables de probabilités conditionnelles.



Figure D.3 : fenêtres d'extraction des connaissances.

Apprentissage de structure

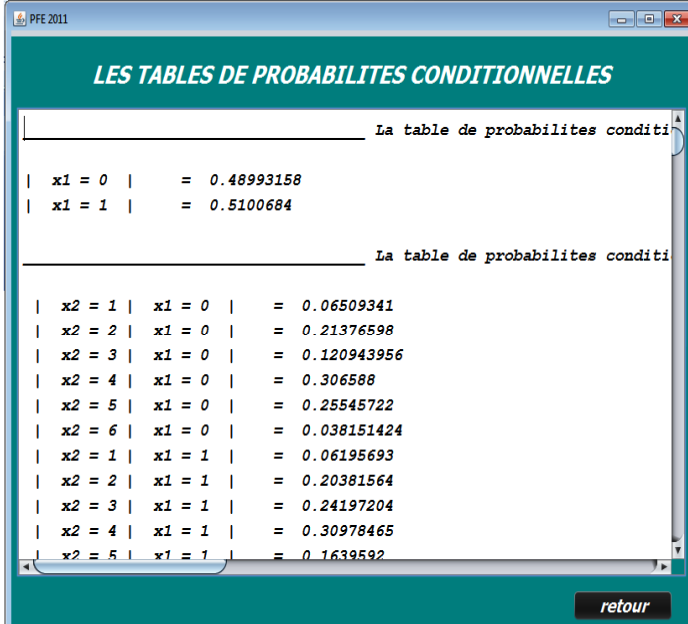


The screenshot shows a window titled "PFE 2011" with a green header "GRAPHE CAUSALE". Below the header is a table titled "Tables des parents" listing variables x2 through x16 and their parent variables. A "retour" button is at the bottom right.

Variable	Parents
x2	, x1,
x3	, x2, x1,
x4	, x2, x3, x1,
x5	, x2, x3, x4,
x6	, x2, x3, x5, x4,
x7	, x2, x4, x3, x5, x6, x1,
x8	, x2, x6, x5, x7, x4,
x9	, x2, x3, x4, x7, x6, x5,
x10	, x2, x3, x4, x9, x6, x5, x7, x8,
x11	, x3, x10, x2, x7,
x12	, x5, x9, x7, x10, x6,
x13	, x2, x9, x4, x3,
x14	, x3, x2, x7, x6, x8, x9,
x15	, x2, x3, x10, x4,
x16	, x10, x3, x6, x7, x2, x4, x9,

Figure D.4 : représentation du graphe causale (table parents).

Apprentissage de paramètres



The screenshot shows a window titled "PFE 2011" with a green header "LES TABLES DE PROBABILITES CONDITIONNELLES". It displays two tables of conditional probabilities. A "retour" button is at the bottom right.

La table de probabilités conditionnelles		
x1 = 0		= 0.48993158
x1 = 1		= 0.5100684

La table de probabilités conditionnelles		
x2 = 1	x1 = 0	= 0.06509341
x2 = 2	x1 = 0	= 0.21376598
x2 = 3	x1 = 0	= 0.120943956
x2 = 4	x1 = 0	= 0.306588
x2 = 5	x1 = 0	= 0.25545722
x2 = 6	x1 = 0	= 0.038151424
x2 = 1	x1 = 1	= 0.06195693
x2 = 2	x1 = 1	= 0.20381564
x2 = 3	x1 = 1	= 0.24197204
x2 = 4	x1 = 1	= 0.30978465
x2 = 5	x1 = 1	= 0.1639592

Figure D.5 : tables des probabilités conditionnelles.

D.4 Exploitation des connaissances extraites (inférence)

Nous avons utilisé le logiciel d'inférence « GeNIe » pour valider nos résultats. On a dessiné le graphe causal qu'est obtenu par l'implémentation de l'algorithme K2.

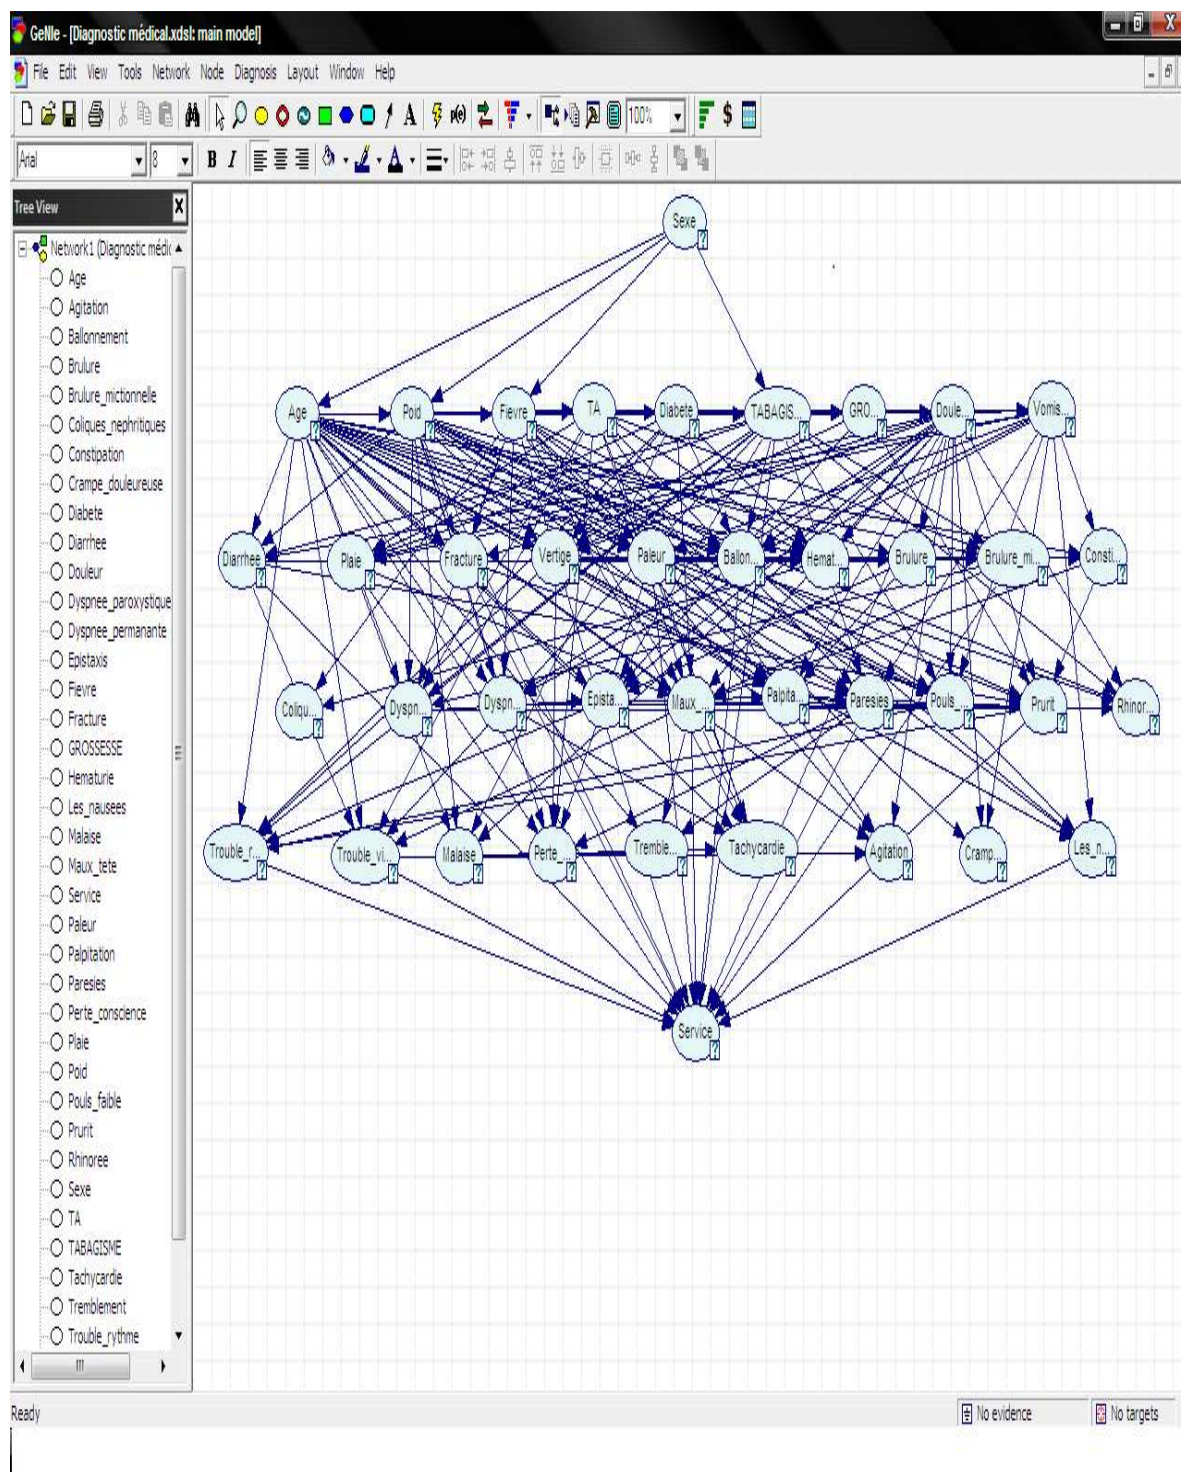


Figure D.6 : Réseaux Bayésien généré.

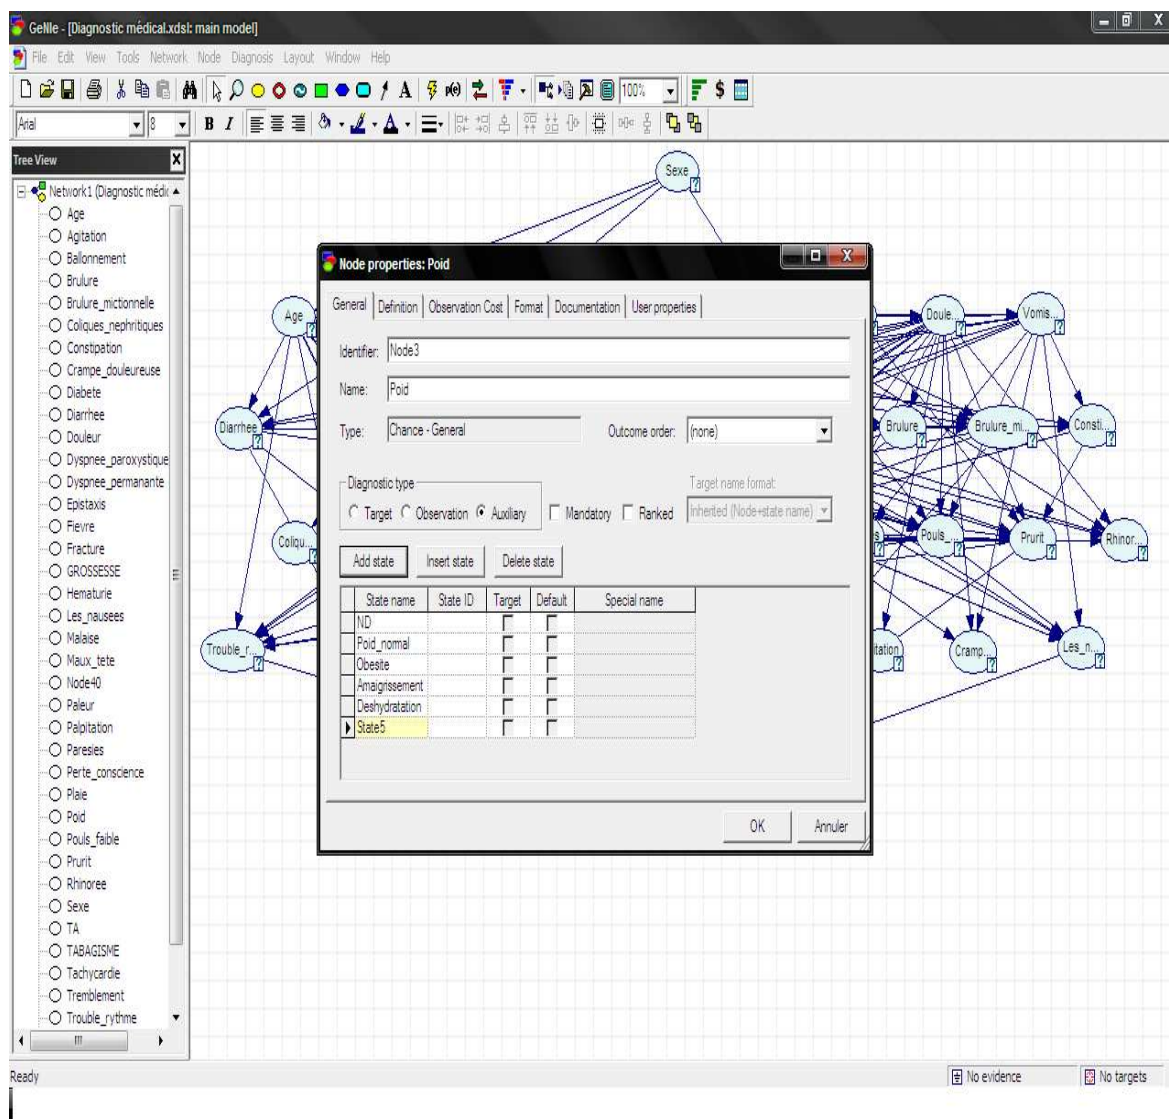


Figure D.7 : Saisie des modalités de chaque nœud.

Nous avons remplis les tables de probabilités conditionnelles qui sont obtenus par apprentissage de paramètres.

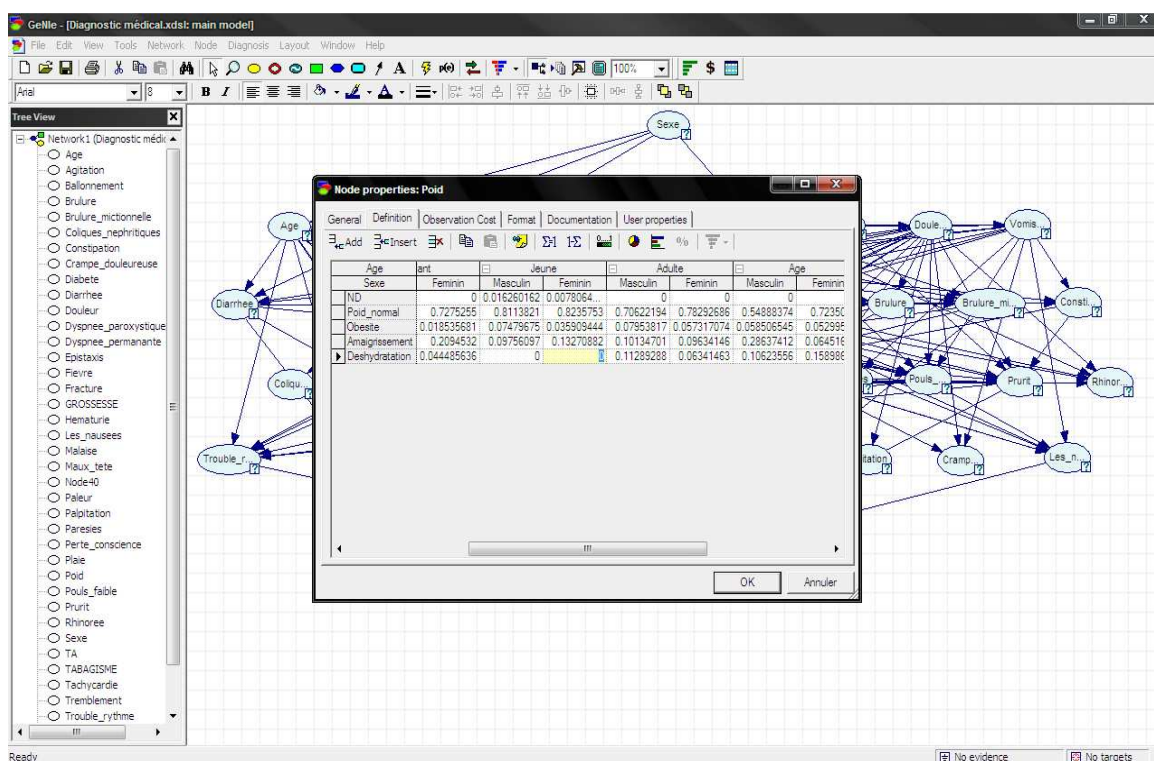


Figure D.8 : remplissage des tables des probabilités conditionnelles.

Nous avons saisi les evidences à partir des cas réel qu'onous avons obtenu par l'expert (medecin).

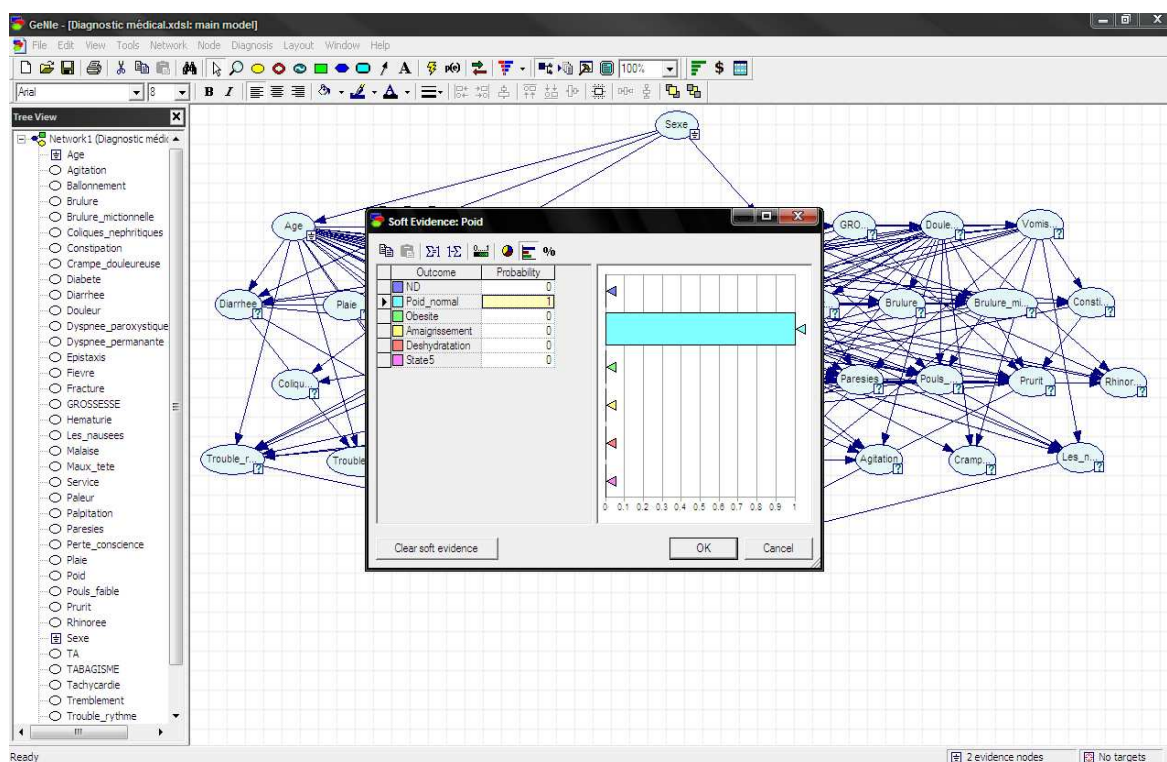


Figure D.9 : saisie des evidences.

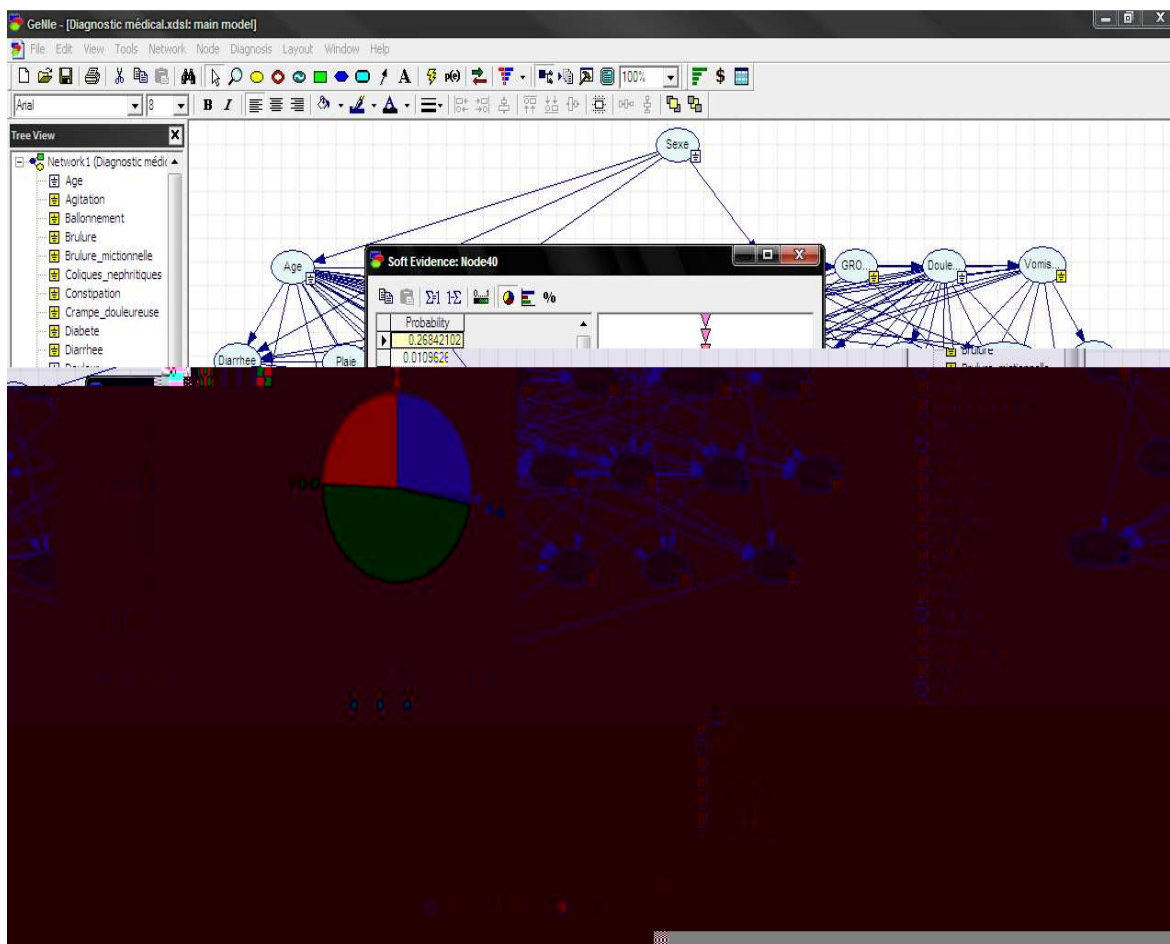


Figure D.11: représentation graphique des résultats.

Ce travail a été implémenté par les étudiantes HAMIDAT FELLA et BOUZOUIDJA YASMINE dans le cadre de la réalisation de projet de fin d'étude pour l'obtention du diplôme d'ingénieur en informatique de l'université SAAD DAHLEB de Blida. Les données sont prises du travail Mme Zerf Nadjet.

REFERENCES

- [1]: Uffe, B., Kjarulff, A., Madsen, L., "Bayesian Networks and Influence Diagrams", Springer, Science+Business Media, New York (USA),(2008).
- [2]: Murphy, K.P., "Dynamic Bayesian Networks: Representation, Inference and Learning", Thèse du doctorat de University of California, Berkeley, (2002).
- [3]: Cram, D., May, M., Guelton, R., Touch, S., "Résumé: Réseaux Bayésiens", (Novembre 2005).
- [4]: Koller D., Pfeffer, A., "Object-Oriented Bayesian Networks", the Thirteenth Annual Conference on Uncertainty in Artificial Intelligence (UAI-97), (1997), 302 - 313.
- [5]: LERAY, P., " Réseaux bayésiens : apprentissage et modélisation de systèmes complexes", HABILITATION A DIRIGER LES RECHERCHES, Université de Rouen, (2006).
- [6]: Fauré, C., "Découvertes de motifs pertinents par l'implémentation d'un réseau bayésien : application à l'industrie aéronautique", thèse de doctorat de L'Institut National des Sciences Appliquées de Lyon, (2006).
- [7]: Richard, E., "Learning Bayesian Networks", Neapolitan, Northeastern Illinois University, Chicago, Illinois, (2004).
- [8]: Kim, J., Pearl, J. "A computational model for combined causal and diagnostic reasoning in inference systems", Dans Proceedings IJCAI-83, Karlsruhe, Germany, (1983), 190–193.
- [9]: Pearl, J., "Bayesian networks: a model of self-activated memory for evidential reasoning", Technical Report 850021 (R-43), UCLA Computer Science Department Technical Report, and in Cognitive Science Society, UC Irvine, (1985), 329-334.
- [10]: Pearl, J., "Fusion, propagation, and structuring in belief networks", Journal of Artificial Intelligence, 29, (1986), 241–288.
- [11]: Lauritzen, S., Spiegelhalter, D., "Local computations with probabilities on graphical structures and their application to expert systems". Journal of the Royal Statistical Society B, 50(2), (1988), 157–224.

- [12]: Jensen, F., Lauritzen, S., & Olesen, K., "bayesian updating in causal probabilistic networks by local computations. *Computational Statistics Quarterly*", (1990), 269–282.
- [13]: Shachter, R.D., "Intelligent probabilistic inference. Dans *Kanal*", L. N. & Lemmer, J.F, (Eds.), *Uncertainty in Artificial Intelligence*, Amsterdam. North-Holland, (1986), 371–382.
- [14]: Henrion, M., "An introduction to algorithms for inference in belief nets", Dans *Proceedings of the 5th Annual Conference on Uncertainty in Artificial Intelligence (UAI-90)*, New York, NY. Elsevier Science Publishing Company, Inc (1990).
- [15]: Zhang, N. & Poole, D., "A simple approach to bayesian network computations". Dans *In Proceedings of the tenth Canadian Conference on Artificial Intelligence*, (1994), 171–178.
- [16]: Dechter, R., *Bucket elimination: a unifying framework for structure-driven inference*. Technical report, Dept. of Computer and Information Science, University of California, Irvine, USA, (1998).
- [17]: Lauritzen, S., Spiegelhalter, D., "Local computations with probabilities on graphical structures and their application to expert systems", *Journal of the Royal Statistical Society B*, 50(2), (1988), 157–224.
- [18]: Guo, H., Boddhireddy, P., Hsu, W., "An aco algorithm for the most probable explanation problem", Dans *Australian Conference on Artificial Intelligence*, (2004), 778–790.
- [19]: Shachter, R. D., D'Ambrosio, B., DeFabero, B., *Symbolic probabilistic inference in belief networks*. Dans *Proceedings of the Eighth National Conference on Artificial Intelligence*, (1990), 126–131.
- [20]: Li, Z., D'Ambrosio, B., "Efficient inference in bayes nets as a combinatorial optimization problem". *International Journal of Approximate Reasoning*, 11(1), (1994), 55–81.
- [21]: Castillo, E., Gutiérrez, J. M., Hadi, A.S., "A new method for symbolic inference in bayesian networks". *Networks* 28, (1996), 31–43.
- [22]: Darwiche, A., Provan, G., "Query dags: A practical paradigm for implementing beliefnetwork inference", *Journal of Artificial Intelligence Research*, 6, (1997), 147–176.
- [23]: Mekhnacha, K., Ahuactzin, J.-M., Bessière, P., Mazer, E., & Smail, L., "A

unifying framework for exact and approximate bayesian inference”, Technical Report RR-5797, Rapport de recherche de l'INRIA - Rhone-Alpes, Equipe: E-MOTION, (2006).

[24]: Smail, L., “Algorithmique pour les Réseaux Bayésiens et leurs Extensions”, PhD thesis, Université de Marne-La-Vallée, (2004).

[25]: Darwiche, A., “A differential approach to inference in bayesian networks”, Dans Proceedings of Uncertainty in Artificial Intelligence, (2000), 123–132.

[26]: Cooper, G., “The computational complexity of probabilistic inference using bayesian belief networks”. Artificial intelligence, 42, (1992), 393–347.

[27]: Gilks, W., Richardson, S., Spiegelhalter, D., “Markov Chain Monte Carlo in Practice, Interdisciplinary Statistics”, Chapman & Hall, (1996).

[28]: Robert, C., Casella, G., “Monte Carlo Statistical Methods”, Springer texts in statistics”, (2004).

[29]: Lauritzen, S., “Graphical Models. Oxford”: Clarendon Press, (1996).

[30]: Geman, S., Geman, D., “Stochastic relaxation, Gibbs distributions, and the Bayesian restoration of images”, IEEE Transactions on Pattern Analysis and Machine Intelligence, 6(6), (1984), 721–741.

[31]: Lawrence, N., “Variational Inference in Probabilistic Models”, PhD thesis, University of Cambridge, U.K, (2000).

[32]: Jordan, M., Ghahramani, Z., Jaakkola, T., Saul, L., “An introduction to variational methods for graphical models”, Dans M. I. Jordan (Ed.), Learning in Graphical Models, Kluwer Academic Publishers, Boston, (1998), 105–161.

[33]: Wainwright, M., Jordan, M., “Graphical models, exponential families, and variational inference”, Technical report, Departement of Statistics, University of California, Berkeley, (2003).

[34]: Henrion, M., “An introduction to algorithms for inference in belief nets”, Dans Proceedings of the 5th Annual Conference on Uncertainty in Artificial Intelligence (UAI-90), New York, NY. Elsevier Science Publishing Company, Inc, (1990).

[35]: Poole, D., “Average-case analysis of a search algorithm for estimating prior and posterior probabilities in bayesian networks with extreme probabilities”, Dans Proceeding of the thirteenth International Joint Conference on Artificial Intelligence, (1993), 606–612.

[36]: Pearl, J., “bayesian networks: a model of self-activated memory for evidential

reasoning”, Technical Report 850021 (R-43), UCLA Computer Science Department Technical Report, and in Cognitive Science Society, UC Irvine, (1985), 329-334.

[37]: Pearl, J., “Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference”, (1988). Morgan Kaufmann, second edition in 1991.

[38]: Murphy, K., Weiss, Y., Jordan, M., “Loopy belief propagation for approximate inference: An empirical study”, Dans Proceedings of the Fifteenth Conference on Uncertainty in Artificial Intelligence (UAI-99), San Francisco, CA. Morgan Kaufmann Publishers, (1999), 467–475.

[39]: Kjærulff, U., “Approximation of Bayesian networks through edge removals”, Research Report IR-93-2007, The Machine Intelligence Group, Aalborg University, (1993).

[40]: Guo, H. & Hsu, W., “A survey of algorithms for real-time bayesian network inference”, (2001). (Non publié).

[41]: François O., “De l’identification de structure de réseaux Bayésiens à la reconnaissance de formes à partir d’informations complètes ou incomplètes”, Thèse de doctorat de l’Institut National des Sciences Appliquées de Rouen, (novembre 2006).

[42]: Boudali, H., Dugan, J.B., “A discrete-time Bayesian network reliability modeling and analysis framework”, Reliability Engineering and System Safety 87, (Aout 2004), 337–349.

[43]: Friedman, N., Murphy, K., Russell, S., “Learning the Structure of Dynamic Probabilistic Networks”, In Proc. Conf. On Uncertainty in AI (UAI), Madison, WI, (1998), 1- 9.

[44]: Arroyo-Figueroa, G., Sucar, L.E., “Temporal Bayesian Network of Events for Diagnosis and Prediction in Dynamic Domains”, Springer Science + Business Media, Inc. Manufactured in The Netherlands Applied Intelligence 23, (2005), 77–86.

[45]: Severino, F.G, Francisco, J.D., “Modelling Dynamic Causal Interactions with Bayesian Networks: Temporal Noisy Gates”, CaNew’2000, the 2nd International Workshop on Causal Networks, (Aout 2000), 1-5.

[46]: Mihadjlovic, V., Petkovic, M., “Dynamic Bayesian networks: a state of the art”.

[47]: Dempster, A., Laird, N., et Rubin, D., “Maximum likelihood for incomplete

data via the EM algorithm”, *Journal of the Royal Statistical Society*, (1977), V 39:1–38.

[48]: Lauritzen, S. L., “The EM algorithm for graphical association models with missing data”, *Computational Statistics & Data Analysis*, (1995), 19(2):191–201.

[49]: Heckerman, D., “A tutorial on learning bayesian networks”, Technical Report MSR-TR-95-06, Microsoft Research, Redmond, WA, (1995).

[50]: Delaplace, A., “Approche évolutionnaire de l’apprentissage de structure pour les réseaux Bayésiens”, Thèse de doctorat de l’université FRANÇOIS RABELAIS TOURS, (décembre 2007).

[51]: Brown, L., Tsamardinos, I., Aliferis, C., “A comparison of novel and state-of-the-art polynomial bayesian network learning algorithms. Dans *Proceedings of the Twentieth National Conference on Artificial Intelligence*, Pittsburgh, Pennsylvania. AAAI Press, Menlo Park, California, (2005), 739–745.

[52]: Tsamardinos, I., Brown, L., & Aliferis, C., “The max-min hill-climbing bayesian network structure learning algorithm”, Technical Report DSL-TR-05-01, Vanderbilt University, (2005).

[53]: Cheng, J., Greiner, R., Kelly, J., Bell, D., Liu, W., “Learning Bayesian networks from data: An information-theory based approach”, *Artificial Intelligence*, 137(1-2), (2002), 43–90.

[54]: Yehezkel, R. & Lerner, B., “Recursive autonomy identification for bayesian network structure learning”, Dans *The 10th International Workshop on Artificial Intelligence & Statistics, AISTATS 2005*, Barbados, (2005), 429–436.

[55]: Aussem, A., Kebaili, Z., Corbex, M., & Marchi, F., “Apprentissage de la structure de réseaux bayésien à partir des motifs fréquents corrélés : application à l’identification des facteurs environnementaux du cancer du nasopharynx”, Dans *Actes des journées Extraction et Gestion de Connaissances (EGC’06)*, *Revue des Nouvelles Technologies de l’Information (RNTI-E-6)*, Cépaduès-Éditions, (2006), 651–662.

[56]: Godenberg, A. & Moore, A., “Tractable learning of large bayes net structures from sparse data”, Dans *21st International Conference on Machine Learning*, Banff, Alberta, Canada. ACM Press, ISBN: 1-58113-828-5, (2004), pp. 44–52.

[57]: Margaritis, D., “Learning Bayesian Network Model Structure from Data”, PhD thesis, School of Computer Science, Carnegie Mellon University, Pittsburgh,

(2003).

[58]: Heckerman, D., Geiger, D., Chickering, D., "Learning Bayesian networks: The combination of knowledge and statistical data", *Machine Learning*, 20, (1995), 197–243.

[59]: Buntine, W., "Theory refinement of bayesian networks", In *Proceedings of the Seventh Conference on Uncertainty in Artificial Intelligence*, American Mathematical Society, (1991), 52–60.

[60]: Kayaalp, M., Cooper, G. F., "A bayesian network scoring metric that is based on globally uniform parameter priors", In *Proceedings of the Eighteenth Annual Conference on Uncertainty in Artificial Intelligence (UAI-2002)*, (2002), 251–258.

[61]: Akaike, H., "Statistical predictor identification", *Annals of the Institute of Statistical Mathematics*, 22, (1970), 203–217.

[62]: Bozdogan, H., "Model selection and akaike's information criteria (AIC): The general theory and its analytical extentions", *Psychometrika*, 52, (1987), 354–370.

[63]: Hurvich, C. M., Tsai, C.-L., "Regression and time series model selection in small samples", *Biometrika*, 76(2), (1989), 297–307.

[64]: Rissanen, J., "Modelling by shortest data description", *Automatica*, 14, (1978), 465–471.

[65]: Suzuki, J., "Learning bayesian belief networks based on the minimum description length principle: An efficient algorithm using the b&b technique", In *International Conference on Machine Learning*, (1996), 462–470.

[66]: Lam, W., Bacchus, F., "Learning bayesian belief networks: An approach based on the MDL principle", *Computational Intelligence*, 10, (1994), 269–294.

[67]: Schwartz, G., "Estimating the dimensions of a model", *The Annals of Statistics*, 6(2), (1978), 461–464.

[68]: Bouckaert, R., "Properties of bayesian belief network learning algorithms", In *Proceedings of the 10th Annual Conference on Uncertainty in Artificial Intelligence (UAI-94)*, San Francisco, CA. Morgan Kaufmann, (1994), 102–10.

[69]: Chow, C. & Liu, C., "Approximating discrete probability distributions with dependence trees", *IEEE Transactions on Information Theory*, 14(3), (1968), 462–467.

[70]: Geiger, D., Heckerman, D., "Knowledge representation and inference in similarity networks and bayesian multinets", *Artificial Intelligence*, 82(1-2), (1996),

45–74.

[71]: Friedman, N., “The Bayesian Structural EM Algorithm”, In UAI-98, (1998).

[72]: Davies, S., Moore, A., “Mix-nets: Factored mixtures of gaussians in bayesian networks with mixed continuous and discrete variables”, Dans Boutilier, C. & Goldszmidt, M. (Eds.), Proceedings of the 16th Conference on Uncertainty in Artificial Intelligence (UAI-00), SF, CA. Morgan Kaufmann Publishers, (2000a), 168–175.

[73]: Cobb, B., Shenoy, P., “Approximating probability density functions in hybrid Bayesian networks with mixtures of truncated exponentials”, Statistics and Computing, 16(3), (2006), 293–308.

[74]: Colot, O., Olivier, C., Courtellemont, P., El Matouat, A., “Information criteria and abrupt changes in probability laws”, In Signal Processing VII: Theories and Applications, (1994), 1855–1858.

[75]: Friedman, N., Goldszmidt, M. “Discretizing continuous attributes while learning bayesian networks”, In ICML, (1996), 157–165.

[76]: Margaritis, D., “Distribution-free learning of bayesian network structure in continuous domains”, In AAAI, (2005), 825–830.

[77]: Fu, L. D., “A comparison of state-of-the-art algorithms for learning Bayesian network structure from continuous data”, Master’s thesis, Faculty of the Graduate School of Vanderbilt University, (2005).

[78]: Zouaq, A., “Systèmes Tutoriels Intelligents pour l’Organisation1: Gestion de la connaissance et de l’intelligence collective”, Thèse doctorat, Université de Montréal, (Août 2005).

[79]: Tanguy, C., Villavicencio, D., « Apprentissage et innovation dans l’entreprise, Une approche socio-économique des connaissances », Eres, Aix en Provence, (2005).

[80]: Fadi, B., "Extraction de connaissances d'adaptation en raisonnement à partir de cas", Doctorat de l'université Henri Poincaré, Nancy 1, (novembre 2009).

[81]: Chen, M.S, Han, J., Yu, P.S., “Data Mining: An Overview from Database Perspective”, (1996).

[82]: Oded, Z.M., Lior, R., “Decomposition Methodology for Knowledge Discovery and Data Mining”, World Scientific Pub Co Inc (USA), (July 30, 2005).

[83]: Ben Messaoud, R., Loudcher Rabas, S., Boussaid, O., Missaoui, R.,

- “Enhanced Mining of Association Rules from Data Cubes”, DOLAP, (2006).
- [84]: CEGLAR, A., RODDICK, J.F., “Association Mining”, ACM Computing Surveys, (2006).
- [85]: Fauré, C., Delprat, S., Mille, A., Boulicaut, J.F., “Utilisation des réseaux bayésiens dans le cadre de l'extraction de règles d'association”, Acte EGC 06, Cepadues RNTI-E-6, (2006), 569-590.
- [86]: Padmanabhan, B., Tuzhilin, A., “A belief-driven method for discovering unexpected patterns”, In Proceedings of the 1998 KDD International Conference on Knowledge Discovery and Data Mining, (1998), 94-100.
- [87]: Szymon Jaroszewicz et Dan A. Simovici, “Interestingness of frequent itemsets using bayesian networks as background knowledge”, In Proceedings of the 2004 ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, pages 178_186, New York, NY, USA, 2004. ACM Press.
- [88]: Jaroszewicz, S., Scheffer, T., “Fast discovery of unexpected patterns in data, relative to a bayesian network”, In Proceedings of the 2005 ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, New York, NY, USA, ACM Press, (2005).
- [89]: TRUONG PHAM, D., RUZ, G.A., “Unsupervised training of Bayesian networks for data clustering”, Proc. R. Soc. A doi:10.1098/rspa.2009.0065, (2009).
- [90]: HECKERMAN, D., “Bayesian Networks for Data Mining”, Data Mining and Knowledge Discovery 1, (1997), 79–119.
- [91]: Dimitri B.K., “Reliability Engineering Handbook, Volume 1”, DEStech publications, Inc, USA, (2002), 61- 65.
- [92]: Wallace, R., Blischke, D.N., Prabhakar, M., “Case Studies in Reliability and Maintenance”, A JOHN WILEY & SONS, INC., PUBLICATION, New Jersey (USA), (2003), 3 - 5.
- [93]: Dhillon, B.S., “Maintainability, Maintenance, and Reliability for Engineers”, Taylor & Francis Group, LLC, (2006), 1- 54.
- [94]: Crowe, D., Feinberg, A., “DESIGN FOR RELIABILITY”, CRC Press LLC, (2001).
- [95]: Stamatelatos, M., William, V., Dugan, J., Fragola, J., Railsback, J., “Fault Tree Handbook with Aerospace Applications”, NASA Office of Safety and Mission Assurance, NASA Headquarters Washington, DC 20546, (August 2002), 156.

- [96]: Dhillon, B.S., "Reliability, Quality, and Safety for Engineers", CRC PRESS, (2005).
- [97]: Guangbin, Y., "LIFE CYCLE RELIABILITY ENGINEERING", JOHN WILEY & SONS, INC., PUBLICATION, New Jersey (USA), (2007).
- [98]: Weber P., Munteanu P., Jouffe L, "Dynamic Bayesian Networks modelling the dependability of systems with degradations and exogenous constraints", In: Proceedings of the 11th IFAC Symposium on Information Control Problems in Manufacturing (INCOM'04) Salvador-Bahia, Brazil, April 5–7, (2004), 1-7.
- [99]: Weber, P., Jouffe, L., "Reliability modelling with dynamic Bayesian networks", Reliability modelling with dynamic bayesian networks. 5th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes (SAFEPROCESS'03), Washington, D.C., USA, June 9-11, (2003), 1-8.
- [100]: BEN SALEM, A., MULLER, A., WEBER, P., "Dynamic bayesian networks in system reliability analysis", In: Proceedings of the 11th IFAC Symposium on Information Control Problems in Manufacturing (INCOM'04) Salvador-Bahia, Brazil, (April 2004).
- [101]: Langsetha, H., Portinale, L., "Bayesian networks in reliability", Reliab Eng Syst Saf, (January 2006).
- [102]: Doguc, O., Ramirez-Marquez J.E., "A generic method for estimating system reliability using Bayesian networks", Reliab Eng Syst Saf, (2008).
- [103]: Weber, P., Medina-Oliva, G., Simon, C., lung, B., "Overview on Bayesian networks applications for dependability, risk analysis and maintenance areas", Engineering Applications of Artificial Intelligence, (juin 2010).
- [104]: Zio, E., "Reliability engineering: old problems and new challenges", Reliability Engineering and System Safety, Vol. 95, (2009), 125–141.
- [105]: Sigurdsson, J.H., Walls, L.A., Quigley, J.L., "Bayesian belief nets for managing expert judgement and modelling reliability", Qual. Reliab. Engng. Int, (2001), 17: 181–190.
- [106]: Bobbio, A., Portinalea, L., Minichinob, M., Ciancamerlab, E., "Improving the analysis of dependable systems by mapping fault trees into Bayesian networks", Elsevier Science Ltd, (2001).
- [107]: Wilsona, A.G., McNamarab, L.A., Wilson, G.D., "Information integration for complex systems", Reliab Eng Syst Saf, (2006).

- [108]: Alyson, G. Wilsona, Aparna V. Huzurbazar, "Bayesian networks for multilevel system reliability", *Reliab Eng Syst Saf*, (2006).
- [109]: SIMON, Ch., WEBER, Ph., LEVRAT, E., "Bayesian Networks and Evidence Theory to Model Complex Systems Reliability", *Journal Of Computers*, Vol. 2, No. 1, (February 2007).
- [110]: Simon, C., Weber, P., Evsukoff, A., "Bayesian networks inference algorithm to implement Dempster Shafer theory in reliability analysis", *Reliability Engineering and System Safety* 93, (March 2007), 950–963.
- [111]: Neil, M., Tailor, M., Marquez, D., Fenton, N., Peter Hearty, "Modelling dependable systems using hybrid Bayesian networks", *Reliab Eng Syst Saf*, (2007).
- [112]: Langseth, H., Nielsen T.D., AntonioSalmero, R.R., "Inference in hybrid Bayesian networks", *Reliab Eng Syst Saf*, (2009).
- [113]: Neil, M., Marquez, D., Fenton, N., Improved reliability modeling using Bayesian networks and dynamic discretisation, *Reliability Engineering and System Safety*, Vol.95, (2009), 412–425.
- [114]: Hadi-Hosseini, S.M., Takahashi, M., "Combining Static/Dynamic Fault Trees and Event Trees Using Bayesian Networks", *SAFECOMP 2007, LNCS 4680*, (2007), 93–99.
- [115]: Weber, P., Jouffe, L., "Complex system reliability modelling with Dynamic Object Oriented Bayesian Networks (DOOBN)", *Reliability Engineering and System Safety* 91 (Mai 2005) 149–162.
- [116]: Boudali, H., Dugan, J.B., "A New Bayesian Network Approach to Solve Dynamic Fault Trees", *IEEE*, (2005).
- [117]: Boudali, H., Member, Dugan, J.N, "A Continuous-Time Bayesian Network Reliability Modeling, and Analysis Framework", *IEEE transactions on reliability*, vol. 55, no. 1, (march 2006).
- [118]: Bobbio, A., Montani, S., Portinale, L., "Dynamic Bayesian Networks for modeling advanced Fault Tree features in dependability analysis", in: K. Kolowrocki (Ed.), *Proceedings of the European Safety and Reliability Conference 2005 (ESREL 05)*, Balkema Publisher, Tri City, Poland, (2005).
- [119]: Montani, S., Portinale, L., Bobbio, A., Codetta, D., "RADYBAN: A tool for reliability analysis of dynamic fault trees through conversion into dynamic

Bayesian networks”, *Reliability Engineering and System Safety* 93, (Mai 2007), 922–932.

[120]: Portinale, L., Raiteri, D.C., Montani, S., “Supporting reliability engineers in exploiting the power of dynamic Bayesian Networks”, *International Journal of Approximate Reasoning*, Vol. 51, (2010), 179–195.

[121]: Boyen, X., Koller, D., “Tractable inference for complex stochastic processes”. *Proceedings UAI’88*, (1998), 33-42.

[122]: Lampis, M., Andrews, J. D., “Bayesian Belief Networks for System Fault Diagnostics”, *Quality and Reliability Engineering International*, Vol. 25, (2009), 409–426.

[123]: Ghahramani, Z., “Learning Dynamic Bayesian Networks”, C. Lee Giles and Marco Gori (Eds.): *Adaptive Processing*, LNAI 1387, (1998), 168-197.

[124]: LAETITIA, J., “Métaheuristiques pour l’extraction de connaissances : application à la génomique” Thèse de doctorat de l’université des sciences et technologies de LILLE, (Novembre 2003).

[125]: Papadimitriou, C.H., “The complexity of combinatorial optimization problems”, Thèse doctorat, Princeton, (1976).

[126]: Kirkpatrick, S., Gelatt, D.C., Vechhi, M.P., “Optimization by simulated annealing”, *Science* 220, (May 1983), 671–680.

[127]: Glover, F., “Future paths for integer programming and links to artificial intelligence”, *Computers and Operations Research*, 13, (1986), 533–549.

[128]: Hansen, P., “The steepest ascent mildest descent heuristic for combinatorial programming”, In *Congress on Numerical Methods in Combinatorial Optimization*, Capri, Italy, (1986).

[129]: Fogel, J., Owens, J., Walsh, J., “Artificial Intelligence through Simulated Evolution”, John Wiley, (1966).

[130]: Rechenberg, I., “Evolutions Strategie: Optimierung technischer Systeme nach Prinzipien der biologischen Evolution”, Frommann-Holzboog, Stuttgart, (1973).

[131]: Schwefel, H.P., “Numerical optimization of Computer models”, John Wiley & Sons, Ltd., Chichester, (1981).

- [132]: Holland, J., "Adaptation in Natural and Artificial Systems", University of Michigan Press, (1975).
- [133]: Koza, J. R., "Genetic Programming: On the Programming of Computers by Natural Selection", MIT Press, Cambridge, MA, (1992).
- [134]: Kennedy, J., Eberhart, R.C., "Particle swarm optimization. In IEEE Service Center", editor, Proceedings of the 1995 IEEE International Conference on Neural Networks, (1995), 1942–1948
- [135]: Baluja, S., "Population-based incremental learning: A method for integrating genetic search based function optimization and competitive learning", Technical Report CMU-CS- Carnegie Mellon University, Pittsburgh PA, (1994), 94-163.
- [136]: Baluja, S., Caruana, R., "Removing the genetics from the standard genetic algorithm", The Int. Conf. on Machine Learning, San Mateo, CA, Morgan Kaufmann Publishers, (1995), 38–46.
- [137]: Mühlenbein, H., Paass, G., "From recombination of genes to the estimation of distributions i. binary parameters", In *PPSN 1996*, (1996), 178–187.
- [138]: Yu, T-L., "A survey of estimation of distribution algorithms", Technical report, Illi- GAL, Illinois Genetic Algorithms Laboratory Department of General Engineering University of Illinois at Urbana-Champaign, USA, (2002).
- [139]: P. Larrañaga and J. Lozano, editors. "Estimation of Distribution Algorithms : A New Tool for Evolutionary Computation", chapter A review on estimation of distribution algorithms (Chapter 3), Kluwer Academic Publishers, (2001), 57–100.
- [140]: Pelikan, M., Goldberg, D., Lobo, F., "A survey of optimization by building and using probabilistic models", Technical Report Report No. 99018, IlliGAL, Illinois Genetic Algorithms Laboratory Department of General Engineering University of Illinois at Urbana-Champaign, USA, (1999).
- [141]: Dorigo, M., Gambardella, L.M., "Ant colonies for the traveling salesman problem", *IEEE Transactions on Evolutionary Computation*, volume 1, numéro 1, (1997), 53-66.
- [142]: Dorigo, M., Gambardella, L.M., "Ant Colony System: A Cooperative Learning Approach to the Traveling Salesman Problem", *BioSystems*, (1997).
- [143]: Dorigo, M., Maniezzo, V., Colorni, A., "The Ant System: Optimization by a

colony of cooperating agents”, IEEE Transactions on Systems, Man, and Cybernetics–Part B, Vol.26, No.1,(1996),1-13

[144]: Dorigo, M., Blum, C., “Ant colony optimization theory: A survey”, Theoretical Computer Science 344, (2005), 243 – 278.

[145]: CHEN, L., XU X., CHEN, X.Y., “An adaptive ant colony clustering algorithm”, Proceedings of the Third International Conference on Machine Learning and Cybernetics, Shanghai, (August 2004), 26-29.

[146]: Campos, L.M., Gámez, J.A., Puerta, J.M., “Learning Bayesian network by ant colony optimisation: Searching in two different spaces”, Mathware and Soft Computing IX (2-3), (2002), 251-268.

[147]: Daly, R., Shen, Q., “Learning Bayesian network equivalence classes with ant colony optimization”, Journal of Artificial Intelligence Research, vol. 35, (2009), 391–447.

[148]: Wu, Y., McCal, J., Corne, D., “Two Novel Ant Colony Optimization Approaches for Bayesian Network Structure Learning”, 2005.

[AGBN]: Larrafiaga,P., Poza, M., Yurramendi, Y., Murga, R., Kuijpers, C., “Structure Learning of Bayesian Networks by Genetic Algorithms: Performance Analysis of Control Parameters”, IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE, VOL. 18, NO. 9, (SEPTEMBER 1996).

[150]: Guillaume, M., Jean-Marc R., "Modélisation algébrique des arbres de défaillance temporels", JD-MACS'07, (2007).

[151]: Cassio, P., Zhi, Z., Qiang, J., “An Improved Structural EM to Learning Dynamic Bayesian Nets”, International Conference on Pattern Recognition, IEEE Computer Science, (2010), 605-604.

[152]: Malone, B., Yuan, C., Hansen, E. A., “Memory-Efficient Dynamic Programming for Learning Optimal Bayesian Networks”, Proceedings of the Twenty-Fifth AAAI Conference on Artificial Intelligence,(2011), 1057-1062.

[153]: P., Singh, Moore, A.W., “Finding Optimal Bayesian Networks by Dynamic Programming”, NSF IIS-0325581, NSERC PGS-B.

[154]: Eaton, E., Murphy, K., “Belief net structure learning from uncertain interventions”, Journal of Machine Learning Research 1 (2000), 1-48.

[155]: Langseth, H., “Bayesian Networks with Applications in Reliability Analysis”,

Dr. Ing. Thesis, Department of Mathematical Sciences, Norwegian University of Science and Technology, (2002).

[156]: Guest editorial, "Special session on Bayesian networks in dependability", Reliab Eng Syst Saf, (2007).

[157]: Dana L.Kelly, CurtisL.Smith, "Bayesian inference in probabilistic risk assessment —The current state of the art", Reliab Eng Syst Saf, (2008).

[158]: Rebbaa, R., Mahadevan, S., "Computational methods for model reliability assessment", Reliab Eng Syst Saf, (2007).

[159]: Jinqiu Hu, Laibin Zhang, Lin Mab, Wei Liang, "An integrated safety prognosis model for complex system based on dynamic Bayesian network and ant colony algorithm", Expert Systems with Applications, In press (2010).

[160]: Friedman, N., Koller, D., "Being bayesian about network structure". In Proc. 16th Conf. on Uncertainty in AI (UAI), (2000).

[161]: Li1, J., Shi, J., Satz, D., "Modeling and Analysis of Disease and Risk Factors through Learning Bayesian Networks from Observational Data", Quality and Reliability Engineering International, Vol. 24, 2008, 291–302.

[162]: Boudali, H., Crouzen, P., Stoelinga, M., "Dynamic fault tree analysis using input/output Markov chains", in: Proceedings of the 37th IEEE/IFIP, Conference on Dynamic fault tree analysis using Dependable Systems and Networks (DSN'07), (2007).

[163]: Shin, S.K., Poong, H.S., "Review Of Various Dynamic Modeling Methods And Development Of An Intuitive Modeling Method For Dynamic Systems", Nuclear Engineering And Technology, Vol.40 No.5, (August 2008), 375-386.

[164]: Ruggeri, F., "On the Reliability of Repairable Systems: Methods and Applications", Reliability of Repairable Systems, (2008), 536 - 552.

[165]: Dingzhou, C., Shaobai, K., Yu S., "Design of Reliable System Based on Dynamic Bayesian Networks and Genetic Algorithm", IEEE, Reliability and Maintainability Symposium, (January 2012).

[166]: Corset, F., "Aide de l'optimisation de maintenance à partir de réseaux Bayésiens et fiabilité dans un contexte doublement censuré", Thèse de doctorat de l'université JOSEPH FOURIER, (janvier 2003).

[167]: Christian P.R., "Le choix Bayésien Principes et pratique", Springer-Verlag

France, Paris, (2006).

[168]: Mahadevan, S., Zhang, R., Smith, N., "Bayesian networks for system reliability reassessment", Elsevier Science Ltd, (September 2001).

[169]: Kim, M.C., Seong, P.H., "Reliability graph with general gates: an intuitive and practical method for system reliability analysis", Elsevier Science Ltd, (2002).

[170]: Dingzhou, C., Shaobai, K., Yu S., "Design of Reliable System Based on Dynamic Bayesian Networks and Genetic Algorithm", IEEE, Reliability and Maintainability Symposium, (January 2012).

[171]: Heckerman, D., Mamdani, A., Wellman, M. P, "Real world applications of bayesian networks", Communications of the ACM, 38(3), (1995), 24–30.

[172]: Dubois, N., Wilkerson, T., "Gestion des connaissances : un document d'information pour le développement d'une stratégie de gestion des connaissances pour la santé publique", le Centre de Collaboration Nationale des Méthodes et Outils Presse, (Octobre 2008).

[173]: Florence Cloppet, Jean-Marc Petit, Nicole Vincent, "Extraction des connaissances : Etat et perspectives", Revue des Nouvelles Technologies de l'Information Sous la direction de Djamel A. Zighed et Gilles Venturini, (2005).

[174]: Van Bommel, J.H., van Mulligen, E.M., Mons, B., Wijk, M. V., Kors, J.A., der Lei, J.V, "Databases for knowledge discovery Examples from biomedicine and health care", International Journal of Medical Informatics 75, (2006), 257—267.

[175]: Marbán, O., Mariscal, G., Segovia, J., "Data Mining and Knowledge Discovery in Real Life Applications", Edited by Julio Ponce and Adem Karahoca, I-Tech, Vienna, Austria, (February 2009).

[176]: KURGAN, L.A., MUSILEK, P., "A survey of Knowledge Discovery and Data Mining process models", *The Knowledge Engineering Review*, Vol. 21:1, Cambridge University Press, (2006), 1–24.

[177]: Fournier, P., "Un modèle de représentation des connaissances à trois niveaux de sémantique pour les systèmes tutoriels intelligents", Thèse de l'UNIVERSITÉ DE SHERBROOKE CANADA, (Décembre 2005).

[178]: Fayyad U., Piatetsky-Shapiro, G., Padhraic, S., "From Data Mining to Knowledge Discovery in Databases", American Association for Artificial Intelligence, 1996, 36-54.

[179]: Lefébure, R., Venturi, C., "Data Mining", Edition (Eyrolles) deuxieme

edition (2001).

[180]: Leray, P., .François, O., "Réseaux Bayésiens pour la Classification
Méthodologie et Illustration dans le cadre du Diagnostic Médical", RIA. 15/2002.
Réseaux Bayésiens, (2002) ,1-25.