



HAL
open science

Approche probabiliste pour l'estimation dynamique de la confiance accordée à un équipement de production : vers une contribution au diagnostic de services des SED

Quoc Bao Duong

► To cite this version:

Quoc Bao Duong. Approche probabiliste pour l'estimation dynamique de la confiance accordée à un équipement de production : vers une contribution au diagnostic de services des SED. Autre. Université de Grenoble; 243 University of Danang, 2012. Français. NNT : 2012GRENT102 . tel-00910079

HAL Id: tel-00910079

<https://theses.hal.science/tel-00910079>

Submitted on 27 Nov 2013

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

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

THÈSE

pour obtenir le grade de
DOCTEUR DE L'UNIVERSITÉ DE GRENOBLE
Spécialité : **Automatique Productive**
Arrêté ministériel : 7 août 2006

Présentée par
QUOC BAO DUONG

Thèse dirigée par **Eric ZAMAI** et
codirigée par **Khoi Quoc TRAN DINH**

préparée au sein du **Laboratoire G-SCOP**
dans l'**École Doctorale EEATS**

Approche probabiliste pour l'estimation dynamique de la confiance accordée à un équipement de production : vers une contribution au diagnostic de services des SED

Thèse soutenue publiquement le **19 décembre 2012**,
devant le jury composé de :

M. Jean-Marie FLAUS

Professeur, Université Joseph Fourier, Grenoble, Président

M. Bernard GRABOT

Professeur, École Nationale d'Ingénieur de Tarbes, Rapporteur

M. Jean-François PETIN

Professeur, Institut National Polytechnique de Lorraine, Nancy, Rapporteur

M. Stephane HUBAC

Process Control Expert, STMicroelectronics, Crolles, Examineur

M. Sébastien HENRY

Maître de conférences, Université Lyon 1 IUT, Villeurbanne, Examineur

M. Eric DESCHAMPS

Project Development Manager, Rockwell Automation, Invité

M. Eric ZAMAI

Maître de conférences, Grenoble-INP, Directeur de thèse

M. Khoi Quoc TRAN DINH

Enseignant-Chercheur, Université de Danang, VN, Co-Directeur de thèse



Avant-Propos

Le travail présenté dans ce mémoire a été préparé dans l'équipe Gestion et Conduite des Systèmes de Production (GCSP) du Laboratoire G-SCOP. Je voudrais utiliser quelques lignes de ce manuscrit pour remercier toutes les personnes qui ont participé, de façon directe ou indirecte, à mes travaux tout au long de ces trois années de thèse.

Tout d'abord je voudrais remercier Monsieur Yannick FRIEN, directeur du Laboratoire G-SCOP, pour m'avoir accueilli dans le laboratoire G-SCOP. Je tiens à remercier beaucoup Monsieur Eric ZAMAI, Maître de Conférences à l'Institut National Polytechnique de Grenoble, mon directeur de thèse pour m'avoir accueilli dans l'équipe GCSP, pour avoir accepté de diriger ce travail, pour tous ses conseils et pour toute la confiance qu'il a eu envers mon travail, son soutien inestimable et pour son immense patience. Également je remercie Monsieur Khoi Quoc TRAN DINH pour son co-encadrement, pour tous ses conseils, sa disponibilité, son support.

Je tiens à exprimer ma gratitude également à :

- M. Jean-Marie FLAUS, Professeur de l'Université Joseph Fourier, Grenoble.
- M. Bernard GRABOT, Professeur de l'École Nationale d'Ingénieur de Tarbes.
- M. Jean-François PETIN, Professeur de l'Institut National Polytechnique de Lorraine, Nancy.
- M. Stephane HUBAC, Process Control Expert, STMicroelectronics, Crolles.
- M. Sébastien HENRY, Maître de conférences, Université Lyon 1 IUT, Villeurbanne.
- M. Eric DESCHAMPS, Project Development Manager, Rockwell Automation.

qui m'ont honoré en apportant leur compétence pour l'évaluation de ce travail et en acceptant de participer au jury de ma thèse, et à M. Bernard GRABOT et M. Jean-François PETIN qui ont accepté d'être rapporteurs et contribué à l'amélioration de ce mémoire par leurs critiques constructives.

Un grand merci à mes amis de longue date, Ho, Bouaziz, Nguyen, Ngo, Le et ..., qui ont su m'apporter leur soutien tout au long de ces trois ans et me changer les idées lorsque j'en avais besoin.

Un énorme merci à ceux qui m'entourent depuis toujours, mes parents, ma femme, mon fils, qui m'ont toujours donné le courage et la force pour avancer dans la vie. Je conclurai en remerciant ceux qui me supportent au quotidien pour leur confiance et pour tout ce qu'ils m'apportent.

Table des matières

Introduction générale	11
Partie I Problématique	15
Chapitre 1 Contexte général	17
1 Introduction	17
2 Systèmes Automatisés de Production (SAP)	17
2.1 Description générale	17
2.2 Structure d'un SAP	18
2.3 Chaînes fonctionnelles	19
2.3.1 Chaîne d'action	19
2.3.2 Chaîne d'acquisition	20
2.4 Système de pilotage	21
3 Aléas de fonctionnement	22
3.1 Réactivité aux aléas	23
3.2 Diagnostic des défaillances	25
4 Conclusion	26
Chapitre 2 Problématique et Démarche Proposée	27
1 Introduction	27
2 Problématique du diagnostic dans le cadre d'une propagation de dé- faillance	27
3 L'approche développée au GCSP	30
3.1 Modélisation des services offerts	31
3.2 Prise en compte de l'observabilité pour le diagnostic	33
3.3 Modèle pour le diagnostic	34
4 Approche proposée	35
5 Conclusion	37
Chapitre 3 Modèles probabilistes	39
1 Introduction	39
2 Théorie des probabilités	39

2.1	Définitions et propriétés	39
2.2	Probabilité conditionnelle	40
3	Réseaux Bayésiens	40
3.1	Définition	41
3.2	Inférence Bayésienne	41
3.3	Apprentissage d'un réseau Bayésien	42
3.4	Réseaux Bayésiens naïfs	43
3.5	Réseaux Bayésiens naïfs augmentés	45
4	Théorie de Dempster-Shafer	47
4.1	Principes fondamentaux	47
4.2	Règle de combinaison de Dempster-Shafer	48
4.3	Aide au diagnostic	49
4.4	Discussion	51
5	Chaîne de Markov	52
5.1	Les processus stochastiques	52
5.2	Chaîne de Markov : Définitions et Propriétés	52
5.3	Modèles de Markov	54
5.3.1	Modèle de Markov Observable	54
5.3.2	Modèle de Markov Caché	55
5.4	Discussion	57
6	Réseaux Bayésiens Dynamiques	57
6.1	Représentation de Réseaux Bayésiens Dynamiques	58
6.2	Réseaux Bayésien Naïf Dynamiques	60
6.3	Positionnement	61
7	Conclusion	61

Partie II Modèle de la Confiance du compte-rendu 63

Chapitre 4 Confiance du compte-rendu 65

1	Introduction	65
2	Définition	65
3	Analyse des paramètres ayant un impact sur CLFI	66
4	Spécificité des paramètres ayant un impact sur le CLFI	68
4.1	Fiabilité du système de capteurs (R)	68
4.2	Position des capteurs (P) dans la chaîne d'acquisition	70
4.3	Contexte de production (C)	70
4.4	Type de produit (TP) et résultat de contrôle de la machine de métrologie pour chaque type de produit (Me)	70
4.5	Maintenance préventive (PM) et corrective (CM)	75
5	Caractérisation du CLFI	77
6	Conclusion	77

Chapitre 5 Contribution à la modélisation de la confiance	79
1 Introduction	79
2 Modèle bayésien Naïf	79
2.1 Méthode de calcul	80
2.2 Exemple d'application	81
3 Modèle TAN	83
3.1 Modélisation	83
3.2 Calcul du CLFI	83
3.3 Calcul des composantes dans le modèle	84
4 Modèle RBDCM	84
4.1 Modélisation	85
4.2 Proposition du modèle mathématique	86
4.3 Méthode de calcul des composants dans le modèle	87
4.4 Exemple de distribution de la probabilité transitoire	88
5 Conclusion	89
Chapitre 6 Algorithme de calcul	91
1 Introduction	91
2 Étape d'apprentissage	91
3 Étape de calcul en ligne	92
4 Algorithme de calcul	93
4.1 Algorithme de calcul de $P(R_t Re_t)$	94
4.2 Algorithme de calcul de $P(Me_t Re_t, TP_t)$	95
5 L'algorithme pas à pas	95
6 Conclusion	98
Partie III Exemple d'application	99
Chapitre 7 Cas d'étude	101
1 Introduction	101
2 Système de production de Semi-Conducteur	101
2.1 Généralités	101
2.2 Process de fabrication	102
2.3 Process de production et maîtrise de la qualité de fabrication	103
3 Procédures de contrôle dans le domaine du semi-conducteur	106
3.1 Contrôle de Run to run	106
3.2 Contrôle de FDC	106
3.3 Contrôle de SPC	106
4 Conclusion	109

Chapitre 8 Modélisation et Résultats	111
1 Introduction	111
2 Système de production considéré	111
3 Modélisation	113
3.1 Modèle	113
3.2 Processus d'apprentissage	114
3.2.1 Processus de calcul des probabilités : $P(C Re), P(TP Re), P(PM Re), P(CM Re)$	114
3.2.2 Calcul de la probabilité $P(R Re)$	115
3.2.3 Calcul de la probabilité $P(Me Re, TP)$	115
3.3 Processus de calcul en ligne du CLFI	117
3.4 Interface de calcul du CLFI	119
4 Évaluation sur la base de scénarios	119
5 Intégration au diagnostic de service	122
6 Conclusion	123
Conclusion générale	125
Bibliographie	129
Annexes	139
Annexe A Glossaire	141
Annexe B Bases de Donnés	143

Introduction générale

Dans un contexte aujourd'hui mondialisé, l'industrie manufacturière se trouve plongée dans un stress permanent lié à une compétitivité extrême. La pérennité des entreprises correspondantes est donc liée à une maîtrise totale de l'outil de production à tous les niveaux de la pyramide CIM, où les maîtres mots des industriels sont plus que jamais : réduction des coûts et des délais de production, amélioration de la qualité de fabrication pour accroître encore la productivité de l'entreprise, faire face aux perturbations internes ou externes qui peuvent occasionner des rejets plus ou moins importants de produits fabriqués.

Nous allons ici nous intéresser plus particulièrement aux améliorations qui doivent être apportées pour faire face aux situations et problèmes inconnus qui peuvent se produire au cours d'un cycle de production : à savoir maîtriser les aléas issus de la partie opérative.

L'étude d'une telle problématique vise à spécifier et concevoir des Systèmes Automatisés de Production en vue d'une meilleure autonomie en présence de dysfonctionnements et ainsi aider les industriels à mieux maîtriser leur production ; nous parlerons de Surveillance et de Supervision.

Dans ce cadre, de nombreuses approches et solutions ont été proposées, accompagnées du développement de procédures fines de supervision, de surveillance et de commande. Parmi ces dernières il est coutume de retrouver des mécanismes de détection des symptômes de défaillances, de diagnostic permettant de retrouver les origines de ces défaillances, de décision visant non seulement à définir de nouveaux objectifs de production mais aussi de synthétiser de nouvelles lois de commande.

L'ensemble de ces fonctionnalités s'appuie généralement sur un modèle de la partie opérative dont l'état doit être en permanence mis à jour non seulement par l'ensemble des évolutions provoquées par l'exécution des lois de commande, mais également vis-à-vis de l'ensemble des informations, plus ou moins certaines et complètes, issues du système de captage.

Le travail que nous présentons dans ce mémoire propose d'apporter sa contribution au domaine de la surveillance et de la supervision, en ligne, des systèmes à événements discrets complexes. Il se place volontairement dans un contexte perturbé par l'occurrence d'aléas de fonctionnement d'une partie opérative (dérives équipements) au sein du quel nous visons à mettre à disposition des équipes de maintenance en atelier les outils nécessaires pour les aider à localiser rapidement les équipements à l'origine probable de défauts produits : **localiser mieux pour maintenir mieux et donc minimiser encore davantage les temps de dérives équipements.**

Si les équipements de production étaient en mesure de détecter de telles dérives, le problème pourrait être considéré comme simple, cependant, l'intégration d'équipements de métrologie au sein des ateliers de production montre le contraire. C'est bien parce qu'il y a systématiquement un doute qu'un équipement de production dérive que la métrologie a été introduite. Aussi, partant du constat que les équipements de production ne peuvent être dotés d'un système de captage couvrant de manière exhaustive l'ensemble des paramètres à observer, que la fiabilité des capteurs est variable dans le temps, que les contextes de production (multi-produits, flux R&D, etc) sont particulièrement stressants, nous nous proposons ici de développer une approche permettant d'estimer en temps réel la confiance qui peut être accordée aux opérations produits réalisées.

Ce mémoire est organisé en trois parties dont les thèmes sont donnés ci-après :

La première partie présente de manière générale la problématique à laquelle nous nous intéressons. Ainsi après avoir exposé le contexte général des systèmes automatisés de production réactifs aux aléas de fonctionnement, nous positionnons nos apports au niveau temps réel de coordination des équipements de production, en particulier au sein d'une approche diagnostique. Sur cette base, nous dévoilerons le cahier des charges des travaux développés dans ce manuscrit, ainsi qu'une étude des principales approches ayant apporté une contribution au domaine de la caractérisation des incertitudes pour le diagnostic ; les approches de type Bayésiennes y sont largement plébiscitées.

La partie II expose notre contribution. Ainsi, après avoir introduit et détaillé le concept de compte rendu d'exécution, nous dévoilons les différents paramètres qui ont une influence significative sur la confiance qui peut leur être accordée. Sur cette base, les différents modèles que nous préconisons sont exposés : modèles Bayésiens Naïfs, Modèles Bayésiens Augmentés et Modèles Bayésiens Dynamiques à chaînes de Markov. Chacune de ces propositions répond à un besoin spécifique de modélisation du concept de confiance. A la suite de quoi, cette partie se termine par la présentation des algorithmes de calcul que nous avons développés et qui s'appuient sur les différents modèles soumis.

La partie III développe un exemple d'application des mécanismes proposés sur la base d'un atelier largement inspiré d'un cas d'étude industriel issu du domaine du semi-conducteur. Après avoir présenté d'une façon générale la partie opérative ainsi que son architecture de pilotage, nous proposons non seulement une étape de modélisation centrée sur l'apprentissage des données historiques de production mais également une confrontation de l'atelier logiciel de calcul en ligne de la confiance que nous avons développé à différents scénarios de test. Cette partie se termine par une présentation de l'intégration d'un tel outil à des fins de diagnostic de services.

Première partie

Problématique

Chapitre 1

Contexte général

1 Introduction

Dans le cadre de ce premier chapitre, nous nous proposons de positionner le contexte général de notre étude. Celle-ci prend place au sein des Systèmes Automatisés de Production (SAP) en environnement stressé par le flux de produit et où le nombre de machines de production et le nombre d'opérations des gammes considérées sont importants. Fort d'une présentation de la structure même de pilotage d'un SAP, nous convergerons rapidement sur la problématique générale auquel ces travaux visent à apporter une pierre supplémentaire, à savoir l'aide à la localisation des équipements de production à l'origine possible des dérives produits détectées en phase de métrologie. Pour cette raison, nous consacrerons la section trois de ce chapitre à une présentation générale et succincte des approches de diagnostic des systèmes à événements discrets complexes.

2 Systèmes Automatisés de Production (SAP)

Dans le domaine industriel, pour faire face aux enjeux économiques, les entreprises de production manufacturière se sont dotées depuis de nombreuses années d'un outil de production performant, le Système Automatisé de Production (SAP). Nous nous proposons dans ce qui suit de détailler cet outil.

2.1 Description générale

Les Systèmes Automatisés de Production (SAP) se composent de stations de travail majoritairement automatisées et reliées par un système de coordination. Les interventions manuelles sont généralement réservées aux fonctions auxiliaires telles que les changements d'outils, le chargement et le déchargement des pièces, et les activités de réparation et d'entretien (maintenances). Les SAPs sont donc développés pour :

- Soulager l'homme dans ses tâches pénibles et dangereuses.

- Contribuer à l'amélioration de la productivité des entreprises.
- Transformer des matières premières en produits finis d'une manière rapide. (cf. Figure 1.1)
- Diminuer le temps de production de ces produits et les délais de livraison aux clients (AFNOR, 1991).
- Répondre aux demandes des clients de plus en plus exigeants (Agard et Tolle-naere, 2002).
- Réaliser des opérations complexes qui ne peuvent pas être faites manuellement (Perrin et al., 2004).

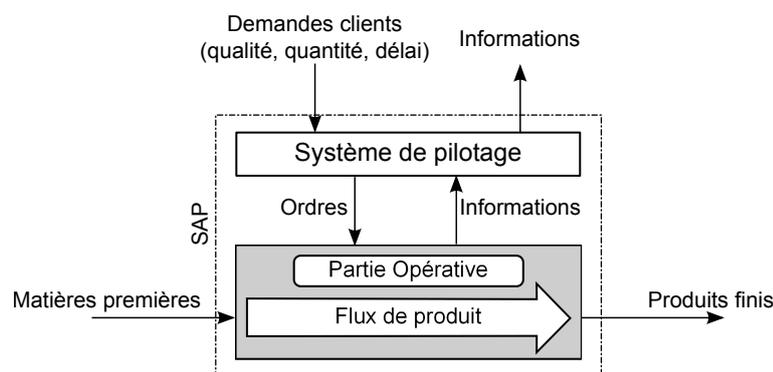


FIGURE 1.1 – Entrées/Sorties d'un SAP avec sa structure générale

Afin d'atteindre ces objectifs, le SAP s'appuie sur une flexibilité physique quant à son exploitation (Berruet, 1998a). Ceci apporte de la flexibilité des activités physiques de la partie opérative. Elle joue un rôle primordial pour répondre aux incertitudes liées aux aléas de fonctionnement de la partie opérative. Toutefois la flexibilité physique de la partie opérative n'est pas en soi suffisante. Elle doit également s'accompagner d'un système de pilotage capable de décider comment les tâches à réaliser s'adaptent aux spécificités des produits et aux aléas de fonctionnement (Zamai et al., 1998).

2.2 Structure d'un SAP

D'une manière générale, les SAP disposent d'une structure interne composée de trois parties (cf. Figure 1.1) (Perrin et al., 2004; Deschamps, 2007).

Le flux de produits représente l'ensemble des entités en cours de transformation dans le SAP (matières premières, transformées, assemblées, produits finis).

La partie opérative (PO) qui reçoit des ordres pour les transformer sous forme d'actions physiques (déplacement, mise en rotation...). Elle utilise des énergies telles que l'électricité, de l'air comprimé (pneumatique) et des fluides hydrauliques; nous parlerons de chaînes d'actions (Perrin et al., 2004). Elle permet également de mesurer des grandeurs physiques (vitesses, température, position d'un vérin, couleur du produit...) au travers de chaînes d'acquisitions afin de remonter des informations vers le système de pilotage.

Le système de pilotage qui commande la partie opérative pour obtenir les effets désirés, par l'émission d'ordres (requêtes) en fonction d'informations disponibles, comptes-rendus, ordre de fabrication et modèles de comportement. Il peut échanger des informations avec des opérateurs humains ou d'autres systèmes. Il surveille l'évolution du flux de produits et de la partie opérative.

2.3 Chaînes fonctionnelles

Comme nous venons de le voir, la partie opérative est constituée de chaînes d'actions et de chaînes d'acquisitions regroupées généralement sous le vocabulaire de chaînes fonctionnelles (Henry et al., 2012). Nous nous proposons de les détailler ci-après.

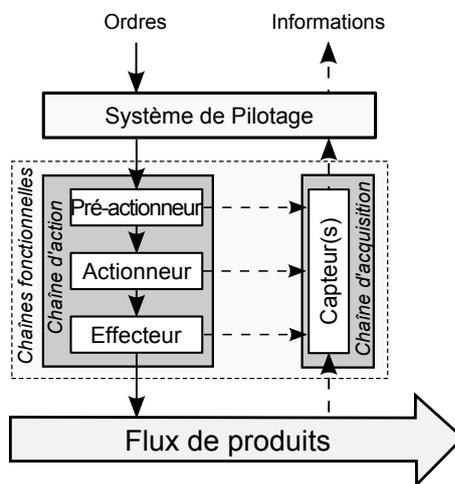


FIGURE 1.2 – Eléments de la partie opérative

2.3.1 Chaîne d'action

La chaîne d'action est chargée de transformer la matière d'œuvre en fonction du besoin. Elle est constituée de trois éléments (Perrin et al., 2004), quelle que soit la technologie employée (cf. Figure 1.3) :

Pré-actionneur : il est chargé de transformer l'énergie électrique produite par le système de pilotage en énergie mécanique, électrique, pneumatique ou encore hydraulique (cf. Figure 1.2).

Actionneur : c'est l'élément moteur de la chaîne d'action. Alimenté en énergie de puissance par son pré-actionneur, il fait fonctionner l'effecteur. Par exemple, l'actionneur pneumatique principal est le vérin (cf. Figure 1.2).

Effecteur : c'est l'élément de la chaîne d'action en contact avec la matière d'œuvre ou le produit. Il est chargé de sa transformation (cf. Figure 1.2) physique, spatiale, etc.

2.3.2 Chaîne d'acquisition

Elle est chargée de prélever des informations sur le processus de production, sur la partie opérative, sur la matière d'œuvre ou sur l'environnement de la chaîne fonctionnelle considérée pour informer le système de pilotage (cf. Figure 1.3) de l'état du processus en cours d'exécution.

Les constituants principaux d'une chaîne d'acquisition sont (Perrin et al., 2004) :

- une chaîne d'acquisition d'information(s) sur l'état de l'équipement et l'état du produit (métrologie). Elle fournit les d'informations nécessaires pour la conduite du procédé en observant les déplacements des actionneurs ou le résultat de leurs actions sur le procédé. Ces informations peuvent être de natures très diverses : présence de matière d'œuvre, positions, pressions, courants électriques, températures, débits, codes, etc.. Sur le plan technologique, elle s'appuie sur des capteurs.
- une chaîne d'acquisition d'informations extérieures (issue de l'opérateur, messages transmis par une autre partie commande)...

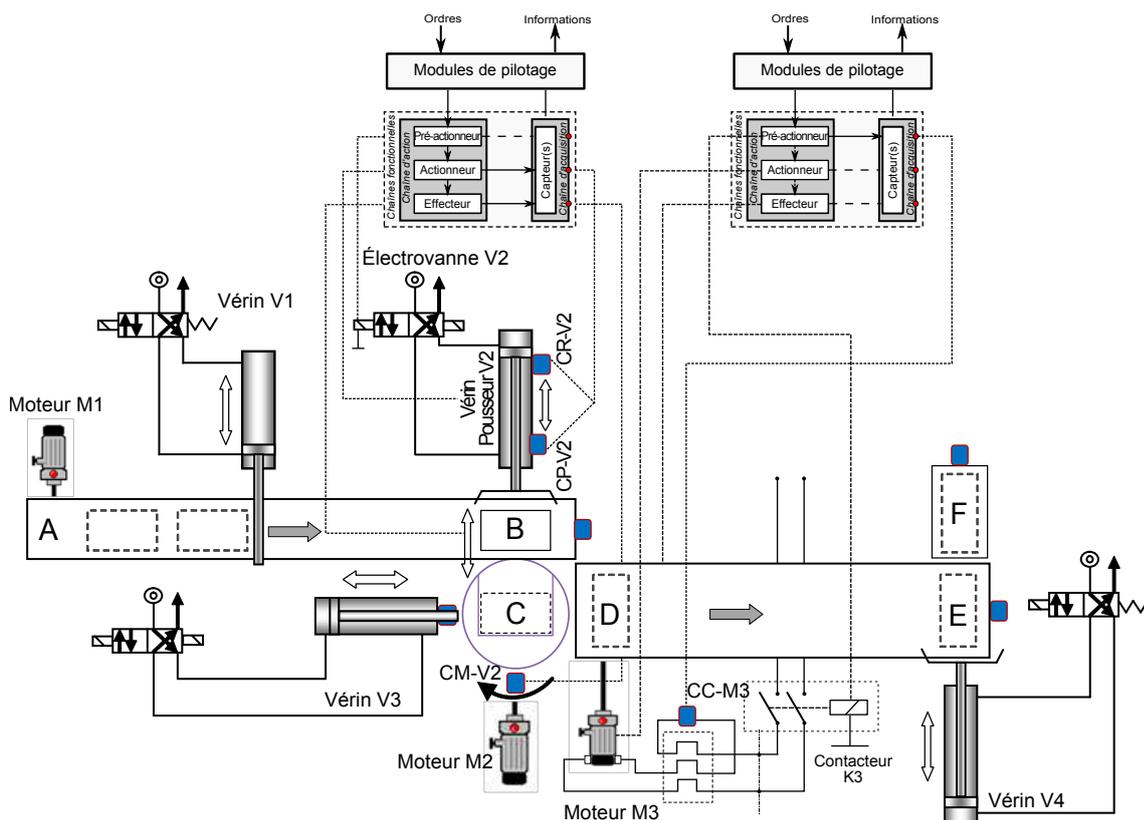


FIGURE 1.3 – Exemple de chaînes fonctionnelles

La Figure 1.3 illustre graphiquement ce concept de chaînes fonctionnelles. Nous y montrons en particulier pour le vérin V2, le moteur M3 et convoyeur [AB] :

- Les comportements successifs des pré-actionneurs (Électrovanne V2, Contacteur K3), des actionneurs (alimentation V2 sens+, alimentation V2 sens- de l'élec-

trovanne, alimentation M3). L'acquisition de l'information logique de Marche/Arrêt du moteur M3 via le capteur CC-M3.

- Les comportements attendus des actionneurs (avance vérin V2, rotation moteur M3) via les informations logiques fournies par les capteurs (CR-V2 et CP-V2).
- Les effets successifs attendus sur le produit et la PO, et mesurés au travers des capteurs de position localisés en C, B ou encore A (métrologie spatiale).

2.4 Système de pilotage

Comme nous venons de le voir, pour une chaîne fonctionnelle, la commande peut s'avérer complexe, mais lorsque le nombre de ces chaînes augmente, une commande centralisée n'est plus envisageable. Afin de prendre en compte ce problème crucial, de nombreuses architectures de pilotage ont été proposées (Jones et Saleh, 1989). L'une des solutions la plus utilisée consiste à organiser le système de pilotage en plusieurs niveaux de complexité moindre.

Nous nous proposons ici de retenir le modèle hiérarchique et modulaire de commande structuré en cinq niveaux (cf. Figure 1.4). Il a été proposé sous l'appellation de « Computer Intergrated Manufacturing » au début des années 80 (CIM, 1989).

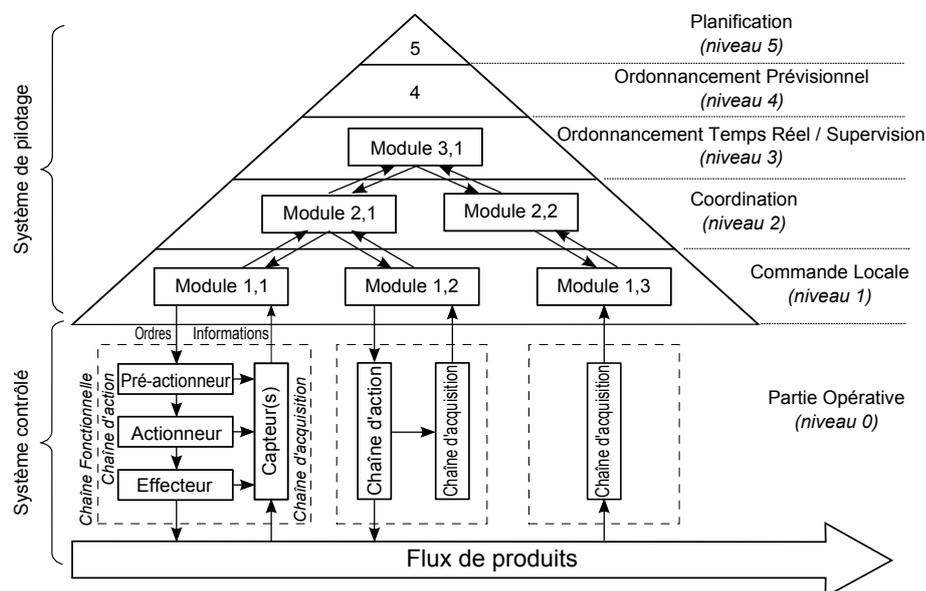


FIGURE 1.4 – Architecture CIM

Le principe de fonctionnement de cette architecture est générique et s'appuie sur un protocole de communication de type *appel/réponse* (Jones et Saleh, 1989; Combacau, 1991; Zamai et al., 1997), traduit de l'expression anglaise : Remote Procedure Call (RPC) (cf. Figure 1.5). Lorsqu'un module de niveau n envoie une requête de commande à un module $n-1$, ce dernier la désagrège en m autres requêtes qu'il envoie vers les niveaux inférieurs et ainsi de suite jusqu'à la chaîne d'action.

En fonctionnement normal, une information ou un ensemble d'informations issues d'une chaîne d'informations caractérisent une fin normale d'activité qui se propage ensuite sous la forme de m comptes rendus correspondants aux m requêtes lancées par les niveaux supérieurs. A m requêtes doivent correspondre m CR. Cependant dans un contexte de dysfonctionnement de la partie opérative, un CR caractérise, lorsqu'il est transmis, l'impossibilité du niveau inférieur d'exécuter la requête qui lui a été envoyée. Ce compte-rendu peut être accompagné d'informations complémentaires telles que les raisons de l'impossibilité d'exécuter la requête envoyée. La réception d'un tel compte-rendu traduira forcément un passage en fonctionnement anormal de la partie opérative pilotée par le module en question.

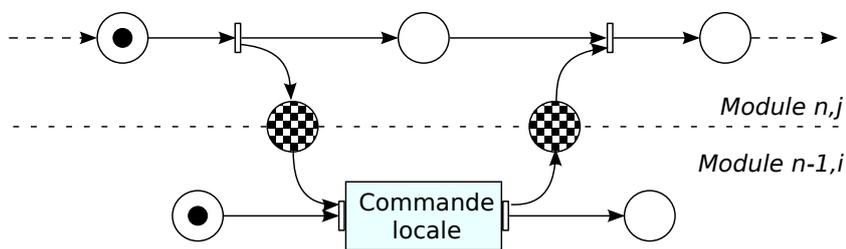


FIGURE 1.5 – Protocole de communication

Afin de gérer ce type de CR, il est coutume d'implanter dans l'ensemble de la structure hiérarchique et modulaire un ensemble de fonctionnalités de Surveillance, Supervision et Commande (Combacau et al., 2000), ceci ayant pour but de rendre chacun des modules capable de réagir à l'occurrence d'une défaillance et de prendre l'initiative du processus réactif afin de respecter le principe de confinement (Combacau, 1991) de la défaillance :

Il faut autant que faire se peut éviter que la défaillance se propage vers le haut de la pyramide CIM afin d'éviter un blocage de toute la structure.

Dans le cadre de nos travaux, nous nous intéressons principalement aux aléas de la partie opérative.

3 Aléas de fonctionnement

Les Aléas de Fonctionnement se définissent comme étant des événements non prévus qui viennent perturber le fonctionnement du SAP.

- Aléas de la chaîne fonctionnelle (casse d'outils, panne de capteur, d'un actionneur, etc.,).
- Aléas liés aux opérations de maintenance (corrective, préventive).
- Aléas de la matière première en entrée du SAP (caractéristiques de la matière, non conforme aux attentes).
- Défaillance du système de commande.
- etc...

3.1 Réactivité aux aléas

La réactivité du système peut être définie comme étant la capacité du système à maintenir la mission qui lui a été confiée en présence d'aléas. De nombreux travaux se focalisent sur cet objectif, comme par exemple (Combacau et al., 2000; Niel et Craye, 2002) au travers du développement de fonctions SSC (Supervision, Surveillance, Commande) qui doivent être intégrées au cœur du système de pilotage. Nous rappelons dans la Figure 1.6 les résultats issus de la communauté scientifique nationale du groupe de travail GT INCOS¹ du GDR-MACS².

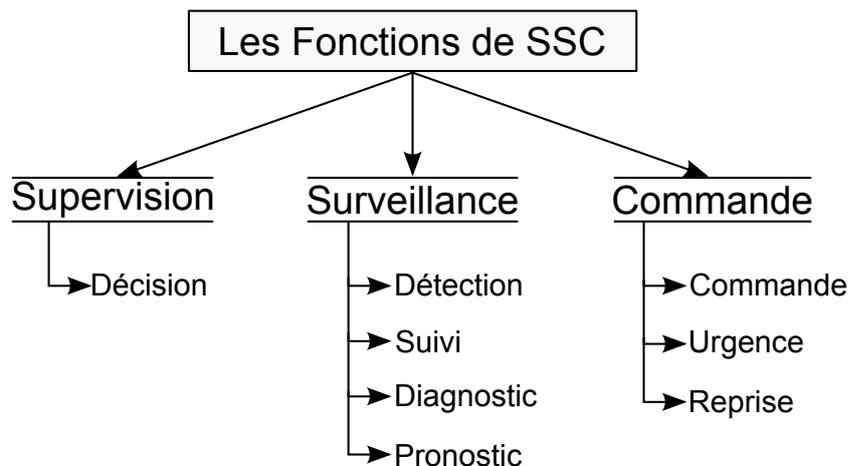


FIGURE 1.6 – Les fonctions de pilotage des SAP

Les fonctions de la supervision se chargent de contrôler et de surveiller l'exécution d'une opération ou d'un travail effectué par d'autres sans rentrer dans les détails de cette exécution (Combacau et al., 2000). Le rôle des fonctions de la supervision est décisionnel en même temps qu'opérationnel. Elles déterminent un état accessible pour le retour en fonctionnement normal (Berruet, 1998b) et les différentes actions correctives modifiant la configuration du procédé et de la commande (Henry, 2005).

Les fonctions de la surveillance recueillent en permanence tous les signaux en provenance du système contrôlé (chaînes fonctionnelles et flux de produits) et de la commande afin de vérifier en permanence si l'état réel du système considéré correspond à celui attendu. Elles intègrent les fonctions telle que la détection, le suivi, le diagnostic ou le pronostic.

Les fonctions de la commande se chargent de contrôler le système en appliquant une séquence d'activités de commande (ordres) à exécuter pour assurer la réalisation d'un produit ou de services contribuant à atteindre un objectif fixé. La commande regroupe toutes les fonctions qui agissent directement sur le système contrôlé : commande dans un but de production, reprise pour assurer un

1. Groupe de Travail INgénierie de la COmmande et de la Supervision des SED

2. Groupement de Recherche, Modélisation, Analyse et Conduite des Systèmes dynamiques

retour en production normale, urgence pour garantir la sécurité des biens et des personnes.

Dans le cadre des fonctions de SSC, de nombreuses approches formelles sont proposées dans la littérature. Le LAGIS³ présente les relations causales entre les fonctions élémentaires des composants de base du système et le graphe fonctionnel. Ce modèle permet d'identifier un état objectif à l'aide d'un graphe fonctionnel (Ghariani et al., 2002; Berruet et al., 2000). Ainsi que la proposition d'une approche basée sur l'exploitation des RdP colorés pour proposer une méthodologie de conception des modèles de contrôle de la fabrication du système flexible avec une application industrielle (Huvenoit et al., 1995). Le CRAN⁴ (Gouyon et al., 2004) a présenté une approche qui combine les techniques de synthèse et d'algorithmes avec une méthode d'automatisation orientée objet, cette dernière fournit des directives pour l'analyse, la conception et la mise en œuvre d'un système de contrôle modulaire. Une architecture de synthèse d'une commande reconfigurable est ainsi proposée. Une approche similaire est proposée par le G-SCOP⁵ (Henry et al., 2012) pour la commande et la reconfiguration dynamique des SED. Elle introduit une synthèse de lois de commande des systèmes automatisés de production en contexte incertain. L'incertain est caractérisé d'une part par les variations imprévues des demandes client, mais également par les aléas de fonctionnement déclarés au niveau de la partie opérative. L'approche proposée utilise une méthode de modélisation de la partie opérative en utilisant un formalisme particulièrement adapté à la complexité des procédés considérés, et une technique de synthèse de lois de commande basée sur un mécanisme de recherche de chemins dans un graphe.

En outre, nous pouvons également citer des contributions telles que la supervision des fonctions : détection, diagnostic, pronostic, décision et contrôle automatique (Zamai et al., 1998) et les travaux de Deschamps (2007) sur le diagnostic de services pour la reconfiguration dynamique des systèmes à événement discrets complexes (Henry et al., 2012). Le LAAS⁶ a proposé plusieurs approches : la détection de l'occurrence d'un symptôme de défaillance (Combacau, 1991) ; la surveillance et le diagnostic actif des SED avec l'objectif de trouver une séquence d'actions (ou d'un plan) admissible qui raffine un diagnostic sans changer radicalement le plan de mission (Chanthery, 2010) ; les aspects pronostics sont également traités notamment au travers des travaux de (Ribot et al., 2009). Sur le plan international, nous préconisons la lecture des travaux de (Weidl et al., 2005; Lafortune et al., 2001; Fanti et Seatzu, 2008).

Le contexte général de notre étude étant désormais dévoilée, nous nous proposons maintenant de localiser précisément nos apports au sein de l'approche de Supervision, Surveillance et Commande développée au G-SCOP, en particulier, au niveau de la fonction diagnostic.

3. Le Laboratoire d'Automatique, Génie Informatique et Signal

4. Centre de Recherche en Automatique de Nancy

5. Laboratoire des Sciences pour la Conception, l'Optimisation et la Production de Grenoble

6. Laboratoire d'Analyse et d'Architecture des Systèmes

3.2 Diagnostic des défaillances

Dans le cadre du diagnostic, de nombreux travaux proposent des solutions différentes, nous nous proposons de les classifier comme suit :

Méthodes basées sur la connaissance (Zwingelstein, 1995; Jackson, 1998; Venkatasubramanian, 2003), cette famille utilise une connaissance explicite de relations entre les symptômes, les défaillances et les fautes. La connaissance est fournie par le processus de conception, l'analyse fonctionnelle et structurelle du système, l'analyse des modes de défaillance et de leurs effets (AMDE) ou la modélisation d'un historique de fonctionnement anormal. Ces méthodes sont utilisées pour identifier les causes des défaillances possibles d'un système. Elles se présentent sous la forme d'associations entre effets et causes.

Méthodes basées sur le traitement de données (Fouladirad et Nikiforov, 2005; Hamou Mamar, 2008; Zwingelstein, 1995) utilisent des techniques d'apprentissage numérique et de classification afin d'établir un modèle de référence du système qui est fondé sur l'expérience (exploitation des données, des mesures sous la forme d'historique). Ce modèle de référence modélise le comportement normal du système, il est utilisé pour la détection et le diagnostic. L'objectif de ces méthodes est d'associer un ensemble de mesures à des états de fonctionnement connus du système. Dans ce cas, les capteurs sont supposés fiables et leurs valeurs correctes. Les réseaux de neurones et la logique floue sont généralement utilisés en tant qu'outils supports.

Méthodes à base de modèles (Debouk et al., 1998; Wang et al., 2007; Deschamps, 2007) sont basées sur une connaissance physique du système à diagnostiquer. La méthode de diagnostic s'appuie sur la comparaison du comportement réel observé sur le système physique avec le comportement prédit à l'aide du modèle. La détection d'incohérences permet de conclure sur l'occurrence de fautes dans le système. Un modèle de dysfonctionnement (modèle de fautes) permet de localiser les fautes et éventuellement de les identifier.

Par ailleurs, nous pouvons trouver d'autres approches complémentaires comme par exemple les systèmes experts (Zwingelstein, 1995), la reconnaissance de scénario (Boufaied, 2003), le diagnostic des SED (Lafortune et al., 2001), le diagnostic logique (Hamscher et al., 1992; Deschamps, 2007) ou encore le diagnostic de plan (Witteveen et al., 2005). Elles adressent chacune des facettes particulières du domaine et amènent des réponses intéressantes soit sur le plan du temps de calcul, soit sur celui de la garantie de performance du résultat obtenu soit encore sur celui de la généralité de l'approche. Naturellement, chacune s'accompagne aussi d'un ensemble d'inconvénients comme pour certaines l'énumération exhaustive des défaillances, le temps de calcul conséquent, le manque de robustesse à une évolution de la partie opérative (intégration de nouvelles machines), etc. Parmi ces approches, nous avons retenu celle du diagnostic logique, qui s'appuie sur un raisonnement indépendant du

type de système étudié et donc indépendant de l'évolutivité possible de la partie opérative. Elle permet de faciliter l'acquisition de la connaissance du système au travers d'une approche modulaire.

4 Conclusion

Ce premier chapitre nous a permis de présenter non seulement le contexte de notre étude en particulier marquée par le contexte des Systèmes Automatisés de Production. Nous avons ainsi présenté de manière détaillée les éléments centraux des architectures de pilotage les animant et nous nous sommes ensuite focalisés sur leur fonctionnement en présence d'aléas de fonctionnement. Dans ce contexte, nous nous sommes naturellement intéressés aux approches permettant leur traitement, et en particulier à celles dédiées à la localisation de défauts, à savoir le diagnostic.

Notre approche visant à apporter sa contribution à ce domaine de recherche, le chapitre suivant se propose de détailler cette activité, en particulier au niveau coordination de la pyramide CIM et donc plus particulièrement sur le traitement des phénomènes de propagation de défaillances.

Chapitre 2

Problématique et Démarche Proposée

1 Introduction

Lorsque nous nous plaçons au niveau "coordination" d'équipements de production, plusieurs remontées d'information en réponse à des ordres de fabrication peuvent être perçues. Parmi elles, nous nous intéressons aux comptes rendus anormaux qui caractérisent un dysfonctionnement de la partie opérative. Ces comptes rendus anormaux peuvent être l'image d'un dysfonctionnement de l'équipement considéré (panne d'actionneur, effecteur, etc) ou bien la propagation d'une défaillance portée par le produit lui-même, défaillance donc non détectée par les équipements précédemment intervenus sur ce produit.

Dans le cadre de cette problématique, nous nous sommes volontairement positionnés sur une extension de l'approche de diagnostic de service proposée au sein de l'équipe GCSP¹ du G-SCOP par M. Eric Deschamps (Deschamps, 2007). Pour cette raison, et après avoir approfondi la problématique de propagation de défaillances dans les SAP, nous nous proposons dans la section 3 de détailler cette approche de diagnostic logique afin d'en montrer les avantages et limites, limites que nous mettrons en perspective de résolution pour la suite de ce mémoire.

2 Problématique du diagnostic dans le cadre d'une propagation de défaillance

Quelque soit le SAP considéré, il est généralement constitué d'équipements de production de leurs systèmes de pilotage et de leurs chaînes fonctionnelles tels que présentés page 19, figure 1.2. Comme nous avons pu le noter dans ce chapitre, le système de captage (chaîne d'information) est basé sur un ensemble de capteurs dont la position dépend des paramètres à maîtriser, de la technologie disponible et de l'environnement direct (humidité, corrosion, vibrations, projections de matières, etc.). Aussi

1. Gestion et Conduite des Systèmes de Production

avons-nous précisé que ces capteurs pouvaient être placés plus ou moins proches du produit sur lequel l'effecteur ou un ensemble d'effecteurs doivent agir. Au mieux, les capteurs sont positionnés sur le produit, au pire ils en sont très éloignés voire non présents. De ce fait, une partie du système de commande (nous incluons ici les chaînes d'actions) se retrouve plus ou moins en boucle ouverte tel que nous l'avons représenté dans la figure 2.1. De cette proportion de boucle ouverte/ boucle fermée au sein de la chaîne d'action naît forcément un doute quant à la bonne réalisation de l'ordre transmis sous la forme d'une énergie électrique au pré-actionneur considéré. Dans l'hypothèse que tous les paramètres mesurés correspondent à ceux prévus par la commande, l'équipement de production témoignera systématiquement que l'opération demandée a été réalisée avec succès. Il n'en demeure pas moins que le produit en sortie d'un tel équipement de production portera une part d'incertitude associée à chacune des étapes de production.

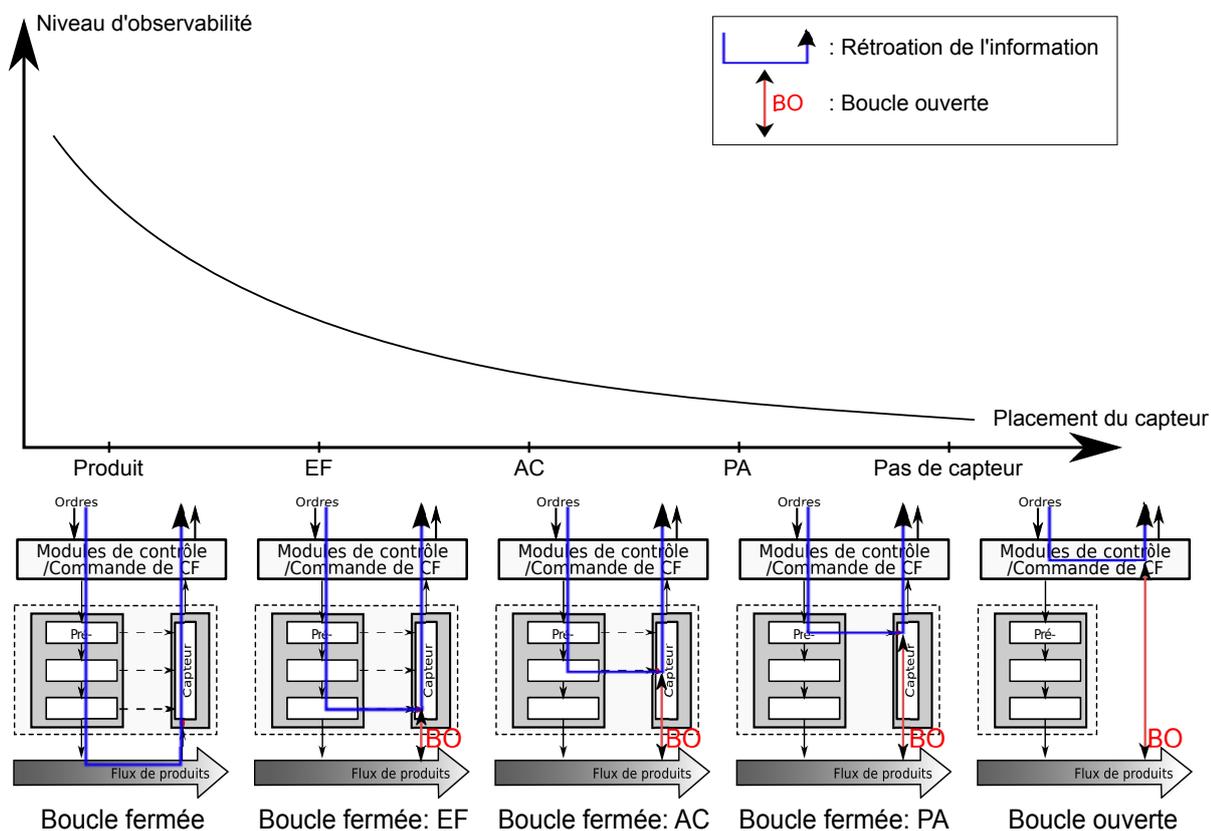


FIGURE 2.1 – Niveau d'observabilité

Dans un système complexe, le produit subissant de nombreuses étapes de production dans un parc de machines important, le contrôle de paramètres non observés augmente le risque que le produit fini ne corresponde pas aux attentes.

Afin de palier ce problème, des machines de métrologie permettant de mesurer des paramètres impossibles à observer durant une étape de fabrication sont intégrées au sein d'un SAP ; l'idéal étant théoriquement d'en positionner une après chaque équipement de production afin de réduire le retard de détection de défauts produits. Ce-

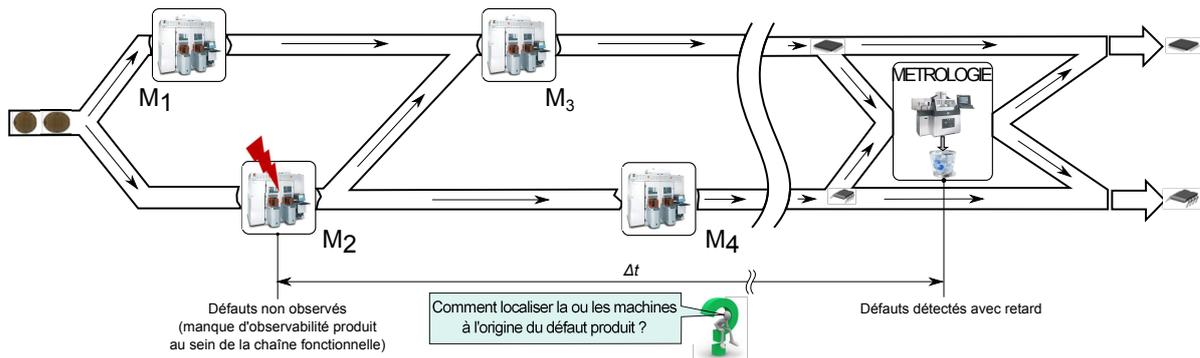


FIGURE 2.2 – Problématique de la propagation de défaillances

pendant, les coûts de tels équipements et les retards introduits par de tels contrôles sont souvent incompatibles avec les contraintes de productivité attendues. Ces équipements de métrologie sont alors positionnés en nombre limités et contrôlent des produits ayant subi plusieurs étapes (cf. figure 2.2).

Dans une telle configuration, lorsqu'un équipement de métrologie détecte une dérive produit (par exemple : une mauvaise épaisseur de dépôt de quartz dans l'industrie du semi-conducteur ou encore un taux de poussières trop important) nous mettons en évidence un phénomène de propagation de défaillance entre le moment où la ou les dérives sont apparues et le moment de leur détection. Se posent alors deux problématiques importantes :

- o la localisation de ou des équipements de production à l'origine du défaut produit détecté : diagnostic,
- o l'analyse des conséquences du passage des produits porteurs d'un défaut sur d'autres équipements a priori sains : pronostic.

Plusieurs techniques sont utilisées à ce jour pour résoudre ces problèmes de localisation, comme par exemple, les FMEA² (Shahzad et al., 2012), SPC³ (Martinez et Edgar, 2006), FDC⁴ (Scanlan et O'Leary, 2003), etc, sans jamais donner à ce jour une pleine satisfaction, ne serait-ce que sur la fiabilité des résultats obtenus et de la rapidité de traitement. Dans le cadre de cette thèse, nous nous sommes donc orientés sur des techniques de diagnostic de services en contexte incertain caractérisées par des informations de captage plus ou moins fiables et accessibles. Ces travaux se positionnent précisément dans la suite de ceux menés par l'équipe GCSP⁵ et visent à étendre les mécanismes de propagation de contraintes, permettant in fine de projeter des niveaux de suspicion au sein même du modèle de la partie opérative, via l'intégration de méthodes probabilistes permettant de calculer, dynamiquement, la confiance qui peut être accordée aux informations issues du système de captage.

Afin d'appréhender au mieux cette problématique du diagnostic du SED, nous nous

2. Failure Mode and Effects Analysis
 3. Statistical process control
 4. Fault Detection and Classification
 5. Gestion et Conduite des Systèmes de Production

proposons de présenter ci-après le mécanisme de diagnostic logique développé au sein de l'équipe GCSP.

3 L'approche développée au GCSP

L'approche de diagnostic proposée par (Deschamps, 2007) peut se spécifier au travers du SADT⁶ donné figure 2.3.

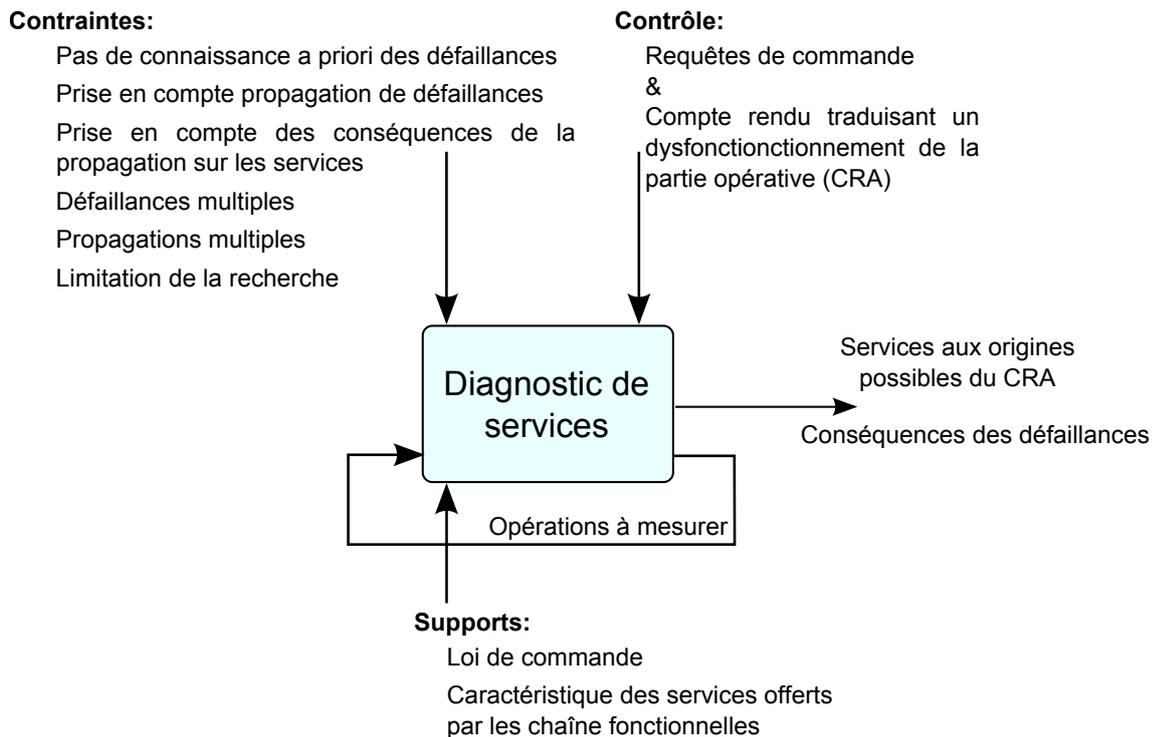


FIGURE 2.3 – Diagramme de contexte de la fonction de diagnostic des services (Deschamps, 2007)

Elle se positionne au niveau coordination des équipements de fabrication et de métrologie d'un atelier manufacturier.

D'un point de vue général, l'approche se déroule selon la méthodologie présentée dans la figure 2.4 dans laquelle sont mises en évidence trois étapes essentielles :

- La première étape consiste à modéliser, hors ligne, les différents services offerts par la partie opérative. Il s'agit en particulier d'une phase experte durant laquelle l'ingénieur automaticien est amené à modéliser les comportements des différentes opérations offertes par les équipements de l'atelier au travers d'un formalisme issu de la planification automatique largement étendu dans le cadre des travaux de Henry (2005).

6. Structured Analysis and Design Technique

- La deuxième étape de la méthode se déroule en ligne et est cadencée par différents ordres et comptes-rendus reçus et générés par les différents équipements de fabrications considérés. Ainsi à chaque ordre émis vers un équipement de fabrication, le modèle de l'opération correspondante est inséré dans le modèle de diagnostic. A la réception d'un compte-rendu (CR) de fin d'activité le modèle d'opération est effacé du modèle de diagnostic si et seulement l'effet sur le produit a pu être directement observé. Sinon, le modèle de l'opération est conservé au sein du modèle de diagnostic.
- La troisième étape est déclenchée en présence d'un compte-rendu anormal témoignant de l'incapacité d'un équipement de fabrication à avoir réalisé le service demandé ou bien lorsqu'un équipement de métrologie a détecté un défaut produit. Sous l'hypothèse que les systèmes de pilotage intégrés aux machines de fabrication et de métrologie disposent de compétences de diagnostiqueurs locaux, tout Compte-Rendu Anormal (CRA) remontant au niveau coordination caractérise une propagation de défaillance. A ce moment là un processus de propagation arrière est lancé dans le modèle de diagnostic afin de localiser le ou les équipements à l'origine du défaut. Un processus de propagation avant est ensuite lancé au sein du modèle à des fins de pronostic.

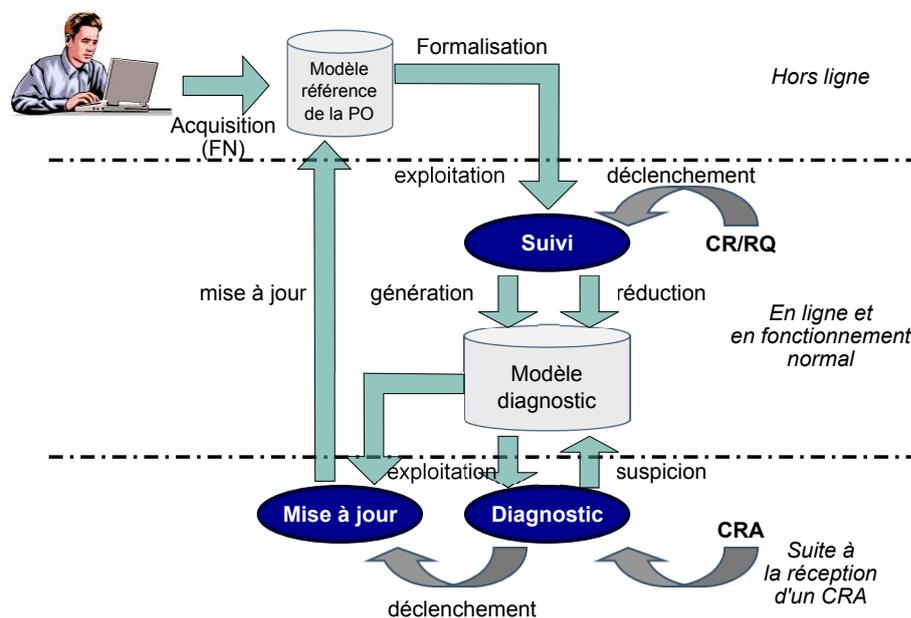


FIGURE 2.4 – Diagnostic de services (Deschamps, 2007)

3.1 Modélisation des services offerts

La modélisation des services offerts par les équipements de production ou de métrologie s'appuie sur une extension des modèles d'opérations issus du domaine de la planification automatique (Henry, 2005).

Ils prennent la forme d'une fiche très structurée que l'expert atelier doit remplir. Une fiche modélisant une chaîne fonctionnelle (CF_k) est composée de :

Opérations d'action i ; Oa_i		
Chaîne fonctionnelle: Cf_k		Service: Se_i
Durée: Du_i		
Evolution de la chaîne fonctionnelle ec_i		
EFFET: <input style="width: 100%; height: 20px;" type="text"/> ↓ IC(EfT(ec_i)) <input style="width: 100%; height: 20px;" type="text"/> Effet transitoire EfT(ec_i) ↓ IC(EfF(ec_i)) <input style="width: 100%; height: 20px;" type="text"/> Effet finalEfF(ec_i)	PRÉ-CONDITION <input style="width: 100%; height: 20px;" type="text"/> PCd(ec_i) CONDITION <input style="width: 100%; height: 20px;" type="text"/> Cd(ec_i)	PRÉ-CONTRAINTÉ <input style="width: 100%; height: 20px;" type="text"/> Pct(ec_i) CONTRAINTÉ <input style="width: 100%; height: 20px;" type="text"/> Ct(ec_i)
1ère évolution du flux de produits $ea_{i,1}$		
EFFET: <input style="width: 100%; height: 20px;" type="text"/> ↓ IC(EfT($ea_{i,1}$)) <input style="width: 100%; height: 20px;" type="text"/> Effet transitoire EfT($ea_{i,1}$) ↓ IC(EfF($ea_{i,1}$)) <input style="width: 100%; height: 20px;" type="text"/> Effet finalEfF($ea_{i,1}$)	PRÉ-CONDITION <input style="width: 100%; height: 20px;" type="text"/> PCd($ea_{i,1}$) CONDITION <input style="width: 100%; height: 20px;" type="text"/> Cd($ea_{i,1}$)	PRÉ-CONTRAINTÉ <input style="width: 100%; height: 20px;" type="text"/> Pct($ea_{i,1}$) CONTRAINTÉ <input style="width: 100%; height: 20px;" type="text"/> Ct($ea_{i,1}$)
⋮		
2ème évolution du flux de produits $ea_{i,j}$		
EFFET: <input style="width: 100%; height: 20px;" type="text"/> ↓ IC(EfT($ea_{i,j}$)) <input style="width: 100%; height: 20px;" type="text"/> Effet transitoire EfT($ea_{i,j}$) ↓ IC(EfF($ea_{i,j}$)) <input style="width: 100%; height: 20px;" type="text"/> Effet finalEfF($ea_{i,j}$)	PRÉ-CONDITION <input style="width: 100%; height: 20px;" type="text"/> PCd($ea_{i,j}$) CONDITION <input style="width: 100%; height: 20px;" type="text"/> Cd($ea_{i,j}$)	PRÉ-CONTRAINTÉ <input style="width: 100%; height: 20px;" type="text"/> Pct($ea_{i,j}$) CONTRAINTÉ <input style="width: 100%; height: 20px;" type="text"/> Ct($ea_{i,j}$)
⋮		
Nème évolution du flux de produits $ea_{i,N}$		
EFFET: <input style="width: 100%; height: 20px;" type="text"/> ↓ IC(EfT($ea_{i,N}$)) <input style="width: 100%; height: 20px;" type="text"/> Effet transitoire EfT($ea_{i,N}$) ↓ IC(EfF($ea_{i,N}$)) <input style="width: 100%; height: 20px;" type="text"/> Effet finalEfF($ea_{i,N}$)	PRÉ-CONDITION <input style="width: 100%; height: 20px;" type="text"/> PCd($ea_{i,N}$) CONDITION <input style="width: 100%; height: 20px;" type="text"/> Cd($ea_{i,N}$)	PRÉ-CONTRAINTÉ <input style="width: 100%; height: 20px;" type="text"/> Pct($ea_{i,N}$) CONTRAINTÉ <input style="width: 100%; height: 20px;" type="text"/> Ct($ea_{i,N}$)

FIGURE 2.5 – Formalisation du comportement des opérations d'action

- Du_i , la durée fixée de l'opération Oa_i .
- ec_i , l'évolution de la chaîne fonctionnelle, elle composée de :
 - o $EfT(ec_i)$, l'effet transitoire sur la chaîne fonctionnelle.
 - o $EfF(ec_i)$, l'effet final sur la chaîne fonctionnelle.
 - o $PCd(ec_i)$, la pré-condition à respecter avant le lancement de l'opération pour que l'effet transitoire sur la chaîne fonctionnelle soit réalisé.
 - o $Cd(ec_i)$, la condition à respecter pendant l'exécution de l'opération pour que

- l'effet final sur la chaîne fonctionnelle soit réalisé.
- o $PCt(ec_i)$, la pré-contrainte à respecter sur l'état du flux de produits et des chaînes fonctionnelles avant le début de l'opération pour que l'effet transitoire sur la chaîne fonctionnelle.
 - o $Ct(ec_i)$, la contrainte à respecter durant l'exécution de l'opération.
 - o $IC(EfT(ec_i))$, l'indice de confiance associé à l'effet transitoire sur la chaîne fonctionnelle.
 - o $IC(EfF(ec_i))$, l'indice de confiance associé à l'effet final sur la chaîne fonctionnelle.
- $ea(i, j); j \in [1, N_i]$, les évolutions associées du flux de produits, pour une opération Oa_i avec N_i évolution possible du flux de produits. Chaque évolution $ea(i, j)$ se compose de :
- o $EfT(ec(i, j))$, l'effet transitoire sur le flux de produits.
 - o $EfF(ec(i, j))$, l'effet final sur le flux de produits.
 - o $PCd(ec(i, j))$, la pré-condition à respecter avant le lancement de l'opération pour que l'effet transitoire $EfT(ec(i, j))$ soit réalisé.
 - o $Cd(ec(i, j))$, la condition à respecter pendant l'exécution de l'opération pour que l'effet final $EfF(ec(i, j))$ soit réalisé.
 - o $PCt(ec(i, j))$, la pré-contrainte à respecter sur l'état du flux de produits et des chaînes fonctionnelles avant le début de l'opération si la pré-condition $PCd(ec(i, j))$.
 - o $Ct(ec_i)$, la contrainte à respecter durant toute exécution $ea(i, j)$.

A titre d'exemple, nous proposons au lecteur une telle fiche modélisant le service de sortie du vérin V1 (cf. Figure 2.6).

3.2 Prise en compte de l'observabilité pour le diagnostic

Afin de prendre en compte le niveau d'observabilité au sein des chaînes d'actions, (Deschamps, 2007) a proposé d'étendre encore la modélisation d'opérations avec la prise en compte d'un Indice de confiance (IC) :

- *L'indice de confiance IC (effet sur chaîne fonctionnelle) est égal à une valeur 1 s'il y a correspondance entre l'évolution observée de la variable d'état de la chaîne fonctionnelle et une connaissance de son comportement, 0 sinon.*
- *Si l'indice de confiance IC (effet sur chaîne fonctionnelle) est égal à 1, le diagnostic qualifiera de correcte la valeur donnée à la variable d'état correspondante, et ne la remettra pas en cause dans son analyse future.*

Cet IC est défini ici statique en considérant que la structure d'une chaîne fonctionnelle n'évolue pas au cours du temps. Il est donc considéré comme faisant partie des caractéristiques intrinsèques des services modélisés (cf. Figure 2.7).

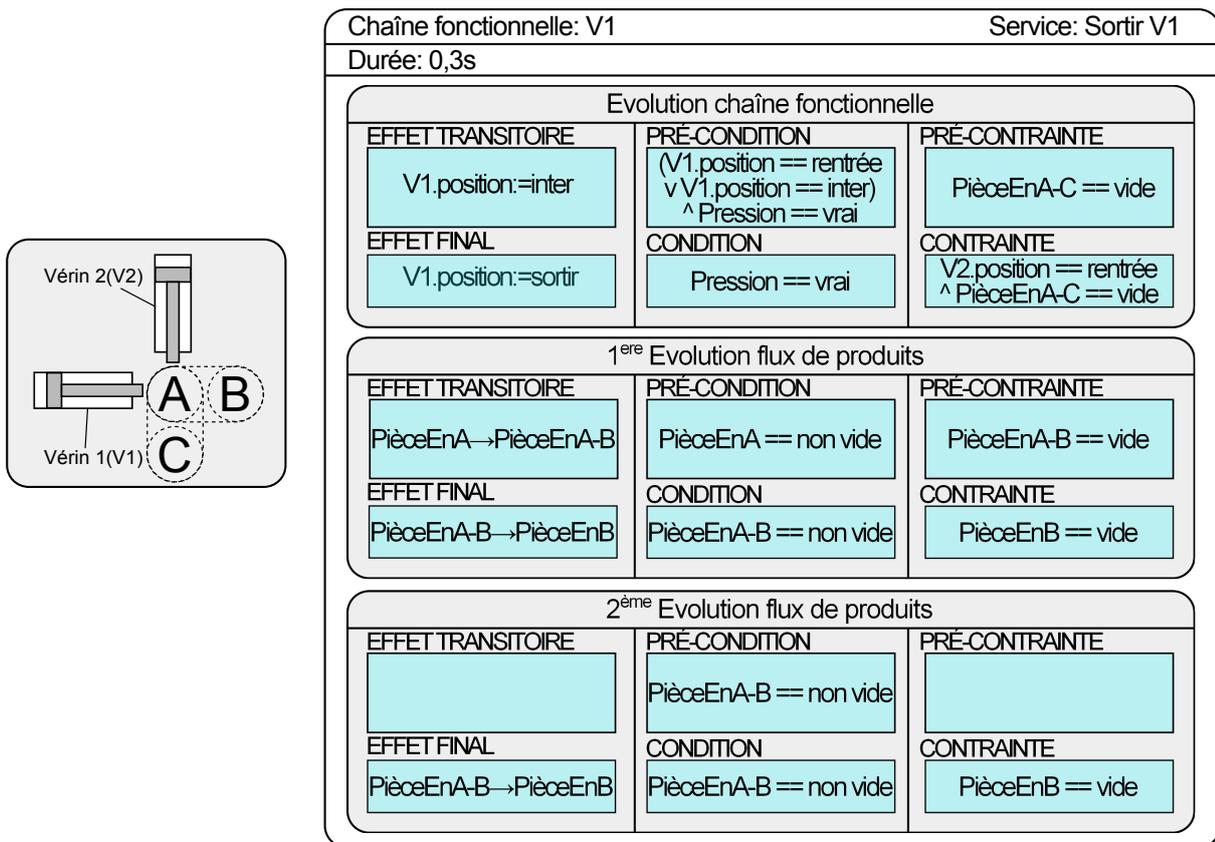


FIGURE 2.6 – Description du service sortir V1

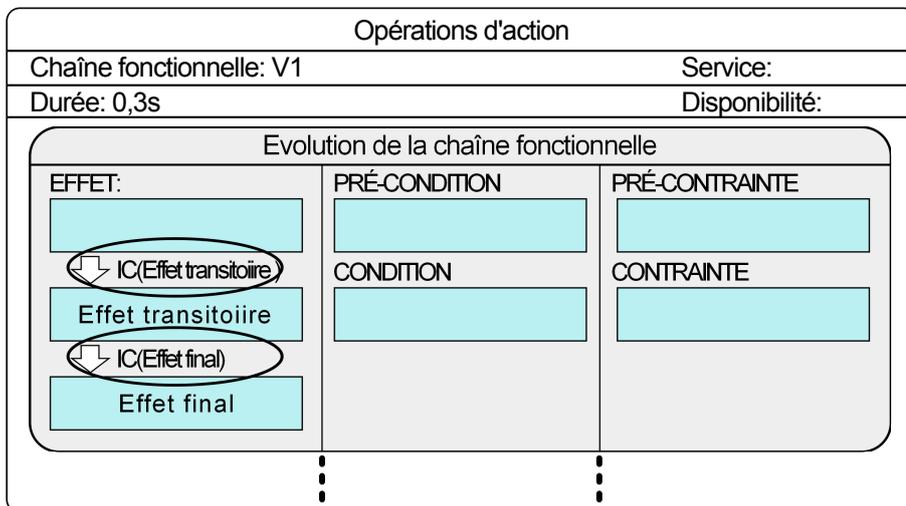


FIGURE 2.7 – Description d’une opération d’action avec l’indice de confiance

3.3 Modèle pour le diagnostic

Fort de cette modélisation des services offerts par les chaînes fonctionnelles, l’auteur (Deschamps, 2007) a proposé une génération dynamique d’un modèle relatant l’historique des opérations exécutées en les liant entre elles via leurs variables d’états :

les effets résultants d'une opération devenant les pré-contraintes et/ou pré-conditions des suivantes (cf. Figure 2.7).

L'indice de confiance est utilisé ici pour réduire le modèle. S'il vaut 1 l'effet résultant de l'opération est considéré comme certain et l'opération est "effacée" du modèle, ainsi que celles précédentes. Suite à l'application de ce mécanisme certes un peu exclusif, les opérations restantes sont considérées comme potentiellement suspectes si une défaillance venait à être par la suite détectée.

D'un point de vue localisation, un processus de propagation arrière de contrainte est utilisé tel que représenté dans la figure 2.8. Ici, en présence d'un compte-rendu anormal issu d'un équipement de métrologie la suspicion est propagée sur toutes les variables d'états conditionnant l'exécution des opérations précédentes dans le modèle de diagnostic. Il est à noter que sans apport d'autres informations de contexte, ce mécanisme revient à considérer toute la branche partant de la dérive détectée jusqu'à la racine comme étant suspecte. Moins d'équipements de métrologie sont installés, plus l'espace des équipements de production à l'origine possible du défaut produit sera grand.

Aussi, nous nous proposons dans le cadre de ces travaux d'apporter notre contribution afin d'optimiser cette phase de diagnostic, en particulier, en réduisant ou enrichissant en information l'espace de recherche des candidats potentiels à l'origine du défaut détecté. Ceci est un enjeu majeur auquel il faut répondre afin notamment d'optimiser les maintenances correctives en atelier : localiser juste, rapidement et efficacement pour optimiser les interventions.

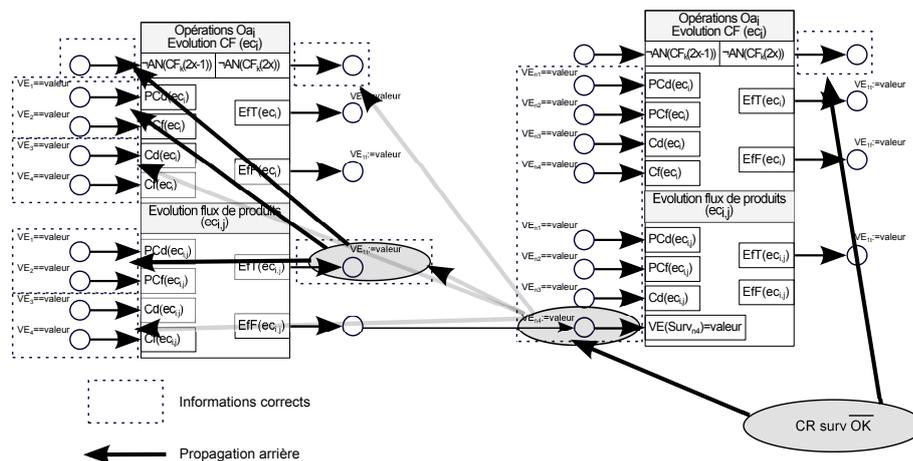


FIGURE 2.8 – Propagation arrière de la confiance accordée aux comptes-rendus

4 Approche proposée

Dans le cadre de ces travaux, notre contribution porte sur une amélioration du processus de diagnostic proposé dans le cadre de la thèse de (Deschamps, 2007). Elle

se focalise en particulier sur la notion d'indice de confiance pour lequel nous levons l'hypothèse forte faite à savoir qu'il est statique et dépend que de la structure même des chaîne fonctionnelles considérées. Comme nous le découvrirons par la suite, ce dernier présente des caractéristiques tant contextuelles que dynamiques qui requièrent un calcul en ligne permanent. Aussi notre apport se présente sous quatre formes distinctes :

- Une proposition de modification structurelle de l'approche globale développée au sein de l'équipe GSCP.
- Une proposition de modélisation probabiliste de l'indice de confiance.
- Des propositions d'algorithmes de calcul dynamique permettant, sur la base des modèles proposés, d'affiner la valeur de cet indice entre 0 et 1.
- L'intégration de ces contributions au sein de la démarche de localisation d'équipements à l'origine du défaut détecté développée dans la thèse de Deschamps (2007).

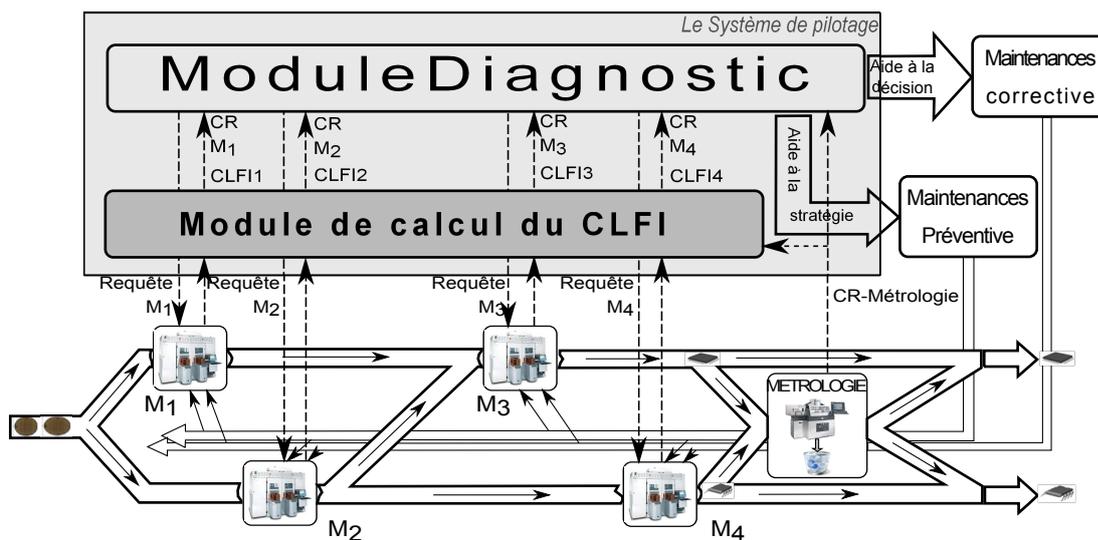


FIGURE 2.9 – Démarche de l'approche proposée

La figure 2.9 résume notre contribution, clairement localisée au sein d'un nouveau module de calcul du niveau de confiance associé aux comptes-rendus d'exécution (CLFI⁷).

Hypothèses de travail : nous considérerons dans la suite de cette étude que les équipements de métrologie sont exempts de défaillances et que par conséquent leurs résultats sont toujours justes.

7. Confidence Level of Feedback Information

5 Conclusion

Dans le cadre de ce chapitre, nous nous sommes attachés à préciser la problématique. Il s'agit de la problématique du traitement des aléas de fonctionnement au niveau coordination caractérisant un phénomène de propagation de défaillance. Parmi les approches relevant de cette problématique, nous nous sommes proposés d'étendre celle proposée par le passé au sein de notre équipe de recherche, à savoir celle proposée dans le cadre de la thèse de M. Eric Deschamps. Après avoir présenté les avantages de cette approche ainsi que ses fondements théoriques, nous avons mis en exergue une limite principale liée à une hypothèse forte posée : la confiance accordée aux comptes rendus émis par les équipements de production est statique. Comme nous le verrons par la suite, cette confiance évolue en fonction de nombreux paramètres importants, paramètres qui doivent donc être pris en compte afin d'améliorer l'étape de localisation des machines à l'origine possible de la propagation de défaillance. Notre ambition ici est donc clairement positionnée dans une extension de cette approche afin de participer à une meilleure aide à la localisation et de contribuer à l'optimisation des interventions de type maintenance corrective.

Les paramètres en jeu dans cette problématique présentant des caractères complexes, incertains et dynamiques, le chapitre suivant se propose de présenter un état de l'art général des méthodes et modèles probabilistes à partir desquels nous proposerons une solution au problème posé.

Chapitre 3

Modèles probabilistes

1 Introduction

L'approche proposée visant à contribuer à une estimation dynamique de la confiance qui peut être accordée à un compte de rendu émis par un équipement de fabrication suite à l'exécution d'un service demandé par le niveau coordination. Nous nous proposons dans ce chapitre de donner les bases des approches probabilistes que nous avons retenues pour nos développements et propositions.

Aussi, les sections suivantes se proposent de plonger progressivement au cœur des approches probabilistes pour converger vers celle retenue dans le cadre de ce mémoire : une approche Bayésienne.

2 Théorie des probabilités

La théorie des probabilités permet de modéliser des phénomènes caractérisés par le hasard et l'incertitude (par exemple pour la classification (Ramoni et Sebastiani, 2001; Friedman et al., 1997), la prédiction (Martínez et Sucar, 2008; Palacios-Alonso et al., 2010; Avilés-Arriaga et al., 2011), l'estimation (Dempster et al., 1977), etc.). Les méthodes issues de la théorie des probabilités s'appliquent également à la description de systèmes complexes dont nous ne connaissons qu'en partie l'état, comme en mécanique statistique.

2.1 Définitions et propriétés

La théorie des probabilités sert à modéliser des situations dont notre connaissance est imparfaite. Le manque d'informations est alors représenté par une composante aléatoire.

Définition 1. *Un espace probabilisé discret est caractérisé par trois ingrédients :*

- *Un univers Ω : c'est l'ensemble des événements élémentaires de l'expérience, supposés ici discrets (finis ou dénombrables).*

- Un ensemble d'événements (ou événements composés) Z : tout événement $A \in F$ est un sous-ensemble de Ω ($A \subset \Omega$).
- Une distribution de probabilités $p : \Omega \rightarrow [0, 1]$, satisfaisant

$$\sum_{\omega \in \Omega} p(\omega) = 1$$

$\forall \omega \in \Omega, p(\omega)$ est appelée la probabilité de l'événement élémentaire ω .

Propriété 1.

$$\forall A \in F, 0 \leq P(A) \leq 1.$$

$$P(\Omega) = 1; P(\emptyset) = 0.$$

$$\forall \{A_i, i \in N\}; P\left(\bigcup_{i \in N} A_i\right) \leq \sum_{i \in N} P(A_i).$$

$$\forall \{A_i, i \in N\} \text{ et } A_i \cap A_j = \emptyset; i \neq j \text{ alors } P\left(\bigcup_{i \in N} A_i\right) = \sum_{i \in N} P(A_i)$$

$$A \subset B; P(B) = P(A) + P(B \setminus A).$$

$$A \subset B; P(A) \leq P(B).$$

$$P(A \cup B) = P(A) + P(B) - P(A \cap B).$$

2.2 Probabilité conditionnelle

Définition 2. Soit A un événement arbitraire d'un ensemble fondamental Ω tel que $P(A) > 0$. La probabilité conditionnelle de A sachant que l'événement B s'est réalisé, s'écrit $P(A|B)$.

Définition des probabilités conditionnelles :

$$P(A|B) = \frac{P(A \cap B)}{P(B)} \quad (3.1)$$

Nous en déduisons ainsi :

$$P(A \cap B) = P(A|B) \times P(B) = P(B|A) \times P(A) \quad (3.2)$$

L'équation (3.2) peut se généraliser facilement. Soient A_1, \dots, A_n des événements quelconques d'un espace de probabilités ; à partir de l'équation (3.2), nous obtenons :

$$P(A_1 \cap A_2 \cap \dots \cap A_n) = P(A_1)P(A_2|A_1)P(A_3|(A_1 \cap A_2)) \dots P(A_n|(A_1 \cap A_2 \dots A_{n-1})) \quad (3.3)$$

3 Réseaux Bayésiens

Les Réseaux Bayésiens (en anglais : *Bayesian networks*; ou les réseaux de croyance : *Belief Networks*; les réseaux probabilistes : *Probabilistic Networks*) sont des graphes dont les nœuds définissent les variables du système et les arcs définissent l'existence de relations entre ces variables (Naïm et al., 2004). Ils combinent

la représentation des connaissances sous une forme graphique (relations de dépendance directe : cause \rightarrow effet \rightarrow défaillance) (Populaire, 2000).

Ils sont utilisés pour représenter les connaissances incertaines en intelligence artificielle (Korb et Nicholson, 2004) et pour faire des inférences statistiques afin d'actualiser les estimations d'une probabilité ou d'un paramètre quelconque, à partir des observations et des lois de probabilités de ces observations. Ils permettent de traiter des problèmes en mathématique appliquée ou en ingénierie : l'incertitude et la complexité (Jordan, 1999).

Les réseaux Bayésiens se représentent sous la forme d'un graphe orienté acyclique (en anglais : **D**irected **A**cyclic **G**raph, DAG) modélisant les dépendances entre un ensemble de variables aléatoires (Ben Gal, 2007). Un DAG permet de définir la probabilité conjointe de l'ensemble des variables du graphe, il combine des ensembles de nœuds et d'arcs. Les nœuds sont représentés par des variables et les arcs définissent des relations de dépendance entre les variables (les nœuds du graphe).

3.1 Définition

Définition 3. *Un réseau Bayésien (Naïm et al., 2004) est défini par :*

- *un graphe orienté sans circuit (DAG), $G = (V, E)$, où V est l'ensemble des nœuds de G , et E l'ensemble des arcs de G ;*
- *un espace probabilisé fini (Ω, Z, p) ;*
- *un ensemble de variables aléatoires associées aux nœuds du graphe et définies sur (Ω, Z, p) tel que :*

$$p(V_1, V_2, \dots, V_n) = \prod_{i=1}^n p(V_i | C(V_i)) \quad (3.4)$$

où $C(V_i)$ est l'ensemble des causes (nœuds parents) de V_i dans le graphe G .

3.2 Inférence Bayésienne

L'inférence permet de calculer des probabilités conditionnelles (probabilités a posteriori) d'événements reliés les uns aux autres par des relations de cause à effet.

Considérons un modèle, représenté par des paramètres B , dans lequel nous avons observé des échantillons A . Nous pouvons calculer la probabilité a posteriori de B sachant A .

En reprenant l'équation (3.2), nous obtenons la formule de Bayes :

$$P(B|A) = \frac{P(A|B) \times P(B)}{P(A)} \quad (3.5)$$

avec :

A : Observations

B : Paramètres

$P(A)$: Probabilité *a priori* de A.

$P(B)$: Probabilité *a priori* de B.

$P(B|A)$: Probabilité *a posteriori* de B sachant A.

$P(A|B)$: Fonction de vraisemblance des paramètres B (Probabilité conditionnelle de A étant donné B-*likelihood probability*)

Le théorème de Bayes permet d'inverser les probabilités, il peut être dérivé simplement en mettant à profit la symétrie de la règle de conjonction (équation 3.2).

Le théorème est une forme développée de cette formule que nous introduisons maintenant. Considérons des événements A_1, \dots, A_n tels qu'ils forment une partition de l'ensemble fondamental E . Par définition, les A_i s'excluent mutuellement et leur union est égale à E :

$$\forall (i \neq j), A_i \cap A_j = \emptyset; \bigcup_{i=1}^n A_i = E \quad (3.6)$$

Soit B un événement quelconque.

De $E = A_1 \cup A_2 \cup \dots \cup A_n$ et de $B \cap E = B$, nous pouvons en déduire $B = B \cap (A_1 \cup A_2 \cup \dots \cup A_n)$

Soit, par distributivité $B = (B \cap A_1) \cup (B \cap A_2) \cup \dots \cup (B \cap A_n)$

Ainsi, nous obtenons la formule dite des « probabilités totales » :

$$P(B) = P(B \cap A_1) + P(B \cap A_2) + \dots + P(B \cap A_n) \quad (3.7)$$

En appliquant le théorème de la multiplication, nous obtenons :

$$P(B) = P(B|A_1)P(A_1) + P(B|A_2)P(A_2) + \dots + P(B|A_n)P(A_n) \quad (3.8)$$

Or, par la forme simple du théorème de Bayes, nous avons :

$$P(A_i|B) = \frac{P(B|A_i)P(A_i)}{P(B)} \quad (3.9)$$

D'où le théorème de Bayes :

$$P(A_i|B) = \frac{P(B|A_i)P(A_i)}{P(B|A_1)P(A_1) + P(B|A_2)P(A_2) + \dots + P(B|A_n)P(A_n)} \quad (3.10)$$

3.3 Apprentissage d'un réseau Bayésien

L'apprentissage d'un réseau Bayésien vise à répondre aux deux principaux problèmes :

- Estimer les lois de probabilités conditionnelles à partir de données complètes ou incomplètes en supposant que la structure de ce réseau est déjà connue. Ce problème est appelé "apprentissage paramétrique".

- Trouver le meilleur graphe représentant la tâche du réseau Bayésien à partir de données complètes ou incomplètes. Nous parlerons d'apprentissage de la structure.

De nombreux travaux font référence dans ce domaine. De manière non exhaustive certaines de ces références sont présentées dans le tableau 3.1 :

Structure de RB	Observabilité (<i>données</i>)	Méthode d'apprentissage proposée	Descriptions
connue	complètes	Estimation du maximum de vraisemblance (Maximum-likelihood)	L'estimation statistique d'un événement dans la base de données. (Naïm et al., 2004; Buntine, 1996)
connue	incomplètes	Algorithme itératif EM (Expectation-Maximisation)	Recherche des paramètres en répétant jusqu'à la convergence les deux étapes suivantes : Espérance et Maximisation (Dempster et al., 1977)
inconnue	complètes	Recherche dans l'espace modèle	Utilisation de la méthode de recherche d'indépendances conditionnelles, de la méthode de recherche de structure à base de scores, de la méthode d'expérimentation, etc., (Olivier, 2006; Naïm et al., 2004; Alaeddini et Dogan, 2011)
inconnue	incomplètes	Algorithme itératif EM et recherche dans l'espace modèle	Utilisation de la fonction de scores avec données incomplètes, de la méthode à base de scores, de la méthode d'expérimentation, etc., (Olivier et Philippe, 2005; Olivier, 2006; Leray, 2006)

TABLE 3.1 – Apprentissage d'un réseau Bayésien

3.4 Réseaux Bayésiens naïfs

Un réseau Bayésien naïf est un modèle probabiliste utilisé souvent pour la classification. Le classificateur résultant se base sur le théorème de Bayes et permet de calculer les probabilités conditionnelles. Il s'agit d'une forme particulière de réseau

Bayésien qui permet de réduire sa complexité en introduisant l'hypothèse de l'indépendance conditionnelle (Ramoni et Sebastiani, 2001). Le classifieur Bayésien naïf suppose l'existence d'une caractéristique telle que l'appartenance à une classe est indépendante de l'existence d'autres caractéristiques, cela peut apporter de l'intérêt quand nous considérons un équipement de production avec différentes caractéristiques (eg. contexte de production, fiabilité des capteurs, type de produit, etc). Dans le cadre de notre étude, si nous connaissons certaines probabilités conditionnelles, alors comment pouvons-nous chercher les probabilités inconnues pour les données spécifiques ? Le modèle Bayes naïf (Cuiping et al., 2009; Jiangtao et al., 2009; Lowd et Domingos, 2005) donne de très bons résultats pour des problèmes de classification et de calcul de probabilité combinant des connaissances et ne nécessitant pas un grand nombre de données pour l'apprentissage ; il permet un calcul rapide (Ben Gal, 2007), ainsi qu'une bonne estimation même avec des données incomplètes (Ramoni et Sebastiani, 2001).

Si on note par $X = \{x_1, x_2, \dots, x_n\}$ l'ensemble des variables observées (attributs, caractéristiques) et C la variable de l'état du système (nœud ou classe), une approche à partir du modèle Bayésien naïf consiste à modéliser la distribution de probabilités conditionnelles $P(C|x_i)$.

La Figure 3.1 donne la structure d'un modèle Bayésien naïf.

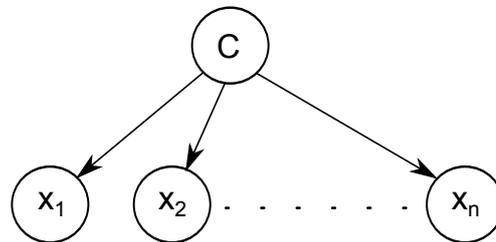


FIGURE 3.1 – Structure d'un modèle Bayésien naïf

Il se base sur la règle de Bayes qui s'énonce de la manière suivante :

$$P(C|x_1, \dots, x_n) = \frac{P(C) P(x_1, \dots, x_n|C)}{P(x_1, \dots, x_n)} \quad (3.11)$$

$P(C)$: Probabilité a priori de l'hypothèse C (en anglais : prior probability)

$P(X)$: Probabilité a priori des données X

$P(C|X)$: Probabilité de C étant donné X

$P(X|C)$: Probabilité de X étant donné C (en anglais : likelihood probability)

Pour calculer l'équation 3.11, nous nous intéressons seulement au numérateur, le dénominateur ne dépend pas de C et donc nous pouvons le considérer comme une constante dans l'équation 3.11. Le numérateur quant à lui peut s'écrire, en appliquant

plusieurs fois la probabilité conditionnelle (équation 3.2) de la façon suivante :

$$\begin{aligned}
 P(C, x_1, \dots, x_n) &= P(C) P(x_1, \dots, x_n | C) \\
 &= P(C) P(x_1 | C) P(x_2, \dots, x_n | C, x_1) = \\
 &= P(C) P(x_1 | C) P(x_2 | C, x_1) P(x_3, \dots, x_n | C, x_1, x_2) \\
 &\vdots \\
 &= P(C) P(x_1 | C) P(x_2 | C, x_1) P(x_3 | C, x_1, x_2) \dots P(x_n | C, x_1, \dots, x_{n-1})
 \end{aligned} \tag{3.12}$$

Nous faisons intervenir l'hypothèse naïve : si chaque x_i est indépendant des autres caractéristiques $x_{i \neq j}$, alors : $P(x_i | C, x_j) = P(x_i | C)$ pour tout $i \neq j$, par conséquent la probabilité conditionnelle peut s'écrire :

$$P(C, x_1, \dots, x_n) = P(C) P(x_1 | C) P(x_2 | C) P(x_3 | C) \dots = P(C) \prod_{i=1}^n P(x_i | C) \tag{3.13}$$

Nous poursuivons alors le calcul en développant la probabilité conditionnelle de la variable de classe C. L'équation 3.11 est donc proposée :

$$P(C | x_1, \dots, x_n) = \frac{P(C) \prod_{i=1}^n P(x_i | C)}{P(x_1, \dots, x_n)} \tag{3.14}$$

Si la variable C est observée dans les données d'apprentissage (x_1, x_2, \dots, x_n) , le modèle Bayésien peut être utilisé en calculant le maximum de $P(C | x_i)$. Si C n'est pas observable, on peut utiliser l'algorithme EM (Dempster et al., 1977) pour regrouper (*clustering*) les données en effectuant alternativement le calcul de l'espérance mathématique pour les données non-observables et le maximum de vraisemblance (*likelihood*).

Le modèle Bayésien naïf est très efficace pour le calcul de la probabilité de classer de nouveaux ensembles de données d'apprentissage dont la structure est facile à construire par un expert. Par ailleurs, il surpasse l'analyse d'un ensemble de classifieurs complexes sur un grand ensemble de données, notamment lorsque les caractéristiques ne sont pas fortement corrélées. Malheureusement, l'hypothèse de forte indépendance conditionnelle des attributs n'est pas toujours vérifiée en pratique.

3.5 Réseaux Bayésiens naïfs augmentés

Afin d'alléger l'hypothèse d'indépendance conditionnelle des attributs, il existe de nombreuses méthodes avancées pour étendre le réseau Bayésien naïf. Elles consistent à identifier les dépendances conditionnelles entre les attributs. L'augmentation de la structure naïve a été proposée par (Friedman et al., 1997) comme une extension naturelle du modèle Bayésien naïf. Dans cette structure, chaque attribut dépend au plus d'un autre attribut. (Pazzani, 1995) a proposé une amélioration des

classifieurs Bayésiens naïfs via les connections des paires de variables dans la même distribution conditionnelle. (Domingos et Pazzani, 1997) ont présenté une méthode avec une fonction de coût entre 0-1 qui permet de construire des classifieurs Bayésiens naïfs augmentés optimaux. Ainsi, nous obtenons la structure naïve augmentée par un arbre (en anglais : *Tree Augmented Naive Bayes (TAN)*) qui a été proposée par (Friedman et al., 1997). L'idée est d'imposer la restriction suivante : une classe n'a aucun parent et chaque nœud a comme parents la classe et un autre nœud au plus. (Olivier et Philippe, 2006) utilisent cette dernière extension dans le but d'apprendre efficacement un classifieur de Bayésien Naïf Augmenté par un arbre à partir de bases d'exemples incomplètes. Il existe plusieurs types d'implémentations différentes pour ces modèles. Nous pouvons nous référer, entre autres, à (Kelner et Lerner, 2012), à (Fagioli et Zaffalon, 1999) ou encore à (Corani et al., 2010).

Parmi ces méthodes, nous nous intéressons à l'approche de (Friedman et al., 1997) qui utilise une structure naïve reliant la classe aux caractéristiques et un arbre reliant toutes les caractéristiques. Dans ce cas, nous pouvons mettre en exergue sept caractéristiques qui sont adaptées à notre étude. Nous les présentons dans les chapitres suivants. L'exemple de la Figure 3.2 comprend les nœuds C, x_1, x_2, \dots, x_7 avec des arcs C et tous les nœuds enfants. Ces derniers sont dépendants des caractéristiques x_1, x_2, \dots, x_7 . Nous pouvons calculer $P(C|x_1, x_2, \dots, x_7)$ pour chaque caractéristique.

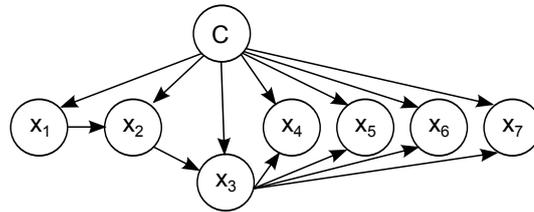


FIGURE 3.2 – Structure d'un réseau Bayésien naïf augmenté

En se basant sur l'approche présentée par (Friedman et al., 1997) et sur le modèle de la figure 3.2, nous pouvons réécrire la probabilité a posteriori comme suit :

$$P(C | x_1, x_2, x_3, x_4, x_5, x_6, x_7) = \frac{P(x_1, x_2, x_3, x_4, x_5, x_6, x_7 | C) \cdot P(C)}{\sum_j P(x_1, x_2, x_3, x_4, x_5, x_6, x_7, C = c_j)} \quad (3.15)$$

$$C = \{c_1, c_j, \dots, c_m\}$$

Où :

$$\begin{aligned} P(x_1, x_2, x_3, x_4, x_5, x_6, x_7 | C) &= \\ &= P(x_1 | C) \cdot P(x_2, x_3, x_4, x_5, x_6, x_7 | C, x_1) \\ &= P(x_1 | C) \cdot P(x_2 | C, x_1) \cdot P(x_3 | C, x_2) \cdot \\ &\quad P(x_4 | C, x_3) \cdot P(x_5 | C, x_3) \cdot P(x_6 | C, x_3) \cdot P(x_7 | C, x_3) \end{aligned} \quad (3.16)$$

Le modèle de base TAN donne de bons résultats en classification par rapport à l'approche Bayésienne naïve. Néanmoins, les réseaux Bayésiens (statiques) et les

modèles TAN ne prennent pas en compte l'aspect temporel lors de la modélisation, ils sont construits en combinant une connaissance préalable des experts et un ensemble de données observées. Dans la pratique, il existe des relations temporelles entre les variables. Une variable peut affecter un lien de causalité et d'autres seront leurs parents dans le réseau. La limitation de considérer une variable comme statique a poussé vers l'étude de méthodologies qui peuvent améliorer les performances des modèles par réseaux Bayésiens. Ainsi, l'aspect temporel spécifie le sens de la causalité et joue un rôle important dans la conception d'un réseau Bayésien dynamique.

Dans notre étude, nous considérons des paramètres importants qui ont un impact direct sur la valeur de la confiance telles que la fiabilité des systèmes de mesure, le contexte de production, les activités de maintenance, le type de produits, les historiques de métrologie, etc.. Ces facteurs représentent les nœuds du réseau Bayésien.

4 Théorie de Dempster-Shafer

La théorie de l'évidence ou théorie des fonctions de croyance a été initiée par (Dempster, 1967) sur les bornes inférieures et supérieures d'une famille de distributions de probabilités et puis complétée par (Shafer, 1976). Ce dernier a proposé un modèle mathématique de croyance connu sous le nom de la théorie des fonctions de croyance pour la modélisation de connaissances incertaines. Il permet de manipuler des degrés de confiance (ou masse de croyance) associés à la validité d'une information (Tacnet et al., 2010; Pearl, 1990). Cette théorie est basée sur un modèle d'inférence statistique qui généralise l'inférence Bayésienne. Plusieurs approches distinctes de la théorie de croyance ont été proposées : (Simon et al., 2007, 2008) proposent un réseau de fonctions de croyance pour l'étude de la fiabilité des systèmes s'appuyant sur les algorithmes d'inférence des réseaux Bayésiens. (Denoeux et Govaert, 1996) proposent une approche basée sur les procédures supervisées et non supervisées en s'appuyant sur la théorie de Dempster-Shafer pour le diagnostic des systèmes. (Smets et Kennes, 1994) proposent un modèle des croyances transférables. (Sallak, 2007) a montré une évaluation de paramètres de sûreté de fonctionnement en présence d'incertitudes et aide à la conception, etc.. Permettez-nous maintenant de détailler cette théorie.

4.1 Principes fondamentaux

Supposons $\Omega = \{H_1, H_2, \dots, H_N\}$ un ensemble de N hypothèses exhaustives et mutuellement exclusives. L'ensemble des parties (les hypothèses A_i) de Ω est noté 2^Ω . La théorie de l'évidence est alors caractérisée par une fonction appelée fonction de masse (en anglais : *basic probability assignment (bpa) ou mass function*) :

$$m : 2^\Omega \rightarrow [0, 1] \quad (3.17)$$

et vérifie les propriétés suivantes :

$$m(\emptyset) = 0 \quad (3.18)$$

$$\sum_{2^\Omega} m(A_i) = 1 \quad (3.19)$$

Les éléments A_i si $m(A_i) \neq 0$ sont appelés les éléments focaux. Leurs valeurs expriment le degré de l'évidence associée à l'ensemble A_i . Cette fonction se différencie d'une probabilité par le fait que la totalité de la masse de croyance est répartie non seulement sur les hypothèses singletons, mais aussi sur les hypothèses combinées. La modélisation issue de cette fonction est appelée jeu de la masse (Lefevre et al., 2004). A partir de la fonction, nous définissons respectivement les fonctions de croyance (fonctions de crédibilité, en anglais : belief function) et de plausibilité (en anglais : plausibility function).

La **fonction de croyance** $Bel(A)$ (croyance que la vérité est dans A) est par conséquent la somme des masses des propositions incluses dans A . Elle est définie comme la somme de toutes les masses de croyances des sous-ensembles B contribuant à A_i tel que $B \subseteq A_i$:

$$Bel(A_i) = \sum_{B \subseteq A_i} m(B) \quad (3.20)$$

La **fonction de plausibilité** $Pl(A)$ (la plausibilité que la vérité est dans A) est la somme des masses des propositions dont l'intersection avec A n'est pas nulle, elle est la somme de toute les masses de croyance des sous-ensembles B tel que $B \cap A_i \neq \emptyset$:

$$Pl(A_i) = \sum_{B \cap A_i \neq \emptyset} m(B) \quad (3.21)$$

À partir de la valeur des croyances et des plausibilités, la croyance peut être interprétée comme une mesure de vraisemblance minimale d'un événement et la plausibilité comme une mesure de vraisemblance maximale (croyance en l'événement ajoutée à l'incertain sur sa réalisation). Nous pouvons alors définir un intervalle de probabilité $[Bel(A_i), Pl(A_i)]$ qui contient la valeur précise de la probabilité d'événement par :

$$\forall A \subset \Omega : Bel(A_i) \leq P(A_i) \leq Pl(A_i) \quad (3.22)$$

4.2 Règle de combinaison de Dempster-Shafer

La théorie de Dempster-Shafer permet de combiner des informations issues de sources différentes, c'est une règle conjonctive normalisée fonctionnant sur l'ensemble 2^Ω . Elle produit une masse de croyance unique résultant de la combinaison de plusieurs fonctions de masse issues de sources d'informations distinctes (Lefevre et al., 2002). Cette règle peut s'énoncer comme suit :

La masse m_{\oplus} résultant de la combinaison de J sources d'information est notée :

$$m_{\oplus} = m_1 \oplus \dots \oplus m_j \oplus \dots m_J \quad (3.23)$$

où \oplus représente l'opérateur de combinaison (C), m_1 et m_2 deux jeux de masses associés aux fonctions de croyance Bel_1 et Bel_2 . Sur le même cadre de discernement, et A_1, A_2, \dots, A_l les éléments focaux de Bel_1 ainsi que B_1, B_2, \dots, B_n ceux de Bel_2 .

$$m_{\oplus}(C) = \frac{1}{1 - K} \sum_{A_i \cap B_j = C \neq \emptyset} m_1(A_i) \cdot m_2(B_j) \quad (3.24)$$

et où K représente la masse affectée à l'ensemble :

$$K = \sum_{A_i \cap B_j = \emptyset} m_1(A_i) \cdot m_2(B_j) \quad (3.25)$$

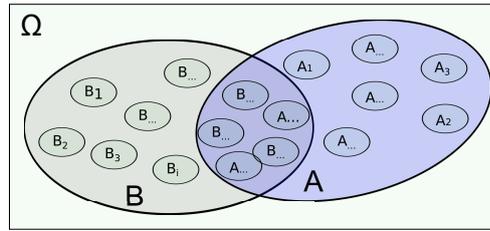


FIGURE 3.3 – La règle de Combinaison de Dempster-Shafer

Afin d'appréhender au mieux cette méthode, nous proposons ici au lecteur un simple exemple d'application de cette théorie.

4.3 Aide au diagnostic

Supposons un SAP tel que montré dans la figure 3.4. Il est constitué de trois équipements de fabrication dont deux de transformation et un d'assemblage. Un équipement de métrologie permet de contrôler le produit fini. Supposons dans ce cas que la métrologie détecte une dérive produit. Comment pouvons-nous localiser le ou les équipements qui sont à l'origine du défaut sur la base de la théorie de Dempster-Shafer.

Un sondage réalisé auprès des opérateurs du système donne le résultat suivant :

- 60% défauts sont dus aux équipements : E_{q_1} et E_{q_2} .
- 40% défauts sont dus aux équipements : E_{q_2} et E_{q_3} .

En outre, une analyse statistique de la base de données historiques donne le résultat suivant :

- 70% des causes du défaut sont d'origine *Transformation*.
- 30% des causes du défaut sont d'origine *Assemblage*.

Nous proposons alors d'écrire les fonctions de masse suivantes :

$$m_1(\{E_{q_1}, E_{q_2}\}) = 0.6$$

$$m_1(\{E_{q_2}, E_{q_3}\}) = 0.4$$

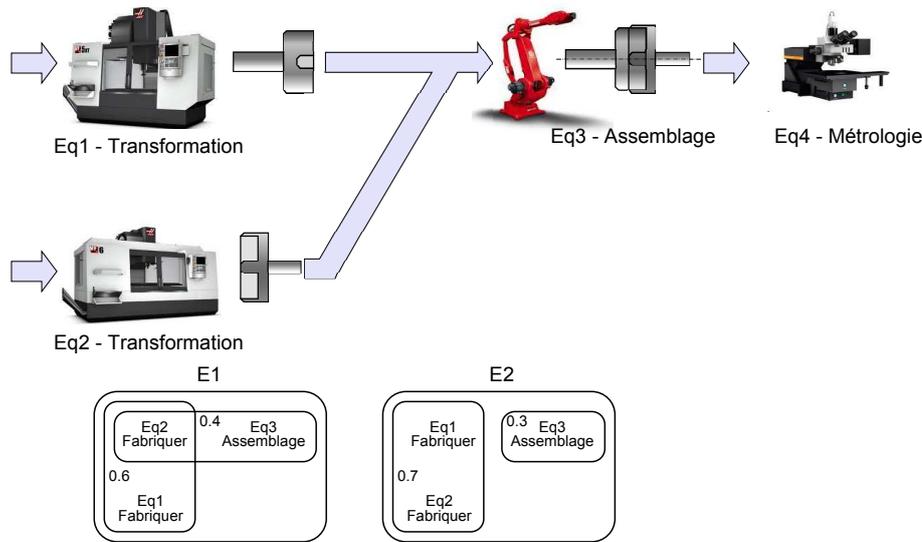


FIGURE 3.4 – Exemple pour appliquer la théorie de Dempster-Shafer

$$m_2(\{Eq_1, Eq_2\}) = 0.7$$

$$m_2(\{Eq_3\}) = 0.3$$

L'application de l'équation (3.25) de Dempster-Shafer donne alors le résultat suivant :

$$K = m_1(\{Eq_1, Eq_2\}) \cdot m_2(\{Eq_3\}) = 0.6 \cdot 0.3 = 0.18 \quad (3.26)$$

En utilisant la règle de combinaison issue de l'équation (3.24), nous obtenons :

$$m(\{Eq_1, Eq_2\}) = \frac{m_1(\{Eq_1, Eq_2\}) \cdot m_2(\{Eq_1, Eq_2\})}{1 - K} = \frac{0.6 \cdot 0.7}{1 - 0.18} = 0.512 \quad (3.27)$$

$$m(\{Eq_2\}) = \frac{m_1(\{Eq_2, Eq_3\}) \cdot m_2(\{Eq_1, Eq_2\})}{1 - K} = \frac{0.4 \cdot 0.7}{1 - 0.18} = 0.341 \quad (3.28)$$

$$m(\{Eq_3\}) = \frac{m_1(\{Eq_2, Eq_3\}) \cdot m_2(\{Eq_3\})}{1 - K} = \frac{0.4 \cdot 0.3}{1 - 0.18} = 0.146 \quad (3.29)$$

La crédibilité résultante peut alors s'écrire :

$$\begin{aligned} Bel(\{Eq_1\}) &= 0.512 \\ Bel(\{Eq_2\}) &= 0.341 + 0.512 = 0.853 \\ Bel(\{Eq_3\}) &= 0.146 \end{aligned} \quad (3.30)$$

A partir de ces résultats, nous pouvons estimer que l'équipement 2 est probablement à l'origine du défaut (avec 85,3%).

4.4 Discussion

Les avantages de la Théorie de Dempster-Shafer, ont été présentés par (Smets, 1994), qui a fourni une vue d'ensemble sur les applications, les méthodes et les approches par la présentation d'exemples spécifiques. Ces critères ont été proposés comme suit :

"The major discriminating criterion is : if there exists a probability measure with known values, use the Bayesian model, if there exists a probability measure but with some unknown values, use the ULP¹ models, if the existence of a probability measure is not known, use the TBM². Dempster's model is essentially a special case of ULP model, The EVM³ and the probability of modal propositions (provability, necessity, etc) corresponds to a special use of the Bayesian model".

Dans les problèmes que nous étudions, les paramètres sont issus de bases de données et à un certain moment nous recevons des rapports de l'équipement après la fin de l'opération. Par conséquent, notre problème correspond à l'utilisation du modèle par réseaux Bayésiens, les autres modèles de Dempster-Shafer n'étant pas vraiment appropriés dans ce cas.

De plus, l'approche utilisant la théorie de Dempster-Shafer est caractérisée par une complexité qui croît exponentiellement en fonction de la taille du problème. Si nous supposons un ensemble de N hypothèses exhaustives de Ω , il y aura jusqu'à $(2^N - 1)$ éléments focaux pour la fonction de masse. Aussi, pour la combinaison de deux fonctions de masse, le calcul peut aller jusqu'à 2^N intersections, ce qui augmente encore la complexité.

Dans ce cas, l'estimation des fonctions de masse et le choix de leur modélisation doivent être réalisées à partir d'une bonne connaissance des données. Une phase d'apprentissage est souvent indispensable (i.e. Martin (2005)). Donc, d'autres approches sont alors à envisager. Par exemple, la théorie des possibilités associée aux sous-ensembles flous et la théorie des croyances ont été introduits pour la représentation et le traitement de l'information imprécise et incertaine (Sallak, 2007). Dans l'approche de (Simon et Weber, 2006), les auteurs ont utilisé la théorie de Dempster-Shafer au sein d'un outil de réseaux Bayésiens pour traiter les problèmes d'incertitudes et d'imprécisions de la fiabilité des systèmes. Néanmoins, cette approche ne traite que l'incertitude épistémique de l'état du système en fonction de l'incertitude épistémique de l'état du composant, mais sans considérer d'autres facteurs liés au système tels que le contexte de production, le type de produits, les variations de la production et les spécifications du produit. Par conséquent, ceux-ci sont incompatibles avec le contexte et notre problème.

Comme nous avons pu le voir dans les sections précédentes, le temps n'est pas pris en compte dans les estimations de probabilités. Pourtant, il s'avère rapidement incontournable à prendre en compte dans les systèmes complexes où l'ordre temporel

1. Upper and Lower Probabilities
2. Transferable Belief Model
3. Evidentiary Value Model

de passage des produits sur les équipements joue un rôle important.

Pour cette raison, nous proposons au lecteur une présentation d'autres méthodes incluant quant à elles la composante temporelle. Ainsi les deux sections suivantes vont s'attacher à présenter les modèles de Markov et les réseaux Bayésiens dynamiques.

5 Chaîne de Markov

Lorsqu'il y a incertitude sur un événement futur, il est courant d'avoir recours aux modèles markoviens. Une chaîne de Markov est de manière générale un processus de Markov à temps discret ou un processus de Markov à temps discrets et à espace d'états discret. Elle décrit un système dont l'évolution ne dépend que de son état présent (pas de son histoire). Les processus de Markov portent le nom de leur découvreur, Andrei Andreyevich Markov (1856-1922) un mathématicien russe.

Les bases théoriques concernant les approches markoviennes dans les applications de diagnostic ont été proposées par (Camci et Chinnam, 2005), ou dans les recherches des propriétés des chaînes de Markov (Shamshad et al., 2005). Pour en savoir plus sur la chaîne de Markov, nous les présentons ici sur la base d'une analyse réalisée par (Stamp, 2012).

5.1 Les processus stochastiques

Un processus stochastique (ou processus aléatoire) est une famille $\{X_1, X_2, \dots, X_t, t \in I\}$ de variables aléatoires définies sur un même espace de probabilité (Ω, F, P) . Le processus est à temps discret. Si I est discret (e.g., $I = \{1, 2, 3, \dots\}$), la variable X_t représente l'état du processus au temps t (observation au temps t) et l'ensemble de toutes les valeurs possibles pour cette variable est appelée l'espace des états du processus et sera noté S .

Les différentes variables aléatoires ne sont en général pas indépendantes les unes des autres. Ce qui fait réellement l'intérêt des processus stochastiques est la dépendance entre les variables aléatoires.

Pour décrire entièrement un processus stochastique, il suffit de spécifier :

- la loi de probabilité $P(X_1 = x_j)$ de la première variable aléatoire x_j , qui spécifie donc l'état du processus lors de la première observation, e.g., l'état initial X_1 .
- pour toute valeur d'observation/état subséquent de $(X_{t+1} : t = 1, 2, \dots)$ la probabilité conditionnelle : $P(X_{t+1} = x_{t+1} | X_1 = x_1, \dots, X_t = x_t)$

5.2 Chaîne de Markov : Définitions et Propriétés

Définition 4. *Le processus stochastique $(X_n)_{n \geq 0}$ à valeurs dans Ω ensemble fini ou dénombrable est une chaîne de Markov si $\forall n \in \mathbb{N}, \forall x_0, \dots, x_n, y \in \Omega$, pour laquelle*

$P(X_{n+1} = y | X_0 = x_0, \dots, X_n = x_n) > 0$, nous avons :

$$P(X_{n+1} = y | X_0 = x_0, \dots, X_n = x_n) = P(X_{n+1} = y | X_n = x_n) \quad (3.31)$$

Cette définition est la propriété de Markov.

Dans un système de production, nous énonçons souvent cette propriété de manière informelle en disant que, pour une chaîne de Markov (où l'indice n est interprété comme un temps t), les états futurs du système ne dépendent de ses états passés que par l'intermédiaire de l'état présent.

Définition 5. Une chaîne de Markov est dite homogène si pour $\forall x > 1$ et $\forall x, y \in S$, nous avons :

$$P(X_n = x | X_{n-1} = y) = P(X_1 = x | X_0 = y) \quad (3.32)$$

Dans ce cas, nous voyons que l'évolution de la chaîne est caractérisée par la matrice $P = P(x, y)$ est appelée *probabilité de transition* de x à y sur $S \times S$ définie par :

$$P(x, y) = P(X_1 = x | X_0 = y)$$

Cette fonction P vérifie les propriétés suivantes :

- $\forall x \in S, \forall y \in S, 0 \leq P(x, y) \leq 1$
- $\forall x \in S, \sum_{\forall y \in S} P(x, y) = 1$

Propriété 2. Probabilités de transition en m étapes

La probabilité conditionnelle d'aller de i à j en m étapes exactement est :

$$p_{ij}^{(m)} = P(X_m = j | X_0 = i) = P(X_{n+m} = j | X_n = i); \forall n \geq 1$$

Cette probabilité est indépendante de n car le processus est homogène et est appelé la probabilité de transition en m étapes de i à j . La matrice $P^{(m)}$ dont l'élément $(i; j)$ est égal à $p_{xy}^{(m)}$ est appelée la *matrice de transition* en m étapes. Cette matrice $P^{(m)}$ a la propriété suivante :

$$P^{(m)} = \begin{bmatrix} p_{11} & \dots & p_{1m} \\ \dots & \dots & \dots \\ p_{m1} & \dots & p_{mm} \end{bmatrix}; p_{ij} \geq 0; \sum_{j=1}^m p_{ij} = 1, i = 1, \dots, m$$

Un processus de Markov peut ainsi être représenté par un automate fini :

- Chaque état du processus est représenté par un état de l'automate
- Une transition de l'état i à l'état j est étiqueté par la probabilité p_{ij} .

Propriété 3. Distribution initiale

La distribution des états d'une chaîne de Markov après n transitions est notée $\pi^{(n)}$. Cette distribution est un vecteur de probabilités contenant la loi de la variable aléatoire X_n :

$$\pi_i^{(n)} = P(X_n = i); \forall i \in S \quad (3.33)$$

La distribution initiale est $\pi^{(0)}$. Si l'état initial est connu avec certitude et est égal à i , nous avons :

$$\pi_i^{(0)} = \begin{cases} 1 & i = j \\ 0 & i \neq j \end{cases}$$

Propriété 4. Soit P la matrice de transition d'une chaîne de Markov $\pi^{(0)}$ et la distribution de son état initial. Pour tout $n > 1$, nous avons :

$$\pi^{(n)} = \pi^{(n-1)}P; \pi^{(n)} = \pi^{(0)}P^n \quad (3.34)$$

5.3 Modèles de Markov

Le modèle de Markov permet de traiter les problèmes avec informations incertaines ou incomplètes déclinables selon deux représentations : Observable ou Caché.

5.3.1 Modèle de Markov Observable

Nous distinguons le processus du système dépendant du temps (discret) $S = \{s_1, s_2, \dots, s_T\}$ qui représente l'évolution des états du Modèle de Markov et à chaque pas de temps t nous connaissons l'état S_t . Une séquence d'observations $O = \{o_1, o_2, \dots, o_T\}$ correspond à la séquence d'états réels du système $S = \{s_1, s_2, \dots, s_T\}$

$$O = S = \{s_1, s_2, \dots, s_T\}$$

Un modèle λ est dit observable si les états sont directement observables. Il est caractérisé par une matrice de transition A et un vecteur d'initialisation Π :

$$\lambda = \{\Pi, A\} \quad (3.35)$$

La probabilité d'obtenir une certaine séquence d'observations est représentée par :

$$P(O = S|A, \Pi) = P(s_1) \prod_{t=2}^T P(s_t|s_{t-1}) = \pi_{s_1} a_{s_1 s_2} a_{s_2 s_3} \dots a_{s_{T-1} s_T} \quad (3.36)$$

où :

S_t : état de l'automate à l'instant t (observable).

$\Pi = (\pi_i)$: la table de probabilités de l'état initial de la CM.

$A = (a_{ij})$: matrice $N \times N$ des probabilités de transition de la CM.

T : la taille d'une séquence d'observations.

Exemple : Considérons un processus à deux étapes et un espace des états $S = \{0, 1\}$. Dessinons alors 2 états symbolisant : 0 = l'état du système n'est pas bon, 1 = l'état du système est bon. La probabilité initiale de 0 est δ . Lorsque le système est dans l'état 0, il se déplace vers l'état 1 avec la probabilité α (et reste dans le même état 0 avec la probabilité $(1 - \alpha)$). Quand le système est dans l'état 1, il reste dans le même état avec la probabilité $(1 - \beta)$ (et se déplace vers l'état 0 avec la probabilité β). Un graphe probabiliste représente la chaîne de Markov correspondante et est illustré dans la figure 3.5. La somme des probabilités des flèches partant d'un point doit être égale à 1.

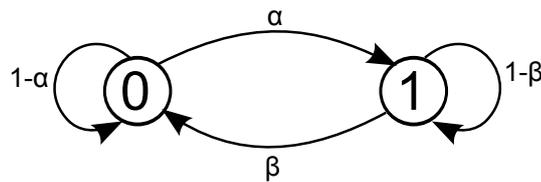


FIGURE 3.5 – Chaîne de Markov à deux états

Les probabilités conditionnelles s'écrivent selon la matrice de transition suivante :

$$P = \begin{pmatrix} P(X_t = 0|X_{t-1} = 0) = 1 - \alpha & P(X_t = 1|X_{t-1} = 0) = \alpha \\ P(X_t = 0|X_{t-1} = 1) = \beta & P(X_t = 1|X_{t-1} = 1) = 1 - \beta \end{pmatrix}$$

Nous pouvons alors représenter le modèle du système en tant que Modèle de Markov observable :

– $S = \{0, 1\}$

– Probabilités initiales : $\pi_{s_0} = \delta$; $\pi_{s_1} = 1 - \delta$

– Probabilités de transitions : $A = P = \begin{bmatrix} 1 - \alpha & \alpha \\ \beta & 1 - \beta \end{bmatrix}$

Probabilité d'observer la séquence $O = \{s_0, s_0, s_1, s_1\}$:

$$\begin{aligned} P(O|A, \Pi) &= P(s_0)P(s_0|s_0)P(s_0|s_1)P(s_1|s_1) \\ &= \pi_{s_0} a_{s_0 s_0} a_{s_0 s_1} a_{s_1 s_1} = \delta \cdot (1 - \alpha) \cdot \alpha \cdot (1 - \beta) \end{aligned}$$

5.3.2 Modèle de Markov Caché

Dans ce paragraphe nous présentons les principes fondamentaux du Modèle de Markov Caché (MMC). Il s'appuie sur le tutorial de (Blunsom, 2004) et (Stamp, 2012), complété par les travaux de (Ghahramani, 2001; Cho et Fadali, 2006).

Un Modèle de Markov Caché (MMC) ou HMM (en anglais : Hidden Model Markov) est un processus doublement stochastique dont une composante est une chaîne de Markov non observable. Ce processus peut être observé au travers d'un autre ensemble de processus qui produisent une suite d'observations. C'est un modèle qui décrit les états d'un processus markovien à l'aide des probabilités de transition et des probabilités d'observation d'états.

Nous distinguons le processus du système dépendant du temps (discret) $S = \{s_1, s_2, \dots, s_T\}$ qui représente l'évolution des états du MMC et le processus $O = \{o_1, o_2, \dots, o_T\}$ qui représente la suite des symboles émis par le MMC. C'est un automate à N états distincts S_t

La figure 3.6 présente un exemple de modèle de Markov caché où :

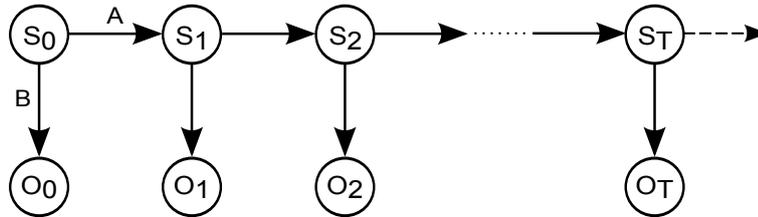


FIGURE 3.6 – Exemple d'un modèle de Markov caché

S_t : état de l'automate à l'instant t (non observable).

M : le nombre de symboles observables.

N : le nombre d'états cachés.

$V = \{v_1, v_2, \dots, v_M\}$: l'ensemble des symboles observables.

$Q = \{q_1, q_2, \dots, q_N\}$: l'ensemble des états cachés.

$\Pi = (\pi_i)$: la table de probabilités de l'état initial.

$A = (a_{ij})$: matrice $N \times N$ des probabilités de transition.

$B = (b_i(v_k))$: matrice $N \times M$ des probabilités des observations.

T : la taille d'une séquence d'observations.

Un Modèle de Markov Caché est défini ainsi par :

$$\lambda = (A, B, \pi) \quad (3.37)$$

A est une matrice de transition ; elle utilise l'hypothèse de Markov du premier ordre tel que l'état courant ne dépend que de l'état précédent. Il est à noter que les probabilités de transition d'état sont indépendantes du temps :

$$A = [a_{ij}]; a_{ij} = P(q_t = s_j | q_{t-1} = s_i) \quad (3.38)$$

B est la matrice d'observation qui décrit la probabilité de l'état v_k par l'état q_i et indépendamment de t :

$$P(O_t | S_t, O_{t-1}) = P(O_t | S_t); t = 1, 2, \dots \quad (3.39)$$

$$B = [b_i(v_k)]; b_i(v_k) = P(o_t = v_k | q_t = s_i) \quad (3.40)$$

De manière générale les MMC visent à traiter trois problèmes fondamentaux.

Problème 1 : Définir les probabilités d'une séquence d'observations : étant donné la séquence d'observations $O_T = \{o_1, o_2, \dots, o_T\}$ et le modèle de paramètre $\lambda = (\Pi, A, B)$, comment calculer $P(O_T|\lambda)$?

Problème 2 : Choisir la séquence optimale d'états connaissant les observations : étant donné la séquence d'observations $O_T = \{o_1, o_2, \dots, o_T\}$, comment choisir la séquence optimale d'états sous-jacentes de Markov ?

$$S^* = \arg \max_S P(S|O_T, \lambda)$$

Problème 3 : Ajuster les paramètres λ : étant donné la séquence d'observations $O_T = \{o_1, o_2, \dots, o_T\}$, comment ajuster les paramètres $\lambda = (\Pi, A, B)$ afin de maximiser $P(O_T|\lambda)$?

$$\lambda^* = \arg \max_{\lambda} P(O_T|\lambda)$$

5.4 Discussion

Le modèle de Markov est un outil stochastique puissant. Cependant, ils ne sont pas totalement adaptés à nos attentes. En particulier, à un instant t , chaque composant observé o_t comprend un ensemble de l valeurs différentes $o_t = \{x_1^t, x_2^t, \dots, x_l^t\}$ (les paramètres du système : position de capteurs, fiabilité du système de mesure, contexte de production, etc.) (Murphy, 2002). En outre, les variables d'état du compte-rendu dans le système considéré sont observées, alors que les variables d'état du modèle MMC sont cachées.

Quelques études ont montré l'intérêt de combiner des Réseaux Bayésiens Dynamiques (RBD) avec une chaîne de Markov (Weber et Jouffe, 2003; Avilés-Arriaga et al., 2003; Rajapakse et Zhou, 2007) pour effectuer des tâches telles que le diagnostic, la surveillance, la prévision, ou encore la modélisation de la fiabilité des procédés de fabrication complexes. La combinaison du processus de Markov avec la méthode RBD est idéale pour le calcul de la fiabilité de systèmes complexes tels que les systèmes de fabrication de semi-conducteurs. Elle va être introduite dans la section suivante.

6 Réseaux Bayésiens Dynamiques

Ces dernières années, certaines approches de Réseaux Bayésiens Dynamiques (RBD), MMC et Réseaux Bayésien Naïf Dynamiques (RBND) ont été développées. Les RBD ont été proposés en 1989 par (Dean et Kanazawa, 1989). Il s'agit d'une extension des réseaux Bayésiens pour modéliser les distributions de probabilité dans le temps (Murphy, 2002). Ils peuvent être définis comme une répétition des réseaux classiques dans lesquels nous ajoutons une relation causale temporelle. Les RBD sont utilisés dans les applications qui ont pour cibles multiples l'incertitude de modélisation dans le

domaine dynamique relationnelle (Manfredotti, 2009). Ils généralisent les modèles de Markov cachés et les filtres de Kalman (Modèles KFMs) en représentant l'état caché et observé en termes de variables d'état qui peuvent avoir des interdépendances complexes (Ghahramani, 1998). En particulier, l'approche par (Avilés-Arriaga et al., 2003; Palacios-Alonso et al., 2010) a introduit les classificateurs Bayésiens naïfs dynamiques (RBND) dont la base est une structure de NBC. Celui-ci combine les avantages d'une structure simple et NBC algorithmes avec ceux d'un MMC, et la capacité de modéliser des processus complexes dynamiques. Un RBND décompose le nœud d'observation dans un ensemble d'attributs indépendants (Martínez et Sucar, 2008). Une méthode est développée pour apprendre automatiquement un RBND de données. Il s'agit de déterminer : le nombre d'états cachés, les attributs pertinents, la meilleure discrétisation et la structure du modèle. (Palacios-Alonso et al., 2010) propose un système de codage spécial pour les attributs du groupe des dépendances et de retirer celles qui sont pertinentes pour le modèle RBND. Les ressemblances et différences des RBND et MMC sont mises en évidence dans (Avilés-Arriaga et al., 2011). Le RBND résout de nombreux problèmes pour la reconnaissance vocale, le traitement d'images, etc., (Weber et Jouffe, 2003) présentent une méthodologie pour développer les réseaux Bayésiens dynamiques afin de formaliser de tels modèles dynamiques complexes. Ils proposent la modélisation de la fiabilité d'un composant au cours du temps grâce à un réseau Bayésien et la chaîne de Markov classique en temps discret permet de calculer la fiabilité d'un composant à un instant donné. Cette approche montre que RBD constitue un outil très puissant pour l'aide à la décision dans la maintenance.

6.1 Représentation de Réseaux Bayésiens Dynamiques

Les réseaux Bayésiens dynamiques (RBD)(Dynamic Bayesian Network) sont une extension temporelle des réseaux Bayésiens, ils représentent des connaissances incertaines sur des systèmes complexes. Ils sont basés sur une association entre la théorie des probabilités et la théorie des graphes afin de fournir des outils efficaces pour représenter une distribution de probabilités jointes sur un ensemble de variables aléatoires.

Définition 6. *Un réseau Bayésien dynamique (RBD) est caractérisé par la paire (B_1, B_{\rightarrow}) (Murphy, 2002), tel que :*

- B_1 est le réseau Bayésien définissant la distribution de probabilités initiale $P(S_1)$.
- B_{\rightarrow} est le réseau Bayésien associé à deux pas de temps (2-TBN : Two Time-slice temporal Bayesian Network) et définit la distribution de probabilités $P(S_t|S_{t-1})$ représentée par un graphe orienté acyclique (Figure 3.7). $P(S_t|S_{t-1})$ s'écrit sous la forme :

$$P(S_t | S_{t-1}) = \prod_{i=1}^N P(S_t^i | Pa(S_t^i)) \quad (3.41)$$

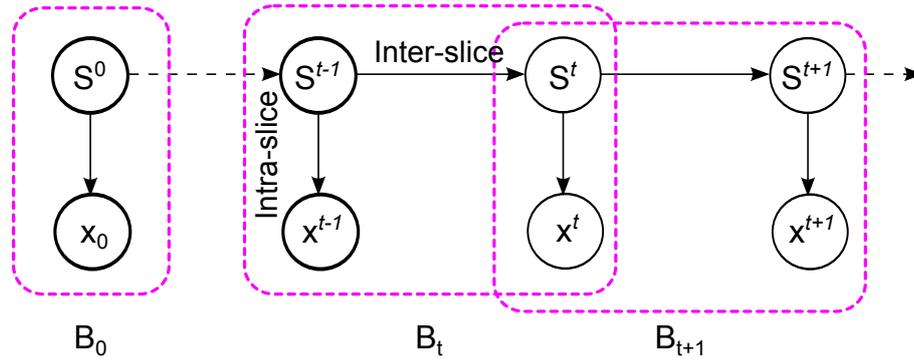


FIGURE 3.7 – Graphe d'un réseau Bayésien dynamique

- S_t^i est la i^{eme} composante aléatoire de S_t à l'instant t . Il peut s'agir d'un nœud caché, d'une observation ou d'un nœud de contrôle. Les relations entre les variables dans un intervalle donné sont représentées par des arcs *intra-slice* $S_t \rightarrow X_t$ (Figure 3.7).
- $Pa(S_t^i)$ représente les composantes aléatoires dont dépend S_t^i . Ils peuvent se situer soit à t ou $t-1$. Les relations entre les variables à pas de temps successifs sont représentées par $S_{t-1} \rightarrow S_t$ (Figure 3.7).
- Les nœuds de la première fenêtre temporelle d'un 2-TBN ne dispose pas des paramètres qui leur sont associés.

Définition 7. Un réseau Bayésien dynamique représente la distribution de probabilité jointe de ces variables par le déroulement du réseau Bayésien B_{\rightarrow} sur T séquences temporelles (Murphy, 2002). Il s'écrit :

$$P(S_0, \dots, S_T) = \prod_{t=1}^T \prod_{i=1}^N P(S_t^i | pa(S_t^i)) \quad (3.42)$$

Pour davantage de détails sur l'approche mathématique, les algorithmes d'inférences et l'apprentissage, nous invitons le lecteur à respectivement se reporter à (Ghahramani, 1998, 2001; Baghdadi et al., 2008).

Un réseau Bayésien dynamique peut être ainsi décrit comme un MMC qui est représenté sous forme graphique comme illustré dans la figure 3.7 dans laquelle un nœud représente l'état du système S_t et un autre pour l'observation X_t .

La différence entre un RBD et un MMC réside dans le fait que le RBD représente l'état caché S_t en terme d'ensemble de variables aléatoires, $X_t = \{x_1^t, x_2^t, \dots, x_l^t\}$ alors que dans un MMC, l'espace d'état S_t se compose d'une seule variable aléatoire $X_t = x_i$ (Murphy, 2002).

Dans notre étude, nous considérons que les systèmes présentent les caractéristiques spécifiques suivantes :

- le système dépend du temps (discret),
- à un certain moment, le système comporte des événements aléatoires (les paramètres du système),

- l'état réel du système ne dépend que des variables observées et de son état précédent.

Ces caractéristiques correspondent à celles d'un RBND tel que proposé par (Avilés-Arriaga et al., 2003; Martínez et Sucar, 2008; Palacios-Alonso et al., 2010; Avilés-Arriaga et al., 2011). Détaillons désormais le RBND.

6.2 Réseaux Bayésien Naïf Dynamiques

Un Réseau Bayésien Naïf Dynamiques (RBND) peut être considéré comme une extension d'un MMC ou un cas particulier de RBD. C'est familier comme un MMC dans lequel le nœud d'observation est décomposé en un certain nombre d'attributs qui sont considérés comme indépendants. Du point de vue RBD, à chaque fois qu'il y a un classifieur Bayésien naïf (structure de base), les variables d'état sont reliées entre elle d'une date à une autre (structure de transition). Un exemple de RBND est donné dans la figure 3.8 (Avilés-Arriaga et al., 2003; Martínez et Sucar, 2008; Palacios-Alonso et al., 2010; Avilés-Arriaga et al., 2011) :

Considérons un modèle avec les paramètres $X = \{X_1, X_2, \dots, X_t, \dots, X_T\}$, où chaque $X_t = \{X_t^1, X_t^2, \dots, X_t^j, \dots, X_t^n\}$ est un ensemble de n attributs observables qui sont générés par un processus dynamique, et où l'ensemble des instances de la variable d'état cachée (ou états) $S = \{S_1, S_2, \dots, S_t, \dots, S_T\}$ est généré par le même procédé, à chaque instant t .

Un modèle RBND est défini par la fonction de distribution de probabilité :

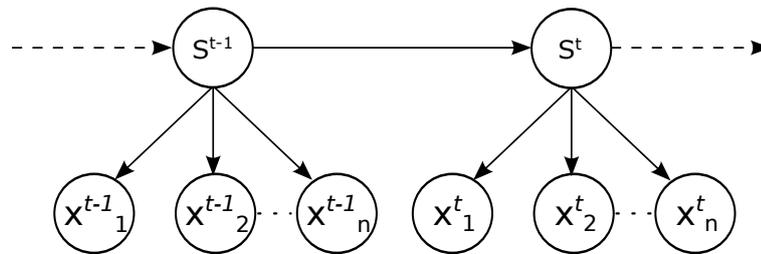


FIGURE 3.8 – Réseaux Bayésien Naïf Dynamiques avec n attributs

$$P(S_t, X_t) = P(S_1) \prod_{t=1}^T \prod_{j=1}^n P(X_t^j | S_t) \prod_{t=2}^T P(S_t | S_{t-1}) \quad (3.43)$$

Où :

$P(S_1)$ est la distribution de probabilité initiale pour la variable de classe S_1

$P(X_t^j | S_t)$ est la distribution de probabilité d'un attribut compte tenu de la variable d'état cachée dans le temps.

$P(S_t | S_{t-1})$ est la distribution de probabilité entre les états dans le temps.

L'élément $\prod_{j=1}^n P(X_j^t | S_t)$ dans l'équation (3.43) représente l'hypothèse d'indépendance conditionnelle des attributs compte tenu de la variable d'état cachée S_t dans le

temps t (cf. hypothèse naïveté présentée, dans la section 3.4). Ce modèle est représenté sur la base de deux suppositions :

- les états futurs du système ne dépendent de leurs états passés que par l'intermédiaire de l'état présent (cf. propriété de Markov, equation 3.31, page 53).
- les probabilités de transition entre les états ne sont pas dépendants du temps (cf. probabilité de transition, équation 3.34).

6.3 Positionnement

Les Réseaux Bayésiens Dynamiques sont une extension des modèles naïf et TAN au travers de la prise en compte du temps. Ils sont souvent utilisés pour estimer les états futurs et les paramètres ou une probabilité, (c'est-à-dire que l'on va chercher la probabilité : $P(S_t, X_t)$). Cependant, ce n'est pas le sujet traité dans cette thèse. Notre objectif est d'estimer la probabilité d'états lorsque les paramètres sont observés à l'heure l'actuelle, et à l'état précédent ce qui correspond à $P(S_t | X_t, S_{t-1})$. Par ailleurs, en termes d'approches, ainsi que des formes géométriques, le modèle RBDN est similaire à MMC. Néanmoins, les variables d'état du compte-rendu d'information dans le système considéré sont observées, alors que les variables d'état du modèle MMC sont cachées. Nous avons donc proposé d'utiliser un nouveau modèle (RBDCM) sur la base d'un RBD et d'une chaîne de Markov pour estimer la confiance du compte-rendu. Il est utilisé pour calculer la probabilité de l'état à l'instant t avec la connaissance de la probabilité de l'état à l'instant $t - 1$, et les paramètres courants, basés sur la structure représentée à la figure 3.9.

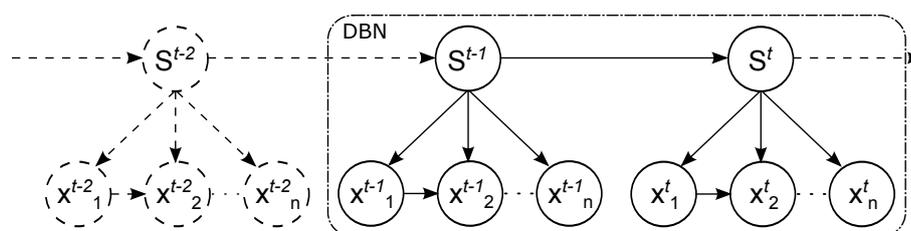


FIGURE 3.9 – Réseau Bayésien dynamique combiné avec une chaîne de Markov (RBDCM)

Cette approche est utilisée comme modèle de référence pour construire un nouveau modèle. L'implémentation de ce modèle pour l'estimation de confiance du compte-rendu sera présentée en détail dans le chapitre suivant.

7 Conclusion

Au sein de ce chapitre, nous avons mené une étude bibliographique centrée sur les besoins de notre approche, à savoir les approches probabilistes et en particulier les approches Bayésiennes. Au fur et à mesure de leur présentation, nous avons pris soin

de positionner ces différentes approches en faveur ou en défaveur de nos besoins. Cela s'est traduit par la mise en exergue de deux approches intéressantes, à savoir les réseaux Bayésiens dynamiques et les chaînes de Markov. Cependant, la combinaison de ces deux approches ne satisfaisant pas totalement nos besoins, nous avons proposé une extension de cette combinaison permettant ainsi de considérer une estimation d'une variable à un instant t sachant son état à l'instant $t - 1$ et un ensemble d'autres paramètres considérés eux aussi à l'instant t .

Sur cette base, le chapitre suivant se propose de corrélérer ce nouveau modèle avec le calcul de l'indice de confiance qui peut être accordé à un compte rendu d'exécution.

Deuxième partie

Modèle de la Confiance du compte-rendu

Chapitre 4

Confiance du compte-rendu

1 Introduction

La problématique et un état de l'art étant désormais présentés, nous nous proposons dans ce chapitre de dévoiler notre approche d'estimation de l'indice de confiance qui peut être accordé en temps réel à chaque occurrence de compte rendus d'exécution émis par un équipement de fabrication. Cependant, avant d'aller plus loin dans cette présentation, nous proposons au lecteur d'analyser dans les premières sections de ce chapitre les paramètres pris en compte dans le calcul de ce que nous appellerons désormais par souci de simplification le **CLFI** : *Confidence Level of Feedback Information*.

2 Définition

Préalablement à l'étude des éléments qui ont un impact sur la confiance qui peut être accordée ou non à un compte-rendu, permettez-nous de proposer une définition de ce concept de confiance.

Définition 8. *La confiance qui peut être accordée à un compte rendu d'exécution d'un équipement de production (CLFI) correspond à la capacité de l'équipement à avoir correctement réalisé le service demandé. Il sera caractérisé par une valeur comprise entre 0 et 1 témoignant donc d'un pourcentage de confiance qui pourra être utilisé à différentes fins comme le diagnostic, le pronostic ou encore l'aide à la décision à des fins d'optimisations des plans de maintenances préventives et ou correctives.*

La définition étant désormais posée, nous nous proposons dans ce qui suit de mener une analyse des paramètres ayant un impact potentiel sur ce concept de confiance du compte-rendu.

3 Analyse des paramètres ayant un impact sur CLFI

Préalablement à cette étude rappelons les constats qui nous ont amenés à proposer le concept de calcul de la confiance d'un compte-rendu : les niveaux d'observabilité liés au placement des capteurs au sein de la chaîne d'action font apparaître des boucles ouvertes impliquant naturellement des doutes quant à la bonne réalisation du ou des services demandés.

C'est ce que nous avons illustré dans la figure 4.1 dans laquelle apparaît le fait que malgré trois étapes de fabrication a priori achevées avec succès ($CR=OK$), le produit contrôlé par l'équipement de métrologie se révèle être non conforme aux attentes ($CR=Not\ Pass$).

Afin d'aider l'expert dans sa phase de localisation des défauts produits nous suggérons l'idée de lui donner accès à un ensemble de *sources* caractérisant en temps réel le niveau de confiance accordé à chaque compte-rendu d'exécution. Bien entendu, si ce *score* ou *niveau de confiance* du compte-rendu était uniquement calculé sur la base du niveau d'observabilité liée à la chaîne d'information, la proposition pouvait être remise en cause. Aussi, nous nous proposons d'intégrer d'autres paramètres à ce calcul, paramètres que nous dévoilons ci-après.

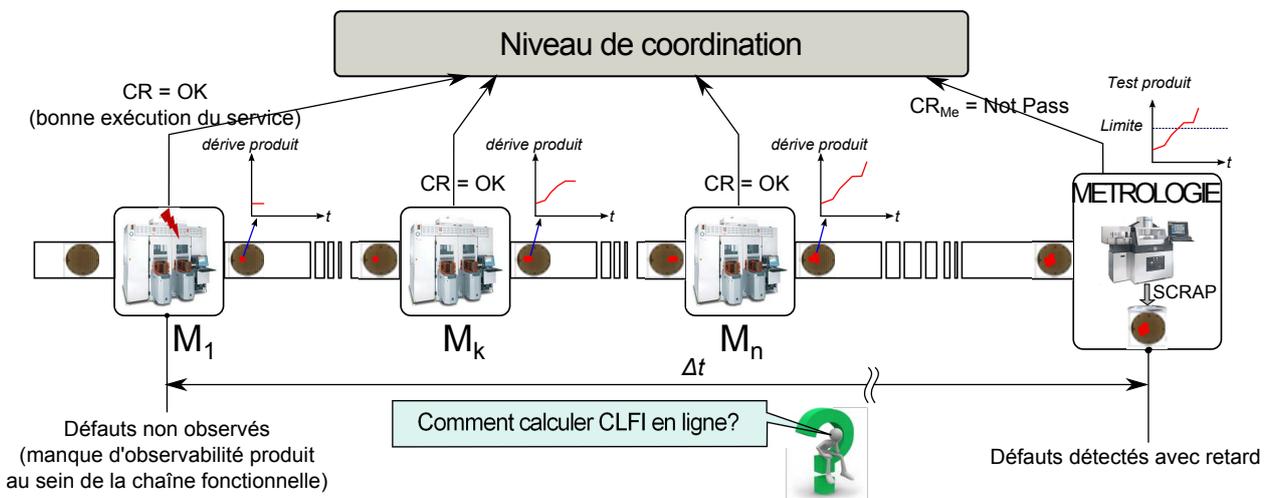


FIGURE 4.1 – La problématique du CLFI

Afin de conforter la prise en compte de paramètres requis pour le calcul du CLFI, nous avons profité d'un partenariat industriel développé dans le cadre du projet européen IMPROVE¹. Ce partenariat nous a permis d'avoir accès à un certain nombre de bases de données et d'expertises au sein du secteur du semi-conducteur, en particulier avec l'entreprise STMicroelectronics Crolles.

Ces données issues des bases de données telles que les FDC (détection et classification des défauts), les SPC (contrôles statistiques des procédés), ou encore les

1. Le projet Européen IMPROVE (*Implementing Manufacturing science solutions to increase equipment pROductiVity and fab pERformance*)

AMDEC (*Analyse des modes de défaillance, de leurs effets et de leur criticité*) nous ont permis de mener des analyses statiques.

Sur le plan métrologie, il s'est agi de corrélérer différentes bases avec les données historiques issues des équipements de métrologie (Bouaziz et al., 2011). Ainsi une base de données unique a été mise au point témoignant de la vie d'un équipement (Cf. Table 4.1). Pour des raisons de confidentialité, les données reprises dans ce mémoire sont simulées.

Equipment	Event	Start Time	End Date	Maint state name	Maint previous state	...
EQ01	FAILURE	9 :18 :12	10 :15 :03	REPAIR	FAIL	...
EQ01	MAINT	10 :58 :16	11 :21 :38	PM	IDLE	...
EQ01	PROD	18 :27 :19	19 :22 :46	NONE	NONE	...
...

TABLE 4.1 – Données de vie d'un équipement (FDC)

L'analyse Pareto s'appuie cependant sur les données réelles qui ont révélé des relations de causes à effets majeures sur les paramètres suivants :

- Fiabilité du système de captage (R).
- Contexte de production (C).
- Position des capteurs (P).
- Type de produit (TP).
- Résultat métrologie (Me).
- Maintenance préventive (PM).
- Maintenance corrective (CM).

Analysons les brièvement :

1. Pour deux types de produits subissant un traitement de production similaire, les taux de rejets au niveau métrologie peuvent être différents.
2. De l'étude des maintenances préventives sur les chaînes d'acquisition embarquées nous avons mis naturellement en exergue la problématique bien connue soulignée par Weibull (Dhillon, 2005) . La fiabilité de la chaîne d'information est donc à prendre en compte.
3. Le contexte de production caractérisé par des périodes de fortes production (stress), production normale ou fort taux de changement de recettes augmente de manière significative le nombre de rejets en métrologie, témoignant ici du manque de robustesse des équipements à supporter des changements de paramétrages fréquents. Le passage d'un produit A puis B sur une machine ne présente pas les mêmes taux de rejets que B puis A.
4. La fait que des maintenances préventives ou correctives ont été effectuées sur les équipements de production a un impact direct sur la qualité des produits fabriqués et contrôlés. Leur fréquence est aussi à prendre en compte.

Sept paramètres ont donc été mis en exergue pour ce type de process. Pour d'autres, la méthode d'analyse reprise de (Bouaziz et al., 2011) peut être naturellement appliquée en fonction des bases de données disponibles.

Nous nous proposons maintenant de détailler chacun de ces paramètres.

4 Spécificité des paramètres ayant un impact sur le CLFI

4.1 Fiabilité du système de capteurs (R)

La fiabilité de chaque capteur est définie comme une probabilité $r(t)$ qu'il soit sans faute pendant une période de temps t . De manière triviale, plus $r(t)$ est important, plus la CLFI sera importante, il sera calculé sous la forme suivante :

$$r(t) = 1 - \int_0^t f(t) dt \quad (4.1)$$

avec $f(t)$: la fonction de distribution des défauts.

Pour m capteurs appartenant à la chaîne d'acquisition considérée la fiabilité de cette dernière sera définie par :

$$R = f(r_1(t), r_2(t), \dots, r_m(t)) \quad (4.2)$$

Si nous considérons l'exemple donné figure 4.2, l'équation 4.3 en considérant les différentes classes (système en série, système en parallèle ou système en mixte) développées dans (Dhillon, 2005) donne :

$$R(t) = 1 - (1 - e^{-\lambda_1 t})(1 - e^{-\lambda_2 t})^2(1 - e^{-\lambda_4 t})^2 \quad (4.3)$$

Le problème qu'il faut désormais résoudre, c'est de corrélérer la fiabilité du système d'acquisition d'une chaîne fonctionnelle d'un équipement de production avec le CLFI.

Le lien n'étant pas direct, nous avons proposé ici de corrélérer le CLFI au travers des comptes-rendus d'exécution émis par l'équipement de production considéré.

Pour ce faire, nous nous sommes appuyés sur les données historiques issues de l'atelier et avons recherché à rapprocher $R(t)$ et les occurrences des compte-rendus *OK* ou *Not OK*.

Nous avons donc proposé ici de nous appuyer sur l'algorithme EM (D'Souza, 2002) pour déterminer la loi de distribution de probabilité de $R(t)$ via la détermination des paramètres de Gaussian Mixture comme τ_i, μ_i, σ_i :

$$f(x) = \sum_{i=1}^k \tau_i \frac{1}{\sigma_i \sqrt{2\pi}} e^{-\frac{(x-\mu_i)^2}{2\sigma_i^2}} \quad (4.4)$$

Où :

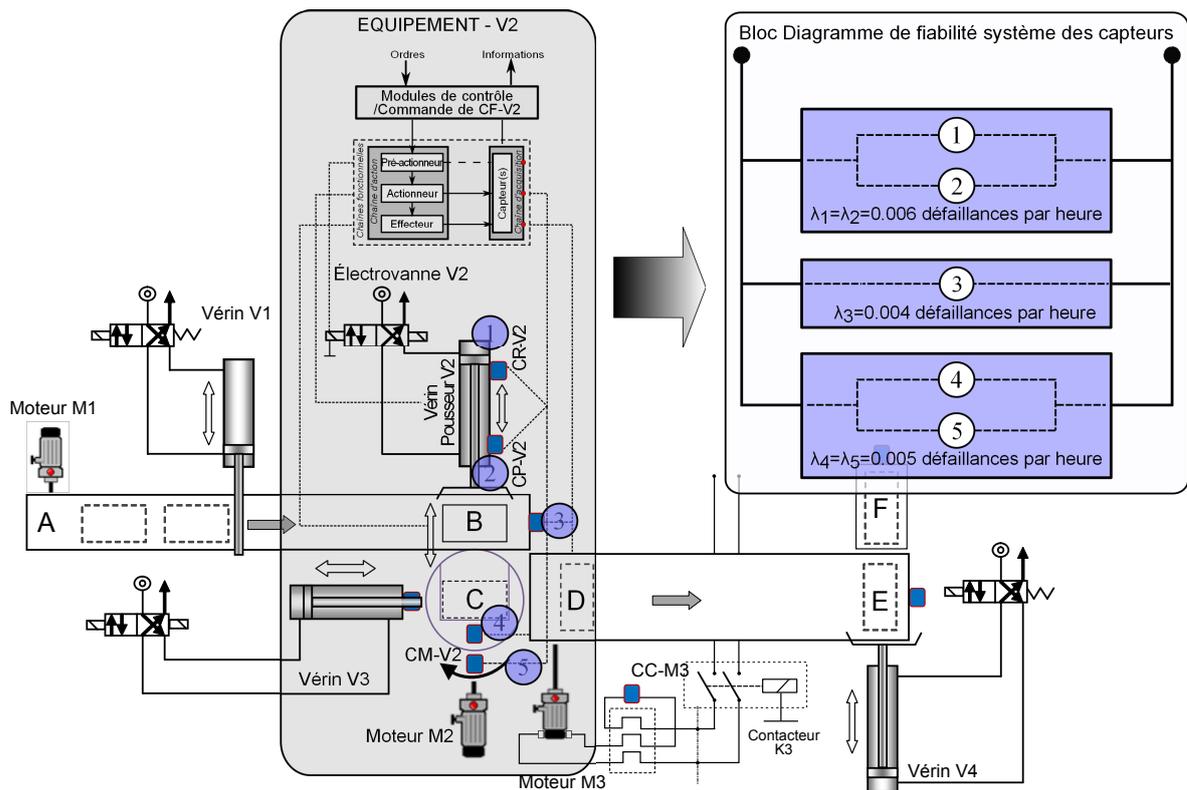


FIGURE 4.2 – La structure de système de mesure

- τ_i : Coefficients proportionnelles (ou poids) ; $(\sum_i^k \tau_i = 1)$.
- μ_i : Moyenne
- σ_i : Variance

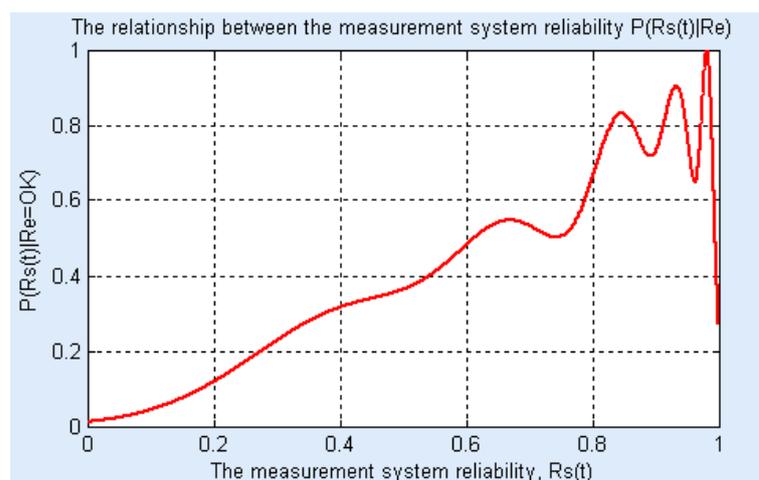


FIGURE 4.3 – La probabilité de $P(Rs|Re)$

Nous avons mis en œuvre cette loi de distribution sous Matlab (cf. Algorithme 2, page 94) pour lequel nous avons choisi le nombre de Gaussian égal à 5 pour assurer un compromis entre le temps de calcul et la précision des résultats. Ces derniers

sont représentés dans la figure 4.3 où l'abscisse représente la fiabilité du système et l'ordonnée représente la probabilité de $P(Rs|Re)$.

4.2 Position des capteurs (P) dans la chaîne d'acquisition

Comme nous l'avons déjà présenté précédemment le nombre et la position des capteurs au sein des chaînes fonctionnelles permet d'améliorer la perception de ce qui est réellement produit par un équipement.

Afin d'intégrer ce paramètre important dans le calcul du CLFI, nous avons proposé de répertorier l'ensemble des cas de figures qui peuvent être rencontrés au sein du tableaux 4.2. Un exemple est pris (cf. figure 4.4) afin de faciliter l'interprétation du tableaux au lecteur.

4.3 Contexte de production (C)

Sans grande surprise, l'analyse des historiques a montré que le stress (caractérisé ici par une augmentation du flux de production, ou encore de la diversité des produits) dégrade de manière significative le CLFI.

Aussi, avons-nous proposé de prendre en compte le contexte de production au travers de trois de ses états que sont (cf. Figure 4.5) :

N : La production normale (Normal production).

MP : La production de masse (Mass production) caractérise une production stressée par un flux de produit très important. Les équipements travaillent à charge maximale.

CR : Le changement de recettes de production (Change recipes) caractérise une production stressée par la diversité des produits à traiter et donc des changements de recettes fréquents augmentant les dérives non maîtrisée des équipements de production.

Notons cependant que d'autres contextes de production existent (cf. GEMMA (Mendez Auzua, 2002)) mais que l'analyse statistique menée sur le cas d'étude ne les a pas révélées comme étant d'autres points singuliers.

4.4 Type de produit (TP) et résultat de contrôle de la machine de métrologie pour chaque type de produit (Me)

L'analyse statistique a bien révélé un lien significatif entre les tests de métrologie et le type de produits contrôlés. Certains d'entre eux passent régulièrement les tests sans révéler de déviations importantes, ce qui n'est pas le cas de tous.

C'est ce que nous pouvons voir dans les tableaux 4.6 et 4.7 au sein desquels nous avons représenté un extrait de l'historique d'un équipement de fabrication et celui d'un équipement de métrologie associé.

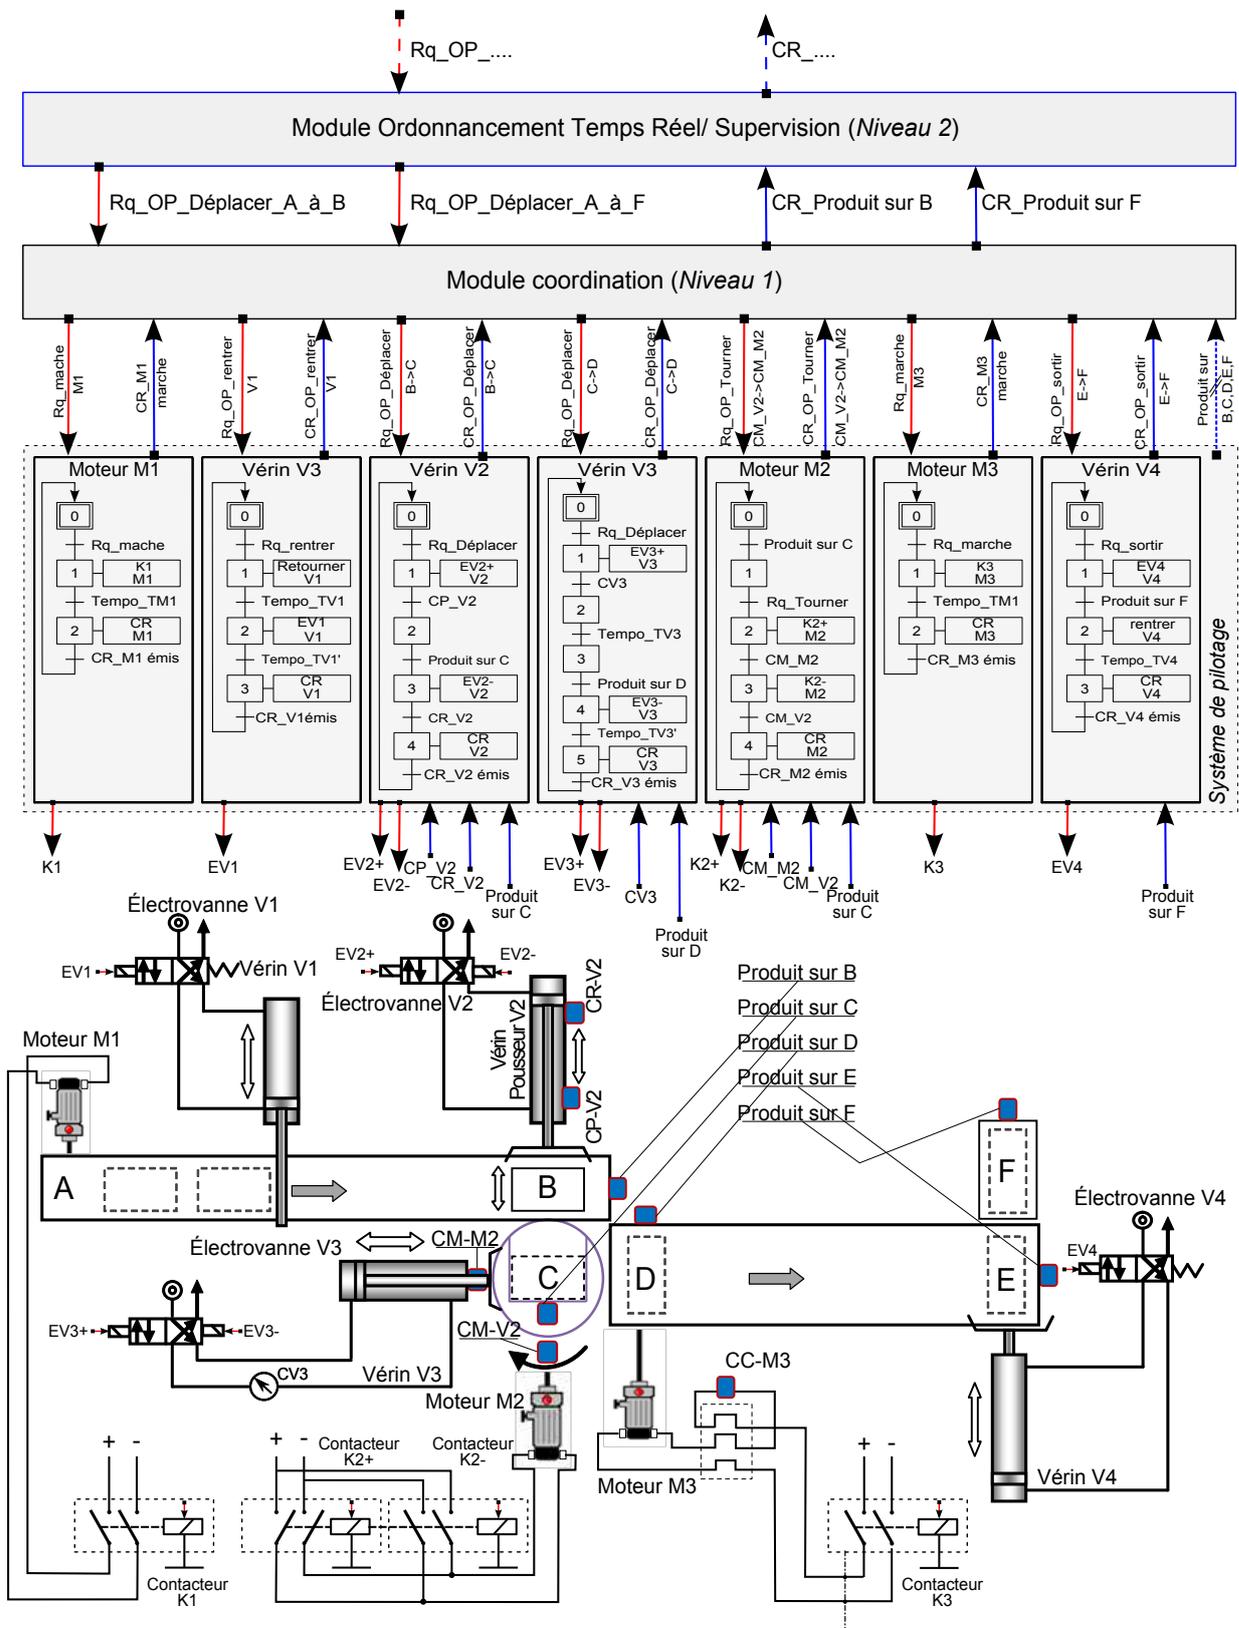


FIGURE 4.4 – Exemple de système de pilotage illustrant la position des capteurs

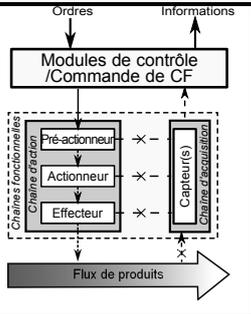
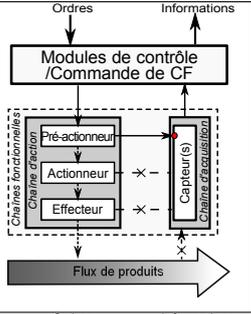
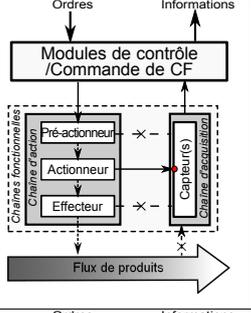
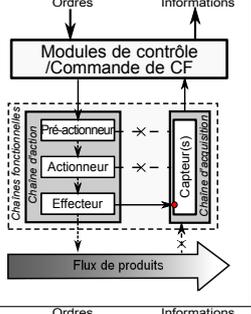
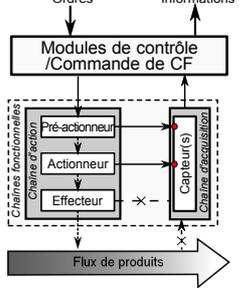
Placement du capteur	Exemple (cf. 4.4)	Symbole
Boucle ouverte		Absence de capteurs OL
Pré-actionneur		Capteurs chargés de surveiller l'ouverture/fermeture des distributeurs de pression d'air (CV3 de électrovanne V3 - vérin V3) PA
Actionneur		Surveillance des évolutions des actionneurs (CP-V2, CR-V2 surveille la position du piston V2) AC
Effecteur		Capteurs de fin de course (CM-M2, CM-V2 de Moteur M2) EF
Pré-actionneur + Actionneur		Surveillance du distributeur de pression d'air et de la position du piston PA.AC

TABLE 4.2 – Placement des capteurs sur les chaînes d'action et sur flux de produits

Placement du capteur	Exemple (cf. 4.4)	Symbole
<p>Effecteur + Pré-Actionneur</p>		<p>CV3</p> <p>EF.PA</p>
<p>Effecteur + Actionneur</p>		<p>CP-V2, CR-V2 et Produit sur C</p> <p>EF.AC</p>
<p>Effecteur + Actionneur + Pré-Actionneur</p>		<p>Les capteurs surveillent l'ensemble de la chaîne d'action</p> <p>EF.AC.PA</p>
<p>Métrieologie de équipement</p>		<p>Les capteurs sont installés pour observer directement l'effet sur le produit (Cas du capteur Produit sur F)</p> <p>Métrieologie-EQ</p>
<p>Métrieologie + Pré-Actionneur</p>		<p>Me.PA</p>

TABLE 4.3 – Placement des capteurs sur les chaînes d'action et sur flux de produits

Placement du capteur	Exemple (cf. 4.4)	Symbole
Métrologie + Actionneur		Me.AC
Métrologie + Effecteur		Me.EF
Métrologie + Actionneur + Pré-Actionneur		Me.PA.AC
Métrologie + Effecteur + Pré-Actionneur		Me.EF.PA
Métrologie + Effecteur + Actionneur		Me.EF.AC

TABLE 4.4 – Placement des capteurs sur les chaînes d'action et sur flux de produits

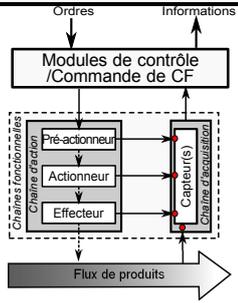
Placement du capteur	Exemple (cf. 4.4)	Symbole
Métrologie + Effecteur + Actionneur + Pré-Actionneur		Cas le plus favorable où la commande est sur- surveillée Me.EF.AC.PA

TABLE 4.5 – Placement des capteurs sur les chaînes d'action et sur flux de produits

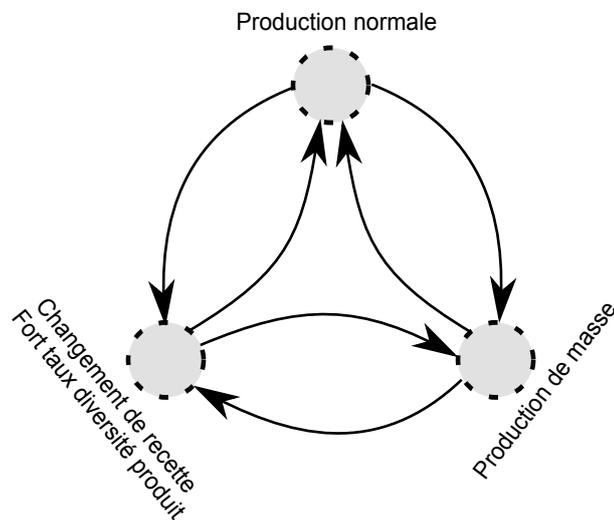


FIGURE 4.5 – Trois états du contexte de production

A noter que la métrologie produit est menée de manière aléatoire sur certains lots (appelés moniteurs). Si nous considérons le cas particulier observé à 01 :42 :00, 08-jan-2005 (Tableau 4.6) au niveau de l'équipement de production, le lot 25 de type B est un considéré comme étant conforme vis-à-vis de la commande. Or, si nous regardons la tableau 4.7, il s'avère que ce lot a été rejeté par l'équipement de métrologie. Il y a donc incohérence entre ce qui est caractérisé par l'équipement de production et celui de métrologie liée à ce type de produit. Si ceci se produit statistiquement souvent sur ce même type de produit, apparaît alors une tendance qu'il est utile de prendre en compte lors du calcul de la confiance qui sera plus tard accordée au compte-rendu d'exécution de cet équipement traitant de ce produit de type B.

4.5 Maintenance préventive (PM) et corrective (CM)

De la même manière, nous avons pu montrer l'impact des maintenances sur la réduction du nombre de produits rejetés en métrologie. Elles augmentent donc la qualité

Date and time	Lot ID	Type of product	Reported information
21 :57 06-Jan-2005	Lot12	TypeA	Not OK
22 :04 06-Jan-2005	Lot30	TypeC	Ok
01 :32 07-Jan-2005	Lot13	TypeA	Not OK
02 :44 07-Jan-2005	Lot21	TypeB	Not OK
02 :49 07-Jan-2005	Lot31	TypeC	Not OK
03 :27 07-Jan-2005	Lot32	TypeC	Ok
08 :09 07-Jan-2005	Lot22	TypeB	Ok
15 :09 07-Jan-2005	Lot14	TypeA	Not OK
16 :00 07-Jan-2005	Lot33	TypeC	Ok
16 :12 07-Jan-2005	Lot15	TypeA	Not OK
17 :50 07-Jan-2005	Lot23	TypeB	Ok
18 :05 07-Jan-2005	Lot24	TypeB	Not OK
01 :42 08-Jan-2005	Lot25	TypeB	OK
02 :56 08-Jan-2005	Lot34	TypeC	Not OK

TABLE 4.6 – Base de données de la production

Date	Lot ID	Type of product	Metrology
08-Jan-2005	Lot15	TypeA	Pass
17-Jan-2005	Lot25	TypeB	NotPass
24-Jan-2005	Lot34	TypeC	Pass

TABLE 4.7 – Base de données de la métrologie

de production, sous réserve bien entendu qu'elles soient correctement réalisées et que l'équipement ou partie d'équipement maintenu soit le bon (celui localisé par le processus de diagnostic). A noter que si tel n'est pas le cas, une maintenance peut aggraver un problème existant, en créer un qui n'existait pas ou encore ne rien améliorer du tout.

Nous nous placerons ici sous l'hypothèse comme quoi une maintenance améliore systématiquement la qualité de production. Ceci nous amènera donc à inférer le fait que si un équipement a été maintenu, la confiance quant à son activité production sera plus grande. Par conséquent, nous nous proposons de représenter les activités de maintenances comme suit :

$$PM = \{0, 1, 2, \dots, m\}$$

$$CM = \{0, 1, 2, \dots, k\}$$

Avec m, k représentant respectivement le nombre de maintenances préventives et correctives.

5 Caractérisation du CLFI

Comme nous venons de le voir, de nombreux paramètres ont un impact sur le calcul du CLFI. Ils présentent une certaine hétérogénéité rendant leur prise en compte conjointe complexe : données incertaines, complexes, incomplètes (par exemple : manque des informations sur les systèmes de mesure, types de données diverses (integer, real, string, time-date, etc), équipements divers dans le système de production, etc).

Parmi les différentes méthodes qui permettent de modéliser les liens de cause à effets pouvant lier ces différents paramètres avec le CLFI, nous citerons Expectation Maximization (EM) (Dempster et al., 1977), Markov chain Monte Carlo (MCMC) (Gilks et al., 1995), Neural Network (Nauck et al., 1997). Notre choix s'est porté sur les réseaux Bayésiens (Bouaziz et al., 2011). Ces derniers, comme nous avons pu le présenter dans les chapitres précédents combinent une représentation des connaissances sous forme graphique et une prise en compte de l'incertitude au travers de probabilités (Populaire, 2000). Ils sont parfaitement adaptés à notre contexte où apprentissage et inférence permettent de corréliser des données incertaines voire incomplètes avec l'assistance d'un expert.

Fort de ces 7 paramètres (cf. page 66), le chapitre suivant va s'attacher à présenter la modélisation bayésienne que nous proposons.

6 Conclusion

Ce chapitre nous a permis de présenter les résultats des analyses statistiques que nous avons menées en collaboration avec le partenaire industriel ST-MicroElectronics Crolles (38). Ces analyses centrées sur les liens de causalités entre les données de production des équipements et les données issues des équipements de métrologie nous ont permis de mettre en évidence un ensemble de paramètres qui ont un impact plus ou moins direct sur le CLFI. Après avoir passé en revue l'ensemble de ces paramètres, nous nous proposons désormais dans le chapitre suivant de construire le modèle correspondant.

Chapitre 5

Contribution à la modélisation de la confiance

1 Introduction

Après avoir caractérisé les différents paramètres pouvant avoir un impact sur le CLFI sur la base de données issues d'un partenariat industriel (semi-conducteur, ST-Microelectronics Crolles), nous nous proposons dans ce chapitre de développer les différents modèles que nous proposons pour le calcul du CLFI. Il s'agit pour nous ici de mettre à la disposition de l'expert différentes modélisations permettant de répondre à différentes classes de problèmes et contribuant toutes au même objectif : estimer la confiance qui peut être donnée à un compte rendu d'exécution.

Pour ce faire, nous avons proposé trois modèles répondant chacun à un problème spécifique et dont l'apprentissage varie du plus simple au plus complexe.

Ainsi, le premier modèle s'attache à traiter un cas statique avec l'hypothèse d'indépendance conditionnelle entre les variables du problème. Le modèle retenu sera le modèle Bayésien naïf (cf. section 2). Ensuite, un modèle de type TAN (cf. section 3) sera soumis afin de s'affranchir de l'hypothèse d'indépendances conditionnelles entre les variables du problème. Enfin, nous présenterons dans la section 4 le modèle le plus abouti intégrant la prise en compte de relations temporelles du problème. Ce modèle est un réseau Bayésien dynamique à chaîne de Markov.

2 Modèle bayésien Naïf

Cette section va donc s'attacher à présenter le cas d'une modélisation bayésienne naïve statique où l'hypothèse d'indépendance conditionnelle entre les variables a été retenue. Ce modèle a fait l'objet d'une publication à INCOM12 (Duong et al., 2012c).

Sous les hypothèses de naïveté retenues, le réseau bayésien naïf correspondant à la modélisation de la confiance d'un compte-rendu noté Re revient à construire un arbre dans lequel Re est un nœud parent et les paramètres R , C , P , TP , Me , PM , CM

les enfants (cf. figure 5.1). Le CLFI peut alors s'écrire :

$$CLFI = P(Re|R, P, C, TP, Me, CM, PM)$$

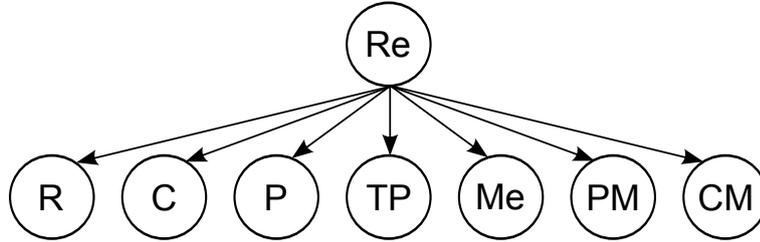


FIGURE 5.1 – Modèle basé sur le modèle bayésien Naïf

2.1 Méthode de calcul

Si nous reprenons l'équation 3.14 page 45, les nœuds $x_1 \rightarrow x_7$ représentent respectivement les paramètres R, C, P, TP, Me, PM, CM . Le calcul du $CLFI(Re)$ peut alors s'écrire :

$$CLFI = \frac{P(Re)P(R|Re)P(P|Re)P(C|Re)P(TP|Re)P(Me|Re)P(CM|Re)P(PM|Re)}{P(R, P, C, TP, Me, CM, PM)} \quad (5.1)$$

$$CLFI = \frac{P(Re)P(R|Re)P(P|Re)P(C|Re)P(TP|Re)P(Me|Re)P(CM|Re)P(PM|Re)}{\sum_{Re_i=1}^n P(R, P, C, TP, Me, CM, PM, Re_i)} \quad (5.2)$$

Dans notre cas d'étude, nous avons considéré que 2 valeurs possibles d'un compte-rendu d'exécution $Re_i = \{OK, NotOK\}$. Ainsi, l'équation 5.2 devient trivialement :

$$CLFI = \frac{P(Re)P(R|Re)P(P|Re)P(C|Re)P(TP|Re)P(Me|Re)P(CM|Re)P(PM|Re)}{P(R, P, C, TP, Me, CM, PM, Re = OK) + P(R, P, C, TP, Me, CM, PM, Re = NotOK)} \quad (5.3)$$

Afin de réaliser ce calcul chacun des termes de cette équation 5.3 doit être évalué :

- $P(C)$ est calculé à partir de l'ensemble de données d'apprentissage en comptant le nombre d'apparitions d'éléments $Re = Re_i$, par exemple : $Re_i = OK$ ou $Re_i = NotOK$; ($Re_i = \{OK, NotOK\}$)
- Les probabilités $P(Re)$; $P(R|Re)$; $P(P|Re)$; $P(C|Re)$; $P(TP|Re)$; $P(Me|Re)$; $P(CM|Re)$; $P(PM|Re)$ peuvent être estimées en comptant le nombre d'apparitions de chaque valeur $R = r_j\%$, $C = C_j, \dots$ dans les données d'apprentissage.
- Bien entendu, ce modèle n'est à retenir que si les données sont toutes observées et complètes. Si elles sont non complètes nous avons privilégié l'algorithme EM pour calculer l'estimation de vraisemblance (MLE) bien adapté ici (Niculescu et al., 2006).

2.2 Exemple d'application

Afin de mieux appréhender ce modèle, un exemple d'application est ici proposé. Il se base sur un SAP représenté dans la Figure 5.2. Dans cet exemple, nous nous concentrons sur les activités de l'équipement M1 avec les données historiques présentées dans le tableau (Table 5.1) de la page suivante.

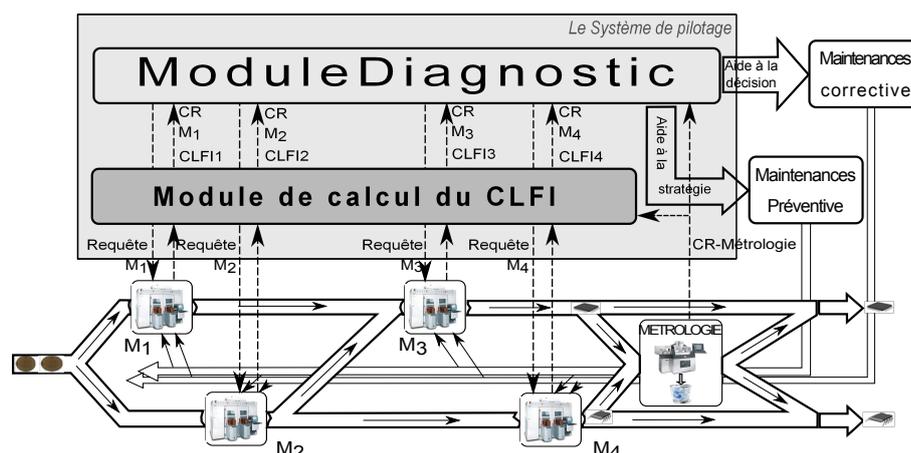


FIGURE 5.2 – Exemple d'un SAP pour le calcul naïf du CLFI

R (%)	P	C	TP	Me	PM (Times)	CM (Times)	Report
70%	EF.AC.PA	N	TypeA	Pass	1	2	OK
80%	EF.AC.PA	MP	TypeA	NotPass	1	1	OK
90%	EF.PA	N	TypeB	Pass	2	3	OK
0%	OL	CR	TypeA	NotPass	3	1	NotOK
90%	AC	N	TypeA	Pass	2	4	OK
70%	EF	N	TypeC	Pass	2	2	OK
80%	EF.AC	MP	TypeA	Pass	4	1	OK
90%	EE.AC.PA	CR	TypeA	NotPass	1	2	NotOK
90%	PA	CR	TypeB	Pass	2	3	NotOK
80%	AC	MP	TypeB	NotPass	2	4	NotOK
90%	PA.AC	N	TypeA	Pass	3	1	OK
80%	EF	N	TypeA	Pass	2	2	OK
60%	EF.PA	N	TypeC	Pass	4	4	NotOK
90%	PA.AC	MP	TypeC	Pass	1	3	OK
80%	EE.AC.PA	MP	TypeA	NotPass	2	1	OK
90%	EF	CR	TypeB	Pass	3	1	OK
60%	EF	N	TypeA	Pass	4	1	OK

TABLE 5.1 – Les données historique de l'équipement M1

Supposons ici une opération exécutée par l'équipement de production noté M1. Supposons également qu'après exécution de cette opération demandée par le système de pilotage père, M1 produise un compte-rendu caractérisant la bonne exécution du service demandé ($Re = OK$). M1 considère donc que le produit transformé l'a été fait avec succès.

Désormais, nous nous proposons de calculer le $CLFI(Re)$ considérant les variables observées suivantes :

$$R = 80\%, P = EF.AC.PA, C = N, TP = TypeA, Me = Pass, PM = 1, CM = 1$$

Cela revient donc à calculer :

$$P(Re|R = 80\%, P = EF.AC.PA, C = N, TP = TypeA, Me = Pass, PM = 1, CM = 1) \quad (5.4)$$

Pour ce faire, deux étapes doivent être traitées :

Apprentissage Sur la base de la table historique 5.1 les probabilités suivantes peuvent être déduites :

En regardant $P(R = 80\%|Re = OK)$, nous avons 12 cas où $Re=OK$, dont 4 avec $R=80\%$. Nous avons $P(Re = OK) = 12/17$ et $P(Re = NotOK) = 5/17$.

$$\begin{array}{ll} P(R = 80\%|Re = OK) = \frac{4}{12} & P(R = 80\%|Re = NotOK) = \frac{1}{5} \\ P(R = EF.AC.PA|Re = OK) = \frac{3}{12} & P(R = EF.AC.PA|Re = NotOK) = \frac{1}{5} \\ P(C = N|Re = OK) = \frac{7}{12} & P(C = N|Re = NotOK) = \frac{1}{5} \\ P(TP = TypeA|Re = OK) = \frac{8}{12} & P(TP = TypeA|Re = NotOK) = \frac{2}{5} \\ P(Me = Pass|Re = OK) = \frac{10}{12} & P(Me = Pass|Re = NotOK) = \frac{2}{5} \\ P(PM = 1|Re = OK) = \frac{3}{12} & P(PM = 1|Re = NotOK) = \frac{1}{5} \\ P(CM = 1|Re = OK) = \frac{6}{12} & P(CM = 1|Re = NotOK) = \frac{1}{5} \end{array}$$

et où :

$$P_OK = P(R, P, C, TP, Me, PM, CM) = 0.003376$$

$$P_NotOK = P(R, P, C, TP, Me, PM, CM) = 0.0000512$$

Calcul En nous basant sur les estimations de probabilité et l'apprentissage des données, le calcul du CLFI supporté par l'équation 5.3 révèle :

Soit un CLFI de ce compte-rendu égal à 99.37% . Il sera considéré qu'il y a une très forte probabilité que M1 a bien effectué le travail pour lequel elle a signalé une bonne fin d'exécution.

$$\begin{aligned}
 P(Re = OK | R, P, C, TP, Me, PM, CM) &= \frac{P_{OK}.P(Re=OK)}{P_{OK}.P(Re=OK)+P_{NotOK}.P(Re=NotOK)} \\
 &= \frac{0.003376 \times 0.7058}{0.003376 \times 0.7058 + 0.2941 \times 0.0000512} = 0.9937
 \end{aligned}$$

3 Modèle TAN

Après avoir traité le problème naïf où nous avons considéré l'indépendance des variables, nous nous proposons ici de lever cette hypothèse, en particulier, en considérant le cas où le résultat d'une métrologie est directement dépendant du type de produit ; cas que nous avons d'ailleurs mis en exergue dans le secteur du semi-conducteur. Cette approche a fait l'objet d'une communication à MOSIM12 (Duong et al., 2012d).

3.1 Modélisation

Sous cette hypothèse, le modèle bayésien augmenté (TAN) est proposé en tant que support à la modélisation. Ici, l'indépendance entre variables étant désormais levée, il nous est possible de représenter à un même niveau que le type de produit, à un instant donné t , impacte le comportement de l'équipement de métrologie considéré. Ceci peut être modélisé tel que proposé dans la figure 5.3.

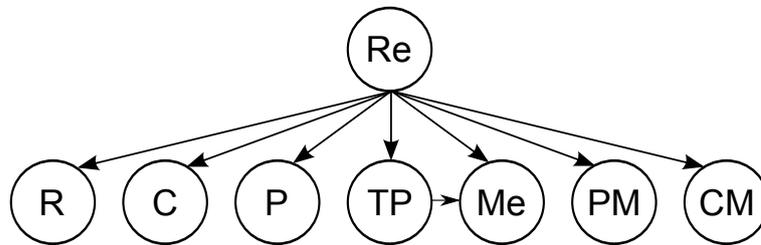


FIGURE 5.3 – Modèle basé sur le modèle TAN

Mathématiquement parlant, le CLFI est formulé par :

$$CLFI = P(Re | R, P, C, TP, Me, CM, PM)$$

3.2 Calcul du CLFI

Pour cela, nous combinons les équations 3.15 et 3.16 proposées page 46 où x_1, \dots, x_7 correspondent respectivement à R, P, C, TP, Me, PM, CM ,

$$\begin{aligned}
 P(Re | R, C, P, TP, Me, PM, CM) &= \\
 \frac{P(Re).P(R|Re).P(C|Re).P(P|Re).P(TP|Re).P(Me|Re,TP).P(PM|Re).P(CM|Re)}{\sum_{Re_j}^n P(R,C,P,TP,Me,PM,CM,Re_j)} & \quad (5.5)
 \end{aligned}$$

3.3 Calcul des composantes dans le modèle

Dans cette équation 5.5, il est nécessaire de calculer séparément les probabilités $P(Re)$, $P(R|Re)$, $P(C|Re)$, $P(P|Re)$, $P(TP|Re)$, $P(Me|Re, TP)$, $P(PM|Re)$ et $P(CM|Re)$. $P(Re)$ est calculé via les données d'apprentissage en comptant le nombre d'occurrences de Re , tel que ($Re = OK$) ou ($Re = NotOK$).

Les probabilités $P(C|Re)$, $P(P|Re)$, $P(TP|Re)$, $P(PM|Re)$, $P(CM|Re)$ peuvent quant à elles être estimées par le nombre d'occurrences de chaque paramètre C , P , TP , PM , CM dans les données d'apprentissage.

Le modèle de calcul pour le CLFI que nous avons présenté dans cette section permet non seulement de prendre en compte les données observées telles que C , P , TP , PM et CM mais aussi la probabilité $P(Me|Re, TP)$.

Aussi, dans l'équation 5.5, nous avons besoin de déterminer $P(Me|Re, TP)$.

En tenant en compte du théorème de Bayes, nous proposons :

$$P(Me|TP, Re) = \frac{P(Me, TP, Re)}{P(TP, Re)} = \frac{P(Me, TP, Re)}{\sum_{Me_j \in U} P(TP, Re, Me_j)}; \quad (5.6)$$

$$U = \{Pass, Not_Pass\}$$

Afin de mieux comprendre la dépendance entre Me et TP , l'exemple utilisé dans la section 4.4, page 70 du chapitre 4 est repris ici.

En atelier, les bases historiques sont associées à chaque équipement, comme nous avons pu le voir dans les Tableaux 4.6 et 4.7, page 76. Afin de rendre possible l'apprentissage, nous avons proposé ici de fusionner les tables en une seule. Cependant, le nombre de compte-rendus équipement de production étant très supérieur au nombre de contrôles en métrologie (tous les produits ne sont pas contrôlés afin d'optimiser les rendements de production) nous avons été amenés à considérer qu'un résultat de métrologie pour un type de produit donné caractérisait la validité des comptes-rendus équipements correspondant depuis la dernière métrologie.

Ainsi, à partir de tableau 5.2, nous avons effectué des statistiques des ensembles tels que :

TP = TypeA, Re = OK, Me = Pass
 TP = TypeB, Re = OK, Me = NotPass
 TP = TypeC, Re = OK, Me = Pass; ...

À partir des statistiques des ensembles de $\{TP, Re, Me\}$, $P(Me, TP, Re)$ est calculé $P(Me|TP, Re)$, résultats que nous détaillons section 4.2 du chapitre 6, page 95.

4 Modèle RBDCM

Dans cette section, nous proposons une modélisation qui permet d'augmenter la précision du modèle TAN lorsque la variation dans le temps des paramètres considérés influence le calcul du CLFI : le passé influence le temps présent.

Date and time	Lot ID	Type of product	Report	Metrology
21 :57 06-Jan-2005	Lot12	TypeA	Not OK	Pass
22 :04 06-Jan-2005	Lot30	TypeC	Ok	Pass
01 :32 07-Jan-2005	Lot13	TypeA	Not OK	Pass
02 :44 07-Jan-2005	Lot21	TypeB	Not OK	Not Pass
02 :49 07-Jan-2005	Lot31	TypeC	Not OK	Pass
03 :27 07-Jan-2005	Lot32	TypeC	Ok	Pass
08 :09 07-Jan-2005	Lot22	TypeB	Ok	Not Pass
15 :09 07-Jan-2005	Lot14	TypeA	Not OK	Pass
16 :00 07-Jan-2005	Lot33	TypeC	Ok	Pass
16 :12 07-Jan-2005	Lot15	TypeA	Not OK	Pass
17 :50 07-Jan-2005	Lot23	TypeB	Ok	Not Pass
18 :05 07-Jan-2005	Lot24	TypeB	Not OK	Not Pass
01 :42 08-Jan-2005	Lot25	TypeB	OK	Not Pass
02 :56 08-Jan-2005	Lot34	TypeC	Not OK	Pass

TABLE 5.2 – Intégration entre les données

Ce modèle est aussi le dernier de notre série et se positionne naturellement comme le meilleur pour estimer le CLFI des comptes-rendus d'exécutions. Il a été présenté dans les deux publications (Duong et al., 2012b,a).

4.1 Modélisation

Lorsqu'il s'agit de modéliser des relations causales temporelles se pose le problème de la *profondeur* du passé à prendre en compte. Plus cette profondeur est importante, plus les temps de calcul seront longs (Murphy, 2002).

Dans le cadre de notre approche, nous avons limité cette profondeur temporelle à un pas de 1, soit la prise en compte de ce qui s'est passé à l'instant $t-1$, ce qui nous place dans le cadre d'une chaîne de Markov du premier ordre.

Considérant les aspects théoriques présentés auparavant dans la section 6 du chapitre 3 et du modèle TAN précédemment dévoilé, nous proposons ici le modèle RBDCM de la figure 5.4b.

où :

$$\theta_{t-1} = \{R_{t-1}, C_{t-1}, P_{t-1}, TP_{t-1}, Me_{t-1}, PM_{t-1}, PC_{t-1}\}$$

$$\theta_t = \{R_t, C_t, P_t, TP_t, Me_t, PM_t, PC_t\}$$

L'objectif est désormais d'estimer la probabilité de Re à l'instant présent connaissant non seulement les paramètres du modèle TAN à ce même instant mais également Re à l'instant $t-1$, soit la probabilité $P(Re_t | \theta_t, Re_{t-1})$:

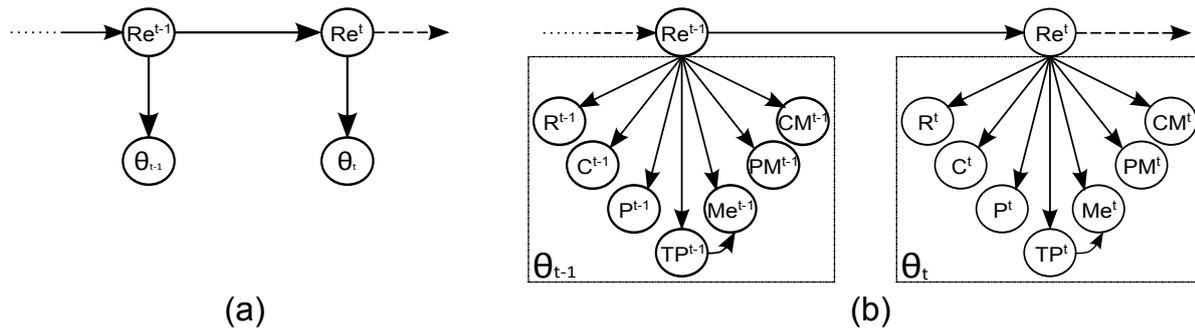


FIGURE 5.4 – Modèle dynamique pour le calcul du CLFI

4.2 Proposition du modèle mathématique

Dans le cadre de la proposition du modèle mathématique correspondant à cette problématique, nous nous sommes appuyés sur la combinaison des théories relatives aux réseaux bayésiens dynamiques et aux chaînes de Markov du premier ordre (Duong et al., 2012b).

Soit la règle fondamentale de Bayes suivante :

$$P(A|B)P(B) = P(A \cap B) = P(B|A)P(A) \quad (5.7)$$

De cette règle, nous proposons une extension via la prise en compte d'une condition supplémentaire que nous noterons C , la règle peut alors s'écrire :

$$P(A \cap B | C) = P(A | B \cap C)P(B | C) \quad (5.8)$$

L'application du théorème de Bayes :

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (5.9)$$

nous permet alors de formuler que :

$$P(A|B, C) = \frac{P(B|A, C)P(A|C)}{P(B|C)} \quad (5.10)$$

et dans notre cas :

$$P(\text{Re}_t | \text{Re}_{t-1}, \theta_t) = \frac{P(\text{Re}_t, \text{Re}_{t-1} | \theta_t)}{P(\text{Re}_{t-1} | \theta_t)} \quad (5.11)$$

Si nous appliquons à nouveau le théorème de Bayes à ce dénominateur, nous obtenons :

$$P(\text{Re}_t, \text{Re}_{t-1} | \theta_t) = P(\text{Re}_{t-1} | \text{Re}_t, \theta_t) \cdot P(\text{Re}_t | \theta_t) \quad (5.12)$$

Où :

$$P(\text{Re}_t | \theta_t, \text{Re}_{t-1}) = \frac{P(\text{Re}_{t-1} | \text{Re}_t, \theta_t) \cdot P(\text{Re}_t | \theta_t)}{P(\text{Re}_{t-1} | \theta_t)} \quad (5.13)$$

A partir du modèle dynamique du CLFI en se basant sur le modèle RBDCM, nous l'avons simplifié pour obtenir celui dans la figure 5.4a. Dans cette dernière, le nœud Re_t dépend de θ_t et Re_{t-1} , mais il ne dépend pas de θ_{t-1} (selon les propriétés de Markov). Le nœud Re_{t-1} dépend de Re_t et θ_{t-1} , ce qui nous permet d'écrire :

$$P(Re_t | \theta_t, Re_{t-1}) = \frac{P(Re_{t-1} | Re_t) \cdot P(Re_t | \theta_t)}{P(Re_{t-1})} \quad (5.14)$$

avec :

$$\frac{P(Re_{t-1} | Re_t)}{P(Re_{t-1})} = \frac{P(Re_t | Re_{t-1})}{P(Re_t)}. \quad (5.15)$$

Et finalement, nous obtenons :

$$P(Re_t | \theta_t, Re_{t-1}) = \frac{P(Re_t | Re_{t-1}) \cdot P(Re_t | \theta_t)}{P(Re_t)} \quad (5.16)$$

4.3 Méthode de calcul des composants dans le modèle

Pour pouvoir calculer la probabilité $P(Re_t | \theta_t, Re_{t-1})$, il est indispensable de déterminer chaque composant de l'équation 5.16. Le lecteur pourra se reporter à (Duong et al., 2012a) pour davantage de détails.

- $P(Re_t)$: la probabilité a priori est calculée à partir des données d'apprentissage en comptant le nombre d'occurrences des événements.
- $P(Re_t | \theta_t)$: fonction d'observation lorsque les données sont observées en temps réel. Il s'agit de la probabilité a posteriori estimée à partir du modèle TAN (comme présenté dans la section 3).
- $P(Re_t | Re_{t-1})$: distribution de probabilité de transition entre les différents états du système au cours du temps, elle décrit les effets des états précédents sur l'état présent.

Pour calculer $P(Re_t | Re_{t-1})$, nous observons $Re_{1:T}$ (T : fréquence d'échantillonnage) et utilisons la matrice normalisée de co-occurrence (cf. l'équation 5.17) :

$$P(M_states) = \frac{N(i, j)}{\sum_k N(i, k)} \quad (5.17)$$

avec :

$$N(i, j) = \sum_{t=2}^T I(Re_{t-1} = i, Re_t = j) \quad (5.18)$$

$$Re_{t-1}, Re_t = \{i, j\}$$

$I(Re)$ est une valeur binaire où 1 correspond à ($Re=OK$), et 0 pour ($Re=Not OK$).

4.4 Exemple de distribution de la probabilité transitoire

Pour mieux comprendre la matrice de transition, un exemple est proposé sur la base du jeu de données de la Figure 5.5 et en utilisant l'équation 5.18 :

Date and time	Type of product	Report
21:57 06-Jan-2005	TypeA	Not OK
22:04 06-Jan-2005	TypeC	Ok
01:32 07-Jan-2005	TypeA	Not OK
02:44 07-Jan-2005	TypeB	Not OK
02:49 07-Jan-2005	TypeC	Not OK
03:27 07-Jan-2005	TypeC	Ok
08:09 07-Jan-2005	TypeB	Ok
15:09 07-Jan-2005	TypeA	Not OK
16:00 07-Jan-2005	TypeC	Ok
16:12 07-Jan-2005	TypeA	Not OK
17:50 07-Jan-2005	TypeB	Ok
18:05 07-Jan-2005	TypeB	Not OK
01:42 08-Jan-2005	TypeB	Not OK
02:56 08-Jan-2005	TypeC	Not OK

FIGURE 5.5 – Exemple d'un jeu de données de production

De cette figure, 4 cas de transition sont à distinguer :

$$\begin{aligned}
 Re_{t-1} = OK &\rightarrow Re_t = Not_OK \\
 Re_{t-1} = OK &\rightarrow Re_t = OK \\
 Re_{t-1} = Not_OK &\rightarrow Re_t = OK \\
 Re_{t-1} = Not_OK &\rightarrow Re_t = Not_OK
 \end{aligned}$$

La matrice de transition que l'on peut obtenir est donc M_{states} :

		Re_{t-1}	
		OK	NotOK
Re_t	OK	1/5	4/5
	NotOK	3/7	4/7

TABLE 5.3 – Matrice de transition d'états

A chaque instant donné, pour estimer la probabilité $P(Re_t | Re_{t-1})$, nous pouvons nous référer à la matrice de transition M_{states} (Table. 5.3) pour trouver la probabilité correspondante $P(Re_t | Re_{t-1})$. Par exemple, à l'instant $t-1$, la valeur du compte-rendu retourné de l'équipement est *Not OK*. Cependant, à l'instant t , elle prend la valeur *OK*. La probabilité de transition entre les états est définie comme suit :

$$P(Re_t = OK | Re_{t-1} = Not_OK) = \frac{4}{5}$$

5 Conclusion

Au terme de ce chapitre nous avons proposé différents modèles du CLFI permettant d'affiner son calcul. La proposition des trois modèles se justifie par rapport à l'utilisation que peut en faire l'expert. Plus il s'orientera vers un modèle de type RBDCM plus le résultat sera précis, mais au détriment d'un apprentissage plus long. Afin de l'aider à faire son choix, et donc à apprécier le juste compromis, nous suggérons le tableau 5.4 qui permet de positionner chacune des trois contributions.

Les critères	Modèle Bayésien naïf	Modèle TAN	Modèle RBDCM
Données incomplètes et incertaines	✓	✓	✓
Les paramètres CLFI sont dépendants et discrets	—	✓	✓
Relations causales temporelles	—	—	✓

TABLE 5.4 – Synthèse des modèles proposés

Chacun des trois modèles présentés permet désormais de calculer en ligne ce CLFI pour chaque équipement de production considéré. Le chapitre suivant va s'attacher à présenter les algorithmes que nous proposons pour cela.

Chapitre 6

Algorithme de calcul

1 Introduction

Dans le cadre de ce chapitre, nous nous proposons de présenter les algorithmes de calcul que nous avons développés dans le cadre de l'estimation dynamique des compte-rendus d'exécution émis par les équipements de production.

Les algorithmes proposés se répartissent à la fois hors ligne mais également en ligne tel que le montre la structure dans la figure 6.1. En effet, avant d'envisager une exploitation en ligne, une étape d'apprentissage doit être préalablement menée afin de produire le modèle Bayésien retenu.

2 Étape d'apprentissage

Apprendre signifie estimer les différents paramètres du modèle du CLFI à partir des données mises à disposition par l'industriel.

Comme nous avons pu le voir dans les chapitres précédents, la méthode d'estimation dépend du paramètre considéré. Nous nous proposons ainsi de résumer par la suite les différentes méthodes retenues pour chacun d'entre eux :

- (a) $P(Re)$. Il s'agit d'une probabilité a priori pour laquelle nous allons étudier le nombre d'occurrences de $(Re = OK)$ ou $(Re = NotOK)$ afin d'estimer $P(Re = OK)$ et $P(Re = NotOK)$.
- (b) $P(R|Re)$. Comme présenté dans la section 4.1, page 94, nous reprendrons ici l'algorithme EM (D'Souza, 2002; Tien, 2010) pour estimer ce paramètre. Il sera présenté en détail par la suite.
- (c) $P(C|Re)$, $P(TP|Re)$, $P(PM|Re)$, $P(CM|Re)$ peuvent être estimées sur la base d'une étude statistique du nombre d'occurrences de chaque facteur C , P , TP , PM , CM dans les données d'apprentissage. Par exemple, nous recherchons dans la base données combien de fois $(C = N)$; $(C = CR)$ ou $(C = MP)$; $(P = EF.AC.PA)$; $(P = EF.AC)$; etc.,.

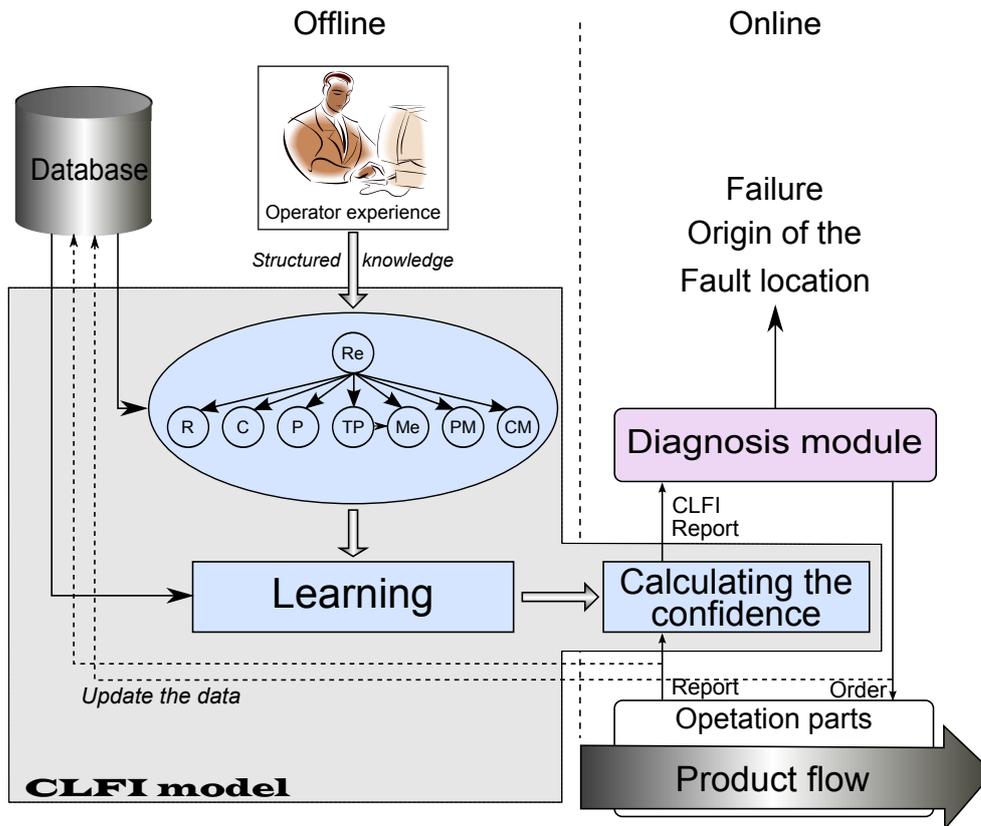


FIGURE 6.1 – Etapes de calcul du CLFI

(d) $P(Me|Re, TP)$. Pour cette estimation, nous avons proposé un nouvel algorithme spécifique que nous détaillons dans le paragraphe 4.2.

(e) $P(M_states)$. La matrice de transition sera quant à elle estimée sur la base de :

$$P(M_states) = \frac{N(i, j)}{\sum_k N(i, k)}$$

avec :

$$N(i, j) = \sum_{t=2}^T I(Re_{t-1} = i, Re_t = j)$$

$$i, j = \{OK, NotOK\}$$

La suite de ce chapitre se propose donc de détailler en particulier les algorithmes d'apprentissage (b), (d) et (e). (a) et (c) restant triviaux.

Préalablement cependant, nous nous proposons d'introduire brièvement l'étape de calcul en ligne.

3 Étape de calcul en ligne

Sur la base des résultats de l'apprentissage, le calcul en ligne est déclenché sur l'occurrence d'un compte-rendu d'exécution émis par la machine de production. Il s'agit alors de calculer $P(Re_t | \theta_t, Re_{t-1})$ qui est décomposé en :

- le calcul de $P(\text{Re}_t|\theta_t)$:

$$P(\text{Re}_t|\theta_t) = \frac{P(\text{Re}_t)P(R_t|\text{Re}_t)P(C_t|\text{Re}_t)P(P_t|\text{Re}_t)P(TP_t|\text{Re}_t)P(Me_t|TP_t, \text{Re}_t)P(PM_t|\text{Re}_t)P(CM_t|\text{Re}_t)}{\sum_{\text{Re}_t^j} P(R_t, C_t, P_t, TP_t, Me_t, PM_t, CM_t, \text{Re}_t)}$$

$$\text{Re}_t^j = \{OK, \text{NotOK}\}$$

- le calcul de $P(\text{Re}_t|\text{Re}_{t-1})$ à partir de la matrice de transition $P(M_states)$. Par exemple, à l'instant t : $(\text{Re}_{t-1} = \text{NotOK})$ et $(\text{Re}_t = OK)$, nous nous appuyons sur $P(M_states)$ pour trouver $P(\text{Re}_t|\text{Re}_{t-1})$.
- et enfin le calcul du CLFI avec

$$P(\text{Re}_t|\theta_t, \text{Re}_{t-1}) = \frac{P(\text{Re}_t|\text{Re}_{t-1}) \cdot P(\text{Re}_t|\theta_t)}{P(\text{Re}_t)}$$

Les étapes d'apprentissage et de calcul en ligne étant désormais montrées, nous nous proposons maintenant de présenter au lecteur les différents algorithmes associés que nous proposons.

4 Algorithmme de calcul

L'algorithme général (cf. Algorithme 1) proposé est naturellement structuré autour des deux grandes étapes présentées précédemment et reprend au sein de ces étapes les calculs intermédiaires requis.

Algorithm 1: Computing CLFI Dynamic algorithm

Input: Training data set ; A new vector of parameters $\{R_t, C_t, P_t, TP_t, PM_t, CM_t\}$, and Report at time t $\{\text{Re}_t\}$

procedure LEARNING

 Compute a prior probability : $P(\text{Re}_t)$

 Compute a probability : $P(R_t|\text{Re}_t)$ over time

 Compute a probability : $P(C_t|\text{Re}_t)$; $P(P_t|\text{Re}_t)$; $P(TP_t|\text{Re}_t)$; $P(TP_t|\text{Re}_t)$; $P(PM_t|\text{Re}_t)$; $P(CM_t|\text{Re}_t)$

 Compute a probability : $P(Me_t|TP_t, \text{Re}_t)$ with respect to TP_t

 Compute a probability : M_States

end procedure

procedure TESTING($\text{Re}_t, R_t, C_t, P_t, TP_t, PM_t, CM_t$)

 Compute a probability : $P(\text{Re}_t|\theta_t)$

 Compute a probability : $P(\text{Re}_t|\text{Re}_{t-1})$

 Compute a probability : $P(\text{Re}_t|\theta_t, \text{Re}_{t-1}) = \frac{P(\text{Re}_t|\text{Re}_{t-1}) \cdot P(\text{Re}_t|\theta_t)}{P(\text{Re}_t)}$

return : $P(\text{Re}_t|\theta_t, \text{Re}_{t-1})$

end procedure

Output: Probability $P(\text{Re}_t|\theta_t, \text{Re}_{t-1})$

4.1 Algorithme de calcul de $P(R_t|Re_t)$

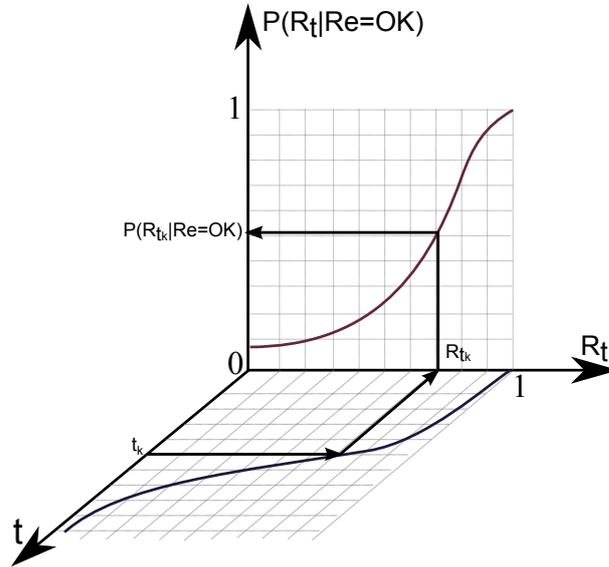


FIGURE 6.2 – Relation entre fiabilité du système de mesure et le compte-rendu émis

L'objectif ici est de calculer à un instant t donné la fiabilité du système de captage de la machine de production considérée et d'estimer alors son influence sur le compte-rendu émis. Cela revient donc à établir une relation entre R et Re comme le montre la figure 6.2

Algorithm 2: Algorithm for compute $P(R_t|Re_t)$

Input: Training data set and λ_i

procedure COMPUTING : $R(\lambda_i)^a$

$$R(t) \leftarrow 1 - \prod_{i=1}^n (1 - e^{-\lambda_i t})$$

return : $R(t)$

end procedure

procedure ESTIMATION : $P(R(t)|Re_t)$ (Training data set)

$$\tau_i, \mu_i, \sigma_i \leftarrow \text{AlgorithmEM}$$

$$f(t) \leftarrow \sum_{i=1}^k \tau_i \frac{1}{\sigma_i \sqrt{2\pi}} e^{-\frac{(t-\mu_i)^2}{2\sigma_i^2}}$$

return : $P(R(t)|Re_t) = f(t)$

end procedure

foreach time t_j **do**

 Calculate $P(R|Re)|_{t_j} \leftarrow f(t_j)$

return : $P(R_{t_j}|Re_{t_j})$

Output: $P(R_t|Re_t)$

a. Hypothèse : système de mesure fortement parallèle

Ceci sera calculé en deux étapes (cf. Algorithme 2) :

- Application de l'équation 4.3 (équation du système en parallèle), page 68 pour calculer la fiabilité du système de captage en fonction du temps $R(t)$.
- Application de l'algorithme EM (D'Souza, 2002; Tien, 2010) pour déterminer la loi de distribution de probabilité de $R(t)$ via la détermination des paramètres τ_i, μ_i, σ_i (Gaussian Mixture).

4.2 Algorithme de calcul de $P(Me_t|Re_t, TP_t)$

Comme nous l'avons montré au chapitre 5, section 3, page 83, le calcul de $P(Me_t|Re_t, TP_t)$ requiert une étape préalable de fusion de données historiques (celles issus de l'équipement de production avec celles issues de l'équipement de métrologie) afin de calculer $P(Me_t|Re_t, TP_t)$.

Le calcul de $P(Me_t|Re_t, TP_t)$ se réalise alors sur la base de l'équation 5.6 page 84. Ces deux étapes sont synthétisées au sein de l'algorithme 3 développé ci-après :

Algorithm 3: Algorithm for compute $P(Me_t|TP_t, Re_t)$

Input: Data :

- Production data
- Metrology data

begin

$TP_P = \{TypeA, TypeB, \dots, TypeL, \dots\} \leftarrow$ Production data;

$TP_M = \{TypeA, TypeB, \dots, TypeL, \dots\} \leftarrow$ Metrology data;

n : Number of TP in Production_data \leftarrow TP_P;

m : Number of TP in Metrology_data \leftarrow TP_M;

for $i=1$ to $lenght(Metrology\ data)$ **do**

for $j=1$ to $lenght(Production\ data)$ **do**

foreach $TP_P(l) = TP_M(k); l \in n; k \in m$ **do**

if $Date(Production\ data(i)) \leq Date(Metrology\ data(j))$ **then**

$Mix\ data(i) \leftarrow$ Production data(i) + Metrology data(j);

foreach Type of produit in the Mix data **do**

 Calculate $P(Me, TP, Re)$;

At time t ;

Calculate $P(Me_t | TP_t, Re_t) = \frac{P(Re_t, TP_t, Me_t)}{\sum_{Me_r} P(TP_t, Re_t, Me_r)}$; $Me_r = \{Pass, NotPass\}$

return : $P(Me_t | TP_t, Re_t)$

Output: Probability : $P(Me_t | TP_t, Re_t)$

5 L'algorithme pas à pas

Afin de faciliter l'interprétation algorithmique, nous proposons ici de l'étudier sur un exemple volontairement réduit (cf. données historiques annexée B).

Rappelons que le calcul du CLFI se réalise sur la base des l'équation 5.16, page 87 :

$$CLFI = P(Re_t | R_t, C_t, P_t, TP_t, Me_t, PM_t, CM_t, Re_{t-1}) \quad (6.1)$$

$$CLFI = P(Re_t | \theta_t, Re_{t-1}) = \frac{P(Re_t | Re_{t-1}) \cdot P(Re_t | \theta_t)}{P(Re_t)} \quad (6.2)$$

Reste donc à calculer les éléments :

- $P(Re_t | \theta_t) = P(Re_t | R_t, C_t, P_t, TP_t, Me_t, PM_t, CM_t) = ?$
- $P(Re_t | Re_{t-1}) = ?$
- $P(Re_t) = ?$

Pour illustrer la méthode apprentissage des paramètres, nous nous proposons de considérer le cas particulier suivant :

Instant t : $Re_t = OK$; $R_t = 0.36245$; $C_t = N$; $P = EF.AC.PA$; $TP_t = Pass$; $Me_t = Pass$; $PM_t = 7$; $CM_t = 4$

Nous implémentons comme suit :

Apprentissage

Évaluation statistique de $P(Re)$:

$$P(Re = OK) = 0.4464$$

$$P(Re = NotOK) = 0.5536$$

Évaluation conditionnelles de :

$$P(R_t = 0.36245 | Re_t = OK) = 0.71501$$

$$P(C_t = N | Re_t = OK) = 0.50134$$

$$P(P_t = EF.AC.PA | Re_t = OK) = 0.099686$$

$$P(TP_t = TypeB | Re_t = OK) = 0.4888$$

$$P(PM_t = 7 | Re_t = OK) = 0.096326$$

$$P(CM = 4 | Re_t = OK) = 0.1017$$

$$P(R_t = 0.36245 | Re_t = Not_OK) = 0.2850$$

$$P(C_t = N | Re_t = Not_OK) = 0.4921$$

$$P(P_t = EF.AC.PA | Re_t = Not_OK) = 0.0983$$

$$P(TP_t = TypeB | Re_t = Not_OK) = 0.5013$$

$$P(PM_t = 7 | Re_t = Not_OK) = 0.1033$$

$$P(CM = 4 | Re_t = Not_OK) = 0.0957$$

Évaluation de $P(Me|TP, Re)$:

$$P(Me_t | TP_t, Re_t) = \frac{P(Re_t, TP_t, Me_t)}{\sum_{Me_t^r} P(TP_t, Re_t, Me_t^r)}; Me_t^r = \{Pass, NotPass\} \quad (6.3)$$

Soit en appliquant l'algorithme 3, page 95 :

$$\begin{aligned}
P(Re_t = OK, TP = TypeB, Me = Pass) &= 0.0967 \\
P(Re_t = OK, TP = TypeB, Me = Not_Pass) &= 0.0133 \\
P(Re_t = Not_OK, TP = TypeB, Me = Pass) &= 0.1211 \\
P(Re_t = Not_OK, TP = TypeB, Me = Not_Pass) &= 0.0142 \\
P(Me_t = Pass | TP_t = TypeB, Re_t = OK) &= \frac{0.0967}{0.0967+0.0133} = 0.8790 \\
P(Me_t = Pass | TP_t = TypeB, Re_t = Not_OK) &= \frac{0.1211}{0.1211+0.0142} = 0.8950
\end{aligned}$$

et $P(Re_t | Re_{t-1})$

$$P(Re_t | Re_{t-1}) = \frac{N(i, j)}{\sum_k N(i, k)}$$

avec les résultats :

		Re_{t-1}	
		OK	NotOK
Re_t	OK	0.42886	0.57114
	NotOK	0.33738	0.66272

TABLE 6.1 – Matrice de transition états

Calcul en ligne du CLFI

La probabilité $P(Re)$ à l'instant t : $P(Re = OK) = 0.4464$

Nous pouvons calculer la probabilité $P(Re_t | Re_{t-1})$ dans l'instant t : $P(Re_t = OK | Re_{t-1} = OK) = 0.42886$

Nous examinons la probabilité : $P(Re_t | \theta_t) =$
 $P(Re_t | R_t, C_t, P_t, TP_t, Me_t, PM_t, CM_t)$

$$\begin{aligned}
P(Re_t | \theta_t) &= P(Re_t | R_t, C_t, P_t, TP_t, Me_t, PM_t, CM_t) \\
&= \frac{P(Re_t) \cdot P(R | Re_t) \cdot P(C | Re_t) \cdot P(P | Re_t) \cdot P(TP | Re_t) \cdot P(Me | TP, Re_t) \cdot P(PM | Re_t) \cdot P(CM | Re_t)}{\sum_{Re_j} P(\theta_t, Re_j)} \quad (6.4)
\end{aligned}$$

Pour calculer la probabilité $P(Re_t | \theta_t)$ dans l'équation 6.4, nous utilisons les probabilités $P(Re)$, $P(C | Re)$, $P(P | Re)$, $P(TP | Re)$, $P(Me | TP, Re)$, $P(PM | Re)$, $P(CM | Re)$ à l'instant t .

Ainsi, à partir de l'équation (6.4), nous pouvons calculer :

$$P(Re_t | \theta_t) = \frac{6.7150 * 10^{-5}}{6.7150 * 10^{-5} + 3.3856 * 10^{-5}} = 0.6648$$

Nous calculons le CLFI utilisant l'équation 6.2 à l'instant t :

$$CLFI = P(Re_t | \theta_t, Re_{t-1}) = \frac{0.42886 * 0.6648}{0.4464} = \frac{0.2851}{0.4464} = 0.6387$$

Ainsi à l'instant t si nous considérons les paramètres de l'équipement : $Re_t = OK$; $R_t = 0.36245$; $C_t = N$; $P = EF.AC.PA$; $TP_t = Pass$; $Me_t = Pass$; $PM_t = 7$; $CM_t = 4$, la confiance calculé du compte-rendu ($Re = OK$) est égal à 63,87%.

6 Conclusion

Ce chapitre s'est attaché à présenter les différents algorithmes de calcul que nous proposons pour estimer le CLFI. Structurés selon deux étapes essentielles, l'une effectuée hors ligne (apprentissage) et l'autre en ligne (calcul dynamique du CLFI), l'approche se prête bien à une intégration progressive en atelier. Elle fournit ainsi un support à l'apprentissage et au calcul qui peut être considéré soit comme un outil indépendant, soit dans une approche de diagnostic automatisée telle que celle proposée dans (Deschamps, 2007).

Algorithmes et modèles étant désormais proposés, la dernière partie de ce mémoire va s'attacher à confronter notre approche à un exemple d'application.

Troisième partie

Exemple d'application

Chapitre 7

Cas d'étude

1 Introduction

Dans le cadre de cette partie, nous nous proposons de confronter notre approche à un cas d'étude réel. Pour ce faire, nous avons profité du contexte de collaboration avec la société STMicroelectronics Crolles et G-SCOP formalisé au travers du projet européen IMPROVE¹.

Comme nous allons le voir rapidement, ce secteur industriel est particulièrement adapté au test d'une telle approche ne serait-ce que de par sa complexité et différents niveaux d'incertitudes constatés.

Aussi, dans ce chapitre, nous nous proposons de présenter le cas d'étude considéré. Il s'agira dans un premier temps de présenter brièvement les caractéristiques principales de ce type de production. Après quoi, nous proposons une analyse détaillée du processus de production qui nous amènera à mettre en exergue les propriétés de complexité et d'incertitude. Enfin, ce chapitre se terminera par la présentation du SAP que nous considérons pour ce cas d'étude.

2 Système de production de Semi-Conducteur

2.1 Généralités

Le marché du semi conducteur est en forte croissance depuis quelques années avec l'évolution considérable des technologies mises à disposition du consommateur (i.e. téléphone, portable, ordinateur,...).

Cette évolution se traduit en particulier par une miniaturisation importante des composants électroniques atteignant des taux de réduction de taille de 13% par an (cf. figure 7.1), les prévisionnistes annonçant un maintien de ce taux au moins jusqu'au milieu de cette décennie.

1. Le projet Européen IMPROVE (*Implementing Manufacturing science solutions to increase equipment pROductiVity and fab pERformance*)

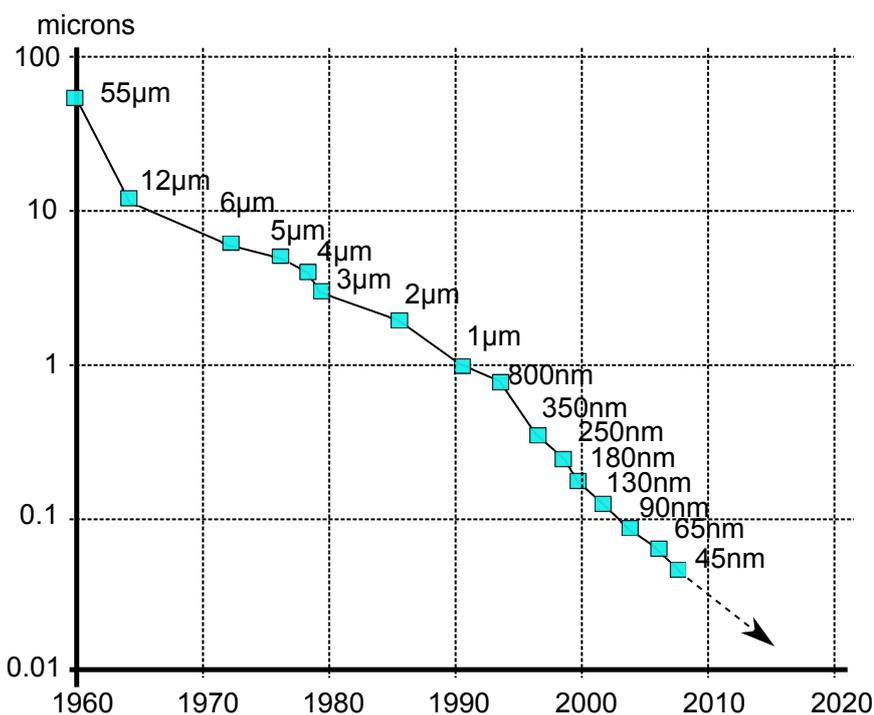


FIGURE 7.1 – Taille minimale des transistors (*Roadmap SIA 1999*)

En parallèle à cette miniaturisation, une augmentation de la taille de disques de siliciums (aussi appelée Wafer) sur lesquels les composants électroniques sont gravés a été opérée passant de diamètres de 100mm, il y a quelques années à des diamètres de 300mm aujourd'hui.

Il en résulte une maîtrise des process de fabrication de plus en plus difficile qui a naturellement participé à l'émergence du contrôle avancé de tels procédés (Advanced Process Control - APC).

2.2 Process de fabrication

La fabrication du wafer s'appuie sur une série d'étapes de traitement importantes (Quirk et Serda, 2001), en moyenne 700 opérations sur un parc de 200 machines.

Nous avons restitué dans la figure 7.2 les macro-étapes de cette fabrication depuis la matière première (silice) au boîtier (microprocesseur).

Ces étapes clés sont Physical Vapor Deposition (PVD) et Chemical Vapor Deposition (CVD), photolithographie, gravures par plasma (Plasma Etch), Rapid Thermal Processing (RTP), et polissage mécano-chimique (CMP) (voir figure 7.3).

Durant la fabrication, un cristal de silicium est étiré lentement afin de former un cylindre appelé lingot. Ce dernier est ensuite découpé en disques appelés *wafers*. Chacun d'entre eux est ensuite poli pour obtenir la qualité de surface requise.

Un procédé de dépôt de substrat est par la suite appliqué au disque poli afin de fournir une surface propre (non contaminée) prête à accueillir les autres process de fabrication. Ainsi, le wafer est exposé à de très hautes températures afin dans un premier

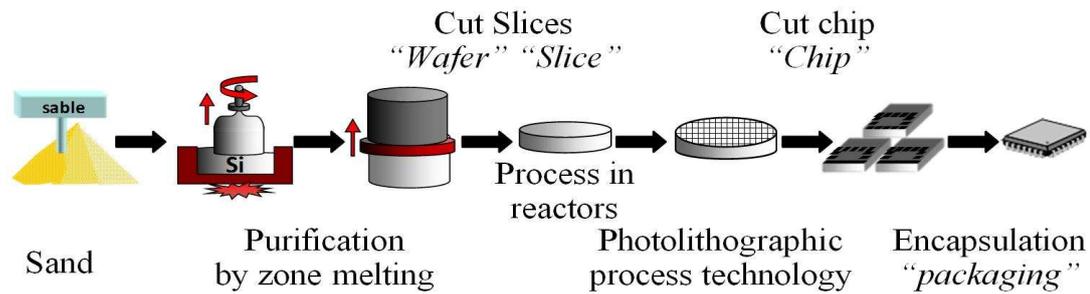


FIGURE 7.2 – Vue simplifiée des étapes de fabrication d'un microprocesseur

temps de former une couche (SiO_2) diélectrique (oxydation). Le wafer est alors revêtu d'un matériau photo-résistant. Un processus de lithographie peut alors être lancé afin de réaliser un masque sur le matériau photo-résistant : la lumière durcit les portions exposées. Un processus de gravure permet alors d'enlever l'oxyde (SiO_2) des parties non durcies, reste alors le motif endurci sur le wafer. Un processus de diffusion et implantation est ensuite appliqué afin de déposer des ions (dopage) sur parties exposées. Différentes régions au caractère de conductivité différentes sont alors obtenues. Ce processus de lithographie est répété autant de fois que le nécessite les spécifications du microprocesseur considéré afin de former les transistors requis. Un processus de métallisation est ensuite lancé afin de déposer une couche d'aluminium ou de cuivre sur le wafer. L'excès de métal est ensuite enlevé par un autre processus de lithographie afin de conférer l'inter-connectivité désirée. Une autre couche d'oxyde diélectrique est déposée sur l'aluminium ou cuivre pour isoler la première couche d'aluminium de la couche suivante. A ce point, chaque wafer est poli utilisant un polissage mécano-chimique (CMP) pour obtenir un wafer à surface lissée. Puis la couche d'aluminium (cuivre, titane) suivante est déposée, modelée, et gravée afin de créer une autre couche. Le processus est répété en autant de couches inter-connectées que nécessaire pour la conception du chip. In fine, pour fabriquer un wafer, il se sera écoulé entre 56 et 60 jours, pendant lesquels plus de 200 opérations/produit auront été effectuées.

2.3 Process de production et maîtrise de la qualité de fabrication

Comme nous venons de le voir, le processus de production des wafers se révèle être complexe et particulièrement sensible ne serait-ce que sur le plan économique :

- Coût d'un wafer nu : 100\$
- Coût d'un wafer en sortie d'usine : 1000\$-15000\$

Aussi, était-il nécessaire de mettre en place un processus de surveillance adapté au contexte. Ainsi, au delà des machines de traitement complexes, des machines de métrologies ont été implantées afin de tester les produits durant le cycle de fabrication. La figure 7.4 les représente.

Une analyse retracée dans la figure 7.5, des rejets des produits ayant subi des tests permettent de révéler que les causes principales des produits jugés *Out of control* (OC)

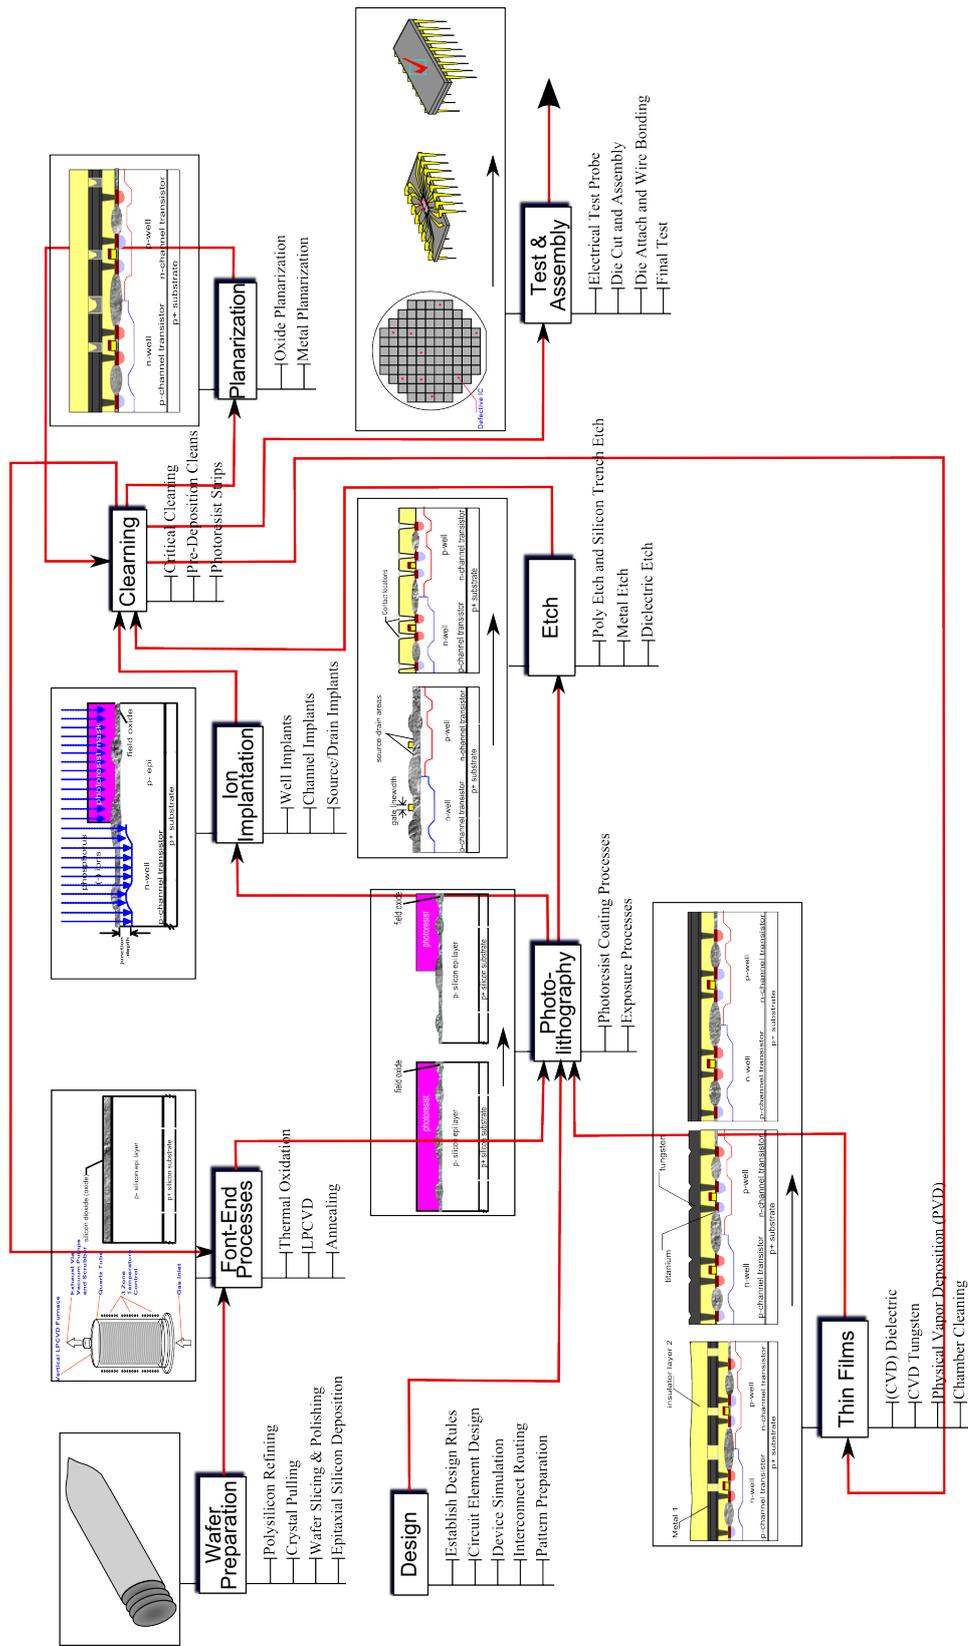


FIGURE 7.3 – Processus global de production semi-conducteurs

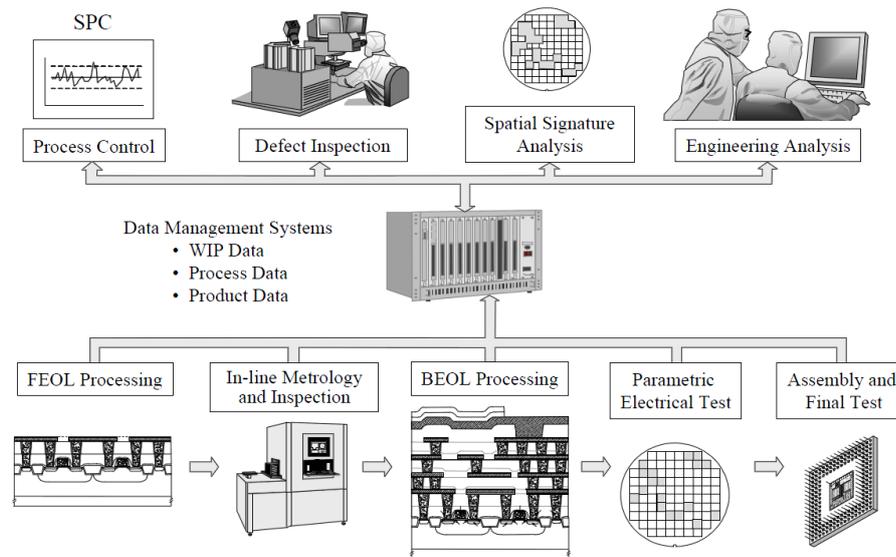


FIGURE 7.4 – Métrologie dans la système de production (Quirk et Serda, 2001)

sont issues des dérives non maîtrisées des équipements de production, ce qui montre à quel point ici l'approche que nous proposons est pertinente : les équipements de production attestent qu'un produit a été correctement traité alors que ce n'est pas le cas. Le besoin de localiser, suite à la détection et un produit hors contrôle, l'équipement à l'origine du défaut est de fait crucial pour :

- lancer une maintenance corrective sur la bonne machine ,
- améliorer ainsi les rendements de production minimisant les temps d'arrêts et de dérives.

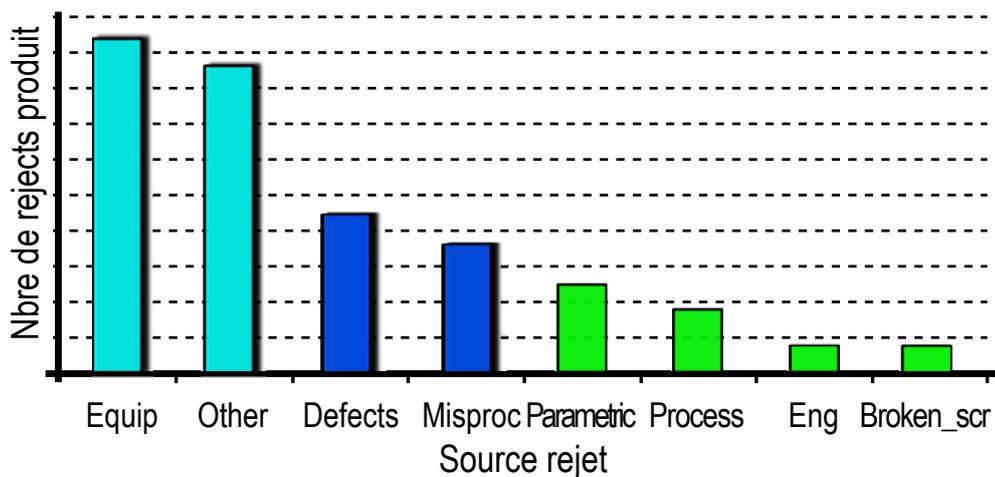


FIGURE 7.5 – Nombre de rejets classés par source (Mili, 2009)

3 Procédures de contrôle dans le domaine du semi-conducteur

D'un point de vue industriel et afin de contribuer à limiter les pertes et donc les rendements les industriels ont intégré différentes techniques de contrôles basées sur l'exploitation des différentes données du site de production, que ce soient celles issues de la métrologie, du monitoring, etc.. Ces approches font parties de ce que l'on appelle l'Advanced Process Control (APC) (Martinez et Edgar, 2006), (Sematech, 1997, 1996) et sont généralement structurées selon trois blocs distincts tel que l'expose la figure 7.6 : le Run 2 Run, la FDC, la métrologie (SPC).

Notons que ces approches se localisent dans la structure CIM au sein des deux premiers niveaux de l'architecture tel que montré dans la figure 7.7 (Hill et Nettles, 1997; Baweja et Ouyang, 2000; Sonderman et Spanos, 2005). Nous nous proposons dans ce qui suit de détailler ces trois blocs.

3.1 Contrôle de Run to run

La Figure 7.8 s'agit de boucles de régulation qui ont pour objectif de garantir la stabilité des processus de fabrication durant toute la vie de l'équipement (Martinez et Edgar, 2006). Ces boucles assurent la liaison entre la SPC de la FDC.

3.2 Contrôle de FDC

Correspondant à *Fault Detection and Classification*, ce système permet de suivre en temps réel l'évolution des paramètres des équipements (température, pression, etc) (Scanlan et O'Leary, 2003). Ainsi, durant les étapes de fabrication, les paramètres équipement sont collectés permettant ainsi de mieux maîtriser les anomalies de fonctionnement.

3.3 Contrôle de SPC

SPC correspond au *Statistical Process Control*. Un tel système permet de contrôler les lignes de production à l'aide d'indicateurs de performance comme par exemple l'épaisseur, la pression, le centrage (Martinez et Edgar, 2006). Le SPC est généralement appliqué sur trois types de mesures :

- Les mesures physiques qui permettent de vérifier avec retard la conformité de ce qui a été fait par rapport à ce qui a été demandé.
- Les mesures paramétriques, réalisées sur tous les wafers d'un lot. Nous parlerons de PT (Parametric Tests).
- Les mesures électroniques faites sur des produits finis et donc en fin de ligne. Nous parlons de EWS (Electrical Wafer Sorting).

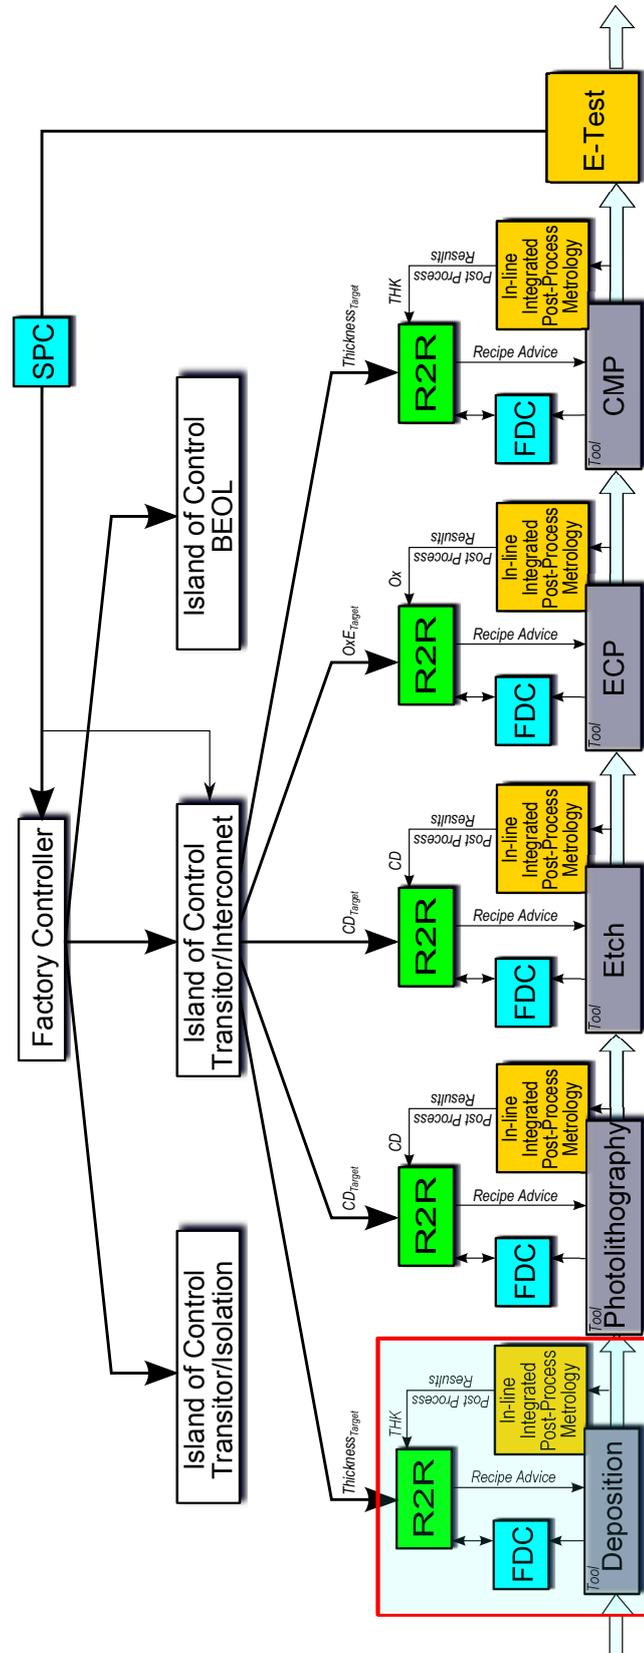


FIGURE 7.6 – Contrôle des processus de semi-conducteurs

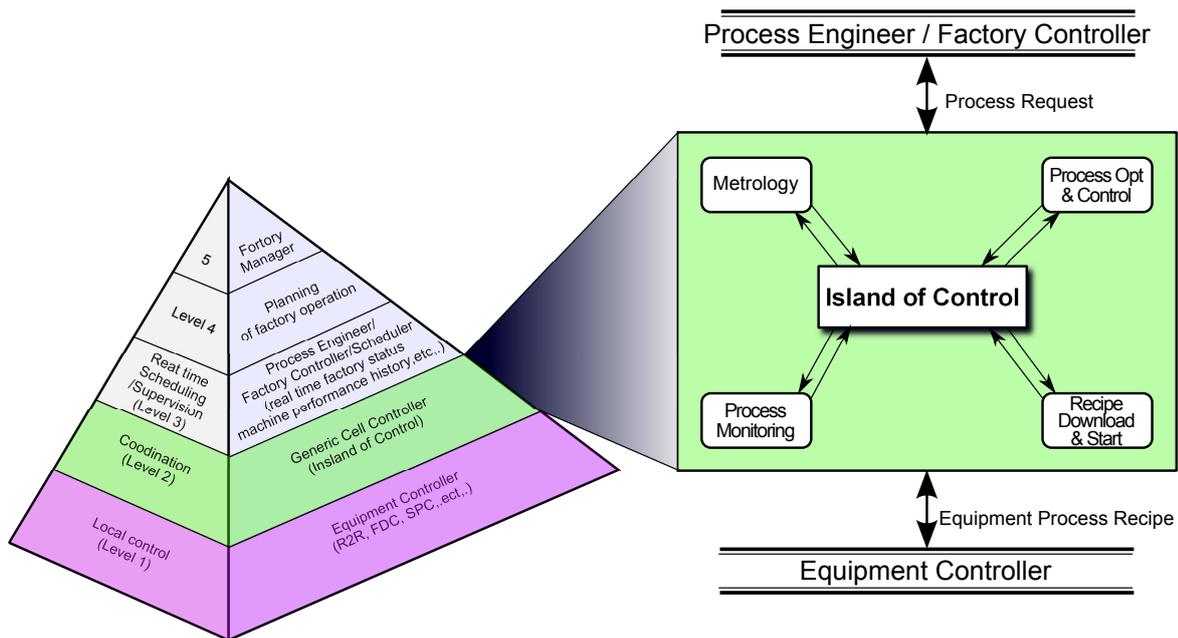


FIGURE 7.7 – Architecture CIM dans la production de semi-conducteurs

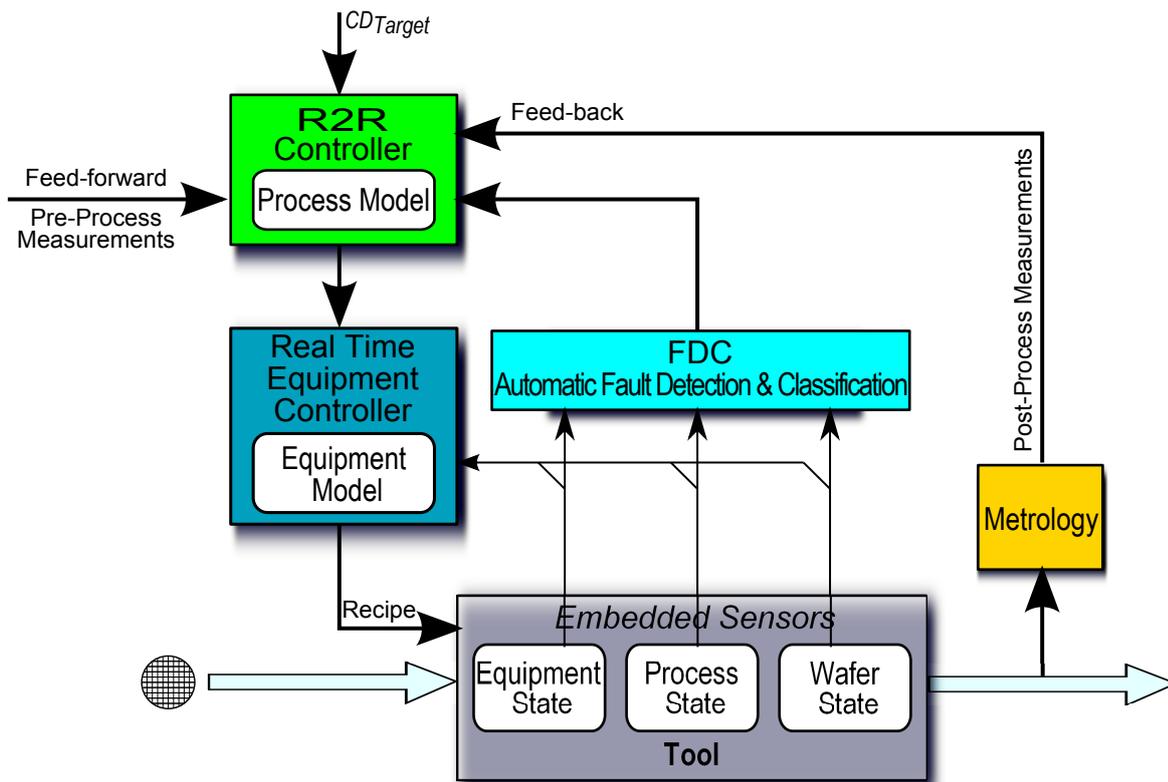


FIGURE 7.8 – Contrôle de Run to Run

Ces types de mesures sont associées à deux types de limites :

- Les limites de spécification à ne pas franchir pour un bon fonctionnement des circuits.

- Les limites de contrôle fixant des frontières qualifiant le bon fonctionnement de l'opération en cours.

4 Conclusion

Ce chapitre nous a permis de présenter le cadre d'application de notre approche, à savoir les ateliers semi-conducteurs. Considérés comme fortement complexes et incertains, ils se prêtent parfaitement à notre étude. Afin de mieux appréhender ce type de process, nous avons présenté comment un produit était fabriqué et quels étaient les problèmes posés au niveau de sa fabrication. Nous avons ainsi montré que la majorité des défauts produits détectés étaient issus des dérives équipement montrant à quel point l'approche proposée se prête bien à ce type de process.

Afin de proposer une intégration lucide de notre approche dans ce milieu, le reste du chapitre s'est attaché à exposer les approches industrielles à ce jour déployées pour limiter ces dérives. Notre approche se positionne en tant que brique supplémentaire à celles déjà mises en pratique afin de contribuer à accroître les rendements de production en améliorant la localisation des équipements de production à l'origine possible du défaut.

Chapitre 8

Modélisation et Résultats

1 Introduction

Dans le cadre de ce chapitre nous nous proposons d'appliquer notre approche à un cas d'étude inspiré d'un process industriel réel : un atelier de production de semi-conducteurs.

Aussi, nous reprendrons dans un premier temps le système de pilotage retenu à titre d'exemple ainsi que les bases de données considérées. Après quoi, nous développerons l'étape de modélisation qui nous amènera naturellement à analyser le comportement des algorithmes de calcul que nous avons développés. La section 4 sera ensuite consacrée à l'évaluation de notre approche sur la base de différents scénarios. Enfin, la dernière section de ce chapitre montera comment notre approche s'intègre dans le cadre d'une analyse diagnostique permettant de localiser au mieux les équipements à l'origine possible du défaut produit détecté.

2 Système de production considéré

L'exemple retenu ici est celui introduit dans le chapitre précédent (cf. la section 3, page 106) et repris dans la figure 8.1. Cet atelier est structuré autour de cinq équipements de fabrication et un équipement de métrologie. Chacun équipements considérés dispose des moyens de commande et de contrôle (R2R, FDC, SPC) et l'ensemble est coordonné par un niveau de coordination intégrant le système de commande ainsi qu'un bloc de diagnostic et de calcul du CLFI.

Les ordres de fabrications émis par le système de coordination correspondent aux différentes étapes de process requises : *Thickness* pour l'équipement de *Deposition*, *CD* pour l'équipement *Photolithography*, etc.,

Afin d'alimenter la modélisation du CLFI et donc de mener l'apprentissage requis, il est nécessaire de pouvoir avoir accès aux données historiques de production. Pour ce faire, nous nous sommes appuyés sur celles de FDC, SPC, R2R mises à disposition par notre partenaire industriel (Hubac et al., 2010). La figure 8.2 présente ces bases

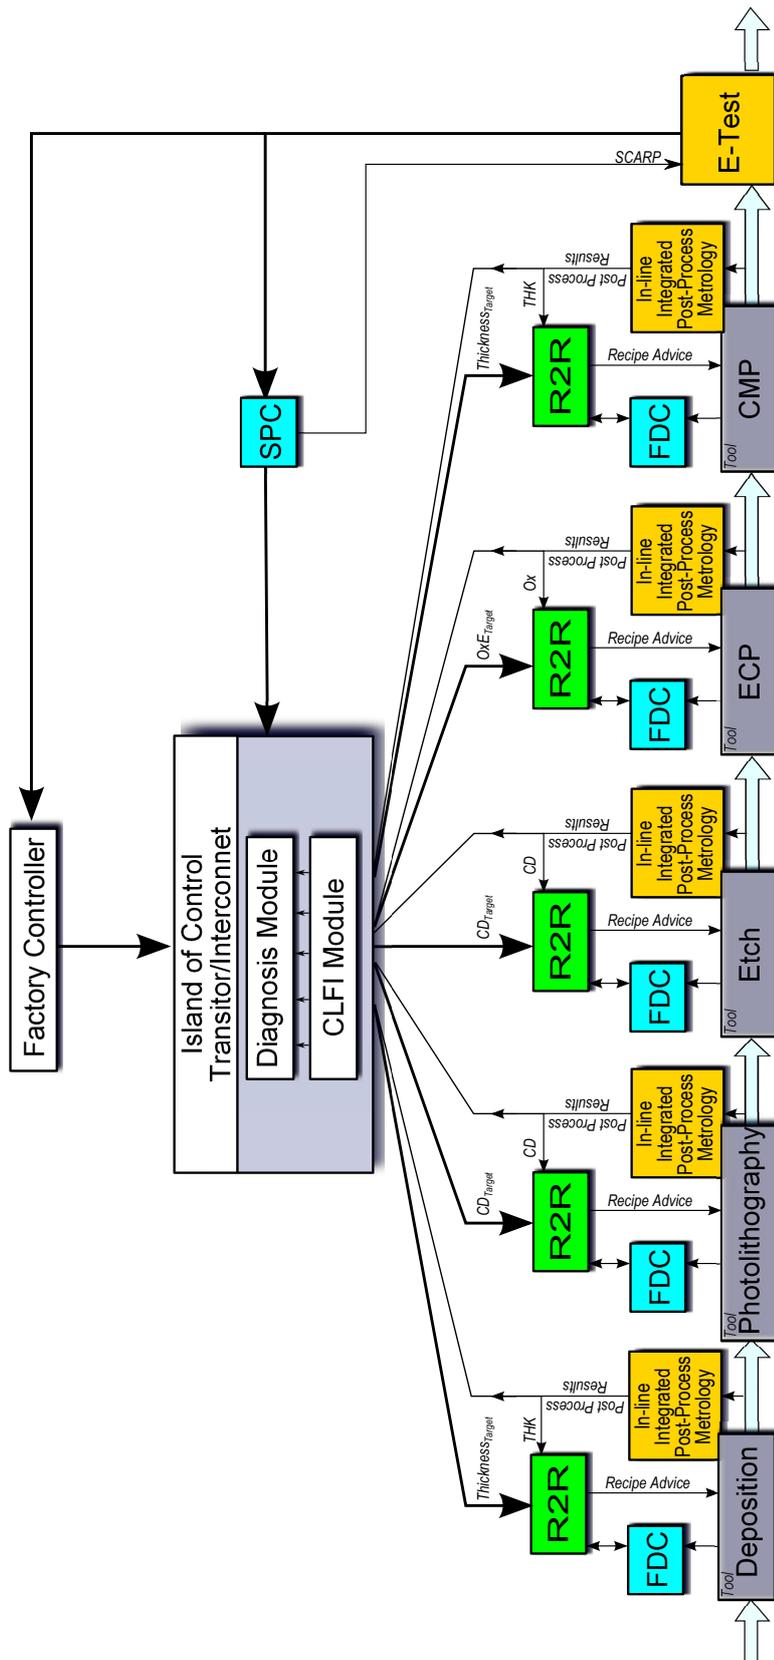


FIGURE 8.1 – Cas d'étude considéré

de données et montre également la synthèse nécessaire à la mise en forme des deux tables de données requises par notre approche : la table de vie de l'équipement, la table de métrologie des produits.

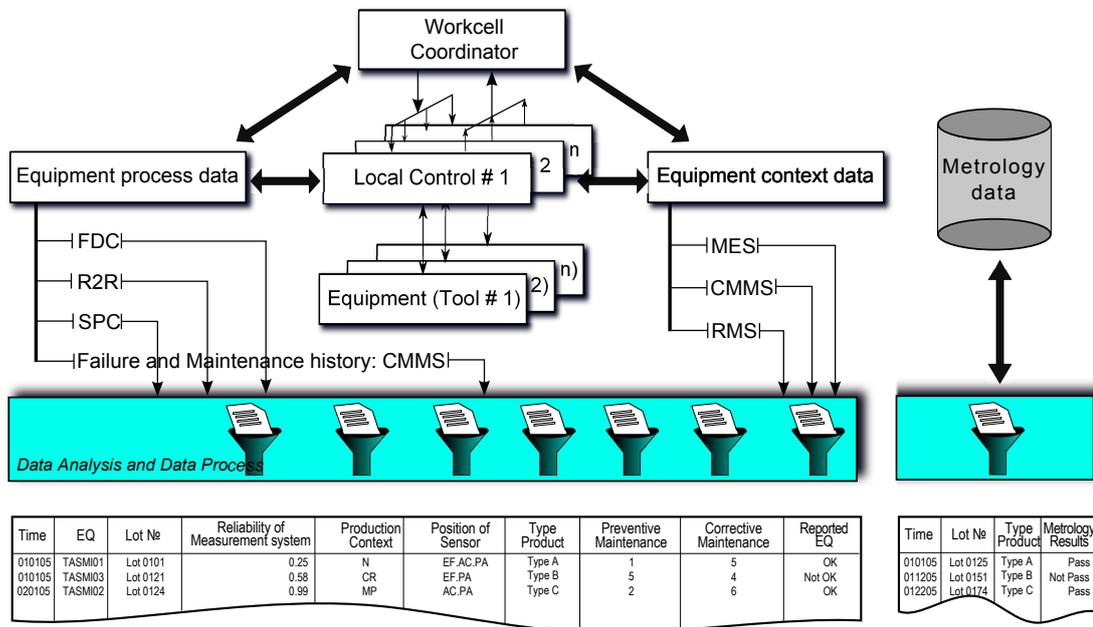


FIGURE 8.2 – Bases de données

Pour des raisons de confidentialité, l'accès aux données a été volontairement limité. L'importance ici étant mis sur la nature des colonnes proposées ; l'approche peut naturellement être appliquée à d'autres contextes de production.

3 Modélisation

Sur la base du SAP considéré figure 8.1 nous nous sommes focalisés ici sur l'équipement de *Photolithographie* et sur les données historiques le concernant.

A partir de ces données que le lecteur peut trouver dans l'annexe B, nous nous proposons de développer l'approche de modélisation.

3.1 Modèle

Nous avons ici proposé de développer le modèle le plus complet soumis dans le cadre de notre approche, à savoir le modèle Bayésien augmenté et dynamique dont la structure a été présentée dans la section 4, page 84 et repris ici dans la figure 8.3. Ce modèle a pour fondement l'équation 8.1 :

$$P(Re_t | \theta_t, Re_{t-1}) = \frac{P(Re_t | Re_{t-1}) \cdot P(Re_t | \theta_t)}{P(Re_t)} \tag{8.1}$$

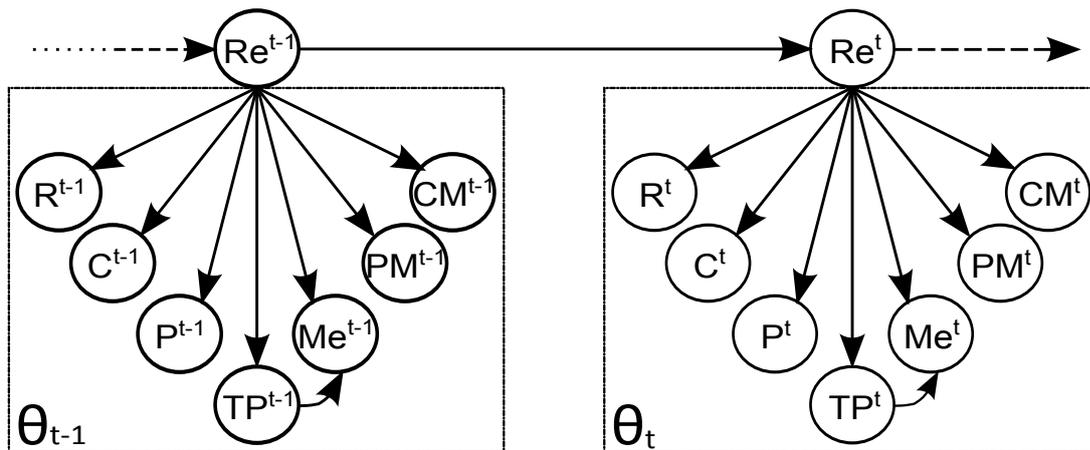


FIGURE 8.3 – Modèle CLFI pour un Système de production Semi-Conducteur

A partir du modèle CLFI et les bases de données présentées dans la section 2, nous appliquons l’algorithme 1, page 93 pour calculer le CLFI de l’équipement. Pour ce faire, les étapes suivantes sont requises.

3.2 Processus d’apprentissage

Tout d’abord, nous exécutons l’étape d’apprentissage de bases de données pour calculer les différentes probabilités tel que montrée dans la figure 8.4.

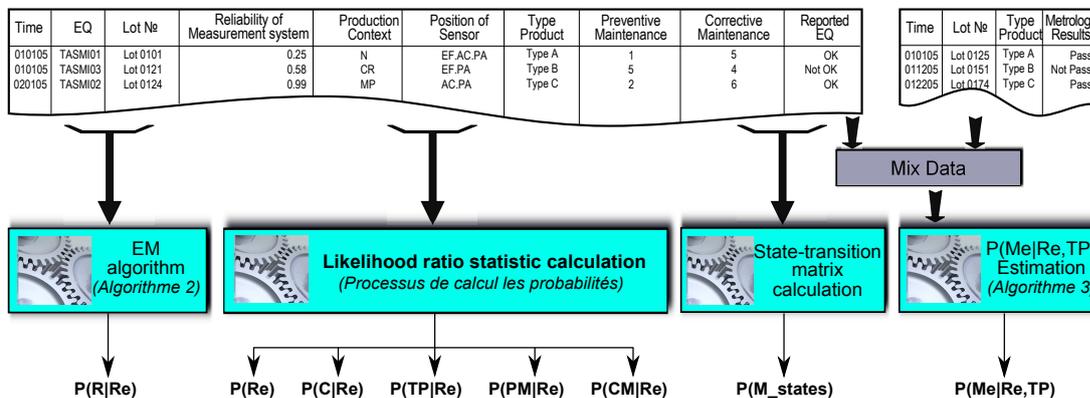


FIGURE 8.4 – Processus d’apprentissage de Bases de Données

Chaque partie des bases de données nous permet d’obtenir un nœud dans le modèle RBDMC. Il nous faut donc calculer les probabilités $P(Re)$, $P(C|Re)$, $P(TP|Re)$, $P(PM|Re)$, $P(CM|Re)$, $P(Me|Re, TP)$ et $P(M_states)$.

3.2.1 Processus de calcul des probabilités : $P(C|Re)$, $P(TP|Re)$, $P(PM|Re)$, $P(CM|Re)$

Comme nous l’avons vu dans les chapitres précédents, il s’agit ici de mener des analyses statistiques essentiellement axées sur des calculs d’occurrence de para-

mètres.

Afin d'illustrer ce principe, nous invitons le lecteur à se reporter à la figure 8.5 et en particulier à la ligne 68 du code que nous avons développé. La fonction $P_Production$ nous permet ici d'évaluer la variable $P_Context$. L'algorithme de cette fonction comptabilise le nombre de changements de contexte de production (par exemple : CR, MP, N) au sein de la colonne de contexte de la base de données. Ensuite, nous combinons simultanément ces données avec les informations dans la colonne de compte-rendu $Re=OK$, ou $Re = Not OK$ dans l'objectif de déterminer la probabilité de $P(C|Re)$ (cf. ligne 10 du code de la *function*).

```

66 String_context = Filter_data(Data_M_fabrication(:,3));
67 Context=get(Edit_C,'string');
68 P_Context = P_Production(NN,Data_M_fabrication(:,3),Data_M_fabrication(:,8),String_context,String_reported);

Command Window of MATLAB
>> String_context
String_context =
'CR'
'MP'
'N'
>> String_reported
String_reported =
'Not Ok'
'Ok'
>> P_Context
P_Context =
0.3300 0.0546
0.2958 0.2266
0.2092 0.1266

1 function P_Prod = P_Production(n,data_input_1,data_input_2,index_data,index_reported)
2 a=0;
3 l=length(index_reported);
4 r=length(index_data);
5 Temp_Metro=zeros(r,l);
6 P_Prod=zeros(r,l);
7 for j=1:l
8 for k=1:r
9 for i=1:n
10 if strcmp(data_input_1(i),index_data(k)) && strcmp(data_input_2(i), index_reported(j))
11 a=a+1;
12 Temp_Metro(k)=a;
13 P_Prod(:,j)=Temp_Metro';
14 end
15 end
16 a=0;
17 end
18 end
19 P_Prod=P_Prod/n;

```

FIGURE 8.5 – Processus de calcul de la probabilité $P(C|Re)$

3.2.2 Calcul de la probabilité $P(R|Re)$

L'algorithme développé ici s'appuie sur les principes développés dans la section 4.1 du chapitre 6, page 94. Le programme correspondant est montré dans la figure 8.6. Il permet de calculer la fiabilité du système de captage embarqué eu sein de l'équipement de production considéré en fonction du temps, en le corrélant aux résultats des comptes-rendus. Aussi ils combinent algorithme de fiabilité et algorithme EM que nous retrouvons ligne 41 à 51 pour l'étape E et ligne 53 à 73 pour l'étape M.

Les résultats $P(R|Re)$ obtenus sont exposés dans la figure 8.7 où le lecteur pourra également visualiser les paramètres τ_i, μ_i, σ_i .

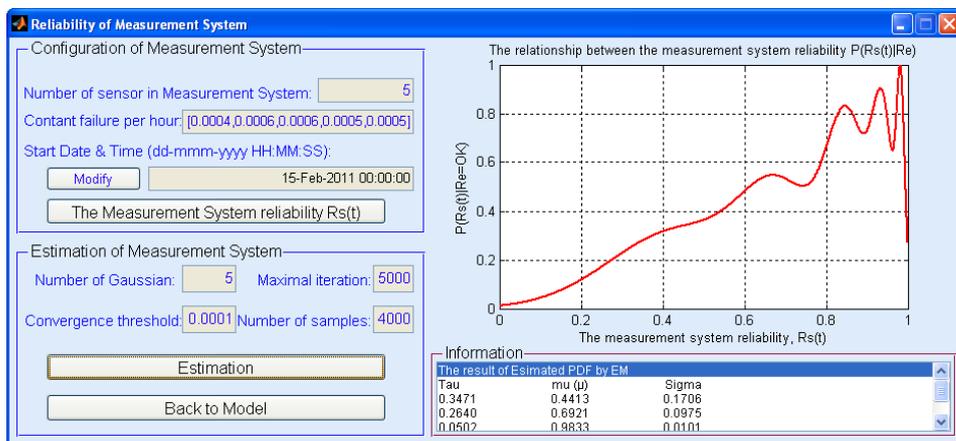
3.2.3 Calcul de la probabilité $P(Me|Re, TP)$

Ce programme met en œuvre l'équation 5.6, page 84 ainsi que l'algorithme 3, page 95. Le calcul de $P(Me, Re, TP)$ est effectué selon 2 étapes : fusion de données historiques pour donner la probabilité $P(Me, Re, TP)$ et puis calculer $P(Me|Re, TP)$.

```

41 - for K=1:30
42 -     while 1
43 -         tau_old= tau;
44 -         mu_old= mu;
45 -         sigma_old=sigma;
46 -         % pmx(m,x|param)
47 -         pmx=zeros(M,N);
48 -         for cm=1:M ...
51 -             p = pmx ./ repmat(sum(pmx), M, 1);
52 -         % M step: ML estimate the parameters of each class (i.e., p, mu, sigma)
53 -         for j=1:M...
58 -             t=max([norm( tau_old- tau)/norm( tau_old);
59 -                   norm( mu_old- mu)/norm( mu_old);
60 -                   norm(sigma_old-sigma)/norm(sigma_old)]);
61 -             c=c+1;
62 -             if t<epsilon
63 -                 break;
64 -             end
65 -             if c>Nit
66 -                 disp('reach maximal iteration')
67 -                 break;
68 -             end
69 -             %pause
70 -         end
71 -         Value_tau_int(:,K)=tau;
72 -         Value_mu_int(:,K)=mu;
73 -         Value_sigma_int(:,K)=sigma;
74 -         if K==29
75 -             tau=mean(Value_tau_int)'; % normalize, such that sum(a_EM)=1
76 -             mu=mean(Value_mu_int)';
77 -             sigma=mean(Value_sigma_int)';
78 -         end
79 -     end

```

FIGURE 8.6 – Programme de calcul de la probabilité $P(R|Re)$ FIGURE 8.7 – Résultats obtenus de $P(R|Re)$

La figure 8.8 illustre l'étape de fusion de données historiques en se focalisant sur les produits de type A (cf. la ligne 49 du code). Afin de valider les informations à l'issue des compte-rendus, si à l'instant t le résultat de l'équipement de Métrologie donne un résultat *Pass*, alors tous les produits de (*TypeA*) sont assignés à *Pass* pour les instants précédents jusqu'au moment où il y a eu un changement. Le principe reste le même pour *NotPass* (cf. lignes 52 et 53 de la figure 8.8).

Ensuite, nous calculons la probabilité $P(Me, Re, TP)$ en nous basant sur ces nouvelles données (cf. la ligne 5 du code dans la figure 8.9). A Partir de cela, nous estimons la probabilité $P(Me|Re, TP)$ à la ligne 6 de la figure 8.9.



FIGURE 8.8 – Processus de fusion des données

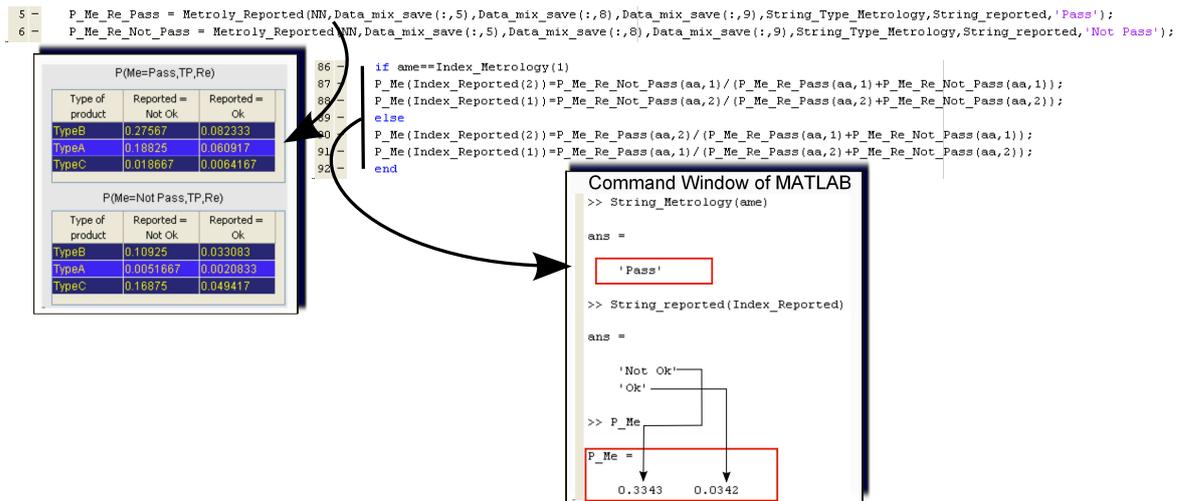


FIGURE 8.9 – Processus de calcul la probabilité $P(Me|Re, TP)$

3.3 Processus de calcul en ligne du CLFI

Le calcul du CLFI est fait en ligne à chaque occurrence d'un compte rendu. Il s'agit donc pour cela de calculer les probabilités $P(Re_t|Re_{t-1})$, et $P(Re_t|\theta_t)$ tel que rappelé par l'équation 8.1, page 113.

La figure 8.10 illustre le code correspondant au calcul de $P(Re_t|Re_{t-1})$. Les calculs se font sur la base des résultats de l'apprentissage où $P(M_states)$ permet de trouver $P(Re_t|Re_{t-1})$ (cf. les lignes de 65 à 77 du code).

La figure 8.1 illustre quant à elle le calcul en ligne du CLFI. Les lignes 102 et 109 reflètent de calcul de $P(Re_t|\theta_t)$ et les lignes 103 et 110 pour $P(Re_t|Re_{t-1}, \theta_t)$.

Comme nous pouvons le constater dans la section 3 du chapitre 6, page 92,

cette étape exécute des tâches à un instant t tel que : le calcul de la probabilité $P(Re_t|Re_{t-1})$, et $P(Re_t|\theta_t)$ afin de calculer en ligne du CLFI par l'équation 8.1, page 113.

```

55 %                               Rt-1
56 %                               Ok     Not Ok
57 %   R(t )   Ok     b     d
58 %                               Not Ok a     c
59
60 -   if isempty(Parameter_disp)
61 -       Ret_1='OK';
62 -   else
63 -       Ret_1=Parameter_disp(size(Parameter_disp,1),8);
64 -   end
65 -   if strcmp(Reported,'Ok')
66 -       if strcmp(Ret_1,'Not Ok')
67 -           P_Ret_1_Ret=M_Ret_1_Ret(1,2);
68 -       else
69 -           P_Ret_1_Ret=M_Ret_1_Ret(1,1);
70 -       end
71 -   else
72 -       if strcmp(Ret_1,'Not Ok')
73 -           P_Ret_1_Ret=M_Ret_1_Ret(2,2);
74 -       else
75 -           P_Ret_1_Ret=M_Ret_1_Ret(2,1);
76 -       end
77 -   end
    
```

FIGURE 8.10 – Programme de calcul de la probabilité $P(Re_t|Re_{t-1})$ à l'instant t

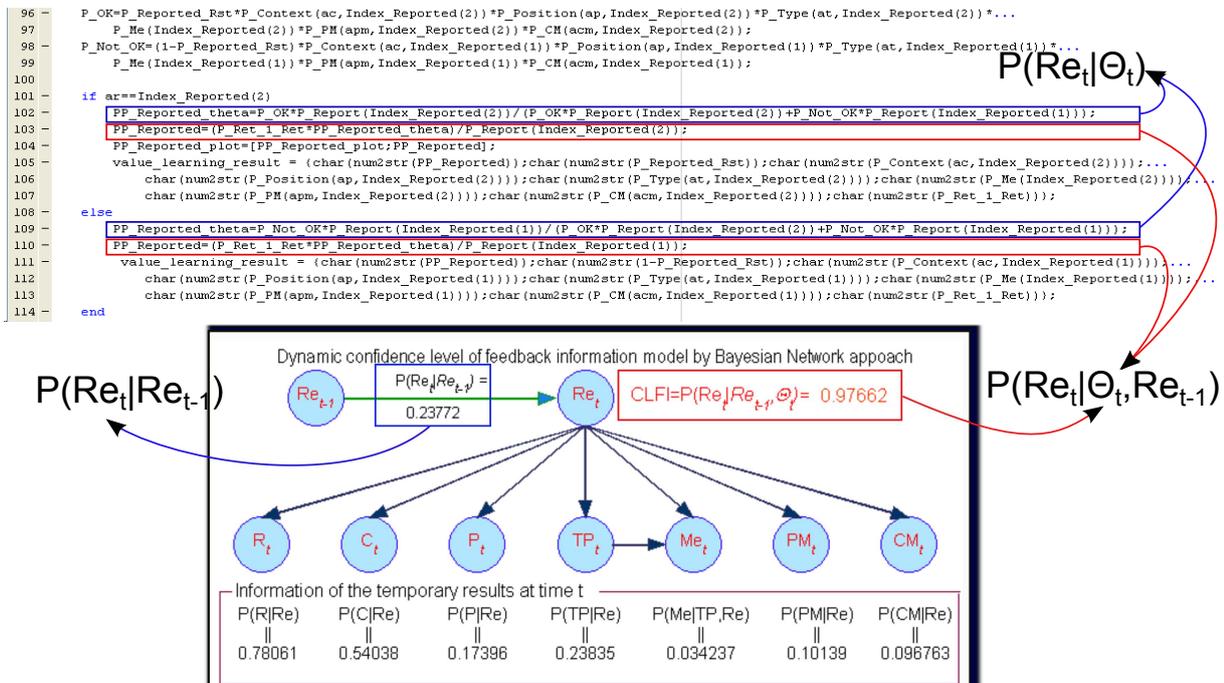


FIGURE 8.11 – Programme de calcul du modèle CLFI

3.4 Interface de calcul du CLFI

Afin de faciliter l'utilisation de tels programmes nous avons développé une interface graphique sous Matlab qui dans la figure 8.12. Elle est structurée comme suit :

- (1) . Données d'entrée (Données de la Production et du Métrologie).
- (2) . Description de la structure du modèle.
- (3) . Résultats temporaires de l'équation 5.5 .
- (4) . Compte-rendu à l'instant t .
- (5) . Présentation de la probabilité $P(R|Re)$ au cours du temps.
- (6) . Résultats temporaires de la probabilité $P(Me, TP, Re)$.
- (7) . Présentation de tous les résultats calculés.

Si nous nous focalisons à la ligne 30 du cadre 7, pour les paramètres $R = 0.8249$; $C = N$, $P = EF$, $TypeA$, $PM = 0$, $CM = 0$, notre atelier logiciel a estimé à 47.49% la confiance qui peut être accordée au compte-rendu reçu attestant que l'opération exécutée l'a été faite avec succès (CR=OK).

4 Évaluation sur la base de scénarios

Dans la dernière section de ce manuscrit, nous nous proposons d'effectuer des inférences probabilistes afin de nous permettre de valider notre approche de calcul du CLFI. Les tests seront basés sur 3 scénarios (cf. table 8.1) de fonctionnement comme suit :

Scenario	R	C	P	T	PM	CM	Re
Scenario A	0.984	N	EF.AC.PA	TypeA	0	0	Ok
Scenario B	0.1	MP	OL	TypeA	10	10	Ok
Scenario C	0.984→0.1	N	EF.AC.PA	TypeA	0	0	Ok

TABLE 8.1 – Scénarios d'exemple pour calculer le CLFI

Pour ces trois situations, nous nous attendons à ce que le modèle CLFI indique une bonne estimation de la confiance en fonction des évidences observées, fixées en entrée du modèle.

Afin de mettre en valeur les apports de notre approche nous montrerons également comment elle améliore le processus de diagnostic développé dans (Deschamps, 2007).

Scénario A : dans ce scénario, nous avons formulé un certain nombre d'hypothèses à savoir que la fiabilité du système de mesure est $R = 98,40\%$. Le système considéré est exploité dans un contexte de production normal. Les capteurs sont placés dans toutes les chaînes fonctionnelles ($P = EF.AC.PA$). Les équipements n'ont pas subi de maintenances dans le passé ($PM = 0$, $CM = 0$) (ligne 1, cf. 8.13). Théoriquement, les compte-rendus de cet équipement qui vont être envoyés au niveau coordination

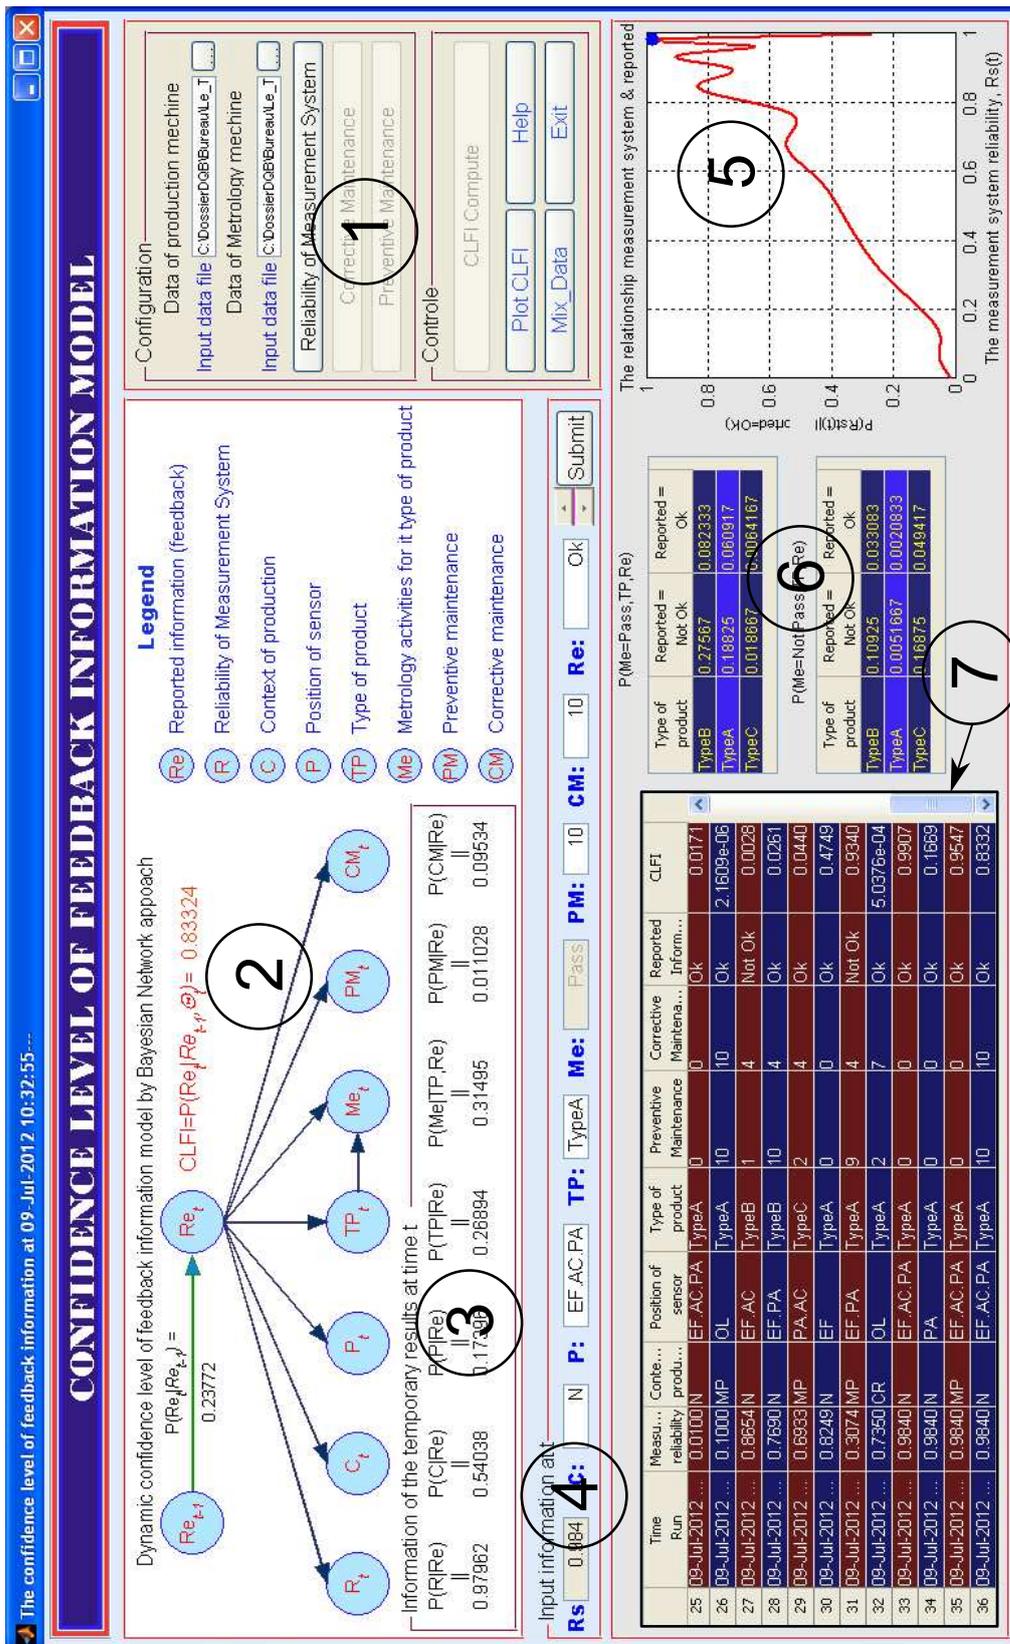


FIGURE 8.12 – Interface de calcul CLFI

devraient arriver avec un niveau de confiance très élevé (Compte-rendu = OK, CLFI = Très haut). C'est bien ce que nous obtenons (cf. 8.13)

	Time Run	Measu... reliability	Conte... produ...	Position of sensor	Type of product	Preventive Maintenance	Corrective Maintenance	Repor... Infor...	CLFI
1	09-Jul-2012 ...	0.9840	N	EF.AC.PA	TypeA	0	0	Ok	0.9907
2	09-Jul-2012 ...	0.9403	N	EF.AC.PA	TypeA	0	0	Ok	0.8787
3	09-Jul-2012 ...	0.9189	N	EF.AC.PA	TypeA	0	0	Ok	0.8302
4	09-Jul-2012 ...	0.8684	N	EF.AC.PA	TypeA	0	0	Ok	0.7748
5	09-Jul-2012 ...	0.8210	N	EF.AC.PA	TypeA	0	0	Ok	0.7418
6	09-Jul-2012 ...	0.8064	N	EF.AC.PA	TypeA	0	0	Ok	0.6599
7	09-Jul-2012 ...	0.7935	N	EF.AC.PA	TypeA	0	0	Ok	0.5902
8	09-Jul-2012 ...	0.7809	N	EF.AC.PA	TypeA	0	0	Ok	0.5361
9	09-Jul-2012 ...	0.7177	N	EF.AC.PA	TypeA	0	0	Ok	0.4953
10	09-Jul-2012 ...	0.6417	N	EF.AC.PA	TypeA	0	0	Ok	0.4892
11	09-Jul-2012 ...	0.6111	N	EF.AC.PA	TypeA	0	0	Ok	0.4513
12	09-Jul-2012 ...	0.5754	N	EF.AC.PA	TypeA	0	0	Ok	0.4074

FIGURE 8.13 – Résultats de l'implémentation du scénario A

Scénario B : dans ce scénario, nous considérons un système avec une faible fiabilité du système de mesure ($R = 10\%$). Les capteurs ne sont pas installés dans toutes les chaînes fonctionnelles ($P = OL$). Le système fonctionne dans un contexte de production stressé par un flux de produits important. Un nombre important de maintenances ont été réalisées sur cet équipement ($PM = 10$, $CM = 10$) dans le passé (ligne 36). Par conséquent, nous pouvons imaginer aisément que les compte-rendus envoyés par un tel équipement au niveau de la coordination seront à considérer avec doute. C'est bien ce que révèlent les résultats obtenus dans la figure 8.14

	Time Run	Measu... reliability	Conte... produ...	Position of sensor	Type of product	Preventive Maintenance	Corrective Maintenance	Reported Inform...	CLFI
25	09-Jul-2012 ...	0.0100	N	EF.AC.PA	TypeA	0	0	Ok	0.0171
26	09-Jul-2012 ...	0.1000	MP	OL	TypeA	10	10	Ok	2.1609e-06
27	09-Jul-2012 ...	0.8654	N	EF.AC	TypeB	1	4	Not Ok	0.0028
28	09-Jul-2012 ...	0.7690	N	EF.PA	TypeB	10	4	Ok	0.0261
29	09-Jul-2012 ...	0.6933	MP	PA.AC	TypeC	2	4	Ok	0.0440
30	09-Jul-2012 ...	0.8249	N	EF	TypeA	0	0	Ok	0.4749
31	09-Jul-2012 ...	0.3074	MP	EF.PA	TypeA	9	4	Not Ok	0.9340
32	09-Jul-2012 ...	0.7350	CR	OL	TypeA	2	7	Ok	5.0376e-04
33	09-Jul-2012 ...	0.9840	N	EF.AC.PA	TypeA	0	0	Ok	0.9907
34	09-Jul-2012 ...	0.9840	N	PA	TypeA	0	0	Ok	0.1669
35	09-Jul-2012 ...	0.9840	MP	EF.AC.PA	TypeA	0	0	Ok	0.9547
36	09-Jul-2012 ...	0.9840	N	EF.AC.PA	TypeA	10	10	Ok	0.8332

FIGURE 8.14 – Résultats de liés au scénario B

Scénario C : Nous considérons ici une haute fiabilité du système de mesure ($R = 98,40\%$) pour ce scénario. L'équipement fonctionne dans un contexte de production normal avec la présence des capteurs dans toutes les chaînes fonctionnelles ($P = EF.AC.PA$). Il n'y a pas eu de maintenances réalisées dans le passé pour cet équipement ($PM = 0$, $CM = 0$). Cependant, contrairement au scénario A la fiabilité du système de mesure va être diminuée au cours du temps. Aussi, le CLFI devra lui même baisser au fil du temps. C'est bien ce que nous pouvons voir dans la figure 8.15.

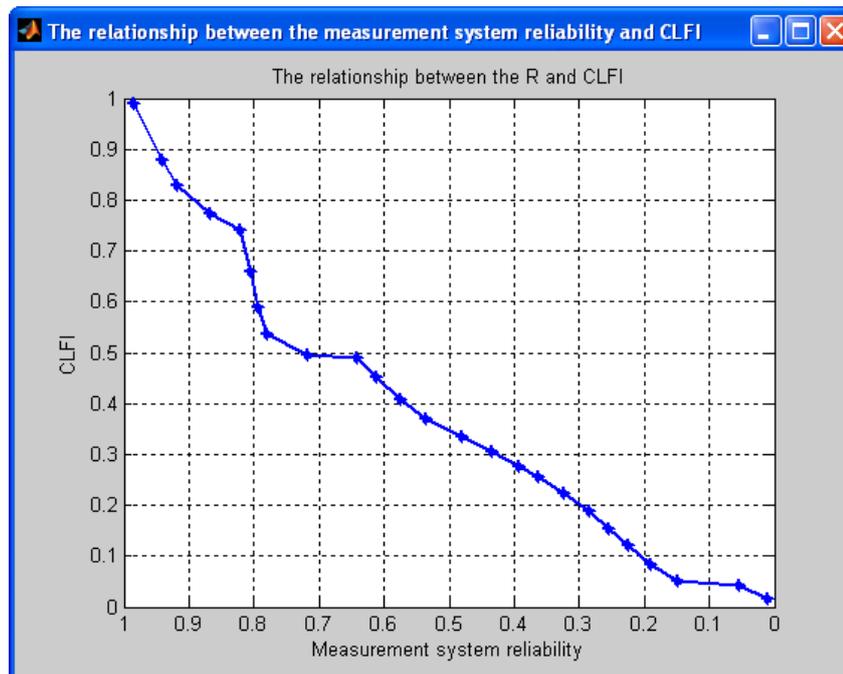


FIGURE 8.15 – Relation entre R et CLFI dans le scénario C

5 Intégration au diagnostic de service

L'objectif n'est pas ici de reprendre dans leur intégralité les résultats de recherche développés par M. Eric DESCHAMPS sur la localisation d'équipements à l'origine de défauts possible. Le lecteur pourra se reporter à (Deschamps, 2007) pour cela, où à la synthèse proposée (cf. chapitre 2). Il s'agira de montrer simplement comment l'approche que nous avons proposée s'intègre au diagnostic de service.

Cette intégration a pris ici la forme d'un nouvel atelier logiciel que nous avons structuré comme suit :

Ce dernier intègre non seulement le mécanisme de réduction du modèle de diagnostic (oubli de toute opération dont le $CLFI = 1$), le mécanisme de calcul du CLFI et enfin le processus de propagation du doute permettant de localiser les équipements à l'origine probable du défaut produit détecté en métrologie.

La figure 8.17 représente l'interface logicielle que nous avons développée. Au sein de cette interface nous pouvons visualiser le fait qu'un produit B est en cours de traitement ; il est passé sur l'équipement M2 *Thin Films* puis M4 *Cleaning* puis enfin en métrologie où il est rejeté (*NotPass*) .

Le modèle de diagnostic correspondant (cf. figure 8.17) permet de considérer que les deux opérations précédentes doivent être considérées comme suspectes. Cependant désormais chacune d'entre elles est fournie avec un niveau de confiance ici 22% pour M4 et 38% M2 qui permet d'orienter l'opérateur sur la priorité à donner à un contrôle machine ; ici, il sera conseillé de visiter l'équipement M4 en tout premier lieu.

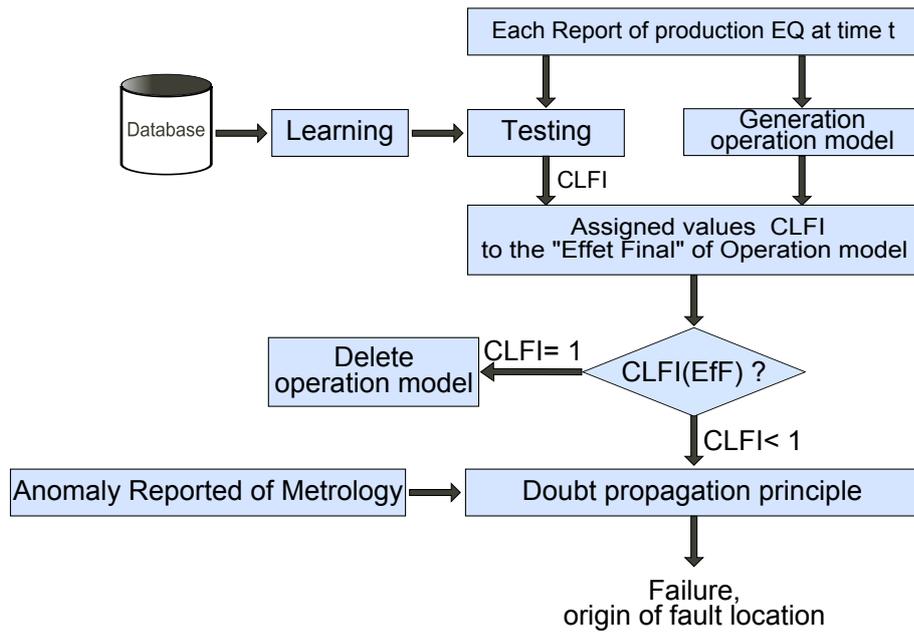


FIGURE 8.16 – Intégration du CLFI au système de diagnostic

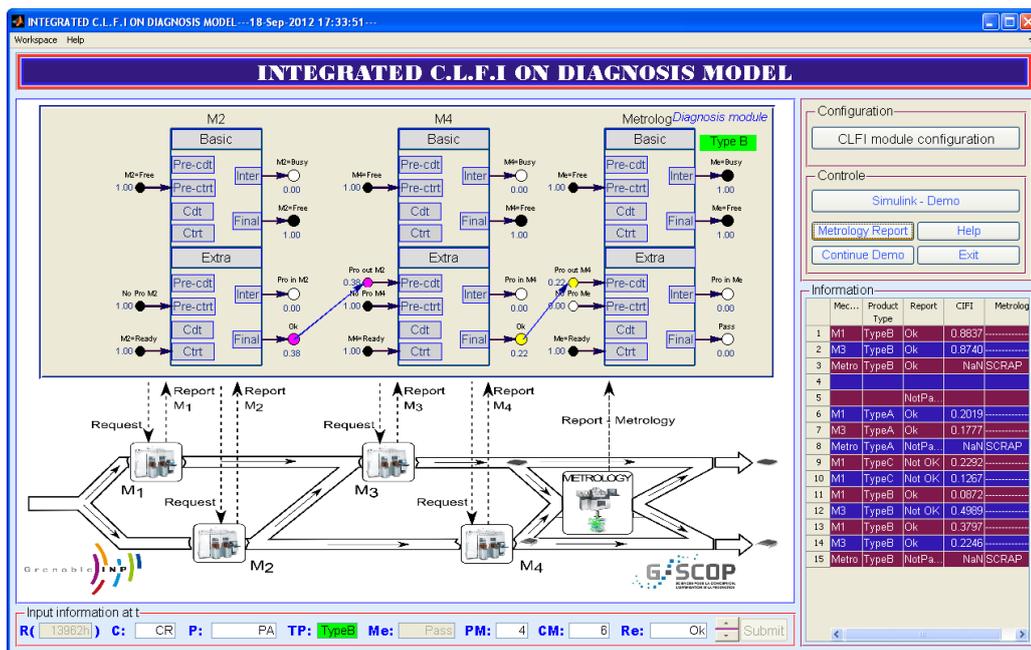


FIGURE 8.17 – Atelier logiciel de diagnostic par CLFI

6 Conclusion

Dans ce chapitre, nous avons mené notre approche jusqu'à sa validation sur la base d'un cas d'étude largement inspiré d'un cas réel issu de l'industrie du semi conducteur. Il s'est agi notamment de prouver que les modèles ainsi que les algorithmes proposés répondent à nos attentes.

Ces derniers ont été développés sous Matlab. Les toolbox du domaine ont été

volontairement écartées de l'activité de codage afin de privilégier la maîtrise des développements actuels et évolutions et adaptations futures. Dans un soucis permanent d'intégration nous avons également développé des interfaces hommes/machines facilitant la prise en main de l'approche que ce soit durant la phase d'apprentissage du modèle, de celle du calcul du CLFI ou encore celle pour l'aide à la localisation des équipements à l'origine du défaut produit détecté en phase de métrologie.

L'ensemble a été évalué sur différents scénarios nous encourageant à pousser cette évaluation désormais plus loin, à savoir en situation réelle sur en atelier semi-conducteur.

Conclusion générale

Les travaux que nous avons présentés dans ce document traitent de la surveillance et de la supervision des dérives des équipements de production ayant un impact sur la qualité des produits fabriqués. Ils font suite à ceux déjà réalisés (Zamai, 1997), (Mendez Auzua, 2002), (Henry, 2005) et (Deschamps, 2007) et visent en particulier à fournir des indicateurs permettant d'améliorer le processus de localisation (diagnostic de services) des équipements responsables de défauts de fabrication.

La contribution de nos travaux réside dans l'élaboration d'une approche d'estimation de la confiance qui peut être accordée aux comptes rendus d'exécution attestant de la réalisation d'une opération sur un produit ou un lot de produits par un équipement de production.

Le formalisme de modélisation que nous avons proposé s'appuie sur une classe de modèles graphiques probabilistes à savoir les réseaux Bayésiens, outils largement déployés dans les domaines tels que la maintenance, l'analyse des risques et plus généralement la sûreté de fonctionnement. Ce formalisme jeune présente des particularités appréciables telles que ses capacités de modélisation graphique synthétique facilitant l'acquisition de la connaissance ainsi que son utilisation. D'autre part, de nombreux algorithmes et outils sont disponibles (Matlab, ProBT, etc) assurant ainsi une intégration et une prise en main intéressante.

En fonction des besoins et des contraintes industrielles (compromis complexité d'apprentissage / performance), nous avons proposé différents modèles, allant de la mise en application de modèles existant dans la littérature jusqu'à proposer des extensions ayant pour conséquence la proposition et le développement de nouveaux modèles. Ainsi, si les données historiques sont incomplètes et/ou incertaines, si les paramètres ayant un impact sur le CLFI sont dépendants et discrets et enfin que les relations entre ces paramètres sont de type causales temporelles, alors avons-nous proposé un nouveau modèle appelé RBDMC caractérisé par :

- Une prise en compte de données complexes, incertaines et incomplètes,
- Une estimation de la confiance du compte-rendu en ligne sur la base de paramètres courants (à l'instant t) de l'équipement considéré,
- Une prise en compte des états précédents (instant $t-1$).

Partant des modèles développés, nous avons ensuite proposé une approche algorithmique permettant non seulement d'automatiser la phase d'apprentissage des modèles mais également de calculer en ligne des indices de confiances accordés aux comptes rendus émis par les équipements de production. Ces indices peuvent être vus comme des scores affectés à chacun des CR.

La démarche, novatrice, a été menée jusqu'à son développement logiciel et à son intégration à des fins de diagnostic de services en ligne, rejoignant ainsi l'approche développée par (Deschamps, 2007).

Au terme de ces travaux, plusieurs axes de recherche se dégagent pour envisager, du point de vue des perspectives, de prolonger l'étude menée pendant ces trois ans.

A court terme, quatre axes d'investigations peuvent être envisagés :

Dans un premier temps, sur la base de l'atelier logiciel développé, une intégration sur site réel devra être envisagée de manière à valider in situ et donc à échelle réelle notre approche. Cette validation devra être menée de manière progressive et en collaboration étroite avec les équipes maintenance et IT de l'entreprise. Les retours d'expériences devront contribuer à l'affinement des modèles proposés. La mise en exergue d'autres paramètres à prendre en compte pourra être envisagée, cela ne remettant pas en cause la généralité de l'approche proposée.

Deuxièmement, nous devons envisager de lever l'hypothèse de bon fonctionnement des équipements de métrologie. En effet, ces derniers ne sont pas exempts de défaillances, en particulier au niveau de leur système de captage. Le concept de CLFI peut tout à fait être appliqué ici. Il faudra dans ce cas mener une analyse fine de ce type d'équipement qui n'est pas soumis aux mêmes contextes de fonctionnement que ceux de production et ainsi élaborer les modèles appropriés.

Troisièmement, il nous semble pertinent de lancer une étude comparative de l'approche ici proposée avec celles développées dans le cadre de l'évaluation de l'état de santé des équipements de production. Bien que les objectifs et les objets considérés ne sont pas les mêmes, estimation de la confiance d'un compte rendu (i.e. le produit a-t-il été correctement fabriqué) d'une part, et prédiction de l'état de santé de l'équipement de production d'autre part, il n'en demeure pas moins qu'elles donnent toutes deux des indicateurs précieux pour envisager d'avancer ou retarder une maintenance préventive. Si l'état de santé d'une machine se dégrade, une maintenance doit être envisagée ; l'indice de confiance doit d'ailleurs normalement lui aussi baisser. Mais n'est-ce pas la même attitude à avoir si la confiance d'un compte rendu baisse, sachant que ce n'est pas parce qu'un indice de confiance chute que cela signifie que l'état de santé de l'équipement chute également (non réciprocity ici) ?

A moyen terme, nous proposons de mettre en perspective quatre orientations de recherche possibles :

Premièrement, rappelons que notre approche est basée sur un apprentissage lié à l'historique des équipements de production et de métrologie. Le fait même d'introduire notre outil d'estimation de la confiance de comptes rendus dans un atelier aura nécessairement pour effet de modifier à court ou moyen terme la vie des équipements considérés ainsi que le comportement des opérateurs de maintenance. Le modèle initialement appris se verra donc progressivement ne plus représenter la nouvelle vie de l'équipement (de nouveaux paramètres seront à considérer par exemple). Il est important ici de pouvoir caractériser « quand » le modèle ne sera plus suffisamment adapté pour envisager de lancer un nouvel apprentissage. Plusieurs pistes peuvent à ce jour être envisagées, comme par exemple la planification à temps fixe de réactualisation (optimalité ?), ou encore la mise en place d'un nouveau indicateur de péremption du modèle (« confiance de la confiance » ?).

Deuxièmement, la problématique doit être considérée de l'erreur de modélisation. Plusieurs pistes ici peuvent être envisagées comme par exemple le « rajout » d'une distribution, une réactualisation bayésienne des paramètres déterministes des modèles, etc. Il faudra distinguer les cas où l'on dispose de points de comparaison permettant de mettre en exergue ces erreurs, d'autres où cette comparaison n'est pas envisageable. Il s'agit donc de développer des recherches centrées sur l'identification des sources d'incertitudes des modèles ; les travaux de (Ditlevsen, 1982) et (Pendola, 2000) sont dans ce cas à considérer comme point de départ.

Troisièmement, notre approche pourra trouver de nouvelles pistes de développement dans le cadre de la conception et de la mise au point des « routages » produits dans un atelier de production. En effet, disposant désormais d'un outil d'évaluation de la confiance des équipements de production, un ensemble d'historiques de CLFI pourrait être retenu en tant que nouveau critère supplémentaire à prendre en compte pour optimiser le routage des produits sur un parc de machines caractérisé par une forte flexibilité physique.

Par ailleurs, à plus long terme il faudrait envisager l'application de nos travaux de recherche à d'autres domaines d'application comme par exemple l'aéronautique, le nucléaire, l'énergie, etc...

Bibliographie

- AFNOR (12/1991). Norme nf x50-151 - "analyse de la valeur, analyse fonctionnelle - expression fonctionnelle du besoin et cahier des charges fonctionnel".
- Agard, B. et Tollenaere, M. (2002). Conception d'assemblages pour la customisation de masse (design of assembly for mass customization). *Mécanique & Industries*, 3(2) :113–119.
- Alaeddini, A. et Dogan, I. (2011). Using bayesian networks for root cause analysis in statistical process control. *Expert Systems with Applications*, 38(9) :11230–11243.
- Avilés-Arriaga, H., Sucar-Succar, L., Mendoza-Durán, C., et Pineda-Cortés, L. (2011). A comparison of dynamic naive bayesian classifiers and hidden markov models for gesture recognition. *Journal of Applied Research and Technology*, 9 :81–102.
- Avilés-Arriaga, H. H., Sucar, L. E., et Mendoza, C. E. (2003). Visual recognition of gestures using dynamic naive bayesian classifiers. In *The 12th IEEE International Workshop on Robot and Human Interactive Communication, ROMAN*.
- Baghdadi, S., Gravier, G., Demarty, C. H., et Gros, P. (2008). Structure learning in a bayesian network-based video indexing framework. In *IEEE International Conference on Multimedia and Expo, 2008*, pages 677–680.
- Baweja, G. et Ouyang, B. (2000). Cim strategy for semiconductor fab-building blocks approach. In *The Ninth International Symposium on Semiconductor Manufacturing. Proceedings of ISSM*, pages 241 –244.
- Ben Gal, I. (2007). Bayesian networks. In Ruggeri, F., Kenett, R., et Faltin, F. W., editors, *Encyclopedia of statistics in quality and reliability*. John Wiley and Sons.
- Berruet, P. (1998a). *Contribution au recouvrement des systèmes flexibles de production manufacturière : analyse de la tolérance et reconfiguration*. PhD thesis, L'université des sciences et techniques de Lille.
- Berruet, P. (1998b). *Contribution au recouvrement des systèmes flexibles de production manufacturière : analyse de la tolérance et reconfiguration*. Ph.d. thesis, Université des Sciences et Technologies de Lille, France.

- Berruet, P., Toguyeni, A., Elkhatabi, S., et Craye, E. (2000). Toward an implementation of recovery procedures for flexible manufacturing systems supervision. *Computers in Industry*, 43(3) :227 – 236.
- Blunsom, P. (2004). *Hidden Markov Models*. Lecture notes.
- Bouaziz, M. F., Zamai, E., Duvivier, F., et Hubac, S. (2011). Dependability of complex semiconductor systems : Learning bayesian networks for decision support. In *The 3rd International Workshop on Dependable Control of Discrete Systems (DCDS)*, pages 7–12.
- Boufaied, A. (2003). *Contribution à la Surveillance Distribuée Des Systèmes à Événements Discrets Complexes*. PhD thesis, Université Paul Sabatier.
- Buntine, W. (1996). A guide to the literature on learning probabilistic networks from data. *IEEE Transactions on Knowledge and Data Engineering*, 8(2) :195 –210.
- Camci, F. et Chinnam, R. B. (2005). Dynamic bayesian networks for machine diagnostics : hierarchical hidden markov models vs. competitive learning. In *IEEE International Joint Conference on Neural Networks. Proceedings of IJCNN '05*, volume 3, pages 1752–1757.
- Chanthery, Elodie ; Pencolé, Y. (2010). Monitoring and active diagnosis for discrete-event systems. In *The 7th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes*, Spain.
- Cho, H. C. et Fadali, S. M. (2006). Online estimation of dynamic bayesian network parameter. In *International Joint Conference on Neural Networks, IJCNN '06*, pages 3363–3370.
- CIM (1989). A reference model for computer integrated manufacturing from the viewpoint of industrial automation. In *International Journal of Computer Intergrated Manufacturing*, volume 2, pages 114–127.
- Combacau, M. (1991). *Commande et surveillance des systèmes à événement discrets complexes : application aux ateliers flexible*. PhD thesis, Université Toulouse Paul Sabatier.
- Combacau, M., Berruet, P., Zamai, E., Charbonnaud, P., et Khatab, A. (2000). Supervision and monitoring of production systems. In *The IFAC 2nd Conference on Management and Control of Production and Logistics (MCPL'00)*, Grenoble, France.
- Corani, G., Antonucci, A., et Zaffalon, M. (2010). *Bayesian Networks with Imprecise Probabilities : Theory and Application to Classification*. Number 49-93. Springer Berlin Heidelberg.

-
- Cuiping, L., Shuangcheng, W., et Hui, W. (2009). Learning naive bayes classifiers with incomplete data. In *International Conference on Artificial Intelligence and Computational Intelligence, AICI '09*, volume 4, pages 350–353.
- Dean, T. et Kanazawa, K. (1989). A model for reasoning about persistence and causation. *Computational Intelligence*, 5(3) :142–150.
- Debouk, R., Lafortune, S., et Teneketzis, D. (1998). Coordinated decentralized protocols for failure diagnosis of discrete event systems. In *IEEE International Conference on Systems, Man, and Cybernetics*, volume 3, pages 3010 –3011.
- Dempster, A. P. (1967). Upper and lower probabilities induced by a multivalued mapping. *Annals of Mathematical Statistics*, 38 :325–339.
- Dempster, A. P., Laird, N. M., et Rubin, D. B. (1977). Maximum likelihood from incomplete data via the em algorithm. *Journal of the Royal Statistical Society. Series B (Methodological)*, 39(1) :1–38.
- Denoeux, T. et Govaert, G. (1996). Combined supervised and unsupervised learning for system diagnosis using dempster-shafer theory. *CESA96 IMACS Multiconference, Computational Engineering Applications. Symposium on Control, Optimization and Supervision, Lille, France*, 1 :104–109.
- Deschamps, E. (2007). *Diagnostic de services pour la reconfiguration dynamique de systèmes à événements discrets complexes*. PhD thesis, Laboratoire des Sciences pour la Conception, l'Optimisation et la Production de Grenoble (G-SCOP).
- Dhillon, B. (2005). Dynamic reliability evaluation models. In Dhillon, B., editor, *Reliability, Quality, and Safety for Engineers*. Taylor & Francis.
- Ditlevsen, O. (1982). Model unvertainty in structural reliability. *Structural Safety*, 1 :73–86.
- Domingos, P. et Pazzani, M. (1997). On the optimality of the simple bayesian classifier under zero-one loss. *Machine Learning - Special issue on learning with probabilistic representations*, 29(2-3) :103–130.
- D'Souza, A. (2002). Using em to estimate a probability density with a mixture of gaussians. Technical report, www.cs.utah.edu.
- Duong, Q.-B., Zamai, E., et Tran-Dinh, K.-Q. (2012a). Confidence estimation of feedback information for logic diagnosis. *The International Journal of Intelligent Real-Time Automation, Engineering Applications of Artificial Intelligence (EAAI)*, 26(3) :1149 – 1161.
- Duong, Q.-B., Zamai, E., et Tran-Dinh, K.-Q. (2012b). Confidence estimation of feedback information using dynamic bayesian networks. In *The 38th Annual Conference of the IEEE Industrial Electronics Society IECON'12, Montréal, Canada*.

- Duong, Q.-B., Zamai, E., et Tran-Dinh, K.-Q. (2012c). Confidence of reported information for real time in diagnosis of complex discrete events systems : A semiconductor application. In *The 14th IFAC Symposium on Information Control Problems in Manufacturing, INCOM'12, Bucharest, Romania*.
- Duong, Q.-B., Zamai, E., et Tran-Dinh, K.-Q. (2012d). New concept to compute confidence of reported information level for logic diagnosis. In *The 9th International Conference on Modeling, Optimization & SIMulation, MOSIM'12, Bordeaux, France*.
- Fagioli, E. et Zaffalon, M. (1999). Tree-augmented naive credal classifiers. In *In IPMU 2000 : Proceedings of the 8th Information Processing and Management of Uncertainty in Knowledge-Based Systems Conference, Universidad Politécnica de Madrid, Spain*, pages 1320–1327.
- Fanti, M. P. et Seatzu, C. (2008). Fault diagnosis and identification of discrete event systems using petri nets. In *The 9th International Workshop on Discrete Event Systems, WODES*, pages 432–435.
- Fouladirad, M. et Nikiforov, I. (2005). Optimal statistical fault detection with nuisance parameters. *Automatica*, 41(7) :1157 – 1171.
- Friedman, N., Geiger, D., et Goldszmidt, M. (1997). Bayesian network classifiers. *Machine Learning*, 29(2-3) :131–163.
- Ghahramani, Z. (1998). Learning dynamic bayesian networks. In *Adaptive Processing of Sequences and Data Structures*, pages 168–197. Springer-Verlag.
- Ghahramani, Z. (2001). Hidden markov models. In *Journal of Parrem Recongition and Arrificial Inrelligence*, volume 15, chapter An introduction to hidden Markov models and Bayesian networks, pages 9–42. World Scientific Publishing Co., Inc., River Edge, NJ, USA.
- Ghariani, A., Toguyéni, A. K. A., et Craye, E. (2002). A functional graph approach for alarm filtering and fault recovery for automated production systems. In *Proceedings of the Sixth International Workshop on Discrete Event Systems (WODES'02)*, WODES '02, pages 289–295, Washington, DC, USA. IEEE Computer Society.
- Gilks, W. R., Richardson, S., et Spiegelhalter (1995). *Markov Chain Monte Carlo in Practice*. Chapman & Hall CRC.
- Gouyon, D., Pétin, J.-F., et Gouin, A. (2004). A pragmatic approach for modular control synthesis and implementation. *International Journal of Production Research*, 2(14) :2839–2858. ISSN 0020-7543.
- Gulati, R. et Smith, R. (2009). *Maintenance and reliability best practices*. New York, Industrial Press. ISBN : 9780831134341.

-
- Hamou Mamar, Z. (2008). *Analyse Temps-Échelle et Reconnaissance des Formes pour le Diagnostic du Système de Guidage d'un Tramway sur Pneumatiques*. PhD thesis, UNIVERSITE BLAISE PASCAL - CLERMONT II.
- Hamscher, W., Consol, L., et Kleer, J. D. (1992). Reading on model-based diagnostic. In *Morgan Kaufmann*, San Mateo, CA, Etats-Unis.
- Henry, S. (2005). *Synthèse de Lois de Commande pour la Configuration et la Reconfiguration des Systèmes Industriels Complexes*. PhD thesis, Institut National Polytechnique de Grenoble.
- Henry, S., Zamai, E., et Jacomino, M. (2012). Logic control law design for automated manufacturing systems. *Engineering Applications of Artificial Intelligence*, 25, Issue 4 :824–836.
- Hill, T. et Nettles, S. (1997). Advanced process control framework initiative. In SPIE, editor, *Plug and Play Software for Agile Manufacturing*, volume 304 of *Proc. SPIE 2913*.
- Hubac, S., Duvivier, F., Zamai, E., et Mili, A. (2010). Predictive maintenance supported by advanced process control (apc) opens new equipment engineering and manufacturing opportunities. In *The 21st Advanced Semiconductor Manufacturing Conference, ASMC 2010, San Francisco*.
- Huvenoit, B., Bourey, J. P., et Craye, E. (1995). Design and implementation methodology based on petri net formalism of flexible manufacturing systems control. *Production Planning & Control*, 6(1) :51–64.
- Jackson, P. (1998). *Introduction to Expert Systems*. Addison-Wesley Longman Publishing Co., Inc., Boston, MA, USA, 2nd edition.
- Jiangtao, R., Sau Dan, L., Xianlu, C., Ben, K., Cheng, R., et Cheung, D. (2009). Naive bayes classification of uncertain data. In *Ninth IEEE International Conference on Data Mining, ICDM '09*, pages 944–949.
- Jones, A. et Saleh, A. (1989). A multi-layer/multi-level control architecture for computer integrated manufacturing systems. In *The 15th Annual Conference of IEEE, Industrial Electronics Society, IECON '89*, volume 3, pages 519–525.
- Jordan, M. I. (1999). *Learning in graphical models*. MIT Press, Cambridge, MA, USA.
- Kelner, R. et Lerner, B. (2012). Learning bayesian network classifiers by risk minimization. *International Journal of Approximate Reasoning*, 53(2) :248–272.
- Korb, K. B. et Nicholson, A. E. (2004). *Bayesian Artificial Intelligence*. Chapman & Hall-CRC.

- Lafortune, S., Teneketzis, D., Sampath, M., Sengupta, R., et Sinnamohideen, K. (2001). Failure diagnosis of dynamic systems : An approach based on discrete event systems. In *The American Control Conference*, volume 25, pages 2058–2071.
- Lefevre, E., Colot, O., et Vannoorenberghe, P. (2002). Belief function combination and conflict management. *Information Fusion*, 3(2) :149 – 162.
- Lefevre, E., Manata, J. p., et Jolly, D. (2004). Classification par la théorie de l'évidence pour la gestion de tournée de véhicules. In *14ème congrès francophone de Reconnaissance des Formes et d'Intelligence Artificielle, RFIA*.
- Leray, P. (Novembre, 2006). *Réseaux bayésiens : apprentissage et modélisation de systèmes complexes*. Habilitation a diriger les recherches - spécialité informatique, automatique et traitement du signal, Département ASI, INSA de Rouen, Université de Rouen, UFR des Sciences.
- Lowd, D. et Domingos, P. (2005). Naive bayes models for probability estimation. In *Proceedings of the 22nd international conference on Machine learning*, volume 119 of *ICML '05*, pages 529–536, New York, NY, USA. ACM.
- Manfredotti, C. E. (2009). *Modeling and inference with relational dynamic bayesian network*. PhD thesis, Università Di Milano - Bicocca.
- Martin, A. (Janvier 2005). La fusion d'informations. Technical report, Polycopié de cours ENSIETA.
- Martinez, V. et Edgar, T. (2006). Control of lithography in semiconductor manufacturing. *Control Systems, IEEE*, 26(6) :46 –55.
- Martínez, M. et Sucar, L. E. (2008). Learning dynamic naive bayesian classifiers. *Proceedings of the Twenty-First International Florida Artificial Intelligence Research Society Conference, May 15-17, 2008, Coconut Grove, Florida, USA*.
- Mendez Auzua, H. (2002). *Systhèse de lois de surveillance pour les procédés industriels complexes*. PhD thesis, Institut National Polytechnique de Grenoble.
- Mili, A. (2009). *Vers Des Méthodes Fiables De Contrôle Des Procédés Par La Maîtrise Du Risque - Contribution À La Fiabilisation Des Méthodes De Process Control D'une Unité De Recherche Et De Production De Circuits Semi-Conducteurs*. Génie industriel, L'Institut polytechnique de Grenoble.
- Murphy, K. P. (2002). *Dynamic Bayesian Networks : Representation, Inference and Learning*. PhD thesis, University of California, Berkeley.

-
- Naïm, P., Wuillemin, P.-H., Leray, P., Pourret, O., et Becker, A. (2004). *Réseaux bayésiens*. Algorithmes. Eyrolles, 2004 (05-Gap), Paris. La couv. porte en plus : Introduction intuitive aux réseaux bayésiens ; Fondements théoriques et algorithmes ; Méthodologie de mise en oeuvre ; Domaines d'application et études de cas détaillées ; Outils logiciels : Bayes Net Toolbox, BayesiaLab, Hugin et Netica.
- Nauck, D., Klawonn, F., et Kruse, R. (1997). *Foundations of Neuro-Fuzzy Systems*. Wiley.
- Niculescu, R. S., Mitchell, T. M., et Rao, R. B. (2006). Bayesian network learning with parameter constraints. *Machine Learning Research*, 7 :1357–1383.
- Niel, E. et Craye, E. (2002). *Maîtrise des risques et sûreté de fonctionnement des systèmes de production*. Hermès-Lavoisier.
- Olivier, F. (2006). *De l'identification de structure de réseaux bayésiens à la reconnaissance de formes à partir d'informations complètes ou incomplètes*. PhD thesis, Institut National des Sciences Appliquées de Rouen.
- Olivier, F. et Philippe, L. (2005). Apprentissage de structure des réseaux bayésiens et données incomplètes. In *5èmes Journées d'Extraction et de Gestion des Connaissances (EGC)*, volume RNTI-E-3 of *Revue des Nouvelles Technologies de l'Information*, pages 127–132. Cépaduès-Éditions.
- Olivier, F. et Philippe, L. (2006). Learning the tree augmented naive bayes classifier from incomplete datasets. In *Proceedings of the Third European Workshop on Probabilistic Graphical Models (PGM'06)*, ISBN : 80-86742-14-8, pages 91–98, Prague, Czech Republic.
- Palacios-Alonso, M., Brizuela, C., et Sucar, L. (2010). Evolutionary learning of dynamic naive bayesian classifiers. *Journal of Automated Reasoning*, 45(1) :21–37.
- Pazzani, M. J. (1995). Searching for dependencies in bayesian classifiers. In *Preliminary Papers of the 5th International Workshop on Artificial Intelligence and Statistics*.
- Pearl, J. (1990). Reasoning with belief functions : An analysis of compatibility. *International Journal of Approximate Reasoning*, 4 :363–389.
- Pendola, M. (2000). *Fiabilité des structures en contexte d'incertitudes statistiques et d'écarts de modélisation*. PhD thesis, Université de Blaise Pascal, Clermont-Ferrand II.
- Perrin, J., Binet, Fand Dumery, J., Merlaud, C., et Trichard, J. (2004). *Automatique et informatique industrielle : Bases théoriques, méthodologiques et techniques*. Nathan Technique.

- Populaire, S. (2000). Introduction aux réseaux bayésiens. In *Rapport interne du laboratoire SIME*, Université de Technologie de Compiègne.
- Quirk, M. et Serda, J. (2001). *Semiconductor Manufacturing Technology*. ISBN : 0130815209. Prentice Hall.
- Rajapakse, J. C. et Zhou, J. (2007). Learning effective brain connectivity with dynamic bayesian networks. *NeuroImage*, 37(3) :749–760.
- Ramoni, M. et Sebastiani, P. (2001). Robust bayes classifiers. *Artificial Intelligence*, 125(1-2) :209–226.
- Ribot, P., Pencolé, Y., et Combacau, M. (2009). Diagnosis and prognosis for the maintenance of complex systems. In *IEEE International Conference on Systems, Man and Cybernetics, SMC'09*, pages 4146–4151.
- Sallak, M. (2007). *Evaluation de paramètres de sûreté de fonctionnement en présence d'incertitudes et aide à la conception : Application aux Systèmes Instrumentés de Sécurité*. These, Institut National Polytechnique de Lorraine - INPL.
- Scanlan, J. et O'Leary, K. (2003). Knowledge-based process control for fault detection and classification. In *Proc. SPIE 5044, Advanced Process Control and Automation*.
- Sematech (1996). Advanced process control framework initiative (apcfi). proposal summary and plan. Technology Transfer 96093181A-ENG, Sematech.
- Sematech (1997). Advanced process control framework initiative (apcfi) 1.0. specifications. Technology Transfer 97063300A-ENG, Sematech.
- Shafer, G. (1976). *A Mathematical Theory of Evidence*. Princeton University Press.
- Shahzad, M. K., Hubac, S., Siadat, A., et Tollenaere, M. (2012). An interdisciplinary fmea methodology to find true dfm challenges. In *12th European Advanced Process Control and Manufacturing Conference*, Grenoble, France.
- Shamshad, A., Bawadi, M. A., Wan Hussin, W. M. A., Majid, T. A., et Sanusi, S. A. M. (2005). First and second order markov chain models for synthetic generation of wind speed time series. *Energy*, 30(5) :693–708.
- Simon, C. et Weber, P. (2006). Bayesian networks implementation of the dempster shafer theory to model reliability uncertainty. In *The First International Conference on Availability, Reliability and Security, ARES'06.*, pages 6–12.
- Simon, C., Weber, P., et Aubry, J.-F. (2008). Fiabilité imprécise par les réseaux de fonctions de croyance. In *16e Congrès de Maîtrise des Risques et de Sûreté de Fonctionnement, Avignon, France*. Centre de recherche en automatique de Nancy (CRAN).

-
- Simon, C., Weber, P., et Levrat, E. (2007). Bayesian networks and evidence theory to model complex systems reliability. *JCP*, 2(1) :33–43.
- Smets, P. (1994). What is dempster-shafer's model? In Yager, R. R., Kacprzyk, J., et Fedrizzi, M., editors, *Advances in the Dempster-Shafer theory of evidence*, pages 5–34. John Wiley & Sons, Inc., New York, NY, USA.
- Smets, P. et Kennes, R. (1994). The transferable belief model. *Artificial Intelligence*, 66 :191–234.
- Sonderman, T. et Spanos, C. (2005). Advanced process control in semiconductor manufacturing. A webcast lecture - the presentation, Computing and Systems Technology, CAST.
- Stamp, M. (2012). A revealing introduction to hidden markov models.
- Tacnet, J., Richard, D., Dezert, J., et Batton-Hubert, M. (2010). Aide à la décision et fusion d'information pour l'expertise des risques naturels : analyse de l'efficacité des ouvrages de protection. In *6èmes journées de la fiabilité des matériaux et des structures (JFMS'10)*, Toulouse, France, pages 21–27, Toulouse, France.
- Tien, H. P. (2010). *Développement et mise en oeuvre de modèles d'attention visuelle*. PhD thesis, L'Institut polytechnique de Grenoble.
- Venkatasubramanian, V. (2003). A review of process fault detection and diagnosis part iii : Process history based methods. *Computers Chemical Engineering*, 27(3) :327–346.
- Wang, Y., Yoo, T.-S., et Lafortune, S. (2007). Diagnosis of discrete event systems using decentralized architectures. *Discrete Event Dynamic Systems*, 17 :233–263.
- Weber, P. et Jouffe, L. (2003). Reliability modelling with dynamic bayesian networks. In *The 5th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes (SAFEPROCESS'03)*, Washington, D.C., USA, pages 57–62. IFAC. SURFDIAG.
- Weidl, G., Madsen, A. L., et Israelson, S. (2005). Applications of object-oriented bayesian networks for condition monitoring, root cause analysis and decision support on operation of complex continuous processes. *Computers & Chemical Engineering*, 29(9) :1996–2009.
- Witteveen, C., Roos, N., Van der Krogt, R., et Weerd, M. (2005). Diagnostic of single and multi-agent plans. In *The 4th international conference on Autonomous Agents and Multi-agent systems*, Utrecht, Nouvelle-Zélande.
- Zamai, E. (1997). *Architecture de Surveillance - Commande pour les Systèmes à Événement Discrets Complexes*. PhD thesis, Laboratoire d'Analyse et d'Architecture de Systèmes (LAAS).

-
- Zamai, E., Chaillet-Subias, A., et Combacau, M. (1998). An architecture for control and monitoring of discrete events systems. *Computers in Industry*, 36(1-2) :95–100.
- Zamai, E., Chaillet-Subias, A., Combacau, M., et Bonneval, A. d. (1997). An hierarchical structure for control of discrete systems and monitoring of process failures. *Studies in Informatics and Control*, 6 :7–16.
- Zwingelstein, G. (1995). Diagnostic des défaillances : Théorie et pratique pour les systèmes industriels. In *Hermes Science Publications*.

Annexes

Annexe A

Glossaire

In-situ sensor can be defined as a technology used to acquire information about an object when the distance between the object and the sensor is comparable to or smaller than any linear dimension of the sensor. A short dictionary-based definition for in situ sensing could be ? sensing in place?. Because many measurements or observations are made from nearby locations that are not strictly speaking in situ, the expression proximal sensing has been adopted in a variety of disciplines. In semiconductor, In-situ sensor refers to processing steps or tests that are done without moving the wafer. It is a measurement made while a silicon wafer resides in the processing chamber of a processing tool. [SEMATECH]. In-situ sensor to detect the end-point of the process, i.e., to detect when the desired process result has been achieved, at which point in time the process is stopped. This type of control is common in processes such as etch.

Physical Vapor Deposition (PVD) : a process whereby films of material, usually metals, are deposited by physical means, for example, evaporation and sputtering. [SEMATECH]

Chemical Vapor Deposition (CVD) : in semiconductor technology, a process in which a controlled chemical reaction produces a thin surface film.

Photolithography : a process in which a masked pattern is projected onto a photo-sensitive coating that covers a substrate. [SEMATECH]. Also called photolithography.

Plasma Etch : Plasma ashing and plasma etching basically rely on the same principles. Plasma Etching is usually confined to the semiconductor industry and more often than not uses carbon tetrafluoride (with oxygen) as the plasma process gas. Probably the most frequent application is the etching of silicon, silicon oxides, silicon nitrate as well as glass passivation layers.

Rapid Thermal Processing (RTP) : a process in which a wafer is heated to a specified temperature for short periods of time. When referring specifically to annealing processes, the process is called rapid thermal annealing (RTA). [SEMATECH]

Chemical-Mechanical Planarization (CMP) : a process for the removal of surface material from a wafer. The process uses chemical and mechanical actions to achieve a mirror-like surface for subsequent processing. [SEMI M1-94 and ASTM F1241] Also called chem-mech polish.

Critical Dimensions (CD) : the width of a patterned line or the distance between two lines, monitored to maintain device performance consistency ; that dimension of a specified geometry that must be within design tolerances.

Recipe : Recipe are the computer program, rules, specifications, operations, and procedures performed each time to produce a wafer that contains functional die. Examples are the setup recipe and the process recipe. [SEMATECH]

BEOL : copper Back-End-Of-Line process steps from contact through completion of the wafer prior to electrical test. Also called back end. [SEMATECH]

ECP : electrochemical polishing treatment that electrochemically alters the surface of a metal. When electropolish is applied to 316L stainless steel, the surface becomes enriched with chromium, and a minor amount of fine polishing of the surface roughness occurs. [SEMATECH]

CMMS : Computerized Maintenance Management System are database applications in an organization that assist in planning and management functions required for effective maintenance (Gulati et Smith, 2009)

RMS : Recipe Management Systems, Recipe and parameter management (RaP) defines equipment support for advanced handling of the specifications (called *recipes*) that control processing on production equipment. Proper management of these recipes can ensure that the correct recipe is executed, reduce the setup time for processing by eliminating most recipe downloads, and enable more advanced process control by making all the needed parameters available for modification without directly modifying the recipe [see SEMATECH SEMI E139].

WIP : Work-In-Progress Inventory, inventory, either inactive or being processed, that has been started into manufacturing but has not been completed. [SEMATECH]

WET : Wafer Electrical Test

Annexe B

Bases de Donnés

Base de données de la production

Time	R	C	P	TP	PM	CM	CR
00:53 01-Jan-2005	0.2956	CR	EF.AC	TypeC	9	5	Not Ok
02:25 01-Jan-2005	0.3282	MP	PA	TypeC	6	7	Not Ok
05:28 01-Jan-2005	0.8490	CR	EF.PA	TypeB	1	6	Ok
07:26 01-Jan-2005	0.0631	MP	OL	TypeB	5	6	Not Ok
08:05 01-Jan-2005	0.1116	CR	OL	TypeA	8	3	Not Ok
08:53 01-Jan-2005	0.8645	MP	PA	TypeA	8	2	Not Ok
08:56 01-Jan-2005	0.4288	N	PA.AC	TypeA	3	9	Not Ok
09:49 01-Jan-2005	0.8755	N	EF.PA	TypeC	2	9	Ok
11:38 01-Jan-2005	0.9878	N	EF.AC.PA	TypeB	1	5	Ok
12:17 01-Jan-2005	0.7700	N	EF.AC.PA	TypeB	3	8	Ok
14:57 01-Jan-2005	0.8674	N	PA.AC	TypeB	5	1	Not Ok
15:54 01-Jan-2005	0.4172	CR	PA.AC	TypeC	8	10	Not Ok
20:04 01-Jan-2005	0.9103	N	EF.AC.PA	TypeA	6	5	Ok
21:02 01-Jan-2005	0.0155	MP	OL	TypeB	4	5	Not Ok
22:47 01-Jan-2005	0.1689	CR	OL	TypeC	7	6	Not Ok
23:13 01-Jan-2005	0.1459	MP	OL	TypeC	4	10	Not Ok
23:40 01-Jan-2005	0.5421	CR	AC	TypeA	10	6	Not Ok
01:05 02-Jan-2005	0.8454	MP	EF	TypeC	3	2	Ok
01:28 02-Jan-2005	0.0064	CR	OL	TypeB	9	8	Not Ok
03:02 02-Jan-2005	0.0727	CR	OL	TypeB	3	6	Not Ok
03:42 02-Jan-2005	0.7731	N	EF.AC.PA	TypeB	7	7	Ok
03:44 02-Jan-2005	0.0852	CR	OL	TypeB	3	9	Not Ok
05:44 02-Jan-2005	0.3415	CR	PA.AC	TypeC	6	1	Not Ok
06:38 02-Jan-2005	0.5849	N	EF.PA	TypeA	3	2	Ok
15:37 02-Jan-2005	0.3774	MP	OL	TypeA	4	2	Not Ok
16:09 02-Jan-2005	0.8484	N	EF.AC	TypeC	9	0	Ok
16:36 02-Jan-2005	0.1728	CR	AC	TypeC	10	9	Not Ok
19:02 02-Jan-2005	0.2930	MP	PA.AC	TypeC	5	2	Not Ok
21:15 02-Jan-2005	0.1862	CR	OL	TypeB	9	6	Not Ok
00:11 03-Jan-2005	0.5741	N	PA.AC	TypeB	3	7	Not Ok
00:24 03-Jan-2005	0.2200	MP	EF.PA	TypeB	9	3	Not Ok
04:05 03-Jan-2005	0.2136	MP	PA.AC	TypeA	7	4	Not Ok
04:37 03-Jan-2005	0.6462	MP	EF	TypeC	10	9	Not Ok
10:00 03-Jan-2005	0.1536	CR	OL	TypeC	4	0	Not Ok
11:00 03-Jan-2005	0.1929	CR	PA.AC	TypeB	3	0	Not Ok
12:26 03-Jan-2005	0.5956	MP	PA	TypeB	9	9	Not Ok
13:52 03-Jan-2005	0.2212	MP	EF.PA	TypeA	8	1	Not Ok
17:20 03-Jan-2005	0.6358	MP	AC	TypeB	5	9	Ok
18:27 03-Jan-2005	0.3701	N	EF.AC.PA	TypeB	8	0	Ok
21:19 03-Jan-2005	0.0564	CR	OL	TypeB	6	9	Not Ok
00:36 04-Jan-2005	0.1594	CR	OL	TypeA	9	6	Not Ok
03:23 04-Jan-2005	0.2843	CR	PA	TypeB	3	1	Not Ok
03:37 04-Jan-2005	0.2326	CR	OL	TypeB	2	1	Not Ok
05:52 04-Jan-2005	0.1138	CR	OL	TypeA	3	7	Not Ok
06:25 04-Jan-2005	0.8592	CR	EF.AC.PA	TypeC	0	7	Ok

FIGURE B.1 – Base de données de la production

06:49 04-Jan-2005	0.1615	CR	OL	TypeB	1	3	Not Ok
08:17 04-Jan-2005	0.3417	CR	EF.PA	TypeC	7	3	Ok
10:08 04-Jan-2005	0.3855	N	EF.PA	TypeC	6	3	Ok
10:50 04-Jan-2005	0.2865	N	PA.AC	TypeB	4	7	Not Ok
11:38 04-Jan-2005	0.2946	MP	EF.PA	TypeC	3	8	Not Ok
12:18 04-Jan-2005	0.3835	CR	PA	TypeC	3	7	Not Ok
12:36 04-Jan-2005	0.1920	CR	OL	TypeC	3	10	Not Ok
14:43 04-Jan-2005	0.2371	N	PA.AC	TypeB	10	4	Not Ok
19:24 04-Jan-2005	0.5185	CR	EF	TypeC	6	6	Not Ok
20:36 04-Jan-2005	0.4504	N	AC	TypeA	2	6	Ok
21:27 04-Jan-2005	0.9588	N	EF.AC.PA	TypeB	3	9	Ok
21:46 04-Jan-2005	0.0234	CR	OL	TypeA	8	9	Not Ok
01:11 05-Jan-2005	0.5840	CR	PA	TypeB	8	6	Not Ok
01:59 05-Jan-2005	0.2311	MP	PA	TypeC	4	9	Not Ok
03:04 05-Jan-2005	0.0567	CR	PA	TypeB	1	2	Not Ok
03:21 05-Jan-2005	0.2009	CR	AC	TypeB	10	1	Not Ok
04:50 05-Jan-2005	0.3357	MP	OL	TypeA	9	0	Not Ok
05:32 05-Jan-2005	0.0264	CR	OL	TypeC	9	8	Not Ok
05:39 05-Jan-2005	0.8948	MP	EF.PA	TypeA	4	9	Ok
05:51 05-Jan-2005	0.6170	MP	PA.AC	TypeB	6	7	Ok
06:14 05-Jan-2005	0.5410	N	AC	TypeB	6	4	Ok
06:45 05-Jan-2005	0.2756	CR	OL	TypeC	2	9	Not Ok
07:25 05-Jan-2005	0.0120	MP	OL	TypeB	10	4	Not Ok
12:20 05-Jan-2005	0.2117	CR	AC	TypeB	6	7	Not Ok
14:06 05-Jan-2005	0.8106	N	PA.AC	TypeB	2	6	Not Ok
15:26 05-Jan-2005	0.3718	CR	AC	TypeB	8	9	Not Ok
15:28 05-Jan-2005	0.0087	CR	OL	TypeC	9	10	Not Ok
16:04 05-Jan-2005	0.0637	CR	PA	TypeC	4	1	Not Ok
18:42 05-Jan-2005	0.2417	CR	OL	TypeB	4	4	Not Ok
18:59 05-Jan-2005	0.0498	CR	OL	TypeC	10	1	Not Ok
20:46 05-Jan-2005	0.1661	CR	OL	TypeB	9	8	Not Ok
21:49 05-Jan-2005	0.0409	CR	OL	TypeC	3	1	Not Ok
21:58 05-Jan-2005	0.5834	CR	AC	TypeB	1	2	Not Ok
23:23 05-Jan-2005	0.0247	CR	OL	TypeB	9	5	Not Ok
01:01 06-Jan-2005	0.1462	MP	AC	TypeA	7	6	Not Ok
01:50 06-Jan-2005	0.4947	CR	AC	TypeA	9	0	Not Ok
02:25 06-Jan-2005	0.0257	CR	OL	TypeB	8	7	Not Ok
03:42 06-Jan-2005	0.2510	N	PA.AC	TypeA	2	9	Not Ok
04:42 06-Jan-2005	0.9449	MP	EF.AC.PA	TypeA	0	0	Ok
05:06 06-Jan-2005	0.0232	CR	OL	TypeC	10	8	Not Ok
05:58 06-Jan-2005	0.1773	CR	OL	TypeA	5	5	Not Ok
07:42 06-Jan-2005	0.2614	CR	OL	TypeB	7	0	Not Ok
08:23 06-Jan-2005	0.2297	CR	PA.AC	TypeA	10	5	Not Ok
14:37 06-Jan-2005	0.3766	N	PA.AC	TypeB	1	7	Not Ok
14:45 06-Jan-2005	0.3409	MP	PA	TypeB	5	8	Not Ok
18:01 06-Jan-2005	0.5235	N	EF.PA	TypeB	6	5	Ok
19:43 06-Jan-2005	0.0296	MP	OL	TypeB	5	5	Not Ok
20:07 06-Jan-2005	0.0662	CR	OL	TypeB	9	5	Not Ok
20:51 06-Jan-2005	0.1137	MP	PA	TypeB	6	1	Not Ok
21:12 06-Jan-2005	0.1988	CR	OL	TypeC	4	3	Not Ok

FIGURE B.2 – Base de données de la production

21:53 06-Jan-2005	0.0093	CR	OL	TypeA	10	7	Not Ok
21:57 06-Jan-2005	0.0600	MP	OL	TypeC	2	6	Not Ok
22:04 06-Jan-2005	0.3983	CR	EF.PA	TypeC	9	9	Not Ok
01:32 07-Jan-2005	0.4382	MP	AC	TypeB	2	5	Ok
02:44 07-Jan-2005	0.0460	CR	OL	TypeA	5	4	Not Ok
02:49 07-Jan-2005	0.2134	CR	AC	TypeA	8	0	Not Ok
03:27 07-Jan-2005	0.2852	CR	EF.PA	TypeB	2	8	Not Ok
08:09 07-Jan-2005	0.7920	N	PA.AC	TypeB	9	3	Not Ok
15:09 07-Jan-2005	0.8005	N	PA.AC	TypeB	7	3	Ok
16:00 07-Jan-2005	0.9052	N	EF.AC.PA	TypeA	1	0	Ok
16:12 07-Jan-2005	0.0686	CR	OL	TypeC	2	3	Not Ok
17:50 07-Jan-2005	0.9671	CR	EF.AC.PA	TypeC	4	2	Ok
18:05 07-Jan-2005	0.5969	MP	EF	TypeB	2	2	Ok
01:42 08-Jan-2005	0.6258	N	EF.PA	TypeB	10	5	Not Ok
02:56 08-Jan-2005	0.2191	MP	AC	TypeC	5	9	Not Ok
03:35 08-Jan-2005	0.0789	MP	OL	TypeA	10	2	Not Ok
04:17 08-Jan-2005	0.1044	CR	OL	TypeB	10	2	Not Ok
06:22 08-Jan-2005	0.0579	MP	OL	TypeB	2	8	Not Ok
06:47 08-Jan-2005	0.4019	CR	PA	TypeB	8	8	Not Ok
07:10 08-Jan-2005	0.2507	N	EF.PA	TypeA	9	9	Not Ok
10:31 08-Jan-2005	0.7527	MP	EF	TypeC	2	2	Ok
11:16 08-Jan-2005	0.2733	N	PA.AC	TypeB	9	4	Not Ok
12:05 08-Jan-2005	0.1722	MP	AC	TypeB	7	4	Not Ok
16:17 08-Jan-2005	0.2658	CR	AC	TypeB	9	9	Not Ok
16:19 08-Jan-2005	0.0788	CR	OL	TypeC	2	3	Not Ok
17:41 08-Jan-2005	0.0812	CR	OL	TypeA	3	4	Not Ok
22:26 08-Jan-2005	0.9650	MP	EF.AC.PA	TypeB	4	5	Ok
00:47 09-Jan-2005	0.0383	MP	PA	TypeB	8	2	Not Ok
03:20 09-Jan-2005	0.7722	CR	PA.AC	TypeC	1	2	Ok
03:53 09-Jan-2005	0.1190	CR	PA	TypeB	7	8	Not Ok
05:12 09-Jan-2005	0.8315	MP	PA.AC	TypeB	8	1	Ok
09:40 09-Jan-2005	0.0492	CR	OL	TypeC	9	1	Not Ok
13:52 09-Jan-2005	0.1796	CR	OL	TypeB	6	8	Not Ok
19:08 09-Jan-2005	0.2528	N	EF.PA	TypeB	2	7	Not Ok
19:29 09-Jan-2005	0.1791	CR	OL	TypeB	8	5	Not Ok
19:51 09-Jan-2005	0.1884	CR	OL	TypeB	1	2	Not Ok
20:08 09-Jan-2005	0.2378	MP	EF	TypeC	4	2	Not Ok
23:23 09-Jan-2005	0.2853	N	AC	TypeB	6	5	Not Ok
00:56 10-Jan-2005	0.2697	N	EF.PA	TypeB	9	6	Not Ok
05:03 10-Jan-2005	0.8180	MP	PA.AC	TypeC	2	3	Ok
07:10 10-Jan-2005	0.1388	CR	OL	TypeB	4	1	Not Ok
09:15 10-Jan-2005	0.1181	CR	OL	TypeC	2	7	Not Ok
11:20 10-Jan-2005	0.3646	CR	PA	TypeB	5	2	Not Ok
12:03 10-Jan-2005	0.8289	N	EF.AC	TypeB	2	6	Ok
13:24 10-Jan-2005	0.8275	MP	PA	TypeB	8	3	Not Ok
15:00 10-Jan-2005	0.8037	CR	PA	TypeB	10	7	Not Ok
16:33 10-Jan-2005	0.9527	N	EF.AC.PA	TypeB	0	3	Ok
16:46 10-Jan-2005	0.0536	CR	OL	TypeC	2	8	Not Ok
00:24 11-Jan-2005	0.7254	CR	EF.AC.PA	TypeC	2	6	Ok
00:26 11-Jan-2005	0.0271	MP	OL	TypeA	9	5	Not Ok

FIGURE B.3 – Base de données de la production

03:31 11-Jan-2005	0.0572	CR	OL	TypeB	7	3	Not Ok
03:39 11-Jan-2005	0.4652	MP	EF.PA	TypeB	4	1	Ok
04:11 11-Jan-2005	0.2924	N	EF.PA	TypeB	1	7	Not Ok
05:11 11-Jan-2005	0.5733	CR	AC	TypeC	2	2	Ok
05:25 11-Jan-2005	0.5271	CR	AC	TypeA	0	2	Ok
07:30 11-Jan-2005	0.1260	CR	OL	TypeA	7	6	Not Ok
07:48 11-Jan-2005	0.1746	CR	OL	TypeC	6	2	Not Ok
09:10 11-Jan-2005	0.4797	MP	OL	TypeB	8	5	Not Ok
11:37 11-Jan-2005	0.8117	CR	EF.PA	TypeC	1	8	Not Ok
12:23 11-Jan-2005	0.9716	N	EF.AC.PA	TypeA	4	9	Ok
13:36 11-Jan-2005	0.1443	CR	AC	TypeB	9	3	Not Ok
15:56 11-Jan-2005	0.2097	CR	EF	TypeB	9	3	Not Ok
16:03 11-Jan-2005	0.6880	N	EF.AC	TypeC	6	0	Ok
19:29 11-Jan-2005	0.9985	MP	EF	TypeC	9	4	Ok
01:04 12-Jan-2005	0.2209	MP	EF.AC	TypeC	2	4	Not Ok
01:52 12-Jan-2005	0.1135	CR	PA	TypeC	3	4	Not Ok
02:37 12-Jan-2005	0.6913	CR	AC	TypeB	8	2	Not Ok
04:52 12-Jan-2005	0.0357	CR	OL	TypeA	5	8	Not Ok
10:43 12-Jan-2005	0.1435	CR	OL	TypeB	6	4	Not Ok
11:10 12-Jan-2005	0.0219	MP	OL	TypeB	10	1	Not Ok
12:48 12-Jan-2005	0.0692	CR	OL	TypeA	10	5	Not Ok
13:10 12-Jan-2005	0.0351	MP	OL	TypeB	8	10	Not Ok
14:17 12-Jan-2005	0.4925	MP	PA	TypeC	4	1	Not Ok
16:24 12-Jan-2005	0.2321	CR	EF	TypeB	2	6	Not Ok
16:32 12-Jan-2005	0.7260	N	PA.AC	TypeC	9	3	Not Ok
23:11 12-Jan-2005	0.0585	CR	OL	TypeB	2	4	Not Ok
01:41 13-Jan-2005	0.4318	CR	PA	TypeC	6	7	Not Ok
02:34 13-Jan-2005	0.8368	N	EF.PA	TypeA	2	4	Ok
05:17 13-Jan-2005	0.2544	N	EF.PA	TypeB	10	9	Not Ok
07:33 13-Jan-2005	0.6527	CR	OL	TypeB	5	8	Not Ok
12:08 13-Jan-2005	0.0673	MP	OL	TypeA	2	7	Not Ok
14:55 13-Jan-2005	0.6042	N	EF.PA	TypeA	1	8	Ok
15:11 13-Jan-2005	0.2260	MP	PA.AC	TypeC	9	5	Not Ok
15:11 13-Jan-2005	0.9691	MP	EF.AC.PA	TypeA	7	0	Ok
18:31 13-Jan-2005	0.8567	CR	EF	TypeA	1	0	Ok
20:10 13-Jan-2005	0.1643	CR	OL	TypeB	1	9	Not Ok
20:22 13-Jan-2005	0.2157	CR	AC	TypeC	7	0	Not Ok
20:26 13-Jan-2005	0.9596	N	EF.AC	TypeB	4	1	Ok
20:35 13-Jan-2005	0.2894	CR	PA	TypeC	8	1	Not Ok
01:52 14-Jan-2005	0.8161	N	PA.AC	TypeC	3	5	Ok
02:03 14-Jan-2005	0.5716	MP	OL	TypeB	10	7	Not Ok
05:40 14-Jan-2005	0.1284	N	PA.AC	TypeB	8	6	Not Ok
07:06 14-Jan-2005	0.0543	MP	OL	TypeB	1	8	Not Ok
12:19 14-Jan-2005	0.9063	N	EF.PA	TypeB	8	1	Not Ok
12:51 14-Jan-2005	0.3778	MP	AC	TypeB	8	5	Not Ok
14:59 14-Jan-2005	0.7092	N	EF	TypeB	3	9	Ok
15:53 14-Jan-2005	0.5717	N	AC	TypeC	3	3	Ok
16:22 14-Jan-2005	0.6557	CR	AC	TypeC	2	9	Ok
17:46 14-Jan-2005	0.2332	N	PA.AC	TypeB	1	6	Not Ok
***	***	***	***	***	***	***	***

FIGURE B.4 – Base de données de la production

Base de données métrologie

Time	TP	Metrology
08-Jan-2005	TypeB	Not Pass
17-Jan-2005	TypeB	Pass
24-Jan-2005	TypeB	Pass
17-Feb-2005	TypeB	Pass
22-Feb-2005	TypeB	Pass
26-Feb-2005	TypeB	Pass
28-Feb-2005	TypeB	Not Pass
28-Feb-2005	TypeA	Pass
15-Mar-2005	TypeC	Pass
19-Mar-2005	TypeC	Not Pass
10-Apr-2005	TypeA	Pass
09-May-2005	TypeA	Not Pass
11-May-2005	TypeB	Pass
15-May-2005	TypeC	Pass
21-May-2005	TypeB	Pass
28-May-2005	TypeA	Pass
30-May-2005	TypeB	Pass
11-Jun-2005	TypeA	Not Pass
04-Jul-2005	TypeB	Pass
23-Jul-2005	TypeC	Pass
24-Jul-2005	TypeC	Pass
28-Jul-2005	TypeA	Not Pass
02-Aug-2005	TypeA	Not Pass
18-Aug-2005	TypeA	Not Pass
07-Sep-2005	TypeA	Pass
07-Sep-2005	TypeC	Not Pass
17-Sep-2005	TypeB	Pass
14-Oct-2005	TypeB	Pass
20-Oct-2005	TypeB	Not Pass
26-Oct-2005	TypeC	Pass
29-Oct-2005	TypeC	Not Pass
07-Nov-2005	TypeA	Pass
08-Nov-2005	TypeA	Pass
09-Dec-2005	TypeA	Pass
24-Dec-2005	TypeB	Pass
24-Dec-2005	TypeB	Pass
25-Dec-2005	TypeC	Pass
30-Dec-2005	TypeB	Pass
01-Jan-2006	TypeB	Not Pass
04-Jan-2006	TypeC	Pass
27-Jan-2006	TypeC	Pass
29-Jan-2006	TypeB	Not Pass
12-Feb-2006	TypeC	Pass
21-Feb-2006	TypeB	Pass
*****	*****	*****

FIGURE B.5 – Base de données métrologie

Intitulé de la Thèse : Approche probabiliste pour l'estimation dynamique de la confiance accordée à un équipement de production : vers une contribution au diagnostic de services des SED.

Résumé de thèse :

Le travail que nous présentons dans ce mémoire apporte sa contribution au domaine de la surveillance et de la supervision en ligne des systèmes à événements discrets complexes. Il se place dans un contexte perturbé par l'occurrence d'aléas de fonctionnement d'une partie opérative au sein duquel nous visons à mettre à disposition des équipes de maintenance des outils pour les aider à localiser rapidement les équipements à l'origine probable de défauts produits : localiser mieux pour maintenir mieux et donc minimiser encore davantage les temps de dérives équipements. Si les équipements de production étaient en mesure de détecter de telles dérives, le problème pourrait être considéré comme simple, cependant, la présence d'équipements de métrologie montre le contraire. Aussi, partant du constat que les équipements de production ne peuvent être dotés d'un système de captage couvrant de manière exhaustive l'ensemble des paramètres à observer, que la fiabilité des capteurs est variable dans le temps, que les contextes de production sont particulièrement stressants, nous avons proposé ici de développer une approche probabiliste basée sur un raisonnement Bayésien permettant d'estimer en temps réel la confiance qui peut être accordée aux opérations réalisées par les équipements de production.

Mots clés : Niveau de confiance, Réseaux Bayésiens, Modèles propabilistes, Diagnostis, Production de Semi-conducteur, Chaîne de Markov.

Title of Thesis: A probabilistic approach to dynamically estimate the confidence of a given production equipment: Contribution towards diagnosis of discrete event systems services.

Abstract:

The work that we present in this paper contributes to the field of supervision, monitoring and control of complex discrete event systems services. It is placed in the context of random failure occurrence of operative parts where we focus on providing tools to maintenance teams by locating the possible origin of potential defect products: better locate to better maintain, so effectively to minimize more equipment's time drift. If the production equipment were able to detect such drifts, the problem could be considered simple; however, metrology equipment adds to the complexity. In addition, because of an impossibility to equip the production equipment with a sensor system which comprehensively covers all parameters to be observed, a variable sensor reliability in time and a stressed production environments, we propose a probabilistic approach based on Bayesian network to estimate real time confidence, which can be used for production equipment's operation.

Key Words: Confidence level, Bayesian Networks, Probabilistic models, Diagnosis, Semiconductor manufacturing, Markov chain.