



Contribution à la modélisation Bayésienne de l'état de santé d'un système complexe : application à l'industrie du semi-conducteur

Mohammed Farouk Bouaziz

► To cite this version:

Mohammed Farouk Bouaziz. Contribution à la modélisation Bayésienne de l'état de santé d'un système complexe : application à l'industrie du semi-conducteur. Autre. Université de Grenoble, 2012. Français. NNT : 2012GRENT109 . tel-00993732

HAL Id: tel-00993732

<https://theses.hal.science/tel-00993732>

Submitted on 20 May 2014

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-Productique**

Arrêté ministériel : 07 août 2006

Présentée par

Mohammed-Farouk BOUAZIZ

Thèse dirigée par **Éric ZAMAÏ**

préparée au sein du Laboratoire **G-SCOP** (Laboratoire des Sciences pour la Conception, l'Optimisation et la Production de Grenoble)
dans l'École Doctorale **EEATS** (Électronique, Électrotechnique, Automatique et Traitement du Signal)

Contribution à la modélisation Bayésienne de l'état de santé d'un système complexe : Application à l'industrie du semi- conducteur

Thèse soutenue publiquement le **27 novembre 2012**,
devant le jury composé de :

Mr, Michel TOLLENAERE

Professeur, Université de Grenoble, France, Président

Mr, Stéphane DAUZÈRE PÉRÈS

Professeur, École des Mines de Saint-Étienne, France, Rapporteur

Mr, Laurent GENESTE

Professeur, École Nationale d'Ingénieurs de Tarbes, France, Rapporteur

Mr, Philippe WEBER

Maître de Conférences, Université de Lorraine, France, Examinateur

Mr, Stéphane HUBAC

Expert Senior, STMicroelectronics de Crolles, France, Examinateur

Mr, Éric ZAMAÏ

Maître de Conférences, Université de Grenoble, France, Directeur de Thèse

Mr, Frédéric DUVIVIER

Directeur du groupe Industrie et Énergie, Probayes, France, Invité



*" la Civilisation n'est pas un entassement,
mais une Construction, une Architecture ".
M. BN.*

Table des matières

Table des matières	i
Liste des tableaux	v
Liste des figures	vi
Abréviations	ix
Introduction générale.....	1
 I. L'EVOLUTION DES BESOINS EN SEMI-CONDUCTEUR	
I.1. Introduction.....	6
I.2. Présentation du domaine semi-conducteur.....	6
I.2.1. Enjeux et spécificités.....	6
I.2.2. Étapes de fabrication d'un circuit intégré.....	8
I.2.3. Maîtrise des procédés.....	10
I.2.4. Premiers constats.....	12
I.3. Problématique de la thèse.....	13
I.3.1. Systèmes automatisés de production.....	13
I.3.2. Systèmes d'information.....	15
I.3.3. Systèmes de métrologie.....	16
I.3.4. Vers le calcul d'un indicateur de santé.....	18
I.4. Positionnement des travaux.....	20
I.4.1. Méthodes qualitatives et quantitatives.....	20
I.4.2. Premier positionnement et travaux connexes.....	23
I.4.3. Projet IMPROVE.....	25
I.4.4. Partenaires industriels principaux.....	26
I.5. Conclusion.....	27

II. VERS DES STRATEGIES DE MAINTENANCE AVANCEES

II.1. Introduction.....	31
II.2. Évolution des stratégies de maintenance.....	31
II.2.1. Impact de la maintenance sur la performance système.....	32
II.2.2. Limites des maintenances correctives et préventives.....	33
II.2.3. Mise en place d'une stratégie PdM.....	36
II.2.4. Architectures supports à la PdM.....	37
II.2.5. Synthèse et positionnement	39
II.3. Pronostic et gestion de la santé PHM.....	40
II.3.1. Concept de traitement de données.....	42
II.3.2. Concept du diagnostic	42
II.3.3. Concept du pronostic.....	43
II.3.4. Concept d'aide à la décision.....	46
II.3.5. Synthèse et positionnement.....	47
II.4. Méthodologie d'intégration du modèle issu du pronostic.....	48
II.4.1. Caractéristiques de l'indicateur de santé EHF.....	49
II.4.2. Étape 1 : Identification des modes de défaillance.....	51
II.4.3. Étape 2 : Modélisation et validation.....	52
II.4.4. Étape 3 : Paramétrage du modèle.....	53
II.4.5. Étape 4 : Analyse en ligne.....	54
II.5. Conclusion.....	55

III. MODELISATION GRAPHIQUE PROBABILISTE

III.1. Introduction.....	59
III.2. Réseaux Bayésiens.....	59
III.2.1. Définitions et avantages.....	60
III.2.2. Propriétés et variantes.....	62
III.2.3. Méthodes algorithmiques.....	68
III.2.4. Domaines d'application et outils.....	70
III.3. Réseaux Bayésiens et mise en œuvre d'un indicateur de santé.....	72
III.3.1. Analyse probabiliste par réseau Bayésien.....	72
III.3.2. Identification des variables du modèle.....	74
III.3.3. Définition de la structure graphique du modèle	76
III.3.4. Définition des lois de probabilités du modèle.....	77
III.4. Configurations de l'indicateur de santé EHF.....	80
III.4.1. EHF par mode de fonctionnement.....	81
III.4.2. Instanciation de l'EHF à partir des tables AMDEC.....	82
III.4.3. Vers un modèle EHF temporel.....	84
III.4.4. Vers un modèle de classification des causes.....	86
III.5. Conclusion.....	89

IV. APPLICATION DES MODELES PROPOSES SUR UN CAS D'ETUDE

IV.1. Introduction.....	93
IV.2. Développement d'outils pour l'identification des variables.....	93
IV.2.1. Outil de simulation.....	94
IV.2.2. Description de la table « vie de l'équipement ».....	95
IV.2.3. Sélection des risques opérationnels prioritaires.....	96
IV.2.4. Classification des causes de défaillances potentielles.....	98
IV.3. Simulation de l'indicateur de santé EHF : étude de cas.....	102
IV.3.1. Présentation du cas d'étude.....	102
IV.3.2. Simulation du modèle EHF statique.....	104
IV.3.3. Simulation de l'EHF en vue du pronostic.....	109
IV.3.4. Propriétés et retour d'expérience.....	113
IV.4. Scénarios de validation pour la prise de décision.....	114
IV.4.1. Validation en mode normal.....	114
IV.4.2. Validation en mode dégradé.....	116
IV.4.3. Validation en mode de dysfonctionnement.....	117
IV.4.4. Exploitation des résultats pour la prise de décision.....	118
IV.5. Conclusion.....	120
 Conclusion générale.....	 123
Bibliographie.....	129
Annexes.....	141
A. Définitions liées à la notion du « Failure ».....	142
B. Formalisation de la connaissance.....	144
C. Four de traitement thermique	145
D. Table AMDEC fonctionnelle.....	146
E. Définition des priorités par l'outil CEP.....	147
Résumé.....	151

Liste des tableaux

I.1. Méthodes d'analyse de risque et de sûreté de fonctionnement.....	21
III.1. Applications des RB.....	71
III.2. Exemple de variables sélectionnées.....	76
III.3. Préparation des données pour l'apprentissage.....	78
IV.1. Format générique d'une table de vie de l'équipement.....	96
IV.2. Variables du classifieur VIP.....	99
IV.3. Causes de défaillances identifiées.....	101
IV.4. Variables identifiées pour le modèle EHF.....	105
IV.5. Lois de probabilités pour les variables FM_1 , RCH_2 et $Para_1$	108
IV.6. Algorithme EM pour l'apprentissage paramétrique.....	111
IV.7. Algorithme JT pour l'inférence exacte.....	112
IV.8. Résultats de prédiction.....	112
D.1. Structure générique d'une « Grille AMDEC » LFoundy.....	146

Liste des figures

I.1. Classement 2010 des industries européennes (investissement en R&D).....	7
I.2. Contexte de production complexe.....	8
I.3. Étapes de fabrication d'un produit semi-conducteur.....	9
I.4. Principaux contrôles réalisés en production.....	11
I.5. Diagramme SAP.....	14
I.6. Structure interne d'un équipement de production.....	14
I.7. Description de l'environnement de production.....	15
I.8. Machines de métrologie.....	17
I.9. Métrologie virtuelle.....	17
I.10. Concept de l'EHF.....	19
I.11. Risque et danger.....	20
I.12. Organisation et liens du projet IMPROVE.....	26
II.1. Rapport entre coûts de maintenance et disponibilité.....	32
II.2. Évolution de la fonction maintenance.....	35
II.3. Structure séquentielle de l'architecture OSA/CBM.....	38
II.4. Principaux concepts liés à la discipline PHM.....	41
II.5. Éléments de traitement de données.....	42
II.6. Principales méthodes du diagnostic.....	43
II.7. Critères de classification des approches de pronostic.....	44
II.8. Intégration du processus d'aide à la décision.....	46
II.9. Approches du pronostic selon le résultat attendu.....	47
II.10. Méthodologie proposée.....	48
II.11. Indicateurs pour le « health monitoring »	50
II.12. Identification des modes de défaillance FM.....	51
II.13. Modélisation et validation.....	53

II.14. Disponibilité des équipements de production.....	56
III.1. Exemple d'un réseau Bayésien à deux variables.....	60
III.2. Indépendance conditionnelle (connexion divergente)	62
III.3. Cas d'un circuit dans un réseau Bayésien.....	63
III.4. Construction d'un réseau Bayésien.....	63
III.5. Réseau Bayésien naïf.....	64
III.6. Réseau Bayésien Dynamique.....	65
III.7. Diagramme d'influence.....	67
III.8. Apprentissage et inférence dans les réseaux Bayésiens.....	69
III.9. Algorithmes d'apprentissage.....	70
III.10. Algorithmes d'inférence.....	70
III.11. Analyse probabiliste par RB.....	73
III.12. Axes de développement en semi-conducteur.....	74
III.13. Structure compacte du modèle EHF.....	77
III.14. Exemple de structure détaillée du modèle EHF.....	77
III.15. Probabilités a posteriori des variables.....	79
III.16. Mise en œuvre d'un EHF par module d'équipement.....	81
III.17. Instanciation de l'EHF à partir des tables AMDEC.....	83
III.18. Prédiction de l'EHF à partir d'un RB dynamique.....	85
III.19. Structure naïf du classifieur des causes.....	87
III.20. Structure dynamique du classifieur VIP.....	88
III.21. Structure « optimale » du classifieur VIP.....	89
IV.1. Architecture des flux de données.	95
IV.2. Histogramme générique pour la classification des FM _i	97
IV.3. Approche pour la classification des causes de défaillance.....	98
IV.4. Exemple d'un classifieur VIP par réseau Bayésien naïf hiérarchique.....	99
IV.5. Paramètres FDC d'un four LPCVD.....	100
IV.6. Évolution de la classification des RC.....	101
IV.7. Schéma de principe du réacteur.....	103
IV.8. Structure du modèle EHF à partir d'un RB statique.....	106
IV.9. Illustration d'une partie du programme sous l'éditeur Matlab.....	107

IV.10. Structure du modèle EHF par simulation.....	107
IV.11. Modélisation et utilisation d'un RBD.....	109
IV.12. Structure du modèle EHF à partir d'un RB dynamique.....	111
IV.13. Probabilités inférées pour le scénario 1.....	115
IV.14. Probabilités inférées pour le scénario 2.....	116
IV.15. Probabilités inférées pour le scénario 3.....	118
IV.16. Interface utilisateur graphique.....	118
IV.17. Modes de marche et d'arrêt de l'équipement.....	119
IV.18. RdP pour le suivi de l'équipement en intégrant les indications de l'EHF.....	120
C.1. Équipement de production : four thermique.....	145
C.2. Modules de l'équipement.....	145
E.1. Status distribution per week.....	148
E.2. Status distribution per month.....	148
E.3. Time line equipment status for all furnaces.....	149

Abréviations

AMDEC	Analyse des modes de défaillance, de leurs effets et de leur criticité.
BD	Base(s) de données
BNT	Bayes Net Toolbox
CEP	Complex event processing
DI	Diagramme d'influence
EHF	Equipment health factor
EM	Expectation-Maximization
FDC	Fault detection and classification
FM	Mode(s) de défaillance « Failure mode »
IMPROVE	Implementing Manufacturing science solutions to increase equiPment pROductiVity and fab pErformance
LPCVD	Low Pressure Chemical Vapor Deposition
PdM	Maintenance prédictive
PHM	Pronostic et gestion de la santé
POC	Proof Of Concept
P(x)	Probabilité de x
RB	Réseau(x) Bayésien(s)
RBD	Réseau(x) Bayésien(s) dynamique(s)
RC	Cause(s) de défaillance
R&D	Recherche et développement
R2R	Run to run
RUL	Remaining Useful Life
SAP	Systèmes automatisés de production
SOD	Sévérité, Occurrence et Détection
SPC	Statistical process control
VIP	Verification and Identification Protocol)
VM	Métrologie virtuelle
W_i	Pondération
WP	Work Packages

Introduction générale

Dans l'industrie du semi-conducteur, les marchés mondialisés sont en perpétuelle évolution et la concurrence est particulièrement rude. Le contexte de développement des produits, souvent perturbé par des variations internes ou externes, a un caractère particulièrement fluctuant et stressant.

Pour survivre et évoluer dans ce contexte fortement variable et concurrentiel, les maîtres mots des industriels sont plus que jamais : réduction des coûts et des délais de production, maîtrise de la qualité des produits de dimensions nanométriques et amélioration de la disponibilité et la fiabilité des équipements pour accroître encore davantage les performances des usines de production.

Un des axes d'amélioration réside dans le traitement des dégradations inéluctables et difficilement contrôlables des équipements de production tenus responsables de plus de 50% des rejets produits. Pour faire face à de telles dérives et obtenir ainsi le meilleur compromis entre disponibilité des équipements, coûts d'exploitation, qualité et compétitivité du produit, de nombreuses approches et solutions ont été proposées dans la littérature notamment dans les domaines de la Maintenance, de l'Analyse des Risques, du Diagnostic ou encore du Pronostic... afin de contribuer au développement et à la mise en place d'une boucle réactive partant d'une dérive produit à la mise en place d'une solution appropriée.

Parmi les solutions aujourd'hui couramment usitées en entreprise, nous pouvons citer les approches de contrôle des procédés comme le *Statiscal Process Control (SPC)* qui consistent à contrôler les lignes de production à l'aide d'indicateurs de performances ; celles

de *Fault Detection and Classification (FDC)* qui visent à suivre en temps réel l'évolution des paramètres équipement, ou encore les approches de type *Run to Run (R2R)* qui lient le *SPC* et la *FDC* afin d'assurer la stabilité du processus global. Bien entendu, différentes politiques de maintenances, qu'elles soient correctives ou préventives sont également légion dans ce type de traitement de dérives.

Cependant, force est de constater que ces approches, même cumulées, ne permettent pas de maîtriser la forte variabilité liée à un outil de production plongé dans un contexte particulièrement complexe et incertain.

Aussi, le travail que nous présentons dans ce mémoire se propose d'apporter sa contribution au domaine de la maintenance prédictive des systèmes complexes, en particulier au niveau de la prédiction des éventuelles dérives des équipements de production. Il prend place au cœur du projet Européen *IMPROVE* et se fixe comme objectif de contribuer à la proposition de méthodes visant à minimiser les maintenances correctives et à optimiser les maintenances préventives systématiques en introduisant des nouvelles politiques de type prédictive. Dans cet esprit, l'approche que nous proposons vise à développer une méthodologie générique permettant de construire un modèle prédictif de l'état de santé des équipements de production (*Equipment Health Factor EHF*). Comme point de départ, nous considérons l'ensemble des données issues d'un atelier de production. A partir de ces dernières nous nous proposons de mettre en exergue des corrélations sur la base d'un raisonnement mathématique (probabiliste et/ou statistique) centré sur le formalisme Bayésien. Les résultats obtenus amènent des éléments de décision afin d'aider les opérateurs d'exploitation dans la phase de planification des stratégies de maintenance sur les équipements et celles de métrologie (inspection) sur les produits.

Ce mémoire est organisé en quatre chapitres dont les thèmes sont donnés ci-après :

Dans le premier chapitre, nous présentons de manière générale la problématique centrée sur les chutes de rendements liées aux dérives des équipements de production dans le domaine du semi-conducteur. Ainsi, après avoir présenté les caractéristiques relatives à ce domaine de production, nous positionnons nos travaux de recherche au sein des systèmes automatisés de production et en particulier au niveau des méthodes d'analyses de données dans un contexte complexe, incertain et où l'expertise est fortement mise en avant.

Sur cette base, nous précisons ensuite notre sujet de recherche ainsi que son positionnement par rapport aux travaux de la communauté scientifique.

Le chapitre II est consacré, quant à lui, à une présentation des éléments requis pour envisager de proposer une méthodologie d'intégration d'un nouvel indicateur. Ainsi, sont présentés tout d'abord les concepts de base liés à l'évolution de la fonction maintenance (en particulier la maintenance prédictive *PdM*) et des architectures supports du type *Pronostic and Health Management (PHM)*. Partant de tels concepts, nous proposons au lecteur une caractérisation du concept d'*EHF*. Après quoi, nous détaillons les différentes étapes requises à sa modélisation.

Dans le chapitre III, nous dévoilons le modèle probabiliste permettant le calcul de l'indicateur de santé d'un équipement de production. Dans un premier temps, le formalisme retenu pour cette modélisation est introduit ; il s'agit des réseaux Bayésiens. Après avoir détaillé avantages, inconvénients, propriétés et méthodes algorithmiques liés à ce formalisme, nous proposons une méthode originale de mise en œuvre de cet indicateur de santé. Cette dernière est structurée autour de 3 étapes : l'identification des variables du modèle, la définition de sa structure graphique et la définition des lois de probabilités associées. En fonction des besoins d'exploitation en atelier, différentes configurations de l'indicateur de santé sont proposées.

Le chapitre IV développe un exemple d'application pour les méthodes et les modèles proposés dans ce mémoire, ceci sur la base d'un équipement de production de type four de dépôt de couche de gaz sur des plaquettes de silicium. Après avoir présenté le cas d'études, différents scénarios de validation de l'approche sont proposés afin d'en évaluer sa pertinence. Des ouvertures vers une prise en compte de l'*EHF* pour l'aide à la prise de décision en atelier marquent la fin de ce chapitre.

Une dernière partie est consacrée aux conclusions et aux perspectives de ce travail.

I. L'évolution des besoins en semi-conducteur

I.1. Introduction.....	6
I.2. Présentation du domaine semi-conducteur.....	6
I.2.1. Enjeux et spécificités.....	6
I.2.2. Étapes de fabrication d'un circuit intégré.....	8
I.2.3. Maîtrise des procédés.....	10
I.2.4. Premiers constats.....	12
I.3. Problématique de la thèse.....	13
I.3.1. Systèmes automatisés de production.....	13
I.3.2. Systèmes d'information.....	15
I.3.3. Systèmes de métrologie.....	16
I.3.4. Vers le calcul d'un indicateur de santé.....	18
I.4. Positionnement des travaux.....	20
I.4.1. Méthodes qualitatives et quantitatives.....	20
I.4.2. Premier positionnement et travaux connexes.....	23
I.4.3. Projet IMPROVE.....	25
I.4.4. Partenaires industriels principaux.....	26
I.5. Conclusion.....	27

I.1. Introduction

Ce premier chapitre se propose de présenter de manière générale le domaine de fabrication dans le cadre des ateliers semi-conducteurs¹, ainsi que le contexte dans lequel nos travaux de recherche se positionnent. Nous décrivons par la suite la problématique que nous allons traiter, ainsi que le besoin accru d'introduire un processus d'anticipation des aléas. Enfin, nous terminerons ce chapitre avec le positionnement de nos travaux par rapport à une synthèse bibliographique consacrée aux méthodes courantes appliquées dans le domaine de l'analyse de risques et de la sûreté de fonctionnement.

I.2. Présentation du domaine semi-conducteur

Les produits issus de l'industrie du semi-conducteur sont très présents dans notre quotidien. Des téléphones portables aux voitures en passant par les ordinateurs et les téléviseurs, les avancées technologiques ont le point commun d'être associées à l'évolution de l'un des composants élémentaires de l'industrie du semi-conducteur, le circuit intégré. Ainsi, cette première partie a pour but de présenter les enjeux majeurs et les spécificités principales auxquelles les fabricants sont contraints. Ce qui nous conduira naturellement à décrire les étapes de fabrication d'un produit.

I.2.1. Enjeux et spécificités

Face à une concurrence internationale et une exigence client de plus en plus forte, l'industrie du semi-conducteur est contrainte d'améliorer continuellement sa performance, et donc son rendement à travers des idées innovantes et une forte qualité de service. La recherche permanente d'une production à capacité maximale est l'un des principaux objectifs de ce secteur, ceci afin d'assurer un retour sur investissement sur des machines très onéreuses caractérisées par un coût d'exploitation très important.

Avec un ratio² de 14,8 %, l'industrie européenne du semi-conducteur est classée au premier rang pour l'intensité des investissements en recherche et développement (*R&D*). Telle est la conclusion d'une étude réalisée par la commission européenne calculant les investissements *R&D* sur les ventes nettes de 1400 sociétés à travers le monde figure I.1.

¹ *Semi-conducteur* : Corps cristallin dont les propriétés de conductibilité électrique sont intermédiaires entre celle des métaux et celle des isolants. Ils sont largement utilisés en électronique pour réaliser des composants tels que des diodes, des transistors, des thyristors, des circuits intégrés ainsi que des lasers à semi-conducteur.

² *Source* : « the 2011 EU Industrial R&D Investment Scoreboard (<http://www.iri.jrc.es>) », ce ratio représente le rapport entre les ventes annuelles nets et les investissements *R&D*.




Figure I.1. Classement des industries européennes (investissement en R&D).

Dans cette course vers la continuité et la pérennité, le moindre aléa peut empêcher la réalisation de ces objectifs. La maîtrise d'une telle productivité doit être menée dans un contexte où le processus de fabrication est caractérisé par :

- *une complexité de production importante* : l'industrie du semi-conducteur de pointe est l'une des industries les plus complexes, cette complexité peut être définie par le grand nombre d'opérations élémentaires (une centaine pour un produit fini), la durée particulièrement longue (plusieurs mois en moyenne pour l'obtention d'un produit fini), les interactions dynamiques entre les différents outils de production (cf. figure I.2) (Liu, 2008), le degré d'automatisation croissant, le rythme élevé de renouvellement des technologies, le coût élevé de la mobilisation des équipements, etc.
- *un environnement très incertain* : défini par l'indéterminisme du flux de produit, la poussière qui peut entraîner des pertes de produits voire des propagations de particules (contamination) sur les machines en aval, le dérèglement des machines de fabrication, la pollution liée à la présence des opérateurs humains, l'insertion en ligne de production de flux de produits issus du service R&D, etc.

Ceci n'est pas sans conséquences sur les temps de cycle, les coûts et les rendements de fabrication. De façon à faire face aux enjeux économiques, il est nécessaire de développer et de mettre en œuvre des méthodes et des outils permettant d'agir dans des contextes complexes et incertains.




Figure I.2. Contexte de production complexe.

I.2.2. Étapes de fabrication d'un circuit intégré

Pour fabriquer un circuit intégré³ (CI), il est nécessaire de parcourir plusieurs étapes sur différents équipements. Ceci doit avoir lieu dans les différents ateliers d'une zone appelée salle blanche⁴ (*Fab*) où l'environnement est strictement surveillé et doit atteindre des degrés très élevés de maîtrise du nombre de particules⁵ par mètre cube (ISO 14644-1, 1999).

Une étape préliminaire consiste à préparer, à partir du sable, une plaquette de silicium ultra pure (*wafer*⁶) de 200 ou de 300 millimètre de diamètre avec une épaisseur millimétrique. Ensuite, le *wafer* subit des opérations élémentaires dans les différents ateliers de la *fab* comme le montre le plan descriptif de la figure I.3 (Mili, 2009). Nous y retrouvons principalement, des opérations de photolithographie, de dépôt de films minces (CVD), de gravure physico-chimique (ETCH), de nettoyage humide (WET), de polissage mécano-chimique (CMP) et d'implantation ionique (IMP), d'isolation et d'interconnexion. Un dernier processus, avant test final et commercialisation, consiste à découper les *wafers* en circuits individuels qui vont être assemblés et mis en boîtier pour obtenir les circuits intégrés. Nous distinguons deux types d'usines, l'usine *Front-end* pour tout ce qui est opérations sur les plaquettes et tests intermédiaires, et l'usine *Back-end* pour tout ce qui est découpage, assemblage, mise en boîtier et tests finaux (Bettayeb, 2012).

³ *Circuit intégré* : aussi appelé puce électronique, est un composant électronique reproduisant une ou plusieurs fonctions électroniques plus ou moins complexes dans un volume réduit.

⁴ *Salle Blanche* : nous parlons d'une salle de Classe 1 lorsque nous détectons au maximum une particule de taille supérieure à 0.5 micron par pied cube (norme *US FED STD 209*).

⁵ *Particules* : c'est la quantité de poussière par unité de volume, cette notion est utilisée comme un critère de classification des salles blanches.

⁶ *Wafer* : tranche de silicium, de quelques dixièmes de millimètre d'épaisseur et de 20 centimètres de diamètre, qui va être transformée pour obtenir un ensemble de circuit intégrés.




Figure I.3. *Étapes de fabrication d'un produit semi-conducteur.*

Dans nos travaux, nous nous intéressons principalement à des équipements de traitement thermique (cas d'étude) dans l'atelier de dépôt de couches de gaz à haute température. Dans cet atelier, deux types d'opérations peuvent être réalisées (Mili, 2009) :

- le dépôt de couches minces de gaz (poly silicium, oxyde...) à haute température (plus de 600°) qui a pour but de créer la grille du transistor.
- le recuit d'activation de dopants suite à l'implantation ou la densification de couches déposées.

Pour mieux caractériser la complexité de la fabrication des circuits intégrés, voici quelques chiffres provenant de nos partenaires industriels (Bassetto, 2005) :

- une forte rentabilité mais sur des durées très courtes (entre 6 et 12 mois).
- une forte valeur ajoutée (de l'ordre de ~500 euros pour un *wafer* vierge à ~5000 euros pour un *wafer* comportant des circuits intégrés).
- un temps de cycle relativement important (entre 6 et 10 semaines en moyenne).
- un grand nombre d'opérations élémentaires (jusqu'à 700 en moyenne).
- un circuit intégré comporte plusieurs millions de transistors, résistances, capacités, etc.

L'usine de STMicroelectronics à Crolles produit des *wafers* de 300 mm et dispose d'une salle blanche de 10000 m² (classée ISO1 : 1000 fois plus propre que l'air ambiant) pour un investissement total de 2,2 Milliard d'euros. Le volume de fabrication est de 3500 *wafers* par semaine, avec l'exploitation d'un parc de 300 équipements. Pour garantir cette production maximale, plusieurs organisations opérationnelles collaborent en permanence pour atteindre un niveau de synergie nécessaire.

I.2.3. Maîtrise des procédés

Dans un tel contexte, de principaux concepts ont été rapidement proposés pour permettre de maximiser la disponibilité des équipements et d'améliorer en continue la qualité des produits et des processus de fabrication. Il s'agit de la fonction « maintenance industrielle » et de la fonction « contrôle des procédés ».

I.2.3.1. Maintenance industrielle

La maintenance est définie comme étant « l'ensemble de toutes les actions techniques, administratives et de management durant le cycle de vie d'un bien, destinées à le maintenir ou à le rétablir dans un état dans lequel il peut accomplir la fonction requise (AFNOR 13306, 2001) ». Selon cette définition, la maintenance a un triple effet : sur la productivité, sur la disponibilité des équipements de production et sur la qualité des produits. Comme pour la plupart des domaines industriels, nous distinguons deux types de maintenance industrielle en semi-conducteur (Hubac, 2012) :

- Maintenance corrective (*Run to Failure maintenance*) : s'applique après détection d'une défaillance ou quand la défaillance est en train de se produire et elle vise à réparer, à restaurer ou à remplacer un élément défaillant. L'équipement concerné prend un statut temps d'arrêt imprévu (*unscheduled downtime*). Le principal inconvénient de la maintenance corrective est la dégradation de la linéarité de l'activité de production. La disponibilité de l'équipement devient imprévisible, donc très variable ce qui signifie des pertes en capacité.
- Maintenance préventive systématique : s'exécute à des intervalles réguliers et avant l'occurrence de la défaillance. Elle repose sur le remplacement ou la remise en état d'un élément dans le but de prévenir une indisponibilité non planifiée. L'équipement concerné prend un statut temps d'arrêt prévu (*scheduled downtime*). Le principal avantage de la maintenance préventive par rapport à l'approche corrective est que l'indisponibilité de l'équipement est théoriquement maîtrisé, d'où la possibilité de réduire la variabilité. Cela nécessite une synchronisation puissante des ressources disponibles (machines, techniciens, pièces de rechange, etc.). Et l'un des principaux inconvénients de l'approche préventive est son coût relativement élevé (par exemple, le remplacement d'une pièce qui est encore opérationnelle).

1.2.3.2. Contrôle des procédés

Afin de fournir des modèles d'aide à la décision pour la maintenance et l'inspection, des méthodes statistiques (analyse et quantification) ou/et méthodologiques (domaine de qualité) sont développées (Liu, 2008 ; Mili et al., 2009). Au sein de l'industrie du semi-conducteur, les principales composantes du contrôle des procédés sont :




Figure I.4. Principaux contrôles réalisés en production.

- *Statistical Process Control (SPC)* : ce système permet de contrôler les lignes de production à l'aide d'indicateurs de performance comme par exemple l'épaisseur, la hauteur, les longueurs, le centrage... (Kohli, 2002). Le *SPC* est appliqué sur trois types de mesures :
 - les mesures physiques : sur un échantillon de plaques de silicium et par des équipements de type métrologie, ils permettent de vérifier, avec retard, que ce qui a été réalisé a été bien fait,
 - les mesures paramétriques : sur toutes les plaques du lot et les structures de tests situés autour du circuit (*Parametric Test PT*),
 - les mesures électriques : sur chacun des circuits intégrés en fin de ligne de production (*Electrical Wafer Sort EWS*).

Ces 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 : des barrières pour qualifier le bon fonctionnement de l'opération de fabrication.
- *Fault Detection and Classification (FDC)* : ce système permet de suivre en temps réel l'évolution des paramètres équipement (température, pression...) (Scanlan, 2003). Tout au long des étapes de la fabrication, les paramètres équipement sont collectés pour chaque *wafers*. L'objectif est de mieux maîtriser les anomalies de fonctionnement des équipements.
- *Run-to-Run (R2R)* : les boucles de régulation ont pour objectif l'assurance de la stabilité des processus de fabrication durant toute la vie de l'équipement (Moyne et al., 2000). Les boucles de contrôle servent à lier les deux composantes *SPC* et *FDC*.

I.2.4. Premiers constats

L'industrie du semi-conducteur se caractérise par un contexte soumis aux aléas de fonctionnement. Les différentes politiques de maintenance, le système de contrôle en ligne, les méthodes de détection et de classification, les tests paramétriques, les mesures électriques, les boucles réactives... permettent de réduire une partie de la variabilité, de mieux maîtriser les dérives des équipements et d'améliorer la qualité des produits. Mais de nombreux problèmes rencontrés dans les ateliers de production (chute de rendement) sont là pour nous rappeler que tout n'est pas observé et observable et que le risque nul n'existe donc pas. Nous résumons nos constatations comme suit :

- le rejet de produits est fréquent et sa variabilité n'est pas maîtrisée,
- la fréquence des interventions correctives imprévues est élevée,
- la planification des maintenances préventives n'est pas optimale,
- le coût lié au processus de contrôle des produits (inspection) est considérable.

Compte tenu de cette brève description, la partie suivante s'attache à décrire dans le détail la problématique à laquelle ce manuscrit est dédié.

I.3. Problématique de la thèse

Après avoir présenté le contexte général des ateliers de fabrication en semi-conducteur, nous nous proposons dans cette partie de cerner la problématique qui fait que les coûts, le rendement et les temps de cycle ne sont pas à leurs meilleurs niveaux. Pour cela, nous allons nous intéresser dans un premier temps à l'organisation du système de production et du système informatique au sein d'une entreprise manufacturière. Ceci nous amènera alors à présenter le problème de l'observabilité et de la réactivité des systèmes face aux aléas de fonctionnement. Après quoi, nous terminerons cette partie par la présentation des objectifs de ce travail.

I.3.1. Systèmes automatisés de production SAP⁷

Dans un atelier de production en semi-conducteur, les équipements sont principalement classés en trois catégories :

- *Les équipements de production* (ou procédé) qui agissent sur le produit.
- *Les équipements d'inspection* (ou métrologie) qui permettent de contrôler que le travail effectué par un équipement de production l'a été fait correctement.
- *Les équipements de transport* (transitique) assurant l'acheminement d'un produit d'un équipement de production à un autre, ou à un équipement d'inspection.

Dans le cadre de nos travaux, nous nous sommes intéressés aux équipements de production, dans l'objectif d'analyser leur disponibilité. Un équipement de production peut être représenté tel que schématisé dans la figure I.5 (Deschamps et Zamaï, 2007) :

- *Le flux de produits* qui regroupe l'ensemble des produits (matière première, transformée, produits finis).
- *Le système contrôlé* qui se compose de pré-actionneurs, d'actionneurs, d'effecteurs et de capteurs.
- *Le système de commande* qui est composé de fonctions (commande, diagnostic, pronostic...) (Combacau et al., 2000) permettant de gérer le système contrôlé.

A titre d'exemple, la salle blanche Crolles 300mm de STMicroelectronics comptabilise jusqu'à 300 équipements appartenant (selon leurs fonctions) à une cinquantaine de familles

⁷ *Systèmes automatisés de production* : Automated Manufacturing Systems AMS.

différentes. Notons aussi que le coût moyen de mobilisation des équipements est très élevé (~300 \$ de l'heure) (Mili, 2009).




Figure I.5. Diagramme SAP.

Le système contrôlé peut être vu comme un ensemble de chaînes d'actions et de chaînes d'acquisition (cf. figure I.6). La chaîne d'action est un ensemble d'éléments permettant de transformer les ordres de commande en actions physiques. La chaîne d'acquisition permet quant à elle de mesurer les grandeurs physiques au travers de capteurs (Henry et al., 2012). Dans l'idéal, l'observation devrait être faite directement sur le produit mais pour des raisons techniques, les capteurs sont plus souvent placés sur l'effecteur, l'actionneur voire même le pré-actionneur. Ainsi, en fonction de ce positionnement le risque de ne pas observer une perturbation affectant la qualité de la fabrication d'un produit augmente et un équipement de production n'a alors aucun moyen pour affirmer que les opérations appliquées au produit l'ont été faites correctement.




Figure I.6. Structure interne d'un équipement de production.

Cette particularité de la chaîne d'acquisition et donc de la position de l'observation dans la chaîne d'action introduit inévitablement un doute quant à ce qui a réellement été fait. L'effet direct sur le produit est donc non observé, ce qui revient à considérer une partie en boucle ouverte dans le système de commande. Aussi pouvons-nous dire que plus le capteur est placé haut dans la chaîne d'action, plus la confiance dans l'action appliquée aux

produits doit être faible ce qui augmente le risque de ne pas avoir « vu » qu’une étape de fabrication d’un circuit intégré a été mal réalisée.

C’est la raison pour laquelle, les industriels placent, en plus des autres techniques, des équipements de métrologie au sein de leur ligne de production. Ces équipements, comme nous les détaillerons plus loin, permettent de contrôler, certes avec retard, la qualité et la conformité des produits.

I.3.2. Systèmes d’information

Comme nous venons de le voir, les contraintes technologiques liées au placement des capteurs dans les équipements de production induisent forcément des retards dans la détection des défauts produits. Afin de participer au traitement d’une telle problématique, faudrait-il encore pouvoir accéder aux informations de l’atelier pour envisager par exemple des inférences statistiques, déterministes ou probabilistes. Aussi nous semble-t-il opportun de présenter ici l’organisation générale des bases de données au sein desquelles nous pourrions par la suite puiser des informations requises pour la modélisation.

La figure I.7 présente une description des différentes bases de données associées aux équipements d’un atelier ainsi que quelques outils d’analyse de données fournies par des sociétés spécialisées (Shahzad, 2012). Les données sont collectées par des appareils de mesure et/ou des machines de métrologie (nous traitons ici l’exemple de STM).




Figure I.7. Description de l’environnement de production.

Nous distinguons deux familles principales de base de données (BD) :

1. BD associées à l'équipement : la BD-EDA « *Engineering Data Analysis* » qui est un entrepôt de données du procédé, la BD-FDC « *Fault Detection and Classification* » permet de suivre en temps réel l'évolution des paramètres équipements, la BD-TGV « *Tool Global Visibility* » qui est une mise en forme des données de maintenance facilitant ainsi leur extraction.
2. BD associées au produit : la BD-Inline contenant toutes les mesures physiques réalisées sur les transistors durant les opérations de production (sur un échantillon de *wafers*), la BD-EWS « *Electrical Wafer Sort* » regroupant les mesures électriques réalisées sur chacun des circuits intégrés en fin de ligne de production, la BD-PT « *Parametric Test* » réunissant les mesures électriques réalisées sur les structures de tests situées autour du circuit (pour tous les *wafers*), la BD-DEF « *Defectivity* » qui centralise les informations relatives à la présence de particules sur la surface du *wafer* afin de vérifier si il est contaminé ou non.

Dans une usine de fabrication de circuits intégrés, plusieurs types de produits sont traités (production de masse), de technologies très avancées et avec un degré d'intégration de plus en plus grand. Le moindre défaut sur le *wafer* implique une probabilité de rejet (ou *scrap*) relativement élevée. Le problème de l'observabilité d'un défaut au bon moment prend une place importante dans la recherche d'amélioration de performances. Afin de pallier à ce problème deux voies sont généralement proposées dans le milieu industriel : la métrologie réelle et la métrologie virtuelle.

I.3.3. Systèmes de métrologie

Comme nous l'avons rapidement évoqué précédemment, une première solution consiste à placer des équipements dits de métrologie réelle (à l'inverse de virtuelle) dans la chaîne de production, comme le montre l'exemple de la figure I.8 (ici nous illustrons le pire des cas sur le plan du coût d'investissement avec une machine de métrologie en sortie de chaque équipement de production). Elles assurent ainsi des étapes de contrôles nécessaires à la surveillance de la qualité des produits. Cela revient en fait à « fermer » la boucle de commande avec retard (voir section I.3.1 page 13). De fait, cela introduit des coûts supplémentaires souvent considérables, ne serait-ce qu'en termes d'investissements, de maintenance et d'augmentation des temps de cycle. De surcroît, et compte tenu des flux de produits importants caractérisant ces sites de production, il est important de noter que

les étapes de métrologie ne peuvent être systématiquement faites sur tous les produits, seuls quelques échantillons sont contrôlés ; ce qui pose également le problème de la pertinence du choix de l'échantillon à contrôler et de l'instant convenable pour le contrôle.




Figure I.8. Machines de métrologie.

Les inconvénients liés à l'intégration des machines de métrologie (d'un point de vue produit) ont conduit au développement naturel de la métrologie virtuelle (*Virtual Metrology VM*) avec comme objectif la minimisation du nombre de plaquettes à contrôler tout en améliorant à la fois la maîtrise des paramètres de la technologie, des rendements et des temps de cycle. Ainsi, la *VM* est définie comme étant une nouvelle technique de prédiction des valeurs de la métrologie sur les produits non mesurés physiquement (Chen et al., 2005). Son principe de base repose sur la possibilité de prévoir en temps réel des valeurs de paramètres à partir des informations collectées sur la production et la métrologie réelle (cf. figure I.9).




Figure I.9. Métrologie virtuelle.

Nous noterons cependant que la métrologie virtuelle se focalise sur la performance et la qualité de fabrication des plaquettes de silicium. Or, la principale source de rejets de produits est attribuée à la dérive des équipements (estimée entre 50% et 70%).

Il est donc nécessaire de développer des solutions complémentaires pour optimiser encore l'utilisation des équipements en termes de quantité, de qualité du résultat et de rendement global. C'est au cœur de ce constat que notre problématique de recherche se positionne. Nous nous proposons d'apporter notre contribution dans le cadre précis de l'amélioration de la disponibilité de l'équipement de production en particulier par le biais de la prédiction de leurs dérives et donc de la minimisation, voire l'annulation, des retards de détection des défauts produits.

I.3.4. Vers le calcul d'un indicateur de santé

Compte tenu de ce positionnement, nous nous proposons ici de synthétiser les éléments essentiels qui ferment le contexte de notre étude :

- la production est plongée dans un contexte complexe et incertain,
- les données de production et les connaissances des experts sont complètement ou partiellement disponibles,
- le niveau de rejet associé aux dérives des équipements est élevé,
- les systèmes de métrologie adressent en partie le problème de rendement de fabrication, et tels qu'ils sont appliqués actuellement, ils ne sont pas directement focalisés sur les dérives équipements (Chen et al., 2005).

De surcroît, il est nécessaire de préciser que les interventions préventives sont dans la plupart des cas planifiées en fonction du temps écoulé ou du nombre de produits passés. Ce type de planification peut entraîner des plans de maintenances « inutiles » ou « insuffisants » impliquant une indisponibilité importante des équipements de production. Aussi, nous constatons que la voie qui s'appuie sur la condition de l'équipement (son état de santé) pour planifier les interventions de maintenance n'est pas bien exploitée.

À partir de l'ensemble des points décrits ci-dessus, la solution à développer devra être en mesure de répondre aux interrogations suivantes :

- Comment estimer l'état de fonctionnement des *équipements* de production ?
- Comment maîtriser les risques de mal fabriquer un *produit* et donc la baisse des rendements ?

De manière à répondre à ces questions et de contribuer aussi à l'amélioration des performances de l'entreprise (limiter les coûts humains, matériels et financiers), il est généralement préconisé de développer des modèles d'apprentissage à partir des données

historiques et des connaissances expertes. De telles solutions doivent permettre d'appréhender, de manière prédictive, le comportement des équipements de production et d'améliorer ainsi leur efficacité.

C'est dans ce cadre que nos travaux se placent, tant sur le plan méthodologique que sur celui de la modélisation. L'objectif est de proposer une méthode générique pour développer un modèle d'estimation de l'état de santé des équipements (*Equipment Health Factor EHF*). Comme point de départ, nous considérons l'ensemble des données issues d'un atelier de production. A partir de ces données nous nous proposons de mettre en exergue des corrélations sur la base d'un raisonnement mathématique (probabiliste et/ou statistique) comme le montre la figure I.10. Les résultats obtenus doivent amener des éléments de décision afin d'aider les opérateurs d'exploitation dans la phase de planification des stratégies de maintenance sur les équipements et celles de métrologie sur les produits.




Figure I.10. Concept de l'EHF.

L'objectif du calcul de l'EHF est donc clairement ciblé sur le comportement des équipements de production. Par conséquent, il adresse l'amélioration du rendement des systèmes de production complexes en jouant sur la détection ou l'anticipation de l'occurrence d'une défaillance future sur le système ou sur la localisation des causes à l'origine des d'une défaillance.

Avant de détailler la méthodologie de calcul de ce nouvel indicateur que nous proposons dans ce mémoire, nous présentons tout d'abord un état de l'art sur les méthodes d'analyse des risques et de sûreté de fonctionnement. Par la suite, nous présentons dans la section II.4 les caractéristiques du concept d'EHF en détails et nous proposons dans l'annexe A un ensemble de définitions liées à la notion de défaillance dans le domaine particulier de l'industrie du semi-conducteur.

I.4. Positionnement des travaux

Après avoir présenté le contexte de notre travail et posé la problématique à laquelle nos travaux apportent leur contribution, nous proposons dans cette dernière partie du chapitre I une revue bibliographique des méthodes les plus utilisées dans les domaines de l'analyse des risques et de la sûreté de fonctionnement. En tenant compte des besoins soulevés plus haut, nous affichons un « premier » positionnement. Nous terminerons cette partie par la présentation du projet européen *IMPROVE* dans lequel cette thèse s'inscrit.

I.4.1. Méthodes qualitatives et quantitatives

Les activités industrielles, tout comme les aléas naturels, peuvent induire des risques de nature diverse, voire conduire à des événements catastrophiques. De façon à réduire ces risques à des niveaux acceptables, à en limiter les coûts aussi bien humains, matériels que financiers, il est nécessaire de les évaluer, d'en prévenir leur survenue (prévention) et d'en limiter leurs impacts (protection). C'est dans ce contexte que les industries de l'armement, de l'aéronautique ou du nucléaire ont développé des méthodes d'analyse prévisionnelle des risques (Favaro et Monteau, 1990). L'industrie du semi-conducteur est considérée comme particulièrement sensible aux aléas et aux contraintes de fonctionnement et la prise en compte du risque est un facteur clef. Raison pour laquelle, un intérêt particulier a été donné aux méthodes d'analyse de risques en les adaptant à leur activité (Zafra-Cabeza et al., 2008).

En général et pour une entité donnée, le risque peut être défini comme étant l'éventualité qu'un événement créant des dommages se produise (Sienou, 2009).




Figure I.11. *Risque et danger (Flaus, 2013).*

Le risque est une probabilité d'apparition d'une défaillance, il est caractérisé par sa sévérité, son occurrence et sa détection (*SOD*) (Bassetto, 2005). Un risque industriel représente les défaillances potentielles qui peuvent avoir un impact sur le produit, les équipements ou les processus de fabrication. Les dommages engendrés peuvent être des pertes de rendement, de temps de cycle ou de coût.

De son côté, la sûreté de fonctionnement (*SdF*) est une discipline des sciences de l'ingénieur qui vise à assurer le bon fonctionnement d'un système. La *SdF* intègre à la fois les aspects de fiabilité, de maintenabilité, de disponibilité et de sécurité (Villemeur, 1988).

Dans le domaine industriel, les exigences client en termes de qualité sont très fortes. Le développement continu des technologies et la complexité des procédés de fabrication sont à l'origine des évolutions des méthodes d'analyse de risques et de sûreté de fonctionnement. Selon la nature du système, le type de problème étudié et les objectifs visés, différentes méthodes sont appliquées. Certaines d'entre elles sont résumées dans le tableau I.1, (Tixier et al., 2002 ; Simeu-Abazi, 1998).

Méthodes inductives Qualitatives	Méthodes déductives Quantitatives	Méthodes stochastiques Fouille de données
<i>APR</i>	<i>Diagramme de fiabilité</i>	<i>Retour d'expérience</i>
<i>HAZOP</i>	<i>Arbre de défaillance</i>	<i>Réseaux Bayésiens</i>
<i>AMDE/AMDEC</i>	<i>Arbre de défaillance dynamique</i>	<i>Simulation Monte-Carlo</i>
	<i>Processus de Markov</i>	
	<i>Réseaux de Petri</i>	

Table I.1. Méthodes d'analyse de risque et de sûreté de fonctionnement.

Lorsqu'un système est caractérisé par un fonctionnement séquentiel, les méthodes de type inductives (ascendantes, causes à effets) sont très efficaces pour l'identification des risques potentiels décrivant ainsi les bons et les mauvais fonctionnements du procédé. Dans l'industrie des procédés classiques (peu complexes), les méthodes les plus utilisées sont :

- *l'Analyse Préliminaire des Risques (APR)*, une technique très générale orientée vers le domaine de la sécurité, elle est utilisée durant les phases préliminaires de conception pour identifier et évaluer les risques (Mazouni, 2009).
- *l'HAZard and OPerability studies (HAZOP)*, cette méthode est utilisée pour identifier et évaluer les problèmes qui peuvent représenter un risque humain et matériel. Elle est surtout développée pour les procédés chimiques.

- *l'Analyse des Modes de Défaillance, de leurs Effets et de leur Criticité (AMDEC)*, c'est la plus détaillée pour les systèmes présentant un aspect dynamique (Faucher, 2004).

Pour les systèmes dépendant peu ou pas du temps (statiques) des méthodes de type déductives (descendantes) sont appliquées, comme par exemple *l'Arbre de Défaillance*. Cette méthode est principalement utilisée dans le domaine de l'ingénierie de la sécurité et elle procède d'une démarche effets-causes.

Pour les systèmes dynamiques, des méthodes stochastiques sont appliquées. *Les processus de Markov* sont basés sur l'identification des différents états du système lors de l'exploitation et sur l'analyse des *transitions* de passage aléatoire d'un état à un autre. Pour un *processus de Markov*, les taux des transitions sont constants. Quant aux *réseaux de Petri*, ce sont des graphes bipartites orientés utilisés pour les modèles dynamiques comportant un plus grand nombre de *variables d'état*. Un réseau de Petri est représenté par une partie statique : les états, les transitions, les arcs et une partie dynamique : les jetons de marquage (David et Alla, 1992). Lorsque le système contient un grand nombre de variables d'état (complexe) ou si le processus n'est pas *markovien* c'est-à-dire que les lois de probabilité ne sont pas exponentielles et que les taux de transition sont quelconques, *les méthodes de Monte Carlo* sont appliquées (Leroy, 1992). Les *Réseaux Bayésiens* généralisent les méthodes des arbres de défaillance et de décision.

De même, les méthodes présentées peuvent être classées en deux catégories : *méthodes probabilistes* et *déterministes*. Pour identifier les risques, les méthodes déterministes utilisent les données du produit, processus ou équipements, elles permettent d'identifier ainsi les conséquences. L'identification des risques par les méthodes probabilistes passe par un calcul des probabilités et l'occurrence du risque (Tixier, 2002).

L'application de ces approches dans le contexte du semi-conducteur se trouve souvent restreinte et exposée à un certain nombre d'inconvénients, les principales limitations sont dûes :

- au développement continu des technologies,
- à la complexité du procédé de fabrication et des stratégies de maintenance,
- à la taille du système comportant un grand nombre d'états,
- à la nécessité de considérer le domaine de l'analyse de données et ses spécificités,
- au besoin de fournir des évaluations quantitatives,

- à la difficulté de maintenir des méthodes qualifiées de lourdes,
- à la longueur du processus d'implémentation quantifiables à long terme,
- à la difficulté de trouver des corrélations entre paramètres (*FDC...*) et événements,
- à l'intégration limitée de la connaissance expertise.

Dans le but de fournir des modèles pour améliorer la prise de décision, de nombreux travaux (Liu, 2008 ; Mili, 2009 ; Ditrome et al., 1989) ont examiné la question de la fiabilité des équipements en semi-conducteurs. D'autre part, au cours de ces dernières années, les méthodes statistiques et probabilistes se sont imposées en apportant des résultats significatifs dans des domaines aussi variés que le traitement de la parole, les finances, le diagnostic et le suivi de fonctionnement d'un système technologique (Naïm et al., 2007 ; Weber et al., 2012). La synthèse des méthodes d'analyse de risques, du contrôle de procédés et les objectifs présentés ici permettent de mettre en exergue l'effort important qui doit être mis sur les techniques d'analyse de données réelles et de connaissances humaines (retour d'expérience, modèles graphiques probabilistes...) afin de trouver des corrélations significatives entre variables et événements observés. Nous nous positionnons ainsi clairement au sein de telles techniques, en particulier à des fins d'estimation des dérives futures des équipements de production. Au sein de cette thématique, plusieurs axes peuvent être envisagés (à base de données, de modèles, de connaissances, etc.). Aussi, proposons-nous au lecteur un rapide tour d'horizon des travaux développés dans le cadre de la communauté automatique-productique nationale.

I.4.2. Premier positionnement et travaux connexes

Compte tenu des préconisations du paragraphe précédent, notre étude s'oriente donc vers des méthodes du domaine du pronostic et de gestion de santé permettant d'estimer l'état de fonctionnement futur d'un équipement de production. Permettez nous ici de présenter brièvement quelques travaux qui ont retenus notre attention.

Plusieurs travaux de recherche ont été réalisés ces dernières années au sein du Centre de Recherche en Automatique de Nancy (*CRAN*). Le travail de (Léger, 1999) a permis de proposer un cadre méthodologique pour la modélisation d'une politique de maintenance préventive avancée. Sur la base de cette contribution, la thèse de (Muller, 2005) a proposé une méthodologie de formalisation d'un processus de pronostic à partir d'un formalisme par réseaux Bayésiens. En se basant sur les résultats du processus de pronostic, les travaux de (Thomas, 2009) ont proposé un concept de maintenance opportune pour la prise de

décision dynamique. Enfin, et dans cette continuité, la thèse de (Cocheteux, 2010) a proposé une formalisation du processus de pronostic pour une politique de maintenance proactive. Toujours sur la même thématique du pronostic industriel, la thèse de (El-Koujok, 2010) au sein de l'institut *FEMTO-ST* de Besançon a abouti à une proposition de l'intégration de la confiance à un modèle prédictif supporté par une technique neuro-flou. Pour une application dans le domaine naval, (Schutz, 2009) a utilisé une approche basée sur le pronostic afin de contribuer à l'optimisation des plans d'exploitation et de maintenance. Au sein du laboratoire *LSIS* de Marseille, deux thèses de doctorat ont adressés le problème du pronostic. (Peysson, 2009) a proposé une méthodologie à caractère générique pour le pronostic de dégradation d'un système complexe, cette méthodologie est fondée sur la description experte est basée sur l'exploitation d'une base de données contenant des séries temporelles de différents scénarios de dégradation d'un équipement. Quant aux travaux de (Gucik-Derigny, 2011), ils proposent de développer des modèles de pronostic pour les systèmes non linéaires à base de modèles d'observateurs (linéaire, à grand gain et à mode glissant) et par l'utilisation des modèles incertains. La thèse de (Ribot, 2009) au sein du *LAAS* de Toulouse en collaboration avec *l'ENIT* de Tarbes, propose une architecture générique de supervision pour aider à la prise de décision d'actions de maintenance. Une application du modèle adaptatif de pronostic est proposée sur un système aéronautique.

Sur la base de cette synthèse et la problématique générale à laquelle nous tendons à proposer une solution, nous pouvons positionner nos travaux comme suit :

- sur l'aspect modélisation, notre contribution est clairement placée dans la thématique du pronostic de défaillance d'un équipement de production afin d'améliorer sa disponibilité au travers d'une planification optimale des interventions de maintenance.
- sur l'aspect applicatif, notre contribution doit prendre en compte les caractéristiques de complexité et d'incertitude de l'étude. En effet, les techniques basées sur la fouille de données et la connaissance experte sont les plus adaptées à notre cas (apprentissage automatique).

Compte tenu de ce positionnement, nous nous focalisons dans le reste du manuscrit sur les trois domaines clefs suivants : la maintenance prédictive, le pronostic et l'estimation de l'état de santé des équipements de production.

I.4.3. Projet IMPROVE

Comme nous l'avons évoqué dans l'introduction générale de ce mémoire, les travaux de recherche exposés ici ont été réalisés au sein du projet européen *IMPROVE*⁸. Ce dernier vise à améliorer la compétitivité des fabricants du semi-conducteur européens par rapport aux autres concurrents du secteur. Les usines doivent être en mesure de produire des circuits intégrés de haute qualité en technologies avancées, avec des temps de cycle de plus en plus courts et à des coûts raisonnables. Ce projet de 42 mois regroupe 35 partenaires industriels et fournisseurs de solutions logicielles (*STMicroelectronics*, *Lfoundry*, *Infineon*, *Probayes*, *PDF-Solutions...*) et des académiques (*G-SCOP*, *EMSE*, *CEA-LETI*, *Franhofer...*) de 6 pays différents et il fait partie du *FP7*.

Le projet *IMPROVE* est structuré en sept *Work Packages (WP)* comportant trois axes de recherche et de développement, pour chacun de ces axes, l'objectif est de proposer des démonstrateurs de faisabilité (*Proof Of Concept POC*) :

- Les techniques de Métrologie Virtuelle (*VM*), permettant de mieux contrôler les opérations de production *WP2* : (Ferreira et al., 2011).
- Les techniques de Maintenance Prédictive (*PdM*), permettant d'améliorer les rendements des équipements (moins d'intervention, disponibilité maximale...) *WP3* : (Bouaziz et al., 2011a ; Pampuri et al., 2011 ; Chen et Blue, 2009 ; Thieullen et al., 2012).
- Les boucles de traitement réactives (évaluation dynamique des risques et plan de contrôle dynamique), afin d'identifier et de supprimer les étapes de contrôle devenues inutiles tout en améliorant la maîtrise des procédés de fabrication *WP4* : (Yugma et al., 2012 ; Bettayeb, 2012 ; Dautère-Pères et al., 2010).

En ce qui concerne le *WPI*, il doit fournir des spécifications et des architectures générales de manière à coordonner et consolider les approches proposées par les trois *WP* précédents. De son côté, le *WP5* assure l'intégration des techniques développées dans les systèmes d'information et d'aide à la décision existants par le développement des maquettes de validation. L'objectif du *WP6* est de transmettre les résultats et la connaissance acquise vers les fabricants d'équipements, tandis que le *WP7* vise à mener à bien les tâches nécessaires à la coordination du consortium du projet. Cette organisation générale ainsi que ses liens est schématisé dans la figure I.12 :

⁸ *IMPROVE*: Implementing Manufacturing science solutions to increase equipment productivity and performance.




Figure I.12. Organisation et liens du projet IMPROVE.

Dans le cadre du projet *IMPROVE*, nos travaux se positionnent à la charnière entre le diagnostic des défaillances et l'analyse des risques et donc au sein de l'axe *WP3*, ces travaux ont été menés en collaboration étroite avec les deux fabricants mondiaux *LFoundry* et *STMicroelectronics*.

I.4.4. Partenaires industriels principaux

LFoundry est une société spécialisée dans la conception et la fabrication des circuits intégrés de haute technologie. *LFoundry* Rousset (*FAB7*) emploie environ 1200 personnes. Avec ses 10000 m² de salle blanche et sa capacité potentielle de 10000 *wafers* de 8 pouces par semaine, elle se positionne comme un modèle de technologie. Ses familles de produits sont principalement :

- *Mémoires non volatiles (NVM)* : mémoires qui ont la caractéristique de conserver leur contenu une fois l'alimentation coupée. Il existe aussi des modèles effaçables et programmables électriquement comme les *EEPROM*, les mémoires *FLASH*...
- *Microcontrôleurs, DSP*⁹ : circuits intégrés rassemblant les éléments essentiels d'un ordinateur. Ils représentent la plus grosse partie des ventes dans le marché des microprocesseurs et ils sont utilisés pour des applications industrielles, la téléphonie mobile, l'automobile, les cartes à puces...

⁹ *DSP* : Digital Signal Processor.

Les produits et les clients de LFoundry sont dans les secteurs d'activité suivants :

- Les télécommunications : *Ericsson, Nokia, Motorola, Siemens, Toshiba,*
- L'industrie, le médical et le militaire : *Honeywell, Roche, BAE Systems,*
- L'informatique et les réseaux : *HP, IBM, Microsoft, Seagate,*
- La sécurité et les smart-cards : *Gemalto, IBM, HP,*
- Les produits Grands Publics : *Sony, Pioneer, Samsung, Sharp, Fujifilm,*
- L'automobile : *Bosch, Delphi, Siemens.*

STMicroelectronics est un fabricant mondial de semi-conducteur. Cette entreprise conçoit, développe, fabrique et commercialise une vaste gamme de circuits intégrés et de composants utilisés dans de nombreuses applications microélectroniques et industrielles. *ST* a pour objectif de devenir le leader incontesté dans les domaines de la convergence multimédia et des applications de puissance. Elle dispose de centres de recherche, de centre de conceptions et de sites de production. *STMicroelectronics* Crolles a construit en 2002 une nouvelle usine de recherche et de production appelée Crolles 2 (ou 300 mm, en relation avec la taille des *wafers*). Pour le dernier trimestre 2010, les parts de marché (en vente) ainsi que les clients potentiels sont :

- Les télécommunications 39 % : *Motorola, Nokia, Siemens, Sony Ericsson,*
- Le grand public 14% : *LG, Nintendo, Panasonic, Philips, Samsung,*
- Secteur industriel et multi-segment 10% : *Delta,*
- L'informatique 18% : *Apple, Dell, HP,*
- L'industrie automobile 19% : *Bosch, Conti, Delphi, Pioneer.*

La fabrication des produits chez *STMicroelectronics* se divise en deux grandes étapes. La première consiste à produire des circuits intégrés et d'en tester la fonctionnalité (le *Front-End*), tandis que la deuxième réside dans le découpage et l'assemblage dans des boîtiers des circuits provenant des usines (le *Back-End*). En termes de chiffre d'affaire, *STMicroelectronics* se place actuellement à la septième place dans le classement des fabricants mondiaux de semi-conducteurs.

I.5. Conclusion

Ce premier chapitre nous a permis de présenter non seulement le contexte de notre étude en particulier marquée par le projet européen *IMPROVE* ainsi que le besoin très fort d'amélioration des rendements du secteur du semi-conducteur : enjeu fondamental et d'avenir pour les entreprises concernées.

Clairement positionnés sur une approche prédictive, nous sommes force de proposition d'une méthode de pronostic à partir de données et de connaissances expertes.

Il s'agit pour nous de proposer une approche à base de modèle capable d'estimer l'état de santé des équipements de production dans un contexte complexe et incertain. A ce niveau, il est nécessaire de préciser une hypothèse importante à nos recherches : nous considérons en effet que seuls les équipements de métrologie sont exempts de défaillances.

Les résultats attendus d'une telle approche doivent contribuer à l'aide à la décision aux opérateurs en atelier afin de les assister dans la programmation optimale des interventions de maintenance. Pour cette raison, nous proposons dans le chapitre suivant une méthodologie de modélisation de l'*EHF* centrée sur les besoins de la maintenance prédictive.

II. Vers des stratégies de maintenance avancées

II.1. Introduction.....	31
II.2. Évolution des stratégies de maintenance.....	31
II.2.1. Impact de la maintenance sur la performance système.....	32
II.2.2. Limites des maintenances correctives et préventives.....	33
II.2.3. Mise en place d'une stratégie PdM.....	36
II.2.4. Architectures supports à la PdM.....	37
II.2.5. Synthèse et positionnement	39
II.3. Pronostic et gestion de la santé PHM.....	40
II.3.1. Concept de traitement de données.....	42
II.3.2. Concept du diagnostic	42
II.3.3. Concept du pronostic.....	43
II.3.4. Concept d'aide à la décision.....	46
II.3.5. Synthèse et positionnement.....	47
II.4. Méthodologie d'intégration du modèle issu du pronostic.....	48
II.4.1. Caractéristiques de l'indicateur de santé EHF.....	49
II.4.2. Étape 1 : Identification des modes de défaillance.....	51
II.4.3. Étape 2 : Modélisation et validation.....	52
II.4.4. Étape 3 : Paramétrage du modèle.....	53
II.4.5. Étape 4 : Analyse en ligne.....	54
II.5. Conclusion.....	55

II.1. Introduction

Dans un premier temps, ce chapitre a pour objet de présenter l'évolution de la fonction maintenance, une évolution fondée sur les améliorations des stratégies traditionnelles. Particulièrement, l'apport de la mise en place d'une stratégie de maintenance prédictive *PdM*¹ (*Predictive Maintenance*) aux performances du système sera exposé. Dans la deuxième partie de ce chapitre, nous présentons les principaux concepts de la discipline du *PHM* (*Prognostic and Health Management*), domaine sur lequel nous nous appuyons pour établir notre propre méthodologie de travail. La dernière partie détaillera ainsi l'approche de modélisation de l'indicateur *EHF* (*Equipment Health Factor*) divisée en quatre étapes, avec comme objectif la prédiction de l'état de santé des équipements de production dans le domaine semi-conducteur. La conclusion du chapitre est consacrée à une synthèse de ces trois aspects : *PdM*, *PHM* et *EHF*, ainsi que le positionnement de notre travail en termes d'outils probabilistes pour la modélisation.

II.2. Évolution des stratégies de maintenance

Ces dernières années, l'importance accordée à la compétitivité a fait passer la maintenance du rang d'un mal nécessaire à un élément contributeur à la réalisation des objectifs des entreprises. Cette évolution de la maintenance a conduit au développement de nombreuses méthodologies visant à optimiser cette activité. Initialement ces méthodologies ont concerné les domaines de l'aéronautique et de l'énergie, mais le principe d'optimisation est applicable aux autres domaines (Despujols, 2005) avec des divergences liées à la nature et aux spécificités de chaque secteur.

Dans le domaine du semi-conducteur, les installations de fabrication sont complexes et les dépenses pour les entretenir représentent une part importante du chiffre d'affaire des compagnies. Les arrêts d'équipements peuvent représenter une perte importante de la productivité, de plus, le temps d'arrêt sur un équipement peut provoquer l'inactivité d'un grand nombre d'autres équipements de fabrication (Montgomery, 2000). L'amélioration de la fonction maintenance est devenue ainsi un enjeu majeur dans un contexte concurrentiel accru. L'amélioration des stratégies de maintenance consiste à la mise en place des méthodes et d'outils pour répondre à l'évolution, de plus en plus rapide et complexe, du contexte de production. Pour mieux positionner l'importance d'optimiser les stratégies de

¹ *Predictive Maintenance*: équivalente en français de « Maintenance Prévisionnelle ». Dans ce travail, l'abréviation *PdM* est utilisée pour désigner la « Maintenance Prédictive ».

maintenance, nous présentons dans ce qui suit l'impact de ce processus sur la performance d'un système et en particulier dans le domaine semi-conducteur.

II.2.1. Impact de la maintenance sur la performance système

Dans le domaine industriel, les principaux enjeux considérés sont la sûreté et la réduction des coûts et en particulier le coût des stratégies de maintenance (Corset, 2003 ; Zille, 2009). En effet, l'idéal est de produire avec une capacité maximale tout en réduisant le coût et en améliorant les aspects de la sûreté de fonctionnement des systèmes (fiabilité, sécurité, maintenabilité et disponibilité). Des études réalisées au cours des 20 dernières années ont révélé que les coûts directs et indirects de la maintenance, dans toute l'Europe, sont compris entre 8 et 16 % du chiffre d'affaires global (Iung et Marquez, 2006). Les coûts directs sont associés simplement aux activités de maintenance et intègrent la main d'œuvre, les outils, les pièces de rechange, les formations, la surveillance, etc. Les coûts indirects sont induits par l'arrêt de l'exploitation des équipements (Al-Najjar et Alsyouf, 2004). Dans ses travaux, (Hohmann, 2009) a présenté sous la forme d'un graphique (cf. figure II.1) le rapport existant entre les coûts directs de la maintenance et la disponibilité des équipements.




Figure II.1. Rapport entre coûts de maintenance et disponibilité.

D'après ce graphe, optimiser la maintenance consiste à trouver un équilibre entre une disponibilité des équipements que nous souhaitons maximiser et un coût des interventions que nous souhaitons minimiser. De ce fait, un certain nombre de points doivent être pris en compte lors de la définition d'une politique de maintenance (Hohmann, 2009), nous les résumons comme suit :

- Le fait d'économiser les coûts de maintenance engendre peu d'interventions, en revanche cela implique généralement des arrêts de production qui se traduisent par d'importantes pertes de chiffre d'affaires global.
- Intervenir trop permet en générale de réduire l'occurrence des défaillances mais cela signifie des coûts élevés sans apport nécessaire à la performance globale de production. C'est ce que nous appelons « phénomène de sur-qualité ».
- Il existe un niveau minimal de dépenses « seuil incompressible » dû aux pannes imprévisibles, sur lesquelles il faut intervenir, peu importe le coût engendré.
- Les coûts de dysfonctionnement engendrés par les défaillances sont inversement proportionnels aux coûts alloués à la maintenance, et les deux additionnés représentent le coût total du maintien du système en conditions opérationnelles.

Ces préconisations permettent de signaler comment est définie une politique de maintenance pour un problème donné, cette tâche difficile doit être réalisée de manière à satisfaire un compromis entre coûts et disponibilité. Avec l'évolution des processus de fabrication, devenus complexes et sophistiqués, se contenter des politiques de maintenance statiques s'avère inefficace car quelque soit le choix réalisé, les objectifs ne seront pas atteints. Ceci est dû principalement aux restrictions de ces stratégies de maintenance. Dans ce qui suit, nous présentons les limites qui ont contribué à l'évolution des stratégies de maintenance traditionnelles vers des approches plus adéquates.

II.2.2. Limites des maintenances correctives et préventives

La fonction « maintenance » joue un rôle central et essentiel dans le maintien en conditions opérationnelles des systèmes (Pinjal et al., 2005). Dans le chapitre précédent, nous avons distingué deux familles principales de maintenance des systèmes industriels, la maintenance corrective et la maintenance préventive. Chaque famille est caractérisée par une condition de lancement (présence ou non de la défaillance) et une tâche à accomplir (rétablir ou maintenir le système). Le choix d'une stratégie est un processus complexe qui repose principalement sur des critères de performance. Néanmoins, certaines approches statiques de maintenance affichent leurs limites car elles engendrent des arrêts inutiles ou des opérations superflues (Muller, 2005), et ne permettent pas d'atteindre les objectifs souhaités :

- *Maintenance corrective palliative ou curative* : appliquée suite à une panne, elle est simple à mettre en œuvre. En revanche, ce type d'approche ne permet pas

d'anticiper les causes potentielles d'une future défaillance et par conséquent d'éviter l'arrêt du système « subir au lieu de maîtriser ». Elle peut entraîner des arrêts longs avec des pertes considérables ne serait ce qu'en termes de rendement de fabrication et de qualité des produits (coûts indirects).

- *Maintenance préventive périodique ou systématique* : exécutée avant la détection d'une panne, en se basant sur un échéancier fixé a priori et considère qu'il est possible d'éviter la défaillance d'un système. En revanche, ce type d'approche ne permet pas de contrôler d'une manière dynamique l'état de la dégradation des paramètres des équipements ou de la dérive de la qualité des produits conduisant à un « phénomène de sur-entretien ».

Le domaine du semi-conducteur n'est pas épargné par ces limites. Suite à une étude de terrain menée avec nos partenaires industriels, nous avons constaté que les arrêts induits par les interventions non programmées représentent une part importante de l'indisponibilité totale des équipements. Pour ce qui est des interventions programmées, nous avons constaté que certaines d'entre elles ne sont pas justifiées. La planification de ces dernières est définie par des recommandations du fournisseur ou de l'expérience. Généralement, ce sont des compteurs qui calculent, par exemple, le temps écoulé depuis la dernière maintenance, le nombre de plaquettes traitées ou le cumul d'épaisseur déposée.

Ces limites pointent le besoin d'améliorer les approches statiques de la maintenance et d'aller au-delà des profits qu'elles offrent. Pour cela, il convient de suivre dynamiquement non seulement l'état du système de production mais aussi l'évolution des causes potentielles d'occurrence des défaillances. Ceci permet de planifier les interventions d'une manière intelligente et optimale tout en minimisant les coûts associés aux interventions.

À partir des années 1980, le concept de la maintenance industrielle a évolué (figure II.2). Les travaux d'amélioration ont visé à intégrer les taux de défaillance et de disponibilité afin d'améliorer les performances des équipements (Nakagawa et Mizutani, 2009). Avec la prise en compte des conditions opérationnelles réelles, deux nouvelles stratégies sont apparues :

- *Maintenance conditionnelle* : elle est définie par l'*AFNOR*² comme étant « une maintenance préventive basée sur une surveillance du fonctionnement du bien

² *Association Française de Normalisation* : organisme officiel français créée en 1926, site officiel : <http://www.afnor.org/>.

et/ou des paramètres significatifs de ce fonctionnement intégrant les actions qui en découlent (AFNOR 13306, 2001) », la programmation des interventions repose essentiellement sur le dépassement des seuils considérés comme critiques, car la date de l'occurrence d'une défaillance future est incertaine.

- *Maintenance prévisionnelle (ou prédictive)* : selon la même norme, elle est définie comme étant « une maintenance conditionnelle exécutée en suivant les prévisions extrapolées de l'analyse et de l'évaluation de paramètres significatifs de la dégradation du bien (AFNOR 13306, 2001) », elle permet de prédire l'occurrence d'une défaillance future sur le système pour une meilleure programmation des interventions.

À partir des années 1990, la fonction de maintenance a encore évoluée avec l'apparition des stratégies proactives. Elles permettent, à la fois, de suivre l'évolution de l'état du système et d'adresser les causes d'une future défaillance. Avec l'évolution des outils informatiques, nous assistons depuis une dizaine d'années à l'émergence de nouveaux moyens de gestion de la maintenance, parmi lesquels nous citons la maintenance à distance assurée par des moyens de télécommunication directs (réseaux) et la e-maintenance définie comme étant un support lié au service internet et basé sur l'intégration des connaissances de maintenance dans un seul système (Muller et al., 2008).




Figure II.2. Évolution de la fonction maintenance.

La minimisation du niveau des interventions correctives non programmées et l'optimisation des interventions préventives régulières sont des objectifs incontournables pour les industriels du semi-conducteur. L'importance accordée à la disponibilité des équipements de production et au suivi de leur état de dégradation, laisse à penser que nous devrions être plus attentifs à la mise en œuvre efficace d'une stratégie de type

prévisionnelle. Dans ce sens, la maintenance prédictive *PdM* suscite particulièrement notre intérêt puisqu'elle répond aux exigences et aux attentes exprimées par les industriels en particulier en ce qui concerne l'identification des causes des futures pannes et l'estimation de l'état de dégradation du système. Dans le paragraphe suivant, nous décryptons les grandes lignes de cette politique préventive.

II.2.3. Mise en place d'une stratégie PdM

L'abréviation *PdM* (*Predictive Maintenance*) est plutôt relative à la littérature anglophone. Dans la littérature francophone, la terminologie « maintenance prédictive » n'est pas encore normalisée, le concept de « maintenance prévisionnelle » est souvent employée afin de caractériser les planifications prévisionnelles des interventions en se basant sur le comportement des équipements. Si nous nous référons à l'*AFNOR*, la *PdM* est définie comme étant une « maintenance conditionnelle exécutée en suivant les prévisions extrapolées de l'analyse et de l'évaluation de paramètres significatifs de la dégradation du bien (AFNOR 13306, 2001) ».

L'aspect prédictif de cette stratégie réside dans l'anticipation et la prévision des états futurs de l'équipement. Cela permet de planifier au mieux la date de la future intervention et d'assurer un intervalle optimal entre deux réparations. Afin de mettre en œuvre une telle stratégie de maintenance, il est nécessaire de (Cocheteux, 2010) :

- mesurer des paramètres significatifs de l'état de dégradation du système,
- valider ces mesures, analyser leurs évolutions et diagnostiquer les anomalies,
- extrapoler les mesures et les courbes de tendance en fonction de l'usage du bien,
- planifier la maintenance selon les prévisions sur les seuils.

D'autre part, l'industrialisation d'une stratégie *PdM* relève un certain nombre de défis pour les spécialistes. Dans le domaine semi-conducteur, nous signalons particulièrement :

- l'installation d'un appareillage approprié et fiable avec suffisamment de mesures,
- la dégradation est mesurable avec des seuils critiques bien définis,
- le développement des méthodes de diagnostic et de pronostic appropriées,
- la planification des interventions en concordance avec la logistique globale.

L'impact de la stratégie *PdM* sur les performances du système peut être mesuré à travers les avantages offerts par rapport aux politiques traditionnelles :

- minimisation du nombre de défaillances imprévues,

- meilleure maîtrise des temps de cycle et de l'organisation,
- amélioration de la disponibilité des équipements,
- réduction des coûts grâce à une planification maîtrisée.

Quant à la modélisation, la *PdM* emploie les techniques issues de l'intelligence artificielle *AI*³ et/ou d'autres méthodes prédictives, elle se base sur les conditions actuelles et passées de l'équipement et du procédé de fabrication (Liu, 2008). Malgré les coûts de développement élevés, les techniques de la *PdM* ont été implémentées avec succès dans certains domaines d'application, tels que les machines tournantes (Velarde-Suarez et al., 2006), l'aéronautique (Byington et al., 2002) ou l'industrie de l'électronique et des composants électriques (Bansal et al., 2005). Néanmoins, un état des lieux sur le développement des programmes de maintenance en général et de la pratique de la *PdM* en particulier, dans l'industrie du semi-conducteur, a révélé un besoin incontestable de porter l'effort vers une intégration des stratégies prédictives (Djurdjanovic et Liu, 2006).

Comme nous l'avons mentionné, l'activité *PdM* inclue plusieurs processus à la fois tels que la mesure, la surveillance, le diagnostic, la prédiction et l'aide à la décision. Ces processus doivent être intégrés dans une architecture fonctionnelle globale. C'est la raison pour laquelle des travaux sont apparus récemment pour proposer des systèmes supports à la maintenance prédictive (El-Koujok, 2010). En se basant sur un inventaire dressé dans (Cocheteux, 2010 ; Muller, 2005 ; El-Koujok, 2010), la partie II.2.4 va décrire la structure de la principale architecture destinée à supporter la *PdM* et les grandes lignes de certaines architectures plus spécifiques.

II.2.4. Architectures supports à la PdM

Un consortium américain, nommé *MIMOSA*⁴, composé de scientifiques et d'industriels a proposé un standard d'architecture unique pour intégrer les processus de la maintenance conditionnelle et de la maintenance prévisionnelle (*PdM*). Il s'agit du programme *OSA/CBM* (*Open System Architecture for Condition Based Maintenance*) (Lebold et Thurston, 2001). La figure II.3 présente la structure générique de cette architecture découpée en sept couches où chaque couche est décrite par l'ensemble des fonctions suivantes :

³ *Artificial Intelligence*: une discipline qui trouve ses origines dans les travaux d'A. Turing (Turing, 1950).

⁴ *Machinery Information Management Open System Alliance*: est une association axée sur le développement des architectures systèmes (standards) ouvertes (<http://www.mimosa.org/>).

- *Module d'acquisition* : il est composé d'éléments d'acquisition et des transducteurs, c'est eux qui fournissent les données numériques au système.
- *Module de traitement* : il traite les données numériques, les met au bon format et extrait des caractéristiques spécifiques (indicateurs).
- *Module de surveillance* : il détermine, sur la base d'algorithmes, si l'écart entre les valeurs en ligne et celles attendues est significatif.
- *Module de diagnostic* : il donne une connaissance sur l'état du système surveillé, définit et localise les défaillances.
- *Module de pronostic* : il donne une prédiction sur l'état futur du système surveillé avec un niveau de confiance et des limites d'erreur.
- *Module d'aide à la décision* : il définit les actions à engager en se basant sur l'état du système, son état futur et des informations contextuelles.
- *Module de présentation* : il utilise les informations antérieures pour les présenter de la façon la plus simple possible (interface homme-machine par exemple).




Figure II.3. Structure séquentielle de l'architecture OSA/CBM.

En plus de son aspect générique, l'architecture OSA/CBM présente d'autres avantages :

- ses modules sont flexibles et configurables,
- le choix d'algorithmes et des outils est soumis à l'utilisateur,
- elle peut être représentée aussi sous forme distribuée (Lebold et al, 2002),
- elle peut être simplifiée si le besoin industriel le recommande.

Depuis quelques années, un certain nombre d'architectures est apparu telle que la structure *WatchDog* introduite par (Lee, 1998), l'architecture opérationnelle distribuée *MPROS*⁵ initiée par (Hadden et al., 2002), le *PEDS*⁶ proposé par (Byington et al, 2002) ou

⁵ *Machinery Prognostics/Diagnostics System.*

plus récemment l'architecture du *SIMP*⁷ détaillée dans (Muller, 2005). Si nous ne les décrivons pas en détail ici c'est parce qu'ils ne présentent pas une différence majeure avec la *OSA/CBM*. Le paragraphe suivant conclut cette partie par une synthèse et un positionnement de nos travaux de recherche dans le cadre de la maintenance dans l'industrie semi-conducteur.

II.2.5. Synthèse et positionnement

Dans cette partie, nous avons examiné le rôle central de la fonction maintenance dans la recherche d'une triple performance technique, économique et environnementale. Ce qui nous a permis d'expliquer l'évolution des pratiques courantes de la maintenance industrielle. En particulier, la maintenance prédictive (*PdM*) a suscité notre intérêt étant donné les avantages qu'elle offre d'une part et d'autre part à la multitude de ses architectures supports permettant son intégration.

Contrairement aux autres industries, le domaine semi-conducteur manque cruellement de recherches et d'applications dans le cadre de la stratégie *PdM*, bien que la nécessité de sa mise en place fasse désormais l'unanimité. Par conséquent, nous nous alignons dans cette direction de recherche et nous nous fixons comme objectifs l'aide à la minimisation des stratégies correctives et à l'optimisation des interventions préventives systématiques à travers l'élaboration efficace de stratégies prédictives. La mise en œuvre d'une stratégie de maintenance prédictive nécessite la prise en compte de certains concepts (processus) importants, nous les résumons comme suit :

- *Acquisition des données* : elle doit être correctement appréhendée,
- *Diagnostic* : il est nécessaire de manière à identifier les causes de défaillances,
- *Pronostic* : il prend ici sa place et permet de prédire les effets de défaillances,
- *Aide à la décision* : il permet de mettre en œuvre des interventions appropriées.

Ces considérations ont entraîné le développement des architectures pour supporter ces concepts spécifiques à la *PdM*. Elles présentent toutes le point commun d'être alimentées par de nouveaux concepts recensés sous le vocable de « *e-maintenance* » (Cocheteux, 2010) où le pronostic se place comme l'un des concepts clé au centre de ces architectures. Nous portons un intérêt particulier à l'architecture *OSA/CBM*, non seulement de par son aspect fédérateur mais aussi de par sa flexibilité permettant d'extraire une version

⁶ *Prognostic Enhancements to Diagnostic Systems.*

⁷ *Système Intégré de Maintenance Prévisionnelle.*

simplifiée. Dans l'industrie du semi-conducteur, la complexité et la criticité du procédé sont importantes et la mise en place d'un nouveau concept ne doit pas être une cause supplémentaire de variabilité. Par conséquent, proposer une solution simple sera fortement apprécié.

Ces nouvelles considérations nous ont poussés à chercher et à proposer un cadre robuste pour atteindre nos objectifs, un cadre où l'anticipation des défaillances futures est mise en avant. Cela nous a donc conduits vers les thématiques du pronostic et de gestion de la santé. Dans ce qui suit, nous allons les présenter ainsi que leurs principales composantes.

II.3. Pronostic et gestion de la santé PHM

L'un des facteurs clés de la performance industrielle est le maintien des systèmes de production dans des états de fonctionnement normal. De ce fait, la prise en compte des défaillances est devenue de plus en plus réactive⁸ et proactive⁹ (Iung et al., 2003), et de nouveaux concepts ont vu le jour (Sheppard et al, 2009). Ainsi nous trouvons le domaine de gestion de la santé des équipements connu sous l'appellation *PHM (Prognostic and Health Management)*.

Le *PHM* est défini comme étant une approche de soutien d'un système durant son cycle de vie, il cherche à réduire ou à éliminer les étapes de contrôle (inspection) et à améliorer la planification des tâches de maintenance réalisées sur un système par le biais des mesures, des modèles et des outils logiciels. Ces derniers effectuent un suivi précis de l'évolution de l'état de santé (*Condition Monitoring*), une détection d'un défaut naissant et une prédiction d'une dégradation imminente (Kalgren, 2006).

En se basant essentiellement sur les avancées réalisées dans les deux domaines de la maintenance conditionnelle *CBM*¹⁰ (*Condition Based Maintenance*) (Rao, 1996). et celui de la maintenance axée sur la fiabilité *RCM*¹¹ (*Reliability Centered Maintenance*) (Military standard, 1986), la discipline *PHM* est apparue il y a environ une dizaine d'années et depuis cette notion se développe pour offrir des solutions afin de réduire les coûts de production tout en étant capable d'améliorer la disponibilité et la fiabilité des systèmes complexes. Afin de constituer un plan de communication efficace pour supporter cette discipline, différentes architectures fonctionnelles ont été développées (Rasovska et al.,

⁸ *Approche réactive* : elle s'intéresse aux symptômes d'une défaillance.

⁹ *Approche proactive* : elle concerne le suivi des causes d'une défaillance.

¹⁰ *Condition Based Maintenance*.

¹¹ *Reliability Centered Maintenance*.

2007 ; Swearingen et al., 2007 ; Cochetoux, 2010) et appliquées dans de nombreux domaines (Roemer et al, 2001 ; Lebold et Thurston, 2001 ; Hess, 2005).

La figure II.4 récapitule les liens d'interaction entre un système complexe (par exemple, les équipements de fabrication des circuits intégrés) et les composantes du *PHM* (Gucik-Derigny, 2011). Une première étape concerne l'acquisition, le prétraitement puis le traitement des données opérationnelles et comportementale afin d'extraire des indicateurs de santé du système complexe. A partir de ces indicateurs, la deuxième et la troisième étape consistent en l'estimation de l'état de santé global (surveillance) et son utilisation pour le diagnostic des défauts et le pronostic des dégradations respectivement. Enfin, la dernière étape concerne l'aide à la décision en vue de réduire les coûts de fabrication et d'améliorer la disponibilité et la sécurité du système complexe. Ainsi, pour boucler le cycle, certaines actions de maintenance et/ou d'inspection peuvent être planifiées et réalisées sur le système complexe.




Figure II.4. Principaux concepts liés à la discipline PHM.

Dans ce qui suit, nous proposons de définir chacun de ces concepts et de donner les principales méthodes de diagnostic et de pronostic utilisées pour la modélisation.

II.3.1. Concept de traitement de données

A l'aire de l'informatique, le concept de traitement des données est aperçu comme une étape clé pour la mise au point des approches modernes de maîtrise des procédés (Mili, 2009). Au préalable, une acquisition de données brutes est réalisée par des dispositifs appropriés. Nous distinguons deux sources principales de données. La première famille contient les informations relatives aux équipements de production (historique des événements et des maintenances, environnement contextuel). La deuxième famille, quant à elle, incorpore les informations associées aux produits (mesures réalisées durant les opérations et à la fin de la ligne de production). Par la suite, une phase de prétraitement permet de préparer (structuration, alignement, correction, réduction de taille, etc.) les données en vue de leur traitement. À la fin, la phase de traitement de données permet, en utilisant des techniques de la statistique ou de l'intelligence artificielle, d'extraire des indicateurs de l'état de santé ou de dégradation. Les éléments de base de ces trois phases sont présentés dans la figure II.5. D'un point de vue entrée/sortie ce concept permet de transformer les données brutes en informations utiles et pertinentes. Une revue des approches et des outils de traitement de données, appliqués dans l'industrie manufacturière, a été présentée dans (Harding et al., 2006).




Figure II.5. Éléments de traitement de données.

Les indicateurs extraits vont être utilisés par la suite pour estimer l'état global de santé ou de dégradation du système complexe. C'est le rôle des méthodes de diagnostic et de pronostic exposées à présent.

II.3.2. Concept du diagnostic

C'est l'une des disciplines de l'intelligence artificielle *AI*, le diagnostic de panne est défini par la Commission Électrotechnique Internationale *IEC*¹² (IEC 191-07-22, 1990)

¹² International Electrotechnical Commission: <http://www.iec.ch/>

comme étant « l'ensemble des opérations effectuées pour la détection de panne, la localisation de panne et l'identification de la cause de la panne ». Nous distinguons trois notions dans cette définition, la détection qui indique l'occurrence d'une défaillance sur le système surveillé, la localisation qui détermine le ou les composants défaillants et l'identification qui permet de préciser la nature de la défaillance (Cambacau et al., 2000). Il convient de noter le rôle important que joue la fonction surveillance, elle fournit une estimation de l'état de santé et de la dégradation du système permettant ainsi au diagnostic de réaliser ses principales tâches suivant un raisonnement logique (des effets vers les causes) (Zwingelstein, 1995). La figure II.6 synthétise les principales méthodes utilisées pour le diagnostic des fautes (Ribot, 2009).




Figure II.6. Principales méthodes du diagnostic.

Le choix d'une catégorie de méthodes dépend d'une part de la complexité du système et de sa dynamique et d'autre part, de la nature des informations disponibles. Les techniques listées ici sont les plus couramment utilisées par la communauté de l'automatique.

II.3.3. Concept du pronostic

Ce concept est associé au domaine de la maintenance conditionnelle *CBM* (Jardine et al., 2006) et il est de même intégré dans la discipline pronostic et gestion de la santé *PHM* (Kalgren, 2006). En général, le pronostic consiste à prévoir l'état futur d'un système, d'un équipement ou d'un composant élémentaire. Une synthèse des différentes définitions de ce concept est présentée dans (Cocheteux, 2010 ; Goh et al., 2006 ; Peysson, 2009), le facteur en commun entre toutes ces définitions est la notion de prévision d'une situation future. Elles se distinguent entre elles essentiellement sur la notion de l'horizon de cette prévision et la notion du domaine dans lequel cette prévision va être appliquée.

Selon l'Organisation Internationale de Normalisation *ISO*¹³ (ISO 13381-1, 2004), le pronostic est défini comme étant « une estimation de la durée de fonctionnement avant défaillance et du risque d'existence ou d'apparition ultérieure d'un ou de plusieurs modes de défaillance ». De son côté, l'organisation Internationale des fabricants d'Équipements et Matériaux Semi-conducteur *SEMI*¹⁴ (SEMI E133-0212, 2001) décrit la prédiction de défaut (ou pronostic) comme étant « une technique de surveillance et d'analyse des variations de données du procédé afin de prédire les anomalies ». L'analyse de ces définitions nous a permis de mettre en exergue les points suivants :

- La vie d'un système est décrite de manière « continue ».
- Les entrées du pronostic peuvent être des données historiques, présentes et futures.
- Les sorties du pronostic sont des durées de vie résiduelle *RUL*¹⁵ (*Remaining Useful Life*) ou des probabilités de défaillance.

De la même manière que pour le diagnostic, plusieurs travaux ont proposé des classifications des approches utilisées pour le concept du pronostic. Principalement, nous pouvons distinguer cinq différentes classifications de ces approches (voir figure II.7) :




Figure II.7. Critères de classification des approches de pronostic.

1. La première classification est une hiérarchisation en fonction du *domaine d'applicabilité et de la complexité* (coût et la précision) résultante (Lebold et

¹³ International Organization for Standardization: <http://www.iso.org/iso/home.htm>

¹⁴ Semiconductor Equipment and Materials International: <http://www.semi.org/eu/>

¹⁵ *Remaining Useful Life*: correspond au temps restant avant que le système dérive ou Durée de Fonctionnement Avant Défaillance *DEFAD* (ISO 13381-1, 2004).

Thurston, 2001 ; Peysson, 2009 ; Byington et al., 2002). Notons que les approches guidées pas des données et celles basées sur l'expérience sont les plus utilisées dans l'industrie (Goh et al., 2006), car il n'est pas toujours facile d'élaborer un modèle issu des lois de la physique et il est relativement difficile de représenter mathématiquement l'évolution de la dégradation.


2. Un nouveau critère de classification a été proposé par (Jardine et al., 2006), les auteurs mettent en avant les *résultats attendus* suite à un processus de pronostic. Notons que les approches visant à déterminer la durée de vie restante d'un système (*RUL*) peuvent être divisées en trois sous-familles équivalentes à la première classification : approches basées modèles, approches orientées données (techniques de l'intelligence artificielle) et approches basées sur l'expérience (techniques issues de la statistique).
3. A l'inverse, les auteurs dans (Heng et al., 2009) proposent un critère de classification en examinant cette fois les *entrées utilisées* par un processus de pronostic. En fonction de la nature de ces entrées, les modèles sont basés soit sur des événements, sur des états soit les deux à la fois. De la même manière, les sous-familles résultantes de cette classification peuvent être projetées sur la première classification : approches basées modèles et orientées données (entrées de nature état) et approches basées sur l'expérience (entrées de nature événement).
4. Dans la même logique, (Vasile, 2008) utilise un nouveau critère en considérant cette fois le *contenu des entrées* utilisées par un processus de pronostic. Dans le sens où une donnée brute n'apporte pas de l'information et que l'information n'est pas forcément une connaissance (Becker et Naïm, 1999). Cette classification regroupe, dans une première famille, les approches qui traitent des données brutes soit par des techniques issues de la statistique ou par des réseaux de neurones (boîtes noires). Si les données ont un sens nous parlons plutôt d'informations, dans ce cas des raisonnements qualitatifs à partir de cas, des estimateurs ou des observateurs quantitatifs peuvent être appliqués. La troisième famille englobe les approches orientées connaissances, tel que les systèmes experts et les arbres de décision.
5. La dernière classification est proposée par (Cocheteux, 2010), elle est basée sur trois critères. Le premier précise *l'objectif* pour lequel la maintenance est

réalisée : a) pour assurer la fiabilité du système, b) pour assurer la fiabilité au niveau composant ou c) pour assurer la performance. Le second critère concerne l'utilisation du *contexte futur* : a) aucune utilisation, b) utiliser des conditions opérationnelles et/ou environnementales ou c) utiliser un scénario de maintenance. Quant au dernier critère, il distingue *l'origine de la connaissance* utilisée : a) provient des lois de la physique, b) issue des données, c) combine les lois de la physique et les données ou d) connaissance résultante du retour d'expérience et des données.

II.3.4. Concept d'aide à la décision

En fonction de l'indication délivrée par le processus de diagnostic ou celui de pronostic, un plan d'action est déclenché afin de garantir la disponibilité du système complexe. Le choix d'un plan d'action « meilleur » est l'une des tâches principales d'un processus d'aide à la décision. Le concept d'aide à la décision se présente donc comme un processus complémentaire au concept du diagnostic qui détecte les dégradations et au processus du pronostic qui estime quant à lui les futures dégradations.

Dans le cas d'un plan d'action en maintenance, l'aide à la décision est définie comme étant « l'ensemble d'activités et d'outils concourant au choix des meilleures stratégies de maintenance selon des critères prédéfinis (El-Aoufir et Bouami, 2003) », un tel choix se présente comme un problème décisionnel complexe (Mathur et al., 2001). L'intégration d'un processus d'aide à la décision (figure II.8) va permettre de réaliser la sélection d'un plan de maintenance en évaluant les performances (coûts, temps de cycle...) de tous les plans envisageables.



Ainsi, le cycle PHM de la figure II.1 sera bouclé à travers l'exécution des actions nécessaires et appropriées afin de garantir les performances du système complexe.

II.3.5. Synthèse et positionnement

Dans cette section nous avons donné une vue d'ensemble sur les concepts liés à la discipline *PHM*. Dans un premier temps nous avons souligné l'importance de la phase de traitement de données, en effet, le contexte dans lequel nous travaillons se caractérise par la quantité considérable des données acquises. Leur traitement pour extraire des indicateurs pertinents s'avère une étape clé et difficile à la fois. Dans un premier temps, une analyse hors ligne nous semble ainsi inévitable. Quant aux modèles de diagnostic et de pronostic, le premier vise à calculer des indicateurs pour expliquer la dérive des états du système et le second cherche à calculer des indicateurs pour évaluer la dynamique de la dégradation du système. Les approches de diagnostic et de pronostic décrites ici sont les plus utilisées par la communauté. Le choix d'un outil d'aide à la décision dépend fortement des approches adoptées pour les processus du diagnostic et du pronostic.

Dans le domaine du semi-conducteur, en plus de la disponibilité des données, la connaissance des experts est fortement mise en avant. Aussi, les approches de modélisation choisies doivent intégrer ces deux éléments. Parmi les critères de classification des approches du pronostic (figure II.7), la classification en fonction des résultats attendus, nous semble la plus proche aux spécifications exprimées par les industriels. Deux grandes familles émanent de cette classification, le pronostic qui vise à calculer la durée de vie restante d'un système RUL (*Remaining Useful Life*) et le pronostic qui vise à déterminer la probabilité d'occurrence d'une future défaillance sur un système donné (cf. figure II.9).




Figure II.9. Approches du pronostic selon le résultat attendu.

Nous nous orientons donc vers des approches qui cherchent à calculer des probabilités à un instant donné. Selon (Jardine et al, 2006), cette famille d'approches présente une voie prometteuse et peu de travaux ont été développés pour la supporter. Compte tenu de ces conclusions, notre étude s'oriente vers des techniques d'apprentissage à partir de données, en particulier les méthodes de type graphiques probabilistes permettant de prédire l'occurrence d'une future défaillance du système. Nous proposons dans ce qui suit, une méthodologie inductive pour le calcul et l'intégration d'un modèle prédictif de l'état de santé des équipements de production pour l'industrie du semi-conducteur.

II.4. Méthodologie d'intégration du modèle issu du pronostic

Afin de proposer une structure générique du modèle prédictif adapté aux ateliers semi-conducteurs, une méthodologie permettant d'appréhender le procédé réel doit être proposée. Nous avons pour cela mené une étude de terrain avec les industriels du domaine (Lfoundry à Rousset et STMicroelectronics à Crolles), avec pour objectifs d'adresser les causes et les modes de défaillance. Pour ce faire nous avons proposé de suivre une approche décrite dans la figure II. 10 (Bouaziz et al., 2012a).




Figure II.10. Méthodologie proposée.

Par rapport aux architectures supports à la PdM incluant plusieurs modules et nécessitant certaines étapes de mise en œuvre, cette approche présente l'avantage d'être simple, progressive et tenant compte de quatre étapes distinctes et suffisantes pour répondre aux besoins de l'industrie du semi-conducteur :

- *Étape 1* : Identification des *FM* (*Failure Mode*).
- *Étape 2* : Modélisation et validation.
- *Étape 3* : Paramétrage du modèle.
- *Étape 4* : Analyse en ligne.

Lors de la définition de cette méthodologie, nous avons pris en compte les aspects suivants :

- l'ensemble des spécifications du projet *IMPROVE*,
- la linéarité de l'architecture support *OSA/CBM*,
- les concepts de la thématique *PHM*,
- le besoin de la généralité.

Chaque étape est divisée en sous étapes. Dans le reste de ce chapitre, nous allons développer chacune de ces phases. Mais avant cela, une caractérisation de l'indicateur *EHF* (*Equipment Health Factor*) est proposée dans ce qui suit.

II.4.1. Caractéristiques de l'indicateur de santé EHF

Dans la littérature, nous pouvons distinguer deux types d'indicateurs de santé (Wang et al, 2012) : indicateur de santé physique *PHI*¹⁶ et indicateur de santé synthétisé *SHI*¹⁷. Le *PHI* est applicable si les signaux des capteurs sont directement liés à la physique de la défaillance (signal vibratoire, impédance, capacité d'enroulement...). Avec la complexité croissante des systèmes et des réseaux de capteurs embarqués, l'extraction de ces signaux devient de plus en plus difficile. Par conséquent, le *SHI* se propose comme une alternative afin de pallier cette difficulté. Ainsi, cet indice de santé est applicable lorsqu'il n'y a pas de signal physique dominant. Le *SHI* peut être extrait par des techniques avancées de traitement de données. L'indicateur que nous proposons de calculer, appartient à la famille des *SHI*. Il convient de noter que la terminologie *EHI*¹⁸ peut être utilisée au même titre que la terminologie *EHF*.

Dans le contexte de fabrication des circuits intégrés, l'équipement de production peut avoir plusieurs modes de fonctionnement (Mendez-Azua et al., 2005). Nous nous intéresserons en particulier à deux de ces modes (figure II.11) :

- *Équipement en fonctionnement normal* : l'équipement est dans un contexte respectant l'ensemble des spécifications enregistrées lors de sa qualification (types

¹⁶ *Physics Health Index.*

¹⁷ *Synthesized Health Index.*

¹⁸ *Equipment Health Index.*

de technologies, suivi des routes, types de recettes, réglage des paramètres, capacité...).

- *Équipement en fonctionnement anormal* : l'une des spécifications nominales sur le produit, l'équipement ou l'ajustement d'une recette n'est plus respectée.




Figure II.11. Indicateurs pour le « health monitoring ».

A chaque instant où l'équipement sort de son fonctionnement normal, il est dans le milieu industriel caractérisé par un ou plusieurs *FM* (*Failure Modes*), tel qu'une contamination des produits, un problème d'épaisseur de plaquette de silicium, etc. Il est donc non seulement primordial pour la production de savoir détecter un mode de défaillance (*which FM ?*), mais de pouvoir prévoir à quel instant il va se produire $T_{passage}$ (*when ?*) et expliquer pourquoi il s'est produit (*why ?*). C'est le rôle exact du calcul de l'état de santé d'un équipement. Son modèle *EHF* doit donc permettre de prédire l'occurrence des futurs modes de défaillance afin de déclencher de manière optimale une boucle réactive appropriée (Zamaï et al, 1998).

En résumé, le facteur de santé d'un équipement peut être défini comme étant « un résultat d'un calcul de probabilités, continu et normalisé. Il est utilisé pour évaluer l'état futur de l'équipement ou de l'un de ses composants. L'*EHF* est basé sur l'analyse des paramètres de l'équipement, la maintenance et les données historiques sur les produits et la qualité. Par ailleurs, cet indicateur doit être disponible au moment opportun en fonction des besoins de contrôle des équipements et afin de prendre des décisions sur la planification de maintenance, ainsi que les plans de contrôle dynamiques (Bouaziz et al., 2011b) ».

Dans ce qui suit, nous décrivons en détail chacune des étapes de la méthodologie proposée dans la figure II.10.

II.4.2. Étape 1 : Identification des modes de défaillance

Cette première étape a pour objectif d'identifier les modes de défaillance, puis de définir sur la base de cette identification les *FM* prioritaires pour le calcul de l'*EHF*. En effet, cette étape est découpée en quatre sous étapes comme le montre la figure II.12 :




Figure II.12. Identification des modes de défaillance FM.

1. **Analyse du contexte de production** : contexte *AEC* (*Advanced Equipment Control*), cette phase d'analyse qualitative vise à évaluer le contexte du contrôle du procédé (*process control*) et celui de la maintenance, contexte dans lequel l'équipement opère (fonctions, éléments, architectures de l'équipement et des données, historique des événements...).
2. **Analyse et traitement de données** : une phase de traitement de données est réalisée, elle est précédée par des opérations d'acquisition et de prétraitement. L'objectif est de synchroniser et d'aligner les données provenant de différentes bases (production, maintenance, métrologie...) avec les informations pertinentes sur les équipements et les produits traités. L'analyse et le traitement de ces données permet de reconstruire la vie de l'équipement suivant une liste d'événements (production, dérives, actions, causes, paramètres...) et une chronologie (par date, run, lots...). Ainsi une table de données structurées est fournie.
3. **Classification des modes de défaillance FM** : nous procédons dans cette phase à une première analyse sur les tables de données structurées. Elle permet de classer, de manière automatique, les modes de défaillance à partir de leurs effets (occurrence,

sévérité...) et de fournir des graphiques pour les utilisateurs. Cette phase est réalisée en utilisant des méthodes et des outils statistiques, la technique la plus utilisée restant basée sur les graphiques Pareto (Hohmann, 2009).

4. **Définition des priorités et des causalités** : à la fin de cette première étape et sur la base des graphiques établis dans la phase 3, l'expert métier définit ses priorités. Par ailleurs, les jugements des experts (connaissances recueillis) et les analyses *AMDEC*¹⁹ permettent de dresser une liste de causes de défaillance potentielles (*Root Causes RC*). Une liste de variables (cause à effet) est ainsi retenue.

II.4.3. Étape 2 : Modélisation et validation

Pour cette étape, une technique de modélisation doit être adoptée en fonction des besoins exprimés par les industriels. Compte tenu des spécifications de l'indicateur *EHF*, des objectifs et de l'état de l'art présentés plus haut, une synthèse nous a permis de mettre en exergue l'effort important qui doit être fourni sur les techniques d'analyse de données (Tixier et al., 2002 ; Mili, 2009 ; Liu, 2008). Notre étude s'oriente ainsi vers des méthodes de type probabilistes permettant de prédire l'état de santé des équipements. Les techniques par réseaux Bayésiens, que nous présentons en détail dans la première partie du chapitre 3, se présentent comme des solutions intéressantes à la problématique d'incertitude et à la prise en compte de l'expertise. Ainsi, cette deuxième étape décrit et évalue le modèle du pronostic. Ce modèle est calculé en fonction des priorités sur les modes de défaillance prédéfinies dans l'étape précédente. De la même manière, cette étape est déclinée en quatre sous étapes comme indiqué dans la figure II.13 :

5. **Classification des causes de défaillance *RC***²⁰ : permet de vérifier les causalités supposées par les experts (test) ou d'en trouver de nouvelles (si non). C'est donc une identification de variables afin de les joindre au modèle de prédiction *EHF*. Cette phase est effectuée en utilisant des techniques issues de la statistique ou/et du domaine des probabilités (classification, filtrage, régression, recherche des corrélations...).
6. **Structure graphique du modèle *EHF*** : une fois les causes et les modes de défaillance identifiés, nous les combinons pour construire une structure du modèle graphique. La structure, représentée par des relations de causes à effets,

¹⁹ Analyse des modes de défaillance, de leurs effets et de leur criticité.

²⁰ *Root Causes*: elles représentent les causes racines.

peut être approuvée par un apprentissage de structure à partir de données ou directement sur la base des tables *AMDEC* préétablies.

7. **Apprentissage paramétrique du modèle *EHF*** : à partir d'une base de données historique dédiée à l'apprentissage et des algorithmes appropriés, cette phase permet de calculer les différentes distributions de probabilités associées à chacune des variables du modèle graphique.
8. **Test et validation du modèle *EHF*** : cette dernière phase consiste à interroger le modèle afin de prédire les modes de défaillance ou de diagnostiquer leurs origines. Avec le support des algorithmes d'inférence (de test) et les données dédiées au test, le modèle sera validé ou enrichi par de nouveaux jeux de données. Ainsi, le modèle *EHF* sera validée à travers un *POC (Proof Of Concept)* avant l'étape d'industrialisation.




Figure II.13. Modélisation et validation.

En sortie de cette deuxième étape, une première instance du modèle *EHF* pour le diagnostic et le pronostic est proposée mais qui nécessite d'être affinée. C'est l'objet donc de la troisième étape « paramétrage du modèle ».

II.4.4. Étape 3 : Paramétrage du modèle

9. **Gestion des algorithmes** : l'intégration de l'indicateur *EHF* représente une couche supplémentaire pour le système qui gère les équipements de production en ligne. Cet indicateur n'agit pas seul, il est en interaction permanente avec d'autres modèles et outils déjà mis en place. La criticité du procédé semi-

conducteur est importante et la variabilité doit être maîtrisée. C'est la raison pour laquelle nous introduisons cette phase qui a pour objectif d'évaluer et de gérer l'impact des algorithmes de calcul sur le système en ligne (temps de calcul, coûts d'intégration, informatique...).

10. **Gestion des modèles :** pour les mêmes raisons citées pour la phase précédente, la gestion des modèles est introduite. Elle vise à comparer les performances des modèles développés pour le calcul de l'*EHF*. Comme résultat de comparaison, l'utilisateur gère sa boîte à outil (modèle complet, modèle simplifié...) selon des critères de performance prédéfinis (précision, coûts, temps de cycle...).
11. **Gestion des décisions :** cette phase permet de collecter les informations relatives aux interventions de maintenance (ressources, types d'actions, coûts...) et de métrologie (disponibilité des machines, durées d'inspection, performance...), ceci afin de mieux gérer les interventions en ligne basées sur le calcul du modèle *EHF*.
12. **Préparer l'intégration *IT*²¹ :** afin d'anticiper les contraintes d'industrialisation, cette phase a pour objectif de vérifier la conformité du modèle avec les ressources informatiques réelles dans les ateliers de production (dépôt, gravure...). Cette phase va naturellement s'appuyer sur l'audit des moyens humains et matériels susceptibles d'interagir avec le modèle *EHF* lors d'une future implémentation.

Les résultats du modèle *EHF* calculés après ces trois étapes sont des éléments pour l'aide à la prise de décision, ils devraient permettre l'amélioration de la fiabilité des équipements de production et l'optimisation des interventions de maintenance et de métrologie. Ainsi, la quatrième et la dernière étape de notre approche traite l'aspect décisionnel.

II.4.5. Étape 4 : Analyse en ligne

13. **Planification de maintenance basée sur le diagnostic :** les résultats du modèle de diagnostic sont exploités pour proposer à l'utilisateur la ou les interventions nécessaires. Ce processus devrait intégrer bien entendu un modèle *EHF* étendu permettant de décrire les actions de maintenances envisageables suite à une estimation sur les causes de défaillances.

²¹ *Information technology*: est une branche de l'ingénierie qui traite l'utilisation des moyens informatiques pour stocker, récupérer et transmettre des informations.

14. **Planification de maintenance basée sur le pronostic :** ce processus utilise les résultats de prédiction du modèle *EHF* probabiliste. Si l'estimation sur l'état futur du système atteint un seuil critique, ce module alerte l'utilisateur et lui propose des plans d'interventions préventifs (et optimaux dans certains cas). Pour cela, une extension du modèle *EHF* doit être définie, elle permettra d'intégrer les coûts des interventions, ainsi que la politique optimale.
15. **Planification de la métrologie :** de la même manière que les deux processus de maintenance précédents, cette phase vise à fournir une information à l'utilisateur pour l'aide à la décision. La planification de la métrologie doit apporter des réponses aux questions suivantes : quels lots faut-il contrôler ? Sur quelle machine ? Et à quel moment faut-il planifier l'inspection ?
16. **Outil d'aide à la prise de décision :** les modèles étendus obtenus sont des outils pour l'aide à la prise de décision en ligne. Ils permettent d'intégrer et de synchroniser l'*EHF* avec les autres indicateurs et outils mis en place dans l'usine.

Il convient de souligner que cette méthodologie en quatre étapes prend en compte de nombreux facteurs. En effet, plusieurs disciplines s'y croisent et s'y retrouvent (informatique, intelligence artificielle, automatique, microélectronique, etc.). Dans le cadre de nos travaux, nous nous sommes focalisés sur les aspects de modélisation. Nous proposons : *i*- un modèle d'identification et de vérification de causes de défaillance (étape 1), *ii*- plusieurs configurations du modèle *EHF* (étape 2) et *iii*- une extension du modèle *EHF* pour la prise de décision (étapes 3 et 4).

II.5. Conclusion

Dans ce chapitre, nous avons présenté une revue de littérature sur l'évolution de la fonction maintenance et l'émergence durant ces dernières années de la stratégie prédictive dans le monde industriel. Il ressort de cette étude, l'écart qui existe dans le domaine du semi-conducteur en termes d'intégration des *PdM*. La deuxième partie de ce chapitre a été consacrée à la description de la thématique du *PHM*. Nous avons souligné le manque d'approches, en semi-conducteur, qui visent à estimer la probabilité d'occurrence d'une future défaillance sur le système. Le pronostic prend particulièrement sa place dans ce cadre. Dans la dernière partie, nous avons décrit une méthodologie pour le développement d'un modèle probabiliste de l'*EHF*. Cette approche part d'une description détaillée du

contexte de l'étude qui intègre la variété des données rendues disponibles, pour arriver à proposer un outil d'aide à la décision pour les interventions de maintenance et de métrologie.

Compte tenu de ces constats, notre travail de thèse se positionne clairement au cœur de ces trois aspects : la stratégie *PdM*, la thématique du *PHM* et la modélisation de l'*EHF*. L'objectif est de contribuer à l'amélioration de la disponibilité des équipements de production dans le domaine semi-conducteur (voir figure II.14) par la proposition d'un modèle probabiliste pour le diagnostic et le pronostic.

Suivant ce positionnement, le chapitre suivant présente brièvement l'outil de modélisation probabiliste basé sur la théorie des réseaux Bayésiens. Nous nous focalisons essentiellement sur les sous étapes, de construction d'un modèle *EHF*, suivantes : la structure graphique du modèle, l'apprentissage paramétrique du modèle et le test et la validation du modèle.




Figure II.14. Disponibilité des équipements de production (Hubac, 2012).

III. Modélisation graphique probabiliste

III.1. Introduction.....	59
III.2. Réseaux Bayésiens.....	59
III.2.1. Définitions et avantages.....	60
III.2.2. Propriétés et variantes.....	62
III.2.3. Méthodes algorithmiques.....	68
III.2.4. Domaines d'application et outils.....	70
III.3. Réseaux Bayésiens et mise en œuvre d'un indicateur de santé.....	72
III.3.1. Analyse probabiliste par réseau Bayésien.....	72
III.3.2. Identification des variables du modèle.....	74
III.3.3. Définition de la structure graphique du modèle	76
III.3.4. Définition des lois de probabilités du modèle.....	77
III.4. Configurations de l'indicateur de santé EHF.....	80
III.4.1. EHF par mode de fonctionnement.....	81
III.4.2. Instanciation de l'EHF à partir des tables AMDEC.....	82
III.4.3. Vers un modèle EHF temporel.....	84
III.4.4. Vers un modèle de classification des causes.....	86
III.5. Conclusion.....	89

III.1. Introduction

Nous avons présenté dans les deux chapitres précédents, la problématique de prédiction du comportement des équipements de production en semi-conducteur et nous avons également exposé les différentes approches liées aux thématiques de la maintenance prédictive *PdM* et du pronostic et gestion de santé *PHM*. Ce chapitre a pour objet d'introduire les modèles graphiques probabilistes et plus particulièrement les réseaux Bayésiens. Ensuite, nous allons appliquer la méthodologie proposée sur un exemple élémentaire pour pouvoir illustrer une première instanciation du modèle *EHF*. Cela concerne essentiellement l'étape II de notre approche (figure II.13, page 53), elle est conduite suivant les spécifications du formalisme Bayésien. Afin de répondre au mieux aux besoins industriels nous présentons à la fin de ce chapitre, différentes configurations du modèle *EHF* et nous proposons aussi de supporter l'identification des variables par un outil de classification probabiliste.

III.2. Réseaux Bayésiens

Les avancées méthodologiques et technologiques réalisées ces dernières années dans le domaine du calcul probabiliste ont permis l'introduction des modèles graphiques probabilistes *PGM* (*Probabilistic Graphical Model*) (Jordan, 1999). Ces modèles offrent un cadre de représentation des connaissances en prenant en compte les dépendances et indépendances conditionnelles entre les variables aléatoires. Ils se trouvent à la frontière entre la théorie des graphes et la théorie des probabilités. Nous distinguons deux grandes catégories de graphes : orientés et non-orientés, ainsi que deux classes principales de graphes : réseaux Bayésiens (*RB*) et modèles de Markov (*CdM*). Les réseaux Bayésiens ont été initiés par J. Pearl¹, à la fin des années 1980, pour la prise en compte des incertitudes dans les systèmes experts et de décision (Pearl, 1988). Depuis, leur utilisation n'a cessé d'augmenter et semble bien adaptée aux spécificités des applications industrielles. Nous évoquons ici quelques exemples issus des domaines de la sûreté de fonctionnement et de la maintenance : dans (Boudali et Dugan, 2005), les *RB* ont été utilisés pour modéliser et analyser les différents types de comportements des composants complexes d'un système dynamique. Dans (Weber et Jouffe, 2006), une autre utilisation intéressante des *RB* est exposée, elle a pour but d'évaluer la fiabilité générale d'un processus de fabrication afin

¹ *Judea Pearl*: professeur d'informatique à l'université de Californie, il est le père fondateur des réseaux Bayésiens. J. Pearl a remporté en 2011 le prestigieux A.M. Turing Award pour ses travaux de recherche, le prix Turing est considéré comme un « prix Nobel » en informatique.

d'optimiser le diagnostic et les interventions de maintenance. Dans le cadre de l'aide à l'optimisation dans un contexte doublement censuré, les travaux de (Corset, 2003) proposent de construire un modèle Bayésien à partir d'avis d'experts tout en intégrant les interventions de maintenance considérées comme variables du modèle. Enfin, l'utilisation des *RB* a permis à (Verron, 2007) d'unifier dans le même outil plusieurs méthodes dédiées à la surveillance (détection et diagnostic) des procédés multivariés.

III.2.1. Définitions et avantages

Les réseaux Bayésiens figurent parmi les modèles d'analyse probabiliste. Ils proposent un formalisme mathématique et des bases théoriques solides pour le développement des modèles pour les systèmes complexes. Les *RB* sont de plus en plus utilisés dans des domaines tels que l'analyse des risques, la sûreté de fonctionnement et la maintenance (Weber et al., 2012). Ils combinent une représentation de la connaissance sous forme graphique (des relations de dépendance directe) et probabiliste (une incertitude sur la connaissance) (Jensen, 1996).

La figure III.1 présente un exemple ordinaire d'un réseau Bayésien à deux variables, ce modèle est défini par (Pearl et Paz, 1985) :

- sa composante graphique représentée par un graphe G orienté sans circuits (ou *GAD* : Graphe Acyclique Dirigé) comportant un ensemble de nœuds V (ou sommets) et des arcs E , ainsi $G = (V, E)$. V symbolise un ensemble de variables aléatoires X , $X = \{X_1, X_2\}$.
- sa composante quantitative μ représentée par des tables de probabilités (*TP*) pour les nœuds parents et des tables de probabilités conditionnelles (*TPC*) pour les nœuds descendants, $\mu = \{\mu_i\} = \{P(X_i/\text{Parents}(X_i))\}$.




Figure III.1. Exemple d'un réseau Bayésien à deux variables.

Les réseaux Bayésiens sont donc une représentation à la fois qualitative et quantitative des relations entre les variables. Ces variables peuvent être discrètes (*TP*, *TPC*) ou continues, observables ou non observables et peuvent prendre différents états (vrai/faux, une échelle de probabilité (Druzel et al., 2000) ...).

Le calcul dans un réseau Bayésien s'appuie sur le théorème de Bayes (introduit par T. Bayes 1702-1761) (Bayes, 1763). Soit deux variables aléatoires X_1 et X_2 , la probabilité conditionnelle de X_2 sachant X_1 est déterminée par la formule suivante :

$$P(X_2 / X_1) = \frac{P(X_1 / X_2) \cdot P(X_2)}{P(X_1)}$$

- $P(X_1)$ est la probabilité a priori (ou marginale) de X_1 .
- $P(X_2/X_1)$ est la probabilité a posteriori de X_2 sachant X_1 .
- $P(X_1/X_2)$ est la fonction de vraisemblance de X_1 connaissant X_2 .

Dans le cas général, où $X = \{X_1, X_2, \dots, X_n\}$, la fonction de distribution de probabilités jointe $P(X)$ s'écrit comme suit :

$$P(X) = \prod_{i=1}^n P(X_i / Parents(X_i))$$

Il existe de nombreuses représentations pour extraire des connaissances à partir des données (arbres de décision, réseaux de neurones...), il en est de même pour les techniques de fouille de données (classification, régression, filtrage...). Parmi ces méthodes, les réseaux Bayésiens ont attiré notre attention en raison de leurs propriétés en terme de modélisation. Nous listons leurs principaux avantages ci-après :

- les *RB* peuvent être utilisés pour apprendre des dépendances causales et pour modéliser des phénomènes aléatoires,
- un *RB* est une représentation graphique compacte et synthétique avec une facilité d'acquisition et d'utilisation de la connaissance,
- les *RB* peuvent combiner plusieurs aspects à la fois, des statistiques, des probabilités, de l'aide à la décision et le management des connaissances,
- pour l'utilisation, leur flexibilité permet d'interroger le même modèle graphique pour des objectifs différents, tels que la prédiction ou le diagnostic,
- de surcroît, ils permettent de modéliser la connaissance par une attribution des probabilités même si les données sont de nature incertaine,
- les algorithmes dédiés au calcul offrent un outil puissant pour la fusion des données incomplètes avec prise en compte des jugements des experts,
- pour les applications industrielles, la qualité de l'offre en matière d'outils rend les *RB* de plus en plus séduisants...

Dans le paragraphe suivant, nous présentons dans un premier temps quelques propriétés théoriques importantes pour la compréhension du formalisme Bayésien. Ensuite, nous exposons leurs principales extensions.

III.2.2. Propriétés et variantes

Dans la théorie des graphes, les propriétés des modèles se présentent comme des outils théoriques permettant leur développement. Nous allons à présent étudier quelques propriétés des réseaux Bayésiens :

➤ *Indépendance conditionnelle :*

Soit X , Y et Z trois variables aléatoires, X est indépendante conditionnellement de Y sachant Z , si et seulement si $P(X|Y,Z) = P(X|Z)$ (Dawid, 1979). Cette propriété se traduit par le fait que sachant l'état Z , l'état de Y n'influence pas l'état de X (cf. figure III.2). Ce résultat est fondamental dans l'utilisation des réseaux Bayésiens, il est très utile dans la recherche des structures graphiques d'un réseau et permet de limiter les calculs de probabilités dans un graphe causal. Un graphe représentant des indépendances conditionnelles détient davantage de propriétés, comme celles de Markov.




Figure III.2. Indépendance conditionnelle (connexion divergente).

➤ *Condition de Markov :*

Soit un graphe orienté avec un ensemble de variables aléatoires, $X = \{X_1, X_2, \dots, X_n\}$. Ce graphe possède la propriété de Markov directe, c'est-à-dire que chaque nœud X_i est indépendant de l'ensemble de ses non-descendants conditionnellement à l'état de ses parents (Pearl et Pas, 1985). Cette propriété importante donne au graphe Bayésien la capacité de représenter, d'une manière compacte, les lois de probabilité entre variables et elle implique la factorisation de la loi jointe. La fonction de distribution jointe est :

$$P(X) = P(X_1, X_2, \dots, X_n) = \prod_{i=1}^n P(X_i / \text{Parents}(X_i))$$

➤ *Équivalence de Markov :*

Deux réseaux Bayésiens sont dits équivalents au sens de Markov, s'ils ont les mêmes modèles d'indépendance conditionnelle, c'est-à-dire les mêmes lois conjointes de probabilités (Verma et Pearl, 1991). Il est possible de démontrer que les graphes équivalents possèdent tous le même squelette (graphe sans orientation des arcs) et les mêmes V-structures (de la forme $X_i \rightarrow X_j \leftarrow X_k$ dans un graphe G , figure III.2).

➤ *Boucle dans un réseau Bayésien :*

La structure d'un réseau Bayésien ne doit pas contenir de circuits orientés (figure III.3). Cependant, l'un des résultats théoriques montrant la puissance de modélisation par *RB* indique qu'il existe toujours une représentation par *RB* des lois conjointes quelles que soient les dépendances stochastiques entre les variables aléatoires.




Figure III.3. Cas d'un circuit dans un réseau Bayésien.

Notons que la construction d'un réseau Bayésien est réalisée suivant trois étapes nécessaires résumées dans la figure III.4.




Figure III.4. Construction d'un réseau Bayésien (Naïm et al., 2007).

La première étape consiste à identifier les variables ainsi que leurs espaces d'états. La sollicitation de l'expertise est fortement appréciée, elle permet de déterminer les variables pertinentes pour la modélisation. Par la suite, la structure causale est définie soit à partir des connaissances d'experts soit par apprentissage automatique à partir de données. Ainsi,

cette deuxième étape consiste à déterminer les liens entre les variables identifiées. Enfin, le renseignement des tables de probabilités associées aux différents nœuds termine la construction du réseau, si nous disposons de suffisamment de données, l'apprentissage des probabilités se fait d'une manière automatique.

Depuis leur apparition les réseaux Bayésiens ont été étendus afin de couvrir d'autres problématiques importantes, parmi les champs de développement nous mentionnons :

➤ *Réseau Bayésien naïf :*

Une première variante des *RB* est appelée réseaux Bayésiens naïfs. Pour les problèmes de classification, cette variante est largement utilisée et elle a donné de très bons résultats (Langley et al, 1992), la terminologie classifieur Bayésien est souvent employée. Un *RB* naïf se compose d'un graphe à deux niveaux, un nœud parent discret pour le premier niveau (nommé nœud de classe C) et des nœuds enfants (ou feuilles notés X_i) pour le second. Les n modalités du nœud de classe C représentent le nombre de classe du problème ($C_1, C_2, \dots, C_n$). Notons, pour cette structure simple, l'hypothèse très forte d'indépendance des feuilles (enfants) conditionnellement au parent. En tenant compte de cette hypothèse « naïve » d'indépendance entre les variables X_i , la probabilité jointe peut être exprimée par la formule :

$$P(C, x_1, \dots, x_n) = P(C) \prod_{i=1}^n P(x_i / C)$$

Où C est la variable de classe recherchée.

La figure III.5 présente un *RB* naïf avec ses deux niveaux. La tâche de classification consiste à reconnaître, après quantification de la structure graphique, la classe C d'une instantiation X_i .




Figure III.5. Réseau Bayésien naïf.

Afin d'améliorer les performances du réseau Bayésien naïf, une autre structure est proposée par (Friendman et al., 1997), ce sont les *RB* naïfs augmentés. Ici, l'hypothèse

d'indépendance directe entre les variables n'est plus considérée et des arcs peuvent être ajoutés entre les nœuds enfants. Nous citons la méthode d'augmentation de la structure naïve par un arbre désignée par *TANB* (*Tree Augmented Naïve Bayes*). L'idée est de relier toutes les feuilles par un arc au plus en créant ainsi un arbre, par conséquent chaque nœud enfant possède deux parents (le nœud de la classe C et un autre nœud enfant X_i). Cette représentation a donné des résultats satisfaisants pour résoudre les problèmes de classification (Greiner et al., 1997).

Dans le cas où la classe C du réseau Bayésien naïf de la figure III.5 est non mesurée, un modèle latent équivalent peut être proposé sous une forme hiérarchique, cette extension est dédiée aux problèmes de classification non supervisée (Zhang, 2002).

➤ *Réseau Bayésien dynamique (ou temporel) :*

Dans un processus réel, l'une des variables les plus importantes est le temps. Pour un réseau Bayésien statique (classique) chaque variable est décrite par un seul nœud et le réseau sous-jacent ne permet pas de prendre en compte des besoins d'application évoluant dans le temps. Les réseaux Bayésiens dynamiques (*RBD*) sont définis en tant qu'une extension des *RB*, où une variable peut être décrite par plusieurs nœuds modélisant son comportement à plusieurs instants (Russell et Norvig, 2003). La structure de la figure III.6 présente un modèle par *RBD*, elle peut être considérée comme une duplication d'un *RB* à chaque pas de temps. Dans ce cas, la distribution de probabilité peut changer en fonction du temps comme dans les chaînes de Markov (Murphy, 2002) et elle est calculée pour une variable X_i à l'instant t connaissant ses états aux instants $t-1$, $t-2$, etc. Une variable X_i dans un *RB* dynamique peut influencer donc sa valeur à l'instant d'après.




Figure III.6. Réseau Bayésien Dynamique.

Un modèle de Markov caché *HMM* (*Hidden Markov Model*) est considéré comme un *RBD* simplifié (Murphy, 2002). La particularité d'un *HMM* réside dans la taille de son espace

d'état composée d'une seule variable aléatoire, tandis qu'un *RBD* est représenté par un ensemble de variables aléatoires. Comme pour un *RB* classique, le *RBD* satisfait la condition Markovienne. L'incorporation de l'aspect temporel dans le calcul du modèle dépend essentiellement du contexte du problème étudié (en termes de besoins et d'objectifs).

La densité de probabilités jointe pour un ensemble de variables $X(t) = \{X_1(t), X_2(t), \dots, X_n(t)\}$ peut être écrite comme suit :

$$P(X(1), X(2), \dots, X(T)) = \prod_{t=1}^T \prod_{i=1}^n P(X_i(t) / Parents(X_i(t)))$$

Où T est l'indice temporel et n est le nombre de variables dans chaque pas de temps.

➤ *Réseau Bayésien orienté objet :*

Pour certains types d'application, rendre le formalisme Bayésien plus générique va simplifier considérablement la tâche de modélisation. En effet, pour un système complexe la modélisation par un réseau Bayésien induit des modèles de taille importante et difficilement abordables. C'est la raison pour laquelle, des travaux ont proposé une nouvelle structure nommée réseaux Bayésiens orientés objets *OOBN (Object Oriented Bayesian Networks)* (Koller et Pfeffer, 1997 ; Bangso et Wuillemin, 2000). Dans ces modèles, un objet regroupe une partie du réseau Bayésien. L'objet peut être réutilisé plusieurs fois permettant ainsi de simplifier la représentation graphique et avoir un modèle avec différents niveaux d'abstraction. Il semble que les *OOBN* soient bien adaptés aux problèmes de modélisation des processus industriels dans le cadre de la maintenance et de la sûreté de fonctionnement (Weber et Suhner, 2004 ; Weber et Jouffe, 2006). Cependant, l'inférence dans de telle structure reste délicate, une nouvelle génération de modèle probabiliste est proposée afin de gagner en efficacité (Medina-oliva et al., 2013).

➤ *Réseau Bayésien étendu à un diagramme d'influence :*

Pour des problèmes liés au domaine de l'aide à la décision, une extension des réseaux Bayésiens (statique et dynamique) est envisageable. Il s'agit du concept des Diagrammes d'Influence (*DI*) qui sont une généralisation de la méthode des arbres de décision. Pour cette structure, la nouveauté dans la démarche de modélisation réside dans l'ajout de deux nouveaux types de nœuds à la structure initiale du réseau Bayésien (Jensen et Nielsen, 2007) comme le montre la figure III.7.

Au final, un diagramme d'influence comporte trois types de nœuds, les nœuds de probabilité du *RB* initial, les nœuds de décision permettent de représenter une action sur le système et enfin les nœuds d'utilité pour modéliser le coût associé à une variable du modèle ou une action sur le système. La prise en compte des coûts et des effets permet de comparer les performances liées à une prise de décision sur le système. En outre, l'optimisation des interventions est aussi possible sur la base des résultats de simulation. Ce calcul compact est en particulier appliqué dans le domaine de l'aide à la maintenance (Clemen et Reilly, 2001 ; Weber et al., 2001 ; Weber et Suhner, 2004).




Figure III.7. Diagramme d'influence.

➤ Réseau Bayésien étendu à un modèle continu Gaussien :

Jusqu'à présent les variantes des réseaux Bayésiens ont été présentées en considérant le fait que les variables sont discrètes. Ceci est dû au fait que la majorité des algorithmes et des outils d'apprentissage et d'inférence utilisent soit des variables discrètes soit discrétisées. Le problème des distributions continues est souvent négligé (Naïm et al., 2007). Cependant, dans de nombreuses applications d'analyse de données, les variables continues existent et leur discrétisation implique une perte d'information. Théoriquement, il est possible de généraliser les techniques développées aux variables continues, ainsi, n'importe quelle fonction de densité de probabilité est représentée. Actuellement, un moteur d'inférence permet de gérer des nœuds continus en faisant une hypothèse sur la forme de la distribution (loi normale). Ce type de réseaux Bayésiens est appelé réseau Gaussien (Shachter et Kenley, 1989 ; Verron, 2007 ; Neil et al., 2008).

Le prochain paragraphe présente les problèmes de base auquel nous sommes confrontés lors de la modélisation par réseaux Bayésiens, à savoir l'inférence et l'apprentissage. Nous

définissons chaque notion ainsi qu'un état des lieux des algorithmes qui peuvent être utilisés dans les deux cas.

III.2.3. Méthodes algorithmiques

Pour construire et utiliser un réseau Bayésien, nous devons introduire les deux concepts d'apprentissage et d'inférence, ce sont les deux principaux problèmes dans le raisonnement probabiliste Bayésien :

- l'apprentissage dans un réseau Bayésien est une approche inductive. Nous distinguons deux types d'apprentissage : paramétrique et structurel. Le premier permet d'estimer les lois de probabilités conditionnelles (paramètres) étant donnée une structure de RB , quant au second, il vise à déterminer une structure graphique optimale du modèle à partir d'un ensemble de données observées. Il convient de noter que le nombre de structures graphiques apprises croît de manière super-exponentielle en fonction du nombre de variables du réseau (par exemple, pour dix nœuds le nombre de graphes possibles est environ 4×10^{18}) (Robinson, 1977). Notons aussi que les deux apprentissages peuvent être complémentaires pour un problème donné et qu'une structure peut être définie à partir des avis des experts, de même pour l'estimation des distributions de probabilités. L'apprentissage trouve son intérêt lorsque les jugements de l'expert présentent leurs limites ou quand la taille de données et le nombre de nœuds sont importants,
- l'inférence dans un réseau Bayésien est une approche déductive, l'objectif de l'inférence est de calculer (ou de mettre à jour) n'importe quelle probabilité conditionnelle d'une variable du modèle à partir de la structure causale (arbre causes à effets) et les distributions de probabilités associées (Jensen et Nielsen, 2007). Le théorème de Bayes et les lois de probabilités conditionnelles sont au cœur de ce calcul. Selon la complexité du réseau, nous distinguons deux types d'inférences : exacte (Pearl, 1988) et approchée (Neal, 1993). Si le graphe est fortement connecté, le problème d'inférence est *NP*-difficile et mène à une explosion combinatoire dans le cas général (Cooper, 1990).

La figure. III.8 récapitule les principales familles d'apprentissage et d'inférence dans les réseaux Bayésiens.




Figure III.8. Apprentissage et inférence dans les réseaux Bayésiens.

Afin de supporter ces différentes familles, de nombreux algorithmes d'apprentissage et d'inférence sont proposés dans la littérature (Naïm et al., 2007). Principalement trois critères permettent de choisir un algorithme :

- *type de problème* : apprentissage ou inférence,
- *nature de données disponibles* : complètes ou incomplètes,
- *jugements de l'expert* : avec ou sans connaissances de l'expert.

En se basant sur la nature de données disponibles, la figure III.9 présente les algorithmes d'apprentissage les plus utilisés pour la modélisation probabiliste par réseaux Bayésiens. Le problème d'incomplétude des données est souvent rencontré dans les applications industrielles où certains paramètres ne sont observés que partiellement voire pas observés du tout. Comme nous l'avons mentionné dans le chapitre I, la cause principale du manque d'observabilité sur les paramètres est liée à la technologie des capteurs, qui sont en panne parfois ou délivrent une information avec un retard important voire inexploitable dans certains contextes pour des raisons techniques. Pour une description plus détaillée nous recommandons la lecture de travaux suivants : (Heckerman, 1998 ; Neal et Hinton, 1998 ; Dempster et al., 1977 ; Francois, 2006).

Pour ce qui est de l'inférence, la figure III.10 présente les principales méthodes de calcul des distributions de probabilité dans un réseau Bayésien. Pour une description plus détaillée, nous invitons le lecteur à consulter les références suivantes : (Pearl, 1988 ; Murphy, 2002 ; Kappen, 2002 ; Robert, 1994).




Figure III.9. Algorithmes d'apprentissage.




Figure III.10. Algorithmes d'inférence.

Les méthodes d'apprentissage citées appartiennent à la famille d'apprentissage à partir de données, la deuxième famille s'appuie quant à elle sur l'acquisition de connaissances (les jugements de l'expert) (Renooij, 2001). Les algorithmes d'inférences de type approchés, basés sur des méthodes stochastiques, sont utilisés pour des réseaux de grande taille. Il est particulièrement intéressant de signaler que les algorithmes listés ci-dessus sont à présent opérationnels si nous procédons à une modélisation de type statique. Ce qui n'est pas le cas pour une modélisation par réseaux Bayésiens dynamiques, car les recherches sont en cours. Il en est de même pour la prise en compte des variables continues. Théoriquement, les principes de calcul dans les *RB* discrets peuvent être généralisés aux *RB* continus. Mais dans la pratique les recherches sont encore d'actualité.

III.2.4. Domaines d'application et outils

La communauté de recherche développant les réseaux Bayésiens rassemble plusieurs disciplines scientifiques (Darwiche, 2010) : l'intelligence artificielle, l'informatique, la théorie des probabilités, la théorie des statistiques, etc. L'apparition des outils puissants pour la modélisation graphique probabiliste a permis d'élargir l'utilisation des réseaux Bayésiens pour différentes applications industrielles. Deux applications ambitieuses sont

décrites dans (Naïm et al, 2007). Il s'agit de la détection de fraude et l'aide à la décision en situation critique développées respectivement par une société américaine de télécommunication *ATT* et le centre de recherche en spatiale *NASA*. Dans le tableau III.1, nous récapitulons d'autres champs d'application des *RB* selon les objectifs et les raisons de leur utilisation.

Domaines	Objectif	Pourquoi les RB ?
Santé:	-Diagnostic en télé-médecine -Surveillance médicale	-Connaissances hétérogènes -Requêtes complexes
Industrie:	-Contrôle des systèmes -Simulation des systèmes	-Incertitudes -adaptation selon la situation
Défense:	-Analyse de données -Prendre des décisions	-Données incomplètes -Données incertaines
Finance:	-Évaluation de risques -Détection des fraudes	-Manipulation de l'incertain -Intégrer un expertise
Marketing:	-Prévoir des besoins -Analyse de risques -Aide à la décision	-Gestion de l'incertain -Intégrer des données incomplètes -Data Mining
Informatique:	-Contrôle des agents logiciels -Sécurité informatique -Filtre anti-spam	-Représentation de la connaissance -Inférence réactive -Apprentissage incrémental

Table III.1. Applications des *RB* (Naïm et al., 2007).

En pratique, les méthodes par réseaux de neurones, systèmes experts, arbres de défaillances, arbres de décisions... peuvent être utilisées au même titre que les réseaux Bayésiens. Les critères de choix d'une méthode peuvent être liés au coût, aux délais et à la facilité de mise en œuvre. L'utilisation des réseaux Bayésiens est généralement privilégiée sur les critères de facilité d'acquisition, de représentation, et d'utilisation de la connaissance. En ce qui concerne la programmation des algorithmes, il existe de nombreuses bibliothèques traitant les réseaux Bayésiens (*BNT Matlab*, *BNJava*, *JavaBayes*, *PNL...*) et la qualité d'offre en matière de logiciels (*ProBT*, *BayesiaLab*, *Netica*, *Hugin*, *Elvira...*) favorise encore davantage leur utilisation.

Après cet aperçu consacré aux *RB*, la partie suivante s'attache à décrire un premier exemple de modélisation d'un indicateur de l'état de santé des équipements de production. Cet exemple est conduit en utilisant le formalisme Bayésien dans un atelier de fabrication en semi-conducteur.

III.3. Réseaux Bayésiens et mise en œuvre d'un indicateur de santé

L'indicateur de santé est utilisé pour représenter l'évolution de l'état d'un équipement de production ou l'un de ses composants. Nous avons choisi de travailler sur un exemple d'équipement opérant dans l'atelier de traitement thermique. L'équipement de production concerné est un four de type *LPCVD* (*Low Pressure Chemical Vapor Deposition*) comportant essentiellement deux réacteurs de traitement à haute température. Ces fours ont pour fonction principale le dépôt de couches de gaz sur des plaquettes de silicium à basse pression. Si une défaillance se produit au niveau des réacteurs, la production est interrompue. Nous avons enregistré une variabilité significative sur ce type d'équipement, de multiples arrêts (indisponibilités), un niveau élevé de maintenances correctives et les interventions préventives ne sont pas optimales. Nous nous orientons vers des méthodes probabilistes par réseaux Bayésiens permettant de prédire l'état de santé de ces équipements. Ainsi, le modèle que nous apportons propose de calculer une probabilité de défaillance à partir de l'analyse des paramètres de l'équipement, de la maintenance et des données historiques.

La partie qui suit est consacrée au développement, à partir du formalisme Bayésien, d'un modèle statique représentant l'évolution de l'état de santé d'un équipement de production d'un mode de fonctionnement normal vers un mode de fonctionnement anormal. Par la suite, ce modèle de base sera enrichi afin de couvrir d'autres spécificités du cas d'étude réel (tables *AMDEC*, aspect temporel...).

III.3.1. Analyse probabiliste par réseau Bayésien

L'élaboration d'un indicateur pour représenter l'évolution de l'état de santé des équipements de production, est réalisée en suivant trois étapes élémentaires : I)-*identification des variables*, II)-*définition de la structure graphique* et III)-*définition des lois de probabilité* (voir figure III.11). En outre, ce qui caractérise l'analyse probabiliste par *RB* dans le domaine semi-conducteur ce sont les entrées. En effet, *l'identification des variables et la définition de la structure graphique* sont basées sur les données historiques, les méthodes qualitatives (type *AMDEC*) et les connaissances des experts. Ensuite, l'apprentissage paramétrique permet de *définir les lois de probabilité* des différentes variables en utilisant la famille d'algorithmes appropriée. Enfin, l'inférence permet de tester le modèle, ce dernier est mis à jour à travers de nouvelles données.




Figure III.11. Analyse probabiliste par RB.

Le calcul d'un indicateur suivant cette analyse doit prendre en compte certaines caractéristiques importantes liées au contexte de fabrication en semi-conducteur :

- Un nombre significatif de paramètres en entrée, lié à la complexité du procédé de fabrication d'un circuit intégré (temps de cycle, quantité de données acquise...).
- Une grande diversité de type de ces paramètres : discrets, continus, qualitatifs ou quantitatifs.
- Une quantité considérable de données provenant des équipements et des produits.
- Des jeux de données incertaines voire incomplètes dans certains cas.
- Une forte causalité entre les événements : défaillance, effets de la défaillance, causes de la défaillance, causes primaires de défaillance, etc.
- Une forte corrélation entre les paramètres d'un même équipement (température, pression...).
- Une grande flexibilité des équipements de production, capables de fabriquer une multitude de produits pour différentes technologies.
- Une forte expertise sur le procédé (connaissances à formaliser ou retour d'expérience) distribuée sur de nombreux acteurs, etc.

En se basant sur ces caractéristiques et les avantages qu'offre la modélisation Bayésienne, la figure III.12 permet d'identifier les principaux verrous scientifiques à lever dans le cadre de ce travail de recherche.




Figure III.12. Axes de développement en semi-conducteur.

Compte tenu de ces préconisations, l'objectif du paragraphe suivant est d'appliquer la démarche de construction d'un *RB* afin de développer un premier indicateur statique représentant l'évolution de l'état de santé d'un équipement de production.

Il convient de rappeler que la démarche suivie pour la modélisation du *RB* fait partie des étapes de la méthodologie proposée dans la section II.4, précisément l'étape I (figure II.12, page 51) pour ce qui est de l'identification des variables et l'étape II (figure II.13, page 53) pour les définitions de la structure et des tables de probabilités. Nous consacrons cette partie du manuscrit aux résultats « théoriques » de la modélisation. Le dernier chapitre sera consacré, quant à lui, à la discussion des résultats du cas d'application et à la présentation des différents outils de calcul développés.

III.3.2. Identification des variables du modèle

Cette première étape de construction du modèle *EHF* par réseau Bayésien est une étape importante et décisive. Il existe essentiellement deux types d'approches pour la

mener. Soit utiliser directement la connaissance des experts du domaine, ou bien se référer aux outils statistiques et probabilistes opérant à partir des données. Dans notre étude, et dans un premier temps, nous avons fait appel à l'expérience des industriels pour tenter de déterminer un ensemble de variables représentatives. Ce recueil d'expertise s'est réalisé principalement au moyen de réunions de collecte d'informations (*brainstorming*), nous présentons dans l'annexe B un exemple de compte rendu de réunion. Par conséquent, les variables utilisées dans les modèles illustratifs que nous décrivons dans cette section sont intrinsèquement issus de l'expérience (Bouaziz et al., 2011a). Cependant, dans le chapitre IV nous proposons deux outils statistiques et probabilistes pour affiner le choix des variables et le rendre automatique pour des modèles plus conséquents.

A travers cette modélisation, notre ambition est de décrire l'évolution d'une défaillance sur l'équipement. L'analyse quantitative doit donc permettre le développement d'un modèle de type causes à effets (par analogie aux tables *AMDEC*) où la notion de défaillance joue un rôle central. À partir de cette notion, nous avons pu identifier trois catégories de variables distinctes :

- *Modes de défaillance FM* : ce sont les variables quantitatives définies prioritaires par l'expert de l'atelier. Ils indiquent si une défaillance a été observée ou non. Nous supposons donc que l'espace d'états de ces variables prend deux valeurs possibles (ex. détecté, non détecté). Le cas le plus évoqué correspond à la contamination de surface des *wafers* par des particules.
- *Causes de défaillance RC* : ce sont les causes potentielles déterminées par les avis d'expert. Leurs valeurs numériques (probabilités) seront renseignées lors de l'apprentissage paramétrique à partir des données. Toutes les causes possèdent une modalité binaire (ex. observée, non observée). Nous distinguons deux catégories de causes : causes physiques potentielles (RCH_i) et causes contextuelles potentielles (RCC_j).
- *Paramètres de description $Para_i$* : ce sont des variables quantitatives considérées comme des « causes primaires » de défaillance, ils permettent la mise à jour des causes physiques (RCH_i) et des causes contextuelles (RCC_j). Chaque variable possède soit une modalité binaire (ex. vraie, fausse), soit une échelle de probabilité (certaine, probable, incertaine, impossible) permettant de convertir les règles qualitatives en probabilités (table d'éllicitation d'avis d'experts).

Dans le but d'illustrer ces aspects de construction de l'*EHF*, nous allons analyser un premier exemple « académique » permettant de représenter le raisonnement qui peut être fait suite à un rejet de produit (*scrap*). Le tableau III.2 présente la liste des variables désignées à partir des avis d'experts. In fine, nous prenons une variable pour les modes de défaillance, deux variables pour les causes de défaillance potentielles et trois variables de mesure pour les paramètres de description :

Nœud	Variables
FM_1	Contamination des <i>wafers</i> par des particules
RCH_i	Usure d'un composant (robot, pompe...)
RCC_j	Contexte de production (lots, maintenance...)
$Para_1$	Mesure du capteur 1 (température, vitesse...)
$Para_2$	Mesure du capteur 2 (pression, débit...)
$Para_3$	Compteur (nombre de <i>Run</i> ...)

Table III.2. Exemple de variables sélectionnées.

Comme il a été précisé plus haut, chaque variable correspond à un nœud dans le modèle de connaissance statique Bayésien. Dans un souci de simplicité, nous avons supposé que les variables identifiées sont discrètes, qu'elles ont été toutes observées et que les causes de défaillance sont indépendantes entre elles.

III.3.3. Définition de la structure graphique du modèle

Sur la base des résultats de l'étape précédente, la deuxième étape consiste à définir les liens entre les variables identifiées. Cette tâche est réalisée à partir des jugements d'experts et elle est souvent validée après plusieurs itérations. Pour le cas général, nous avons proposé d'effectuer cette étape en deux temps. Tout d'abord, nous définissons les groupes de variables réunissant plusieurs nœuds de la même famille (causes primaires, causes secondaires, effets potentiels...) et les types de lien entre ces familles. Par la suite, nous traçons les liens entre les différentes variables de chaque groupe de nœuds.

Dans notre cas, la première phase est plutôt simple. L'identification des variables telle qu'elle a été faite considère d'ores et déjà trois niveaux de groupes. La figure III.13 présente la structure (nœuds et arcs) compacte entre les trois niveaux de variables du modèle.




Figure III.13. *Structure compacte du modèle EHF.*

La deuxième phase, quant à elle, définit en détail les liens existants entre les différentes variables identifiées. Nous tenons soigneusement compte des propriétés graphiques des *RB* (absence de boucles...). Nous prenons comme hypothèse forte pour ce modèle, l'absence de liens entre les paramètres de description, ils sont supposés indépendants. La structure graphique obtenue est représentée dans la figure III.14.




Figure III.14. *Exemple de structure détaillée du modèle EHF.*

Notons que cette phase de définition de structure devient plus complexe si le nombre de variables identifiées est significatif. Le paragraphe suivant décrit comment sont définies les lois de probabilité du modèle.

III.3.4. Définition des lois de probabilités du modèle

Connaissant les variables du modèle ainsi que sa structure graphique, la dernière étape consiste à évaluer les tables de probabilités et les tables de probabilités conditionnelles associées aux différents nœuds du réseau. Contrairement aux deux étapes qualitatives précédentes, les lois de probabilités sont entièrement calculées par apprentissage automatique à partir de données. Le nombre de probabilités pour une table conditionnelle croît rapidement en fonction des modalités de la variable et du nombre total de ses nœuds

parents. Quant aux données réelles, l'apprentissage paramétrique nécessite une qualité et une quantité de données suffisantes. Ensuite, les données doivent être traitées pour les synchroniser et les structurer sous la forme du tableau III.3. Les colonnes renseignent l'état des variables (FM_i , RC_j , $Para_k$) à chaque étape de production ou de maintenance.

Équipement	Module	Évènement	Date/Run	FM_i	RC_j	$Para_k$	...
Furnace ID	Réacteur-1	Production	03/29 – 11:55:00	N	Ok	E_0	
Furnace ID	Boat	Maintenance	03/29 – 11:56:05	N	Ok	E_1	
Furnace ID	Réacteur-2	Production	03/29 – 12:05:30	O	Bad	E_2	

Table III.3. Préparation des données pour l'apprentissage.

À partir de ces données, nous pouvons effectuer l'apprentissage pour remplir les différentes tables de probabilités associées à chaque variable. Pour cet exemple simple où les données sont complètes, nous illustrons cette étape par l'utilisation de l'algorithme de maximum de vraisemblance *MV* (*maximum likelihood*). Il s'agit d'une estimation statistique des probabilités d'un événement à partir de son occurrence (fréquence d'apparition) dans le jeu de données. C'est une méthode assez simple et largement utilisée (Heckerman, 1998). L'estimation de probabilité est donnée par la formule suivante :

$$\hat{P}(X_i = x_k / \text{parents}(X_i) = X_j) = \hat{\theta}_{i,j,k}^{MV} = \frac{N_{i,j,k}}{\sum_k N_{i,j,k}}$$

$N_{i,j,k}$ est le nombre d'occurrences où la variable X_i prend l'état x_k et les parents de X_i prennent l'état x_j .

L'aspect quantitatif de la modélisation étant achevé, il est maintenant possible de poser différentes questions. Il s'agit d'utiliser les moteurs d'inférence afin d'interroger le modèle. Nous avons étudié le problème d'inférence exacte par l'algorithme de propagation de messages (*message passing*), l'idée consiste à envoyer des messages (ou informations) aux nœuds voisins moyennant les arcs du graphe (Pearl, 1988). Cet algorithme fait souvent référence dans la littérature. Cependant pour le cas des modèles de grande taille, l'algorithme à base d'arbre de jonction est souvent utilisé.

La figure III.15 montre un exemple illustratif d'une inférence avec évidence. Nous affichons toutes les distributions de probabilités du réseau sachant l'observation (évidence) de certaines variables.




Figure III.15. Probabilités a posteriori des variables.

Nous avons interrogé le modèle en posant les questions suivantes :

- a) $P(FM_1/RCH_i)$: l'observation ici est « l'usure d'un composant » RCH_i . L'utilisation de la formule de Bayes permet de calculer les probabilités d'avoir un mode de défaillance « contamination des wafers » suite à cette observation. Ainsi, le facteur de santé de l'équipement EHF est défini (prédit) à partir de ce calcul de probabilités. Selon le besoin de l'atelier, il peut être calculé pour un mode de défaillance particulier $P(FM_1/Observations)$ ou pour la moyenne pondérée de plusieurs modes de défaillance $P(FM_1, FM_2.../Observations)$.
- b) $P(RCC_j/FM_1)$: de la même manière, il est possible d'interroger le modèle afin d'établir un diagnostic connaissant l'observation d'un mode de défaillance. Il s'agit de calculer la probabilité que la cause contextuelle RCC_j soit à l'origine d'une contamination des plaquettes de silicium FM_1 .

L'inférence probabiliste est essentiellement une question de calcul. Pour cet exemple d'illustration, nous utilisons le principe de calcul par l'algorithme de propagation de messages à partir du modèle EHF appris. Nous expliquons la méthode de calcul à travers une seule variable, cependant, le principe est le même pour le reste des nœuds du graphe.

Soit la partie du graphe représentée par la variable RCC_j , avec sa table de probabilités apprise. Pour un ensemble de variablesinstanciées E , la probabilité de RCC_j sachant E est calculée suivant les trois étapes de l'algorithme d'inférence *message passing* :

- 1) Calculer le premier type de message : $\lambda(RCC_j) \propto P(D_{RCC_j}/RCC_j)$

Pour chaque enfant FM_i de RCC_j ,

$$\lambda_{FM_i}(RCC_j) = \sum P(FM_i / RCC_j) * \lambda(FM_i)$$

- 2) Calculer le deuxième type de message : $\Pi(RCC_j) \propto P(RCC_j / N_{RCC_j})$

Pour $Para_i$ l'unique parent de RCC_j ,

$$\pi_{F_{Mi}}(Para_i) = \sum P(RCC_j / Para_i) * \pi(Para_i)$$

- 3) Calculer $P(RCC_j / E)$:

$$P(RCC_j / E) = \lambda(RCC_j) * \pi(RCC_j)$$



Cette première instanciation montre clairement l'apport significatif de la modélisation graphique probabiliste, particulièrement en termes de facilité d'acquisition et d'utilisation de la connaissance. Par inférence, différents types de tests (questions) peuvent être effectués, ce qui permet au modèle de calculer l'indice de santé par mode de défaillance *EHF/FM*. Néanmoins, les hypothèses prises en compte lors de la modélisation limitent la flexibilité de l'indicateur de santé face aux besoins multiples des industriels. Dans ce qui suit, nous présentons la mise en œuvre de nouvelles configurations pour le calcul du modèle *EHF*.

III.4. Configurations du modèle EHF

Comme nous l'avons mentionné précédemment, différents critères interviennent lors de la définition des variables et la structure graphique du modèle. Par conséquent, l'intégration d'un tel modèle dans un terrain assez complexe doit répondre aux besoins exprimés par les experts métiers : modes de défaillances prioritaires, causes de défaillances potentielles, modules critiques de l'équipement, risques graves (sévéres), risques courants (occurents), etc.

Pour répondre au mieux à ces attentes, nous avons proposé aux partenaires industriels différentes configurations possibles pour l'exploitation future du modèle *EHF* :

- un modèle *EHF* par mode de fonctionnement,
- un modèle *EHF* instancié à partir des tables *AMDEC*,
- un modèle *EHF* prédictif à partir d'un *RBD*,
- et un classifieur de causes naïf pour supporter le modèle *EHF*.

Dans la suite de cette partie, nous allons définir chaque configuration, sa structure et les méthodes algorithmiques associées. Les modèles sont donc proposés, dans un premier temps, d'un point de vue théorique. Les résultats de validation sur un cas d'étude industriel seront traités dans le dernier chapitre du manuscrit.

III.4.1. EHF par mode de fonctionnement

Si nous nous intéressons à une défaillance potentielle donnée, l'indicateur de santé de l'équipement (EHF) est calculé par mode de défaillance (FM) :

$$EHF_{-eqp} = P(FM_i / Observations)$$

Si nous nous intéressons à l'effet de plusieurs FM , l' EHF est calculé pour la moyenne pondérée de tous ces modes de défaillance. Dans ce cas une modélisation plus fine doit être faite. Nous avons proposé de regrouper les variables du modèle EHF par mode de fonctionnement (stockage en amont, production dans le réacteur n°1, transfert par le robot, stockage dans le Boîtier n°1, production dans le réacteur n°2...). La structure générique résultante de cette décomposition est représentée dans la figure III.16, où chaque mode de fonctionnement correspond à un module d'équipement (cf. annexe C pour les modules) :




Figure III.16. Mise en œuvre d'un EHF par module d'équipement.

Ainsi, chaque module d'équipement correspond à un sous modèle EHF représenté par sa structure compacte. La probabilité résultante de chaque module traduit l'occurrence d'au moins un mode de défaillance (EHF_{module}). L'indice global indiquant l'état de santé de l'équipement est calculé par la formule suivante :

$$EHF(FM_{-eqp}) = \sum W_{Mi} * P(FM_i / Observations)$$

W_i est la pondération (pas une variable du modèle) associée à chaque mode de fonctionnement. W_i est une valeur normalisée entre [0,1] et dépend principalement de la

criticité d'un sous équipement par rapport à un autre. Nous avons proposé aux experts une échelle qualitative comportant quatre niveaux de criticité : gravité mineure, gravité significative, gravité critique, gravité catastrophique (Mendez-Azua, 2002).

Pour cette structure particulière, l'aspect algorithmique est exactement le même. L'estimation des lois de probabilités est effectuée par apprentissage automatique à partir de données et à l'aide de la méthode du maximum de vraisemblance *MV*. Notons que dans le cas où le nombre de variables du modèle *EHF* est plus conséquent, cette décomposition modulaire permet de réduire significativement le temps de calcul alloué à l'apprentissage paramétrique et à l'inférence.

III.4.2. Instanciation de l'EHF à partir des tables AMDEC

La méthode d'analyse des modes de défaillance, de leurs effets et de leur criticité est largement utilisée dans le domaine industriel (Department of Defense, 1980). L'approche *AMDEC* est basée sur une analyse fonctionnelle des procédés, elle vise à prévenir les risques et à améliorer les rendements. Comme dans de nombreux domaines de la sûreté de fonctionnement (David, 2009), l'*AMDEC* souffre de beaucoup d'inconvénients en semi-conducteur (lourde, travail important et fastidieux, incertitudes...). C'est la raison pour laquelle, de multiples travaux ont été entrepris afin d'améliorer cette méthode d'analyse prévisionnelle inductive et qualitative (Mili et al., 2008). Dans cette perspective, nous avons proposé une instanciation d'un modèle *EHF* par réseau Bayésien à partir de l'analyse des tables *AMDEC* fonctionnelles. Dans le domaine semi-conducteur, il existe différents types de tables *AMDEC* : équipement, procédé et produit. Un exemple d'une *AMDEC* fonctionnelle des équipements de déposition (atelier du traitement thermique) est présenté dans l'annexe D.

Dans le cadre de notre travail, nous nous intéressons à des équipements de production pouvant réaliser plusieurs fonctions distinctes (traitement des *wafers* utilisant différents matériaux). Pour chacune de ces fonctions, des modes de défaillance sont recensés. Un mode de défaillance est qualifié à travers sa sévérité, son occurrence et sa détection (*SOD*). Ensuite, les causes et les effets de défaillance sont dénombrés. A partir de cette classification de type causes à effets, la structure du modèle *EHF* à base d'*AMDEC* est définie. Ce modèle est composé de plusieurs sous-structures compactes représentant chacune une fonction spécifique. Pour l'exemple des équipements de traitement thermique, nous avons plusieurs types de dépôt de gaz : oxyde, TEOS, poly-silicium, etc. Selon cette

disposition, chaque fonction peut donc avoir son propre état de santé ($EHF_{fonction}$) comme le montre la figure III.17.




Figure III.17. *Instantiation de l'EHF à partir des tables AMDEC.*

Cette configuration est instanciable (Bouaziz et al, 2012d), ce qui permet de générer des structures du modèle EHF à partir d'autres types de table $AMDEC$ disponibles à condition d'avoir suffisamment d'informations sur les variables du modèle afin d'estimer les lois de probabilités par apprentissage paramétrique. A partir de l'estimation de l'état de chaque fonction, l'indice global indiquant l'état de santé de l'équipement est évalué de la manière suivante :

$$\begin{cases} EHF(FM_{-eqp}) = \sum W_{Fi} * EHF_{-fonction} \\ EHF_{-fonction} = \sum W_i * P(FM_i / Observations) \end{cases}$$

W_{Fi} (nœud violet) est la pondération associée aux différentes fonctions accomplies par l'équipement. W_i (nœud vert) est une pondération normalisée accordée à un mode de défaillance, elle prend des valeurs multiples en cas d'occurrence de plusieurs modes de défaillance pour une fonction donnée.

L'avantage d'une telle modélisation, en plus de la prise en compte des informations renseignées par les tables, c'est qu'elle permet de mettre à jour le modèle au travers des connaissances pas forcément incluses dans ces mêmes tables $AMDEC$.

III.4.3. Vers un modèle EHF temporel

Dans un processus réel, la variable « temps » est très importante pour une prise de décision dynamique. La plupart des études basées sur le formalisme Bayésien se limitent à des modèles classiques (statiques) qui n'intègrent pas le vecteur temps (Ben Salem et al., 2006 ; Antonucci et Zaffalon, 2008 ; Correa et al., 2009). Pour les procédés semi-conducteurs complexes, une modélisation dynamique plus fine nous semble incontournable. Par exemple la dimension temporelle permet non seulement de caractériser certains paramètres statiques tels que la dégradation des composants, les caractéristiques intrinsèques des maintenances correctives ou préventives, mais également et surtout des séquences et des liens de causalité temporels existants entre les variables.

Comme nous l'avons mentionné dans la section III.2.2, les réseaux Bayésiens dynamiques sont une extension des *RB* statiques. Une variable dans un *RBD* peut être décrite par plusieurs nœuds modélisant son comportement à plusieurs instants (Russel et Norvig, 2003). Comme exemple d'application, nous citons le pronostic de l'état de santé d'un outil de coupe dans les machines à commande numérique, un *RBD* est utilisé pour représenter une chaîne de Markov cachée à mélange de Gaussiennes (*MoG-HMM*) (Tobon-Mejia et al., 2011). L'objectif de ce modèle de dégradation étant d'estimer en ligne l'état courant du composant lors de l'usinage de pièces mécaniques et de calculer la valeur de sa durée de vie restante (*RUL*). La méthode utilise des données fournies par les capteurs de surveillance.

Dans notre étude, l'objectif est d'évaluer l'état de santé d'un système à travers l'estimation de sa probabilité de défaillance. Nous proposons d'analyser deux familles de variables présentant des séquences temporelles et qui peuvent être modélisées dynamiquement :

- l'ajustement d'un paramètre de description ($Para_k$),
- la dégradation d'une variable associée à une cause physique (RCH_j).

Nous allons à présent utiliser le cadre des réseaux Bayésiens dynamiques pour modéliser ces comportements temporels. Pour cela, considérant le cas particulier d'un *RBD* à deux tranches de temps (Friedman et al., 1998 ; Weber et al., 2004 ; Bouillaut et al., 2008). Cette représentation, souvent désignée par *2-TBN* (*Two-slice temporal Bayesian Network*), peut être donnée par la figure III.6 en considérant deux instants seulement ($t=1$) et ($t=2$). Soit un ensemble de variables $X(t) = \{X_1(t), X_2(t), \dots, X_n(t)\}$ d'un processus à deux tranches de temps, la première tranche modélise la distribution initiale du réseau comme suit :

$$P_1 (X(t=1)) = \prod_{i=1}^n P(X_i(1) / Parents (X_i(1)))$$

La deuxième tranche définit la distribution jointe de la transition $X(t=2)$ étant donné la transition $X(t=1)$:

$$P_2 (X(t=2) / X(1)) = \prod_{i=1}^n P(X_i(t) / Parents (X_i(t)))$$

Le réseau Bayésien à deux tranches de temps est un système de Markov du premier ordre, c'est-à-dire, les états passés sont indépendants des états futurs et l'état présent est connu.

Les nœuds parents de $X(t=1)$ et $X(t=2)$ se trouvent que dans les tranches $t=1$ et $t=2$ respectivement. Donc, la distribution de probabilité jointe de l'ensemble des variables aléatoires est donnée par :

$$P_{1,2} (X(1 \leq t \leq 2)) = \prod_{i=1}^n P(X_i(1) / Parents (X_i(1))) \\ \bullet \prod_{t=2}^T \prod_{i=1}^n P(X_i(t) / Parents (X_i(t)))$$

La figure III.18 illustre la structure graphique du modèle *EHF* dynamique incluant conjointement les deux cas de figure possibles (ajustement d'un paramètre et dégradation d'un composant).




Figure III.18. Prédiction de l'EHF à partir d'un RB dynamique.

La structure finale du modèle *EHF* dynamique comporte deux sous modèles indépendants, chaque sous-modèle est associé à un module de l'équipement de production (réacteur de traitement, robot de transfert, contrôleur de débit...). Dans le premier cas, la variable $Para_k$ modélise l'ajustement des paramètres de description. La dérive future du module dépend du réglage en cours des paramètres à instant $T+1$, ce réglage dépendent à son tour de l'ajustement effectué dans le passé à l'instant T . La dépendance entre les ajustements de paramètres est représentée par un arc temporel. Tout comme pour le premier cas, le deuxième cas de figure (dégradation d'un composant) permet de modéliser par un arc temporel la relation entre les variables représentant la dégradation d'une cause de défaillance physique RC_i aux instants T et $T+1$. Ainsi, l'estimation des lois de probabilités pour les variables temporelles à l'instant $T+1$ est faite en fonction des tables de probabilités associées à l'instant T .

A partir de ces différentes estimations, l'indice global indiquant l'état de santé futur de l'équipement est prédit comme suit :

$$EHF(FM_{-eqp}) = \sum W_t * P(FM_i / Observations)$$

W_t est la pondération associée à chaque sous modèle et elle est donnée par l'expert. Notons que pour l'aspect quantitatif, les algorithmes d'apprentissage et d'inférence appliqués aux

RB statique peuvent être modifiés et étendus au cas des RB à deux tranches de temps (système de Markov du premier ordre). L'estimation des tables de probabilités pour chaque variable est calculée à partir de données (complètes ou incomplètes) et des avis d'experts (Weber et Jouffe, 2003). L'inférence exacte de cette classe de RB est un problème NP-difficile. Parmi les algorithmes utilisés, nous citons (Murphy, 2002) : *forward-backward*, *unrolled junction tree*, *frontier algorithm*, *interface algorithm*, etc.

III.4.4. Vers un modèle de classification des causes

La modélisation issue du formalisme Bayésien présente de nombreux intérêts dans le domaine semi-conducteur où d'une part les données sont souvent incomplètes, censurées ou encore non représentatives et où, d'autre part la connaissance humaine est fortement mise en avant. Dans ce qui a précédé, nous avons supposé que les variables du modèle EHF sont toutes identifiées à partir des avis des experts. Mais avec l'évolution de plus en plus complexe du contexte de fabrication, le nombre de variables à identifier croît rapidement. Par conséquent, le travail d'identification demandé aux experts devient relativement lourd et difficile. Afin de pallier à ce problème, un outil de classification automatique des variables doit être proposé. Pour cette raison, nous proposons d'étudier un réseau Bayésien naïf (présentée dans la section II.2.2). L'objectif de cette classification est de vérifier, par apprentissage automatique et inférence, les causalités (RC_i) supposées par les experts ou de trouver de nouvelles causalités si non.

Une classe des RB naïfs a particulièrement attiré notre attention, il s'agit des réseaux Bayésiens naïfs hiérarchiques à classes latentes. Dans (Zaarour et al., 2004), une application de ce type de modèle est proposée, elle permet la découverte de stratégies d'écriture manuscrite chez l'enfant en école primaire. Notre objectif ici est de classifier les causes réelles supposées à partir des paramètres qui les décrivent.

Pour la création du réseau Bayésien, une étude de terrain a été menée avec les experts. Elle nous a permis de proposer une structure modulaire en trois couches, une couche pour les variables mesurées ($Para_i$) et deux couches pour les variables latentes (Y_{ci} et RC) (voir figure III.19).




Figure III.19. Structure naïf du classifieur des causes.

- La variable RC (niveau 1) est définie comme étant une classe globale, sa valeur correspond aux causes de défaillances primaires que nous cherchons. Ces causes ne sont pas mesurées et correspondent à la variable racine dans une chaîne de causalité.
- La variable Y_{ci} (niveau 2) correspond aux causes de défaillances intermédiaires non mesurées et indépendantes les unes par rapport aux autres. Ces causes dépendent de la classe globale RC (relations de cause à effet).
- La variable $Para_i$ correspond aux paramètres décrivant une classe intermédiaire Y_{ci} . Ces paramètres sont mesurés et indépendants les uns par rapport aux autres (compteurs, niveaux d'alarmes, températures, pressions, épaisseurs...).

Il s'agit donc d'une classification non supervisée car les valeurs des classes recherchées ne sont pas connues (i.e. les données n'incluent pas les valeurs des variables RC et Y_{ci}). Les variables du modèle, présentées ci-dessus, sont supposées discrètes. Des algorithmes sont développés pour fixer les états (modalités) des variables latentes (Zhang, 2002 ; Zhang, 2003). Comme pour la structure graphique, nous supposons que les états des variables sont fixés à partir des avis d'expert. En ce qui concerne l'estimation des tables de probabilités à partir de données incomplètes, l'algorithme d'apprentissage *Expectation-Maximization EM* est souvent utilisé (Dempster et al., 1977) dans de tels cas de figure, où non seulement les données sont incomplètes mais le modèle présente des variables latentes.

Pour un suivi plus pertinent et une prise de décision dynamique, une extension du modèle vers un réseau Bayésien temporel nous semble ainsi incontournable (voir figure III.20). L'aspect algorithmique de ce modèle est similaire aux modèles de Markov cachés *HMM*.




Figure III.20. Structure dynamique du classifieur VIP.

Notons également que l'utilisation d'un *RB* naïf augmenté permet d'améliorer les performances du classifieur, en effet, il s'agit d'ajouter des arcs entre les variables enfants. Pour une future industrialisation de ce classifieur, nous proposons d'étudier une nouvelle extension afin de remédier aux problèmes de complexité algorithmique (explosion combinatoire). La raison est que pour un tel contexte de fabrication de circuits intégrés, le nombre de mesures est relativement élevé (il atteint environ 2500 capteurs dans certains cas) et par conséquent, la connectivité du modèle sera relativement importante.

Pour cette nouvelle configuration (cf. figure III.21), l'objectif est de réduire le niveau de connectivité du graphe. Nous proposons d'introduire des couches hiérarchiques afin de regrouper une ou plusieurs variables mesurées et selon des critères bien définis (disponibilité des données, pertinence de l'information...). Au niveau algorithmique, nous proposons d'appliquer une heuristique afin que l'inférence algorithmique converge rapidement (temps de calcul). L'heuristique fournit les valeurs des pondérations W_i et en fonction de ce calcul, les $Para_i$ seront pris en compte ou non dans l'estimation de la classe *RC*. Une étude de terrain va être menée afin de définir les critères pour une décomposition optimale en couches.




Figure III.21. Structure « optimale » du classifieur VIP.

En sortie de ce modèle de classification, si une cause primaire (variable latente) est souvent occurrente, elle sera instanciée dans le modèle *EHF* prédictif qui permet, quant à lui, la prédiction de l'état de santé d'un équipement de production. Le calcul de cet indicateur est un élément d'aide pour la prise de décision liée à la planification des maintenances et à l'affectation des échantillons des *wafers* sur les équipements de métrologie.

III.5. Conclusion

Dans ce chapitre, nous avons présenté le formalisme de modélisation graphique retenu dans le cadre du projet *IMPROVE* : les réseaux Bayésiens, leurs avantages, leurs classes, leurs algorithmes et les domaines d'application associés. Les recherches actuelles sur les *RB* portent essentiellement sur les aspects suivants : l'apprentissage des paramètres, l'apprentissage des structures et les algorithmes d'inférence. Pour résumer, une analyse de risques d'un système complexe par réseaux Bayésiens permet de :

- Modéliser les dépendances entre les événements,
- Représenter des variables qualitatives et quantitatives,
- Intégrer le contexte opérationnel et les jugements de l'expert,
- Représenter des facteurs d'influence (vieillesse, dégradation, etc.).

Ensuite, la deuxième partie de ce chapitre a été consacrée au développement d'un indicateur pour le calcul de l'état de santé des équipements de production en semi-conducteur. A travers cette première modélisation, nous avons pu apercevoir l'aspect compact et synthétique d'une représentation graphique par *RB* où l'acquisition et

l'utilisation de la connaissance est relativement simple. Aussi, nous soulignons le pouvoir de modélisation que présentent les réseaux Bayésiens par rapport aux autres méthodes, particulièrement en termes de variables multimodales et structures complexes. Les *RB* généralisent les méthodes comme les arbres de défaillances et les arbres de décisions. Pour finir, la troisième partie a permis de mettre en œuvre de nouvelles configurations du modèle *EHF* en se basant sur les propriétés des *RB*, ces extensions permettent de répondre à certains besoins des industriels.

Pour les applications industrielles, la qualité de l'offre en matière d'outils a permis à la communauté industrielle et académique de simuler et de valider des modèles à base des *RB*. L'ensemble des modèles présentés dans ce chapitre sont proposés pour différents usages et sous un angle théorique, ils nécessitent à présent d'être validés sur un cas d'application.

Dans le chapitre suivant, nous décrivons brièvement les spécificités du cas d'application industriel (*use case*) ainsi que les résultats de l'application de la méthodologie proposée dans la section II.4. Nous présentons aussi quelques outils développés afin de supporter le calcul de l'*EHF* et pour l'aide à la prise de décision.

IV. Application des modèles proposés sur un cas d'étude

IV.1. Introduction.....	92
IV.2. Développement d'outils pour l'identification des variables.....	92
IV.2.1. Outil de simulation.....	94
IV.2.2. Description de la table « vie de l'équipement ».....	95
IV.2.3. Sélection des risques opérationnels prioritaires.....	96
IV.2.4. Classification des causes de défaillances potentielles.....	98
IV.3. Simulation de l'indicateur de santé EHF : étude de cas.....	102
IV.3.1. Présentation du cas d'étude.....	102
IV.3.2. Simulation du modèle EHF statique.....	104
IV.3.3. Simulation de l'EHF en vue du pronostic.....	109
IV.3.4. Propriétés et retour d'expérience.....	113
IV.4. Scénarios de validation pour la prise de décision.....	114
IV.4.1. Validation en mode normal.....	114
IV.4.2. Validation en mode dégradé.....	116
IV.4.3. Validation en mode de dysfonctionnement.....	117
IV.4.4. Exploitation des résultats pour la prise de décision.....	118
IV.5. Conclusion.....	120

IV.1. Introduction

Parmi les objectifs majeurs du projet *IMPROVE* figure la proposition des démonstrateurs de faisabilité ou *POC (Proof Of Concept)*. L'industrialisation des modèles et outils développés s'avère être une tâche délicate qui nécessite un investissement important en moyens humains et matériels, le déploiement en ligne de ces solutions fera donc l'objet d'un futur projet. C'est la raison pour laquelle, les tests de validation effectués ici se font essentiellement par simulation à partir de données, ces données sont pour la plupart générées (pour des raisons de confidentialité) suite à des études de terrain menées chez nos partenaires industriels.

Nous avons présenté précédemment un ensemble de modèles graphiques probabilistes pour différentes configurations associées aux spécificités industrielles. Tous ces modèles ont été proposés pour répondre aux besoins du contexte de production. Dans ce chapitre, nous décrivons les différentes contributions que nous avons apportées à la thématique de la prédiction de l'état de santé d'un équipement dans le contexte particulier de la fabrication semi-conducteur. Aussi, la section IV.2 décrit les outils supports au développement du modèle *EHF*. Dans la section IV.3, nous présentons les résultats de l'utilisation des modèles proposés sur un cas d'étude. Enfin, la section IV.4 concerne une étape de validation appliquée hors ligne sur le modèle et ce pour différents scénarii de fonctionnements possibles. Nous avons choisi de travailler au sein de l'atelier de traitement thermique et avec des équipements de dépôt de gaz sur des plaquettes de silicium. Au-delà de sa complexité et de sa criticité, ce procédé présente des scénarii représentatifs de situations de bon et de mauvais fonctionnement nous permettant ainsi d'étudier la conformité du modèle.

IV.2. Développement d'outils pour l'identification des variables

La sélection « manuelle » des variables par les experts est souvent une tâche compliquée qui requiert leur disponibilité constante et une connaissance profonde du procédé, particulièrement si le nombre de variables à identifier est relativement important. La figure II.10 (cf. section II.4 page 48) propose une méthodologie en quatre étapes permettant d'appréhender de manière progressive le procédé semi-conducteur réel. À présent, nous allons décrire les principaux résultats industriels en termes d'outils développés pour les deux phases d'identification (sous-étape 3) et de classification (sous-étape 5) des

variables du modèle. Ces outils se définissent comme étant un support complémentaire à la modélisation de l'*EHF* et fournissent une sélection de variables pertinentes pour l'apprentissage et l'inférence du réseau Bayésien. Rappelons que l'*EHF* est un modèle cause-effet, il comporte ainsi deux catégories principales de variables : les causes de défaillances et les modes de défaillances.

Afin d'alimenter le modèle *EHF*, nous avons proposé dans le cadre du projet *IMPROVE* deux outils d'identification et de classification automatique des variables. En étroite collaboration avec nos partenaires industriels : *Probayes*, *STMicroelectronics* et *Lfoundry*, des études de terrain ont été menés sur des données historiques, elles nous ont permis d'effectuer les simulations nécessaires pour tester notre méthodologie et pour vérifier la conformité des configurations proposées. Avant d'analyser les résultats obtenus, nous présentons brièvement dans ce qui suit l'outil logiciel choisi pour effectuer les simulations et la description des données utilisées dans cette étude.

IV.2.1. Outil de simulation

Pour la création, l'inférence et l'apprentissage des modèles graphiques probabilistes par réseaux Bayésiens, nous avons privilégié l'utilisation de la bibliothèque open-source *BNT* (*Bayes Net Toolbox*) de *Matlab*© (Murphy, 2001). Au delà de sa documentation très riche, *BNT* met à disposition et propose :

- d'intégrer des variables de type discret ou gaussien,
- de manipuler des modèles graphiques étendus : diagrammes d'influence *ID*, modèles de Markov cachés *HMM* et réseaux Bayésiens dynamiques *RBD*,
- d'apprendre des paramètres à partir de données complètes ou incomplètes grâce aux algorithmes *MV* et *EM*, Maximum de Vraisemblance Expectation-Maximisation respectivement,
- d'effectuer l'inférence exacte ou approchée grâce aux algorithmes d'élimination de variables, d'arbre de jonction et de Message-passing.

En outre, le besoin d'exploiter les sorties de *BNT* pour concevoir des interfaces graphiques nous a mené naturellement à utiliser le logiciel *Matlab*©. En effet, ce dernier propose une fonctionnalité de modélisation appelée *GUI* (*Graphical User Interface*) qui va nous permettre de centraliser et d'organiser nos différents résultats sous forme d'une interface homme-machine facilitant ainsi l'utilisation et la compréhension des modèles par les spécialistes du semi-conducteur.

IV.2.2. Description de la table « vie de l'équipement »

Le traitement de données est une étape clef pour l'élaboration d'un indicateur de santé. Suite aux études de terrain menées avec nos partenaires, une architecture représentant les flux de données a été proposée (voir figure IV.1). En effet, un ensemble de données brutes est recueilli à partir d'une ligne de fabrication, ces données sont acquises dans différentes bases (données procédé, paramètres équipement, informations maintenance, mesures produit...). Par la suite, une phase de prétraitement sur ces bases permet d'identifier les types d'événements à prendre en compte avant d'entreprendre la modélisation mathématique (identification de variables, apprentissage et inférence de l'*EHF*). Tout d'abord, nous nous intéressons à la transition entre bases de données et outils d'identification de variables. Cette transition est assurée par des modules d'extraction dédiés (requêtes en *Structured Query Language SQL*).




Figure IV.1. Architecture des flux de données.

Les trois principales familles d'événements identifiés sont :

- les événements de *process* observés sur les produits (opérations, métrologie...),
- les événements de défaillance (*failure*) survenus lors du cycle de production,
- les événements de maintenance sur les équipements.

Pour chaque catégorie, un fichier d'événement est généré séparément, et sur la base de ces trois fichiers, la table de vie est consolidée pour retracer une seule histoire de tous les événements et par équipement. Cette table est considérée comme étant une nouvelle base de données alignant des informations pertinentes sous un format ordonné et synchronisé. Un extrait de sa structure générique est montré dans le tableau IV.1 :

Evénements process							Evénements défaillance							Evénements maintenance						
Equipment ID	Process N°1	Produit ID	Date début	Date fin	Paramètre N°1	...	Module ID	Défaillance N°1	Date début	Date fin	Effets	Variable N°1	...	Equipment ID	Maintenance N°1	Date début	Date fin	Type d'action	...	...

Table IV.1. *Format générique d'une table de vie de l'équipement.*

Les événements *process* enregistrent l'identifiant de l'équipement ou du sous équipement, l'opération effectuée (recette), l'identifiant du wafer et du lot, l'heure de début de chaque opération (par exemple : le démarrage du dépôt de gaz), les paramètres mesurés lors des opérations... Pour les événements de défaillance, les colonnes renseignent le type des défaillances enregistrées, la chronologie associée à chaque événement, l'identifiant du module d'équipement concerné, les caractéristiques après défaillance (effets, variables de mesure)... Quant aux événements de maintenance, les informations relevées concernent l'identifiant de l'équipement ou du module, le type de maintenance (préventive, corrective, qualification...), l'heure de début de chaque tâche de maintenance... Notons que de nouvelles colonnes peuvent être ajoutées en cas de besoin, ce qui permet d'avoir un certain niveau de flexibilité lors de la construction de la table de vie de l'équipement. Ceci permet également de considérer cette table comme une plateforme d'échange entre les académiques et les experts métiers : des requêtes de données peuvent être demandées, les natures de variables peuvent être spécifiées, des règles de format peuvent être exigées (format des dates, format des nombres...), des priorités d'événements peuvent être mis en place, etc.

In fine, les informations contenues dans les colonnes de cette table de vie sont exploitées par des outils d'identification de variables, ces derniers fournissent des fichiers formatés contenant une liste d'événements (variables) classés selon un ordre prédéfini (chronologique, par occurrence...). Nous introduisons dans la suite de cette partie l'outil de sélection des risques opérationnels prioritaires et l'outil de classification des causes de défaillances potentielles.

IV.2. 3. Sélection des risques opérationnels prioritaires

L'objectif de cette phase est de lister tous les risques pouvant affecter l'équipement de production. En collaboration avec *G-SCOP* et *STMicroelectronics*, la société *Probayes* a

développé un outil appelé *Complex Event Process CEP* (Bouaziz et al., 2011b). L'analyse qualitative à base de cet outil permet, dans un premier temps, d'identifier les modes de défaillance caractérisant la production des circuits intégrés pour un équipement donné. Cette étape nécessite l'utilisation des théories de la statistique. L'outil *CEP* permet entre autres de tracer l'histogramme des modes de défaillance en fusionnant et en synchronisant des données réelles de *Fab* extraites à partir de bases distinctes (procédé, maintenance, métrologie...). Ensuite, ces *FM* sont classés selon leurs effets, soit la fréquence d'occurrence ou le temps d'arrêt.

Appliqué au cas des fours de croissance thermique, le *CEP* définit les modes de défaillance et ce de manière automatique en se basant sur des règles de détection, par exemple la règle relative à la contamination des *wafers* (défectivité) est associée à une limite de nombre de particules mesurées sur toute la surface d'une plaquette de silicium. La figure IV.2, présente la forme générique des courbes données par le *CEP*. Sur l'abscisse du graphe les modes de défaillance réels sont classés suivant leur type (FM_1 , FM_2 , etc.) tandis que les coordonnées indiquent la fréquence de détection (l'occurrence) pour chaque FM_i .




Figure IV.2. Histogramme générique pour la classification des FM_i .

Du fait des bons résultats obtenus par l'outil *CEP* dans l'atelier du traitement thermique, la même procédure est en cours de déploiement dans les lignes de l'atelier de lithographie chez *STMicroelectronics* (évolution vers un nouvel outil *ProLab*). Nous invitons le lecteur à voir l'annexe E pour plus de détails et de résultats industriels.

Pour la modélisation de l'état de santé de l'équipement, chaque mode de défaillance entraîne une instance du modèle Bayésien (un *EHF* par *FM*). En conclusion, le but de

l'outil statistique *CEP* est d'identifier puis de sélectionner les modes de défaillance qui ont le plus d'impact sur la productivité (temps d'arrêt et disponibilité de l'équipement) pour les instancier dans le modèle Bayésien comme étant des effets (modèle causes-effets), de manière à permettre aux experts du semi-conducteur de mettre en place les risques opérationnels prioritaires à adresser.

IV.2.4. Classification des causes de défaillances potentielles

L'analyse des courbes de l'outil de prétraitement *CEP* permet de valider les modes de défaillances et de définir ainsi une partie de la structure graphique du modèle *EHF*. En continuité avec cet aspect d'identification automatique de variables, nous avons proposé un outil probabiliste pour la vérification et l'identification des causes de défaillance appelé *Verification and Identification Protocol VIP* (Bouaziz et al., 2012b). La figure IV.3 rappelle l'approche, en deux phases, sur laquelle est basée la classification des causes de défaillance moyennant la classe des réseaux Bayésiens naïfs hiérarchiques à classes latentes.




Figure IV.3. Approche pour la classification des causes de défaillance.

- *Causalités selon l'expert* : en se basant sur les priorités définies par la classification des modes de défaillances (sortie de l'outil *CEP*), les experts donnent leurs jugements et une liste de causalités est ainsi supposée.
- *Causalités selon le modèle* : afin de vérifier ces causalités supposées ou d'en trouver de nouvelles, l'outil *VIP* utilise le formalisme des *RB* naïfs pour classer les causes selon leur degré d'occurrence et par apprentissage automatique à partir de données historiques.

À présent, nous proposons d'appliquer le modèle naïf hiérarchique à classes latentes de la figure III.19 (page 87) sur des données issues de l'atelier de traitement thermique. Pour cela, nous avons analysé les informations *FDC* (*Fault detection and classification*) collectées sur l'équipement pendant une phase de production. Les informations mesurées (observées) sont associées aux variables $Para_i$ du modèle en question. Ces données précieuses décrivent l'évolution des températures, des pressions, des émissions optiques, etc. Pour illustrer l'apport du classifieur *VIP*, nous avons proposé de travailler sur la structure en trois niveaux de la figure IV.4.




Figure IV.4. Exemple d'un classifieur *VIP* par réseau Bayésien naïf hiérarchique.

Cette structure modulaire comporte un niveau pour les variables observées ($Para_i$) et deux niveaux pour les variables latentes (YC_j et RC). La définition des variables est donnée par le tableau IV.2 :

Nœud	Variables
$Para_1$	Règle FDC (Température en °C)
$Para_2$	Règle FDC (Pression en MTorr)
$Para_3$	Règle FDC (Débit de gaz en SLM)
YC_1 & YC_2	Classe des causes de défaillances intermédiaires
RC	Classe des causes de défaillances primaires

Table IV.2. Variables du classifieur *VIP*.

L'objectif est de découvrir des classes de causes de défaillances partageant des spécificités paramétriques proches. Le formalisme Bayésien nous aide à estimer les relations entre les paramètres mesurés ($Para_i$) et les causes de défaillance non mesurées (YC_j et RC). Par la suite, nous essayons de classer les causes de défaillance les plus courantes. Nous supposons que les nœuds de chaque niveau sont indépendants les uns des autres, toute cause

racine RC est engendrée par une ou plusieurs causes intermédiaires YC_j , les états (modalités) des variables sont constants et fixés à partir des avis des experts et que les variables du classifieur sont discrètes ou discrétisées. En fait, les trois paramètres FDC correspondent aux valeurs des capteurs du procédé et sont mesurables en continu, ils ont été discrétisés. La figure IV.5 représente l'évolution des trois paramètres FDC mesurés lors du fonctionnement du four.




Figure IV.5. Paramètres FDC d'un four LPCVD.

L'aspect quantitatif de ce modèle consiste en deux étapes. Étant donné que la structure du classifieur est fixée au préalable par l'expert, la première étape concerne l'estimation des tables de probabilités conditionnelles pour toutes les variables aléatoires du modèle. L'autre étape concerne l'inférence pour présenter les différentes distributions de probabilité. Nous présentons dans cette section les résultats préliminaires de l'application de ces deux étapes sur des données générées à partir d'une acquisition effectuée sur des équipements exploités sous les mêmes conditions de production. Les observations ont été découpées en deux parties, une partie pour l'apprentissage (environ les deux tiers) et une partie pour l'inférence. Pour la création et la simulation du réseau Bayésien naïf, nous avons utilisé la bibliothèque *BNT* de *Matlab*®.

L'apprentissage probabiliste est réalisée par l'algorithme *EM* (*Expectation-Maximization*) en présence de données incomplètes et des variables latentes. Il s'agit d'une classification non supervisée, les valeurs des feuilles $Para_i$ sont observées alors que les données n'incluent pas les valeurs des variables YC_j et RC recherchées. Pour l'initialisation de l'algorithme, des distributions associées aux variables non mesurées sont obtenues par une prise en compte des connaissances des experts.

Après cette étape d'apprentissage, nous identifions les classes recherchées (RC) à l'aide du calcul des probabilités de chaque nœud compte tenu des évidences des autres nœuds. La probabilité conditionnelle des causes de défaillance peut être déduite par inférence en utilisant l'algorithme *JT* (*Junction Tree*). En effet, la probabilité a priori de la classe

représentative des défaillances primaires nous donne la distribution suivante : $P(RC_1) = 0.55$, $P(RC_2) = 0.10$ et $P(RC_3) = 0.35$. À l'aide de l'inférence, une fois de plus, nous avons pu construire les matrices de confusion pour la classe des causes de défaillances primaires RC et suivre l'évolution de la classification pour différents intervalles de test ($T_1, T_2, \dots$). La figure IV.6 représente cette évolution, l'information que nous pouvons tirer est la constance de la distribution a priori $P(RC)$ au cours du temps. En effet, deux des trois causes de défaillances sont occurrentes.




Figure IV.6. Évolution de la classification des RC .

Ensuite, une analyse approfondie avec les experts nous a permis de trouver la correspondance entre les distributions de probabilité et les causes réelles, compte tenu du fait que les classes ne sont pas connues au départ. Les variables mises en avant sont résumées dans le tableau IV.3.

Classe	Cause de défaillance
RC_1	Dérive du corps de chauffe (Heater)
RC_2	Usure dans le tube (Flaking quartz)
RC_3	Dérive du contrôleur de pompe

Table IV.3. Causes de défaillances identifiées.

Rappelons que l'objectif de l'outil *VIP* est de classer les causes réelles (supposées par les experts) à partir des paramètres qui les décrivent, les causes les plus occurrentes seront validées et instanciées dans la structure finale du modèle *EHF* qui permet quant à lui de prédire l'évolution de l'état de santé d'un équipement de production.

Il est à souligner que cette sous-étape, qui fait partie de la méthodologie proposée pour le développement de l'*EHF*, présente de nombreux avantages. En effet, l'outil tel qu'il est

présenté offre une alternative à la définition des variables exclusivement à partir des avis d'experts. Dans l'industrie du semi-conducteur, la sélection automatique des variables est une activité essentielle dans un contexte où des millions de données sont à analyser. De surcroît, le découplage de cette activité de sélection de variable avec la modélisation probabiliste de l'*EHF* permet de réduire la complexité liée au nombre important de nœuds dans une structure graphique.

En tenant compte des résultats des outils d'identification de variables, la partie suivante s'attache à présenter l'étape de construction d'un indicateur *EHF* à partir d'un cas d'étude industriel et ce pour deux configurations différentes du modèle.

IV.3. Simulation de l'indicateur de santé EHF : étude de cas

Dans cette partie, nous avons souhaité présenter les résultats de simulation pour deux configurations parmi celles proposées pour la modélisation de l'*EHF*, l'*EHF* par mode de défaillance pour le cas statique et l'*EHF* à partir d'un réseau Bayésien temporel pour le cas dynamique. Pour cela, nous avons choisi de travailler sur un cas d'étude issu de l'industrie de la microélectronique (Guide-LPCVD, 2003). Nous organisons, par conséquent, cette partie comme suit : dans un premier temps nous allons nous intéresser à la présentation du cas d'étude sur lequel nous allons évaluer réellement notre approche de pronostic. Ensuite, nous présentons successivement l'apprentissage paramétrique du modèle EHF statique puis dynamique. Enfin, le dernier paragraphe sera dédié à la discussion des résultats obtenus jusqu'à présent.

IV.3.1. Présentation du cas d'étude

L'étude de cas est menée sur des fours *LPCVD*¹ (cf. annexe C). Ces fours sont portés à très haute température. Des gaz spécifiques sont injectés à basse pression, et par réactions chimiques avec les substrats de nouveaux matériaux se composent. À cause des nombreux arrêts enregistrés, des chutes de rendement et de la variabilité associée, cette catégorie d'équipement de production est jugée critique par les industriels du semi-conducteur et partenaires du projet *IMPROVE*. Afin d'assurer d'une part la confidentialité du procédé fonctionnant en salle blanche, nous ne présentons que les caractéristiques essentielles de ce four thermique. D'autre part, et par un souci de clarté, nous allons nous focaliser sur la

¹ *Low Pressure Chemical Vapor Deposition*: est une technique dans laquelle un ou plusieurs réacteurs de gaz sont utilisées pour réaliser un isolant ou une couche conductrice sur la surface d'une plaquette.

partie opérationnelle et critique du four (le réacteur en l'occurrence) en négligeant les modules qui n'ont pas d'influence directe sur le procédé de dépôt des couches de gaz (stockage, robot de transfert...). La figure IV.7 présente le schéma de principe simplifié d'un réacteur de traitement thermique au sein d'un four de croissance *LPCVD* ainsi que les éléments essentiels qui le composent.




Figure IV.7. Schéma de principe du réacteur.

Ce réacteur² est dédié aux dépôts de couche mince de silicium poly-cristallin, de tetraethyl-oxysilane *TEOS*, ou d'oxyde-silicium. Il est constitué : 1- d'une enceinte extérieure sous la forme d'une cloche verticale, 2- d'une enceinte intérieure étanche en *quartz* (*liner*), 3- d'un support de plaquettes (*boat*) pouvant contenir jusqu'à 100 *wafers* de production. 4- d'un arbre pour le mouvement de rotation du *boat* permettant d'obtenir une très bonne uniformité des dépôts, 5- d'une porte étanche de chargement et déchargement, 6- de trois éléments chauffants (*heater*) le long de la colonne délivrant des températures très bien maîtrisées grâce à un système de régulation en zones, 7- d'une ligne d'injection de gaz par le bas ou par le haut du réacteur selon le type du procédé, 8- d'une sonde de température comportant plusieurs thermocouples, 9- d'une jauge de pression (*manometer*),

² *LPCVD poly-silicium* : pour la description technique détaillée de ce procédé, nous recommandons le site du CMI (Center of Micronanotechnology) de l'EPFL : http://cmi.epfl.ch/thinfilms/home_thinfilms.php

10- d'un dispositif de régulation de pression composé d'une vanne papillon pour le contrôle de pression et d'une pompe pour l'évacuation.

L'objectif de cette étude est de modéliser l'évolution de l'état de santé du réacteur. Cette évolution est indiquée au travers des estimations de l'occurrence d'un ou plusieurs modes de défaillance future sur un ou plusieurs éléments critiques du réacteur thermique.

IV.3.2. Simulation d'un modèle EHF statique

Nous allons à présent appliquer la démarche de modélisation par réseau Bayésien, proposée dans le chapitre III, sur le cas du réacteur *LPCVD*. Pour cela, nous avons travaillé dans un premier temps sur une configuration statique en procédant de la manière suivante :

- *Valider les variables identifiées automatiquement par les outils CEP et VIP,*
- *Définir la structure graphique du modèle EHF à partir d'avis d'experts,*
- *Déterminer les lois de probabilités pour chaque variable.*

Comme nous l'avons mentionné, il existe deux approches pour la définition des variables dans un réseau Bayésien. Soit par intervention d'experts comme c'est le cas pour le modèle *EHF* illustré auparavant, ou bien par des outils de traitement de données. Pour ce cas d'étude, nous allons nous servir des résultats de l'outil *CEP* (*Complex Event Process*) et de ceux de l'outil *VIP* (*Verification and Identification Protocol*). Expérimentés dans un atelier de traitement thermique comportant plusieurs équipements de production dont le four *LPCVD*, ces outils nous ont permis d'analyser la notion de causalité en identifiant ses deux principales composantes, les causes et les effets. Nous avons supposé comme critères de sélection d'une variable X_i instanciable pour le modèle *EHF*, la fréquence de détection (l'occurrence) et le temps d'arrêt du système. D'après les histogrammes de classification des modes de défaillance, un four de dépôt peut être soumis à une dizaine de *FM* différents. En ce qui concerne la partie réacteur, nous avons déterminé deux priorités de FM_i à adresser : la contamination d'un *wafer* par des particules (ou *defectivity*) et l'épaisseur d'un *wafer* qui ne correspond pas aux spécifications (ou *thickness*). De son côté, le classifieur *VIP* nous a permis de mettre en exergue un certain nombre de causes de défaillance récurrentes *RC*. Nous distinguons deux catégories de causes : causes physiques RCH_i et causes contextuelles RCC_j , une cause de défaillance est renseignée (influencée) par au moins un paramètre de description $Para_i$. Chaque variable du modèle possède au moins deux états (ou modalités). L'ensemble de variables identifiées est listé dans le tableau IV.4.

Nœud	Variable	{États} – [Unité]
FM_1	Contamination des wafers par des particules	{Oui ; Non} – [%]
FM_2	Épaisseur de wafer après un dépôt de gaz	{Bonne ; Mauvaise} – [$\text{\AA}$]
RCH_1	Dérive du corps de chauffe (Heater)	{Observée ; Non observée}
RCH_2	Usure dans le tube (Flaking quartz)	{Observée ; Non observée}
RCH_3	Dérive du contrôleur de pompe (Draining)	{Observée ; Non observée}
RCH_4	Dérive injecteur de gaz (Injectors)	{Observée ; Non observée}
RCH_5	Rotation du support de chargement (Boat)	{Bonne ; Mauvaise}
RCC_5	Plaquette supplémentaire (Dummies)	{Bonne ; Mauvaise}
$Para_{1,2,3}$	Règle FDC : Températures chambre	{Bonne ; Dégradée ; Mauvaise} – [$^{\circ}\text{C}$]
$Para_4$	Règle FDC : Pression chambre	{Normale ; Anormale} – [MTorr]
$Para_{5,6}$	Règle FDC : Débits de gaz haut et bas	{Bon ; Mauvais} – [SLm]
$Para_7$	Règle FDC : Débit de gaz évacué	{Bon ; Mauvais} – [SLm]
$Para_8$	Cumule du quartz (compteur)	{Bon ; Mauvais} – [Angström]
$Para_9$	Niveau d'alarme équipement	{Bon ; Mauvais} – [Run]
$Para_{10}$	Vitesse de rotation	{Bonne ; Mauvaise} – [tr/min]

Table IV.4. Variables identifiées pour le modèle EHF.

Chaque variable correspond à un nœud dans le modèle de connaissance statique Bayésien. In fine, nous retenons deux nœuds pour les modes de défaillance, six nœuds pour les causes de défaillance potentielles et dix nœuds pour les paramètres de description. Nous supposons que les variables identifiées sont discrètes. Pour le cas de variables continues, nous procédons par discrétisation. La majorité des outils et des logiciels manipulant des *RB* offrent plus de choix algorithmiques pour le cas discret. Il convient de souligner l'aspect limitant de la discrétisation, en effet une bonne discrétisation (fine) implique une grande taille des tables de probabilités et par conséquent un temps de calcul plus important.

La deuxième étape consiste à définir les liens de causalité entre les variables identifiées. Cette tâche est réalisée exclusivement à partir des jugements d'experts. Tout d'abord, nous avons défini des groupes de famille de variables réparties en trois niveaux, ils possèdent chacun les mêmes caractéristiques. Ensuite, nous joignons chaque nœud à sa famille correspondante. Nous supposons l'absence de liens entre les nœuds de la même famille. Enfin, nous traçons les liens entre les variables du modèle. La structure résultante est donnée par la figure IV.8.




Figure IV.8. Structure du modèle EHF à partir d'un RB statique.

L'étape d'apprentissage paramétrique achève l'aspect quantitatif de la modélisation Bayésienne. Elle consiste à évaluer les tables de probabilités marginales et les tables de probabilités conditionnelles associées aux différents nœuds de la structure graphique. Pour la création et la simulation du réseau Bayésien, nous avons utilisé la bibliothèque *BNT* de *Matlab*©. Étant donné que les variables sont observables, l'apprentissage est effectué à partir de données et par l'algorithme de maximum de vraisemblance *MV*. Il s'agit d'une estimation statistique des probabilités d'un événement à partir de son occurrence dans le jeu de données. L'usage de cet algorithme pour l'estimation de probabilités est donné dans la section III.3. Toutefois, nous pouvons résumer les étapes de simulation comme suit :

- fusionner les données *process*, *failure* et *maintenance*,
- préparer les données d'apprentissage et les données de test,
- définir le réseau à étudier (variables et causalités),
- lancer l'algorithme d'apprentissage paramétrique,
- calculer les lois de probabilité pour chaque nœud.

A partir de la table de vie de l'équipement (*equipment life cycle*), nous avons généré plusieurs observations pour pouvoir simuler notre modèle EHF. Par la suite, nous avons utilisé un code sous *Matlab*© (voir figure IV.9) pour importer puis séparer les données d'apprentissage et les données de test (nécessaires pour la validation). Le programme édité sous *Matlab* permet entre autres d'étiqueter les variables, d'afficher la structure du modèle et de réaliser l'apprentissage paramétrique afin d'associer à chaque nœud sa table de probabilités marginales ou conditionnelles correspondante. Nous affichons sur la figure IV.10, la représentation graphique du modèle EHF obtenue par simulation.

```

C:\Simulation\Exercices\Equipment Health Factor.m*
4
5      % Chargement d'une base de données
6      clear all;
7      load C:\Simulation\Exercices\BD\equipementlife.data
8      equipementlife=equipementlife(:,1:18);
9
10     % Préparer les données d'apprentissage et les données de test
11     equipementlife=round(equipementlife);
12     [M,L]=size(equipementlife);
13     lengthApp=M*0.7;
14     lengthTest=M-lengthApp;
15     DBApp=equipementlifeFM1(1:189,:);
16     DBTest=equipementlifeFM1(190:270,:);
17     [M0,N0]=size(equipementlife);
18     [M1,N1]=size(DBApp);
19     [M2,N2]=size(DBTest);

```

Figure IV.9. Illustration d'une partie du programme sous l'éditeur Matlab.




Figure IV.10. Structure du modèle EHF par simulation.

Le tableau IV.5 présente des exemples de tables de probabilités conditionnelles pour les variables *defectivity* (FM_1) et *Flaking quartz* (RCH_2). La variable FM_1 possède deux modalités et dépend de quatre nœuds parents discrets, sa table donne la probabilité de détecter (oui ou non) l'événement sachant l'évidence des variables RCH_1 , RCH_2 , RCH_5 et RCC_6 , les modalités de ces dernières sont représentées par l'état « 0 » pour les situations non observées et mauvaises et par l'état « 1 » pour les situations observées et bonnes. Ainsi, le nombre de cellules pour une table conditionnelle croît rapidement en fonction des modalités et des nœuds parents. Toutes les variables du modèle possèdent donc leurs propres tables de probabilités conditionnelles, à l'exception des variables $Para_i$, qui n'ont pas de nœuds parents. Sur le tableau ci-dessous, nous donnons l'exemple d'une table de probabilités marginales pour la variable température ($Para_1$).

RCH_1	RCH_2	RCH_3	RCH_4	FM_1	
				Oui	Non
0	0	0	0	.05	0.95
0	0	0	1	.15	.85
...	...	...	...	...	...
0	1	1	1	.7	.3
1	0	0	0	.25	.75
...	...	...	...	...	...
1	1	1	0	.99	.01
1	1	1	1	.99	.01

$Para_3$	RCH_2		$Para_1$		
	Observée	Non-Obs	Bonne	Dégradée	Mauvaise
0	.95	0.05			
1	.1	.9	.85	0.1	.05

Table IV.5. Loïs de probabilités pour les variables FM_1 , RCH_2 et $Para_1$.

Une fois les étapes de construction et d'apprentissage terminées, l'utilisation du modèle pour la prise de décision devient envisageable. Par exemple, nous pouvons interroger le modèle en posant les questions suivantes :

- $P(FM_i/Para_3)$: la probabilité d'avoir un mode de défaillance (contamination FM_1 ou épaisseur FM_2) sachant l'observation du paramètre de mesure température à l'intérieur de la chambre. L'indicateur de santé de l'équipement EHF est défini à partir de ce calcul de probabilités.
- $P(RCH_i/FM_1)$: de la même manière, il est possible d'interroger le modèle afin d'établir un diagnostic sachant l'observation d'un mode de défaillance. Il s'agit d'estimer la probabilité que la cause RCH_i soit à l'origine d'une contamination des plaquettes de silicium FM_1 .

Nous allons consacrer la dernière partie du manuscrit à l'exploitation du modèle EHF statique à partir de données de test. L'objectif de cette validation est de vérifier la cohérence du modèle et de mettre en avant l'aspect décisionnel du modèle à travers un certain nombre de scénarios de fonctionnement de l'équipement.

Par ailleurs et dans la perspective d'une prise de décision dynamique, nous allons nous intéresser dans le paragraphe suivant à une configuration particulière de l' EHF , c'est le modèle EHF temporel construit à partir du formalisme des réseaux Bayésiens dynamiques. Cette configuration est particulière dans le sens où elle nous permet de prédire ($P(FM(t))$), une défaillance au plus tôt afin d'envisager par exemple de maintenir l'équipement avant qu'il n'ait dérivé.

IV.3.3. Simulation de l'EHF en vue du pronostic

Pour un suivi plus pertinent et une prise de décision active, l'usage d'un modèle qui tient compte de l'aspect temporel est indispensable. Nous avons présenté dans la section III.4.3 (page 84) une structure générique, du modèle *EHF* temporel, qui montre comment modéliser une séquence temporelle pour un système donné en utilisant le formalisme des réseaux Bayésiens dynamiques à deux tranches de temps *2-TBN* (*Two-slice temporal Bayesian Network*). Afin de simuler un modèle *EHF* temporel et de mettre en avant l'apport de la prédiction pour l'aide à la décision, nous avons généralisé la méthodologie de construction d'un *RB* statique et proposé l'approche représentée dans la figure IV.11 (Bouaziz et al., 2012c). Compte tenu des limites des *RB* (explosion combinatoire, temps de calcul, problèmes logiciels, etc.), il nous semble judicieux de réaliser une étude préalable avant de nous lancer dans la modélisation. Cette étude permet de spécifier les besoins réels en salle, d'analyser les variables candidates à une modélisation temporelle et de définir entre autres les résultats attendus à l'issue de cette modélisation, c'est à la fois une justification pour le choix du *RBD* et une indication sur la valeur ajoutée de son utilisation. À la suite des trois étapes classiques de modélisation par *RB* (identification des variables, définition de la structure graphique, apprentissage et inférence), les résultats du modèle prédictif sont interprétés afin de définir/redéfinir des stratégies d'aide à la décision. Enfin, si la première analyse révèle des insuffisances, une mise à jour doit permettre d'enrichir progressivement le modèle.




Figure IV.11. *Modélisation et utilisation d'un RBD.*

Dans l'industrie du semi-conducteur, la mesure directe des particules à l'intérieur du réacteur est coûteuse et difficile à mettre en place, raison pour laquelle, la contamination est l'une des principales causes de perte de rendement (non observée à temps). Cette perte est exprimée généralement par une fréquence importante d'interventions préventives ou/et

correctives. Pour notre cas d'étude, nous nous focalisons donc sur le problème de la contamination (*defectivity*) et nous proposons de construire un *RB* dynamique pour prédire en temps voulu l'occurrence d'une dérive future. La dimension temporelle des *RBD* permet, par exemple, de caractériser la dégradation des composants, de prendre en compte l'évolution d'un paramètre mesuré, etc. Sur la base des variables identifiées pour le modèle statique (voir tableau IV.4.), nous avons pu dégager deux types d'événements utiles et susceptibles d'évoluer en fonction du temps :

- la dégradation du *quartz* de l'enceinte intérieure (*liner*) : afin d'assurer un certain degré d'uniformité dans les zones de traitement, une quantité de *quartz* est déposée sur les parois de ce tube étanche du four vertical,
- la variation de la vitesse de rotation de l'arbre (*boat*) : le mouvement de rotation permanent du support de chargement permet d'obtenir une bonne uniformité des dépôts sur les plaquettes en traitement, cette vitesse peut être ajustée.

Chacun de ces deux événements influence le mode de défaillance *defectivity*. Nous supposons qu'ils sont indépendants et nous proposons une approche modulaire (en deux sous modèles) pour le calcul de l'*EHF* du réacteur à partir des *RB* temporels. Dans le formalisme particulier des *2-TBN* (*Two-slice Temporal Bayesian Network*), il existe deux types de dépendances entre les variables. Nous distinguons les relations entre les variables à un instant t , et les relations entre les variables aux instants t et $t+1$. Ces définitions sont très utiles pour la construction du modèle *EHF*. En effet, des sous-modèles associés aux différents événements (dégradation du *quartz* et variation de vitesse) seront construits et insérés par la suite dans un modèle global.

Tout d'abord, l'usure du *quartz* dans l'enceinte (*liner*) entraîne la génération de particules à l'intérieur du réacteur. Un compteur permet d'indiquer le niveau de cumul du quartz au fil du temps. L'objectif est de prédire une dégradation future du tube EHF_{LINER} (état de santé). Ce système est un processus markovien qui peut être vu comme un réseau Bayésien dynamique. La relation entre la variable dégradation aux instants t et $t+1$ est modélisée de manière probabiliste (un arc temporel). En pratique, la probabilité d'une dégradation significative du *liner* est estimée sachant sa valeur dans le passé et l'observation sur le paramètre épaisseur cumulée du *quartz*. Le deuxième module important pour la prédiction de la *defectivity* dans le réacteur est le support de chargement des *wafers*. En effet, la variation de vitesse entraîne des particules et peut causer la contamination des plaquettes. La dérive future du support EHF_{BOAT} dépend de la vitesse actuelle, et cette dernière dépend

de sa valeur dans le passé. La dépendance entre les variables représentant la vitesse de rotation est modélisée par un arc temporel. Ainsi, la table de probabilités pour la variable vitesse à l'instant $t+1$ est fonction de sa table de probabilités à l'instant t .

Nous introduisons maintenant la mise en œuvre du modèle EHF pour l'ensemble du réacteur. À l'instant t , la décision sur la stratégie de maintenance à planifier est le résultat de la fusion des deux indices calculés par les sous-modèles EHF_{LINER} et EHF_{BOAT} . La structure du modèle EHF global est donnée par la figure IV.12, où l' EHF du réacteur est estimé à partir de la somme pondérée des $EHFs$ du tube et celui du support de chargement. Les pondérations W_B et W_L sont associées à ces deux modules respectivement et elles sont données par l'expert.




Figure IV.12. Structure du modèle EHF à partir d'un RB dynamique.

Pour l'estimation des probabilités de ce réseau Bayésien, nous avons généré une base de données discrète avec des incertitudes (des données incomplètes), l'apprentissage est donc effectué par l'algorithme itératif *Expectation Maximisation EM* (Dempster et al., 1977). Le tableau IV.6 récapitule les étapes essentielles effectuées par cet algorithme.

N°	Étape
1	Initialiser les paramètres : $\theta^{(0)}$
2	Les paramètres du réseau à l'itération (t) sont : $\theta^{(t)} = \theta_{i,j,k}^{(t)}$
3	Évaluer l'espérance (E) : $P(X_{expected} / X_{measured})$
4	Estimer le maximum de vraisemblance (M) : $P(X_i = x_i / parents(X_i) = X_j) = \theta_{i,j,i}^{(t+1)} = \frac{N_{i,j,i}}{\sum_i N_{i,j,i}}$
5	Répéter ces deux étapes (EM) jusqu'à atteindre la valeur optimale de la fonction auxiliaire évaluée à l'étape (E).
6	Fin

Table IV.6. Algorithme EM pour l'apprentissage paramétrique.

Une fois l'aspect quantitatif évalué, nous proposons de calculer les probabilités des variables en utilisant des algorithmes d'inférence exacte. Nous avons étudié le problème de l'inférence via l'algorithme de l'arbre de jonction *JT* (Jensen, 1996). Le principe de cet algorithme (tableau IV.7) est similaire à celui de *Baum-Welch* utilisé dans les *HMMs*.

N°	Étape
1	Transformation du graphe : Construire un arbre de jonction à partir du graphe original acyclique et dirigé.
2	Moralisation de l'arbre : Relier les nœuds parents entre eux si elles ont des enfants communs.
3	Triangulation de l'arbre : Ajouter des arcs pour obtenir un graphe triangulé à partir d'un graphe non dirigé.
4	Obtention de l'arbre de jonction : Identifier les cliques, puis les connecter pour construire un arbre.
5	Fin

Table IV.7. Algorithme *JT* pour l'inférence exacte.

Afin de suivre dynamiquement l'évolution de l'état de santé du réacteur, nous avons interrogé le modèle par simulation à partir de données générées. La prédiction est présentée par un calcul de probabilité. Si la probabilité estimée est élevée, le risque de dérive est élevé. L'évolution temporelle correspond aux *runs* (i.e. nombre des étapes cumulés), comme le montre le tableau IV.8.

Temps	P(Def) : $EHF_{LINER} * W_L$	P(Def) : $EHF_{BOAT} * W_B$	$EHF_{equipment}$
Run₁	0.005	0.003	0.003
Run₂₀	0.011	0.008	0.007
Run₃₅	0.015	0.015	0.013
Run₅₀	0.039	0.050	0.036
Run₁₀₀	0.090	0.250	0.100
Run₁₅₀	0.160	0.275	0.168
Run₂₀₀	0.230	0.315	0.215
Run₃₀₀	0.455	0.490	0.404
Run₄₀₀	0.555	0.500	0.463
Run₅₀₀	0.610	0.530	0.510

Table IV.8. Résultats de prédiction.

Après un certain nombre de runs, nous remarquons que la probabilité d'avoir une contamination dans le réacteur atteint des niveaux significatifs. Aussi, l'opérateur est invité à lancer une action préventive sur l'équipement pour réduire les niveaux de risque.

IV.3.4. Propriétés et retour d'expérience

Les algorithmes testés à ce jour sur les différentes instances du modèle *EHF*, ont tous convergés. Ceci est dû à la nature même des *RB*. En effet, quelles que soient les dépendances stochastiques entre variables, il existe toujours une représentation des lois conjointes des variables aléatoires. Cette propriété garantit l'absence de boucles dans le modèle et assure par conséquent la convergence des algorithmes de calcul. Quant à la complexité algorithmique, cette notion est liée étroitement au problème d'explosion combinatoire. Le temps de calcul en pratique sera fonction du nombre de probabilités à calculer. Nous avons montré que ce nombre dépend du nombre des états et des parents de la variable en question. Pour les configurations du modèle *EHF* présentées auparavant, les simulations avec l'outil *Matlab*© s'exécutent en quelques secondes (avec une fréquence processeur 2,40GHz, mémoire RAM 3,45Go). Toutefois, de par la possibilité de décomposer la structure du modèle en modules, le nombre d'opérations peut être réduit.

La démarche progressive menée sur le cas d'étude du four *LPCVD* a montré la possibilité de travailler sur un modèle simple et de l'enrichir au fur et à mesure. L'analyse du contexte de production nous a permis de constater une forte expertise sur le procédé réel. Les architectures des modèles proposés sont caractérisées par leur simplicité apparente résultant d'une analyse fine des données. Ces modèles sont instanciables et peuvent être appliqués sur d'autres sites. Notons aussi l'importance d'avoir des informations en quantité et en qualité suffisante pour l'élaboration du modèle *EHF*. Cette notion influence directement la pertinence d'un modèle guidé par les données. De ce fait et dans le cadre d'une future industrialisation, nous préconisons d'étudier la qualité des données avant d'entamer toutes démarches de modélisation. De même, la sollicitation des experts est fortement recommandée lors de la construction des modèles.

Le modèle *EHF* temporel est basé à ce jour sur une dizaine de variables significatives, il est simulé sur des données générées. Son aspect prédictif permet de représenter l'évolution de l'équipement d'un mode de fonctionnement normal vers un mode de fonctionnement anormal. Afin d'évaluer les performances algorithmiques pour ce type de modèle, le taux de reconnaissance des défaillances doit être calculé, c'est-à-dire, le rapport entre le nombre de défaillances estimées et le nombre de défaillances mesurées réellement.

Après avoir présenté comment construire un modèle par *RB* et comment effectuer l'apprentissage des paramètres, nous passons dans ce qui suit à l'étape de validation. Pour cela, nous considérons la structure du modèle *EHF* de la figure IV.10, page 107.

IV.4. Scénarios de validation pour la prise de décision

Dans cette dernière partie du manuscrit, nous nous proposons d'effectuer des inférences probabilistes permettant de valider en hors ligne et par simulation notre approche de calcul de l'*EHF*. Les tests sont basés sur trois scénarios de fonctionnement, ces scénarios représentent les principales situations dans lesquelles un équipement de production en salle blanche peut se retrouver : le cas d'un fonctionnement normal sans défaillance, le cas d'un fonctionnement dégradé suite à une défaillance sur un élément redondant et en dernier lieu le cas d'un dysfonctionnement causé par la panne d'un élément critique. Pour ces trois situations, nous nous attendons à ce que le modèle *EHF* indique une bonne estimation de probabilité en fonction des observations (évidences) que nous fixons en entrée, l'estimation de l'*EHF* constitue un élément clé pour l'aide à la décision.

Afin de mettre en valeur les apports de notre approche, nous montrons également comment exploiter les résultats de l'indicateur *EHF* pour la prise de décision concernant la planification des interventions de maintenance.

IV.4.1. Validation en mode normal

L'objectif de l'étape de validation est de vérifier la conformité du modèle Bayésien appris avec les conditions réelles en salle blanche. Tout d'abord, nous allons interroger le modèle *EHF* de la figure IV.10 dans une situation de fonctionnement normal sans défaillance. En fonction de l'état des nœuds observés, nous analysons la probabilité a posteriori des deux modes de défaillance *defectivity* et *thickness*. Rappelons que nous nous focalisons sur le cas où l'évolution de l'état de santé de l'équipement est calculée par la probabilité de détecter un mode de défaillance donné.

$$EHF_{-eqp} = P(FM_i / Observations)$$

Pour notre cas d'étude, un mode de fonctionnement normal (absence de défaillance) est caractérisé par de bonnes observations des variables mesurées. Cela peut se traduire sur le terrain par des mesures, à partir des paramètres équipement, qui indiquent une bonne température dans les trois zones de l'enceinte en quartz (*Para₁*, *Para₂* et *Para₃*), la pression indiquée par le manomètre est normale (*Para₅*), les débits de gaz mesurés sur les deux injecteurs (haut et bas) et le dispositif d'évacuation sont tous dans les spécifications attendues (*Para₅*, *Para₆* et *Para₇*), le compteur de cumul du quartz n'a pas encore atteint

sa valeur critique ($Para_8$), le niveau d'alarme sur les plaquettes fictives n'est pas mauvais ($Para_9$) et enfin la vitesse de rotation du *boat* est bonne.

Pour cette phase de validation, nous avons utilisé la partie des données destinée au test, et non utilisée pendant l'apprentissage du modèle. Par la suite, nous avons supposé que les paramètres sont mesurés. En fonction des observations réalisées sur ces paramètres de description, la figure IV.13 affiche les différentes distributions des probabilités inférées pour les causes de défaillance $P(RC_i/Para_j)$ et pour les modes de défaillance $P(FM_i/Para_j)$. L'EHF de l'équipement est dans ses meilleures conditions et affiche un niveau « bon » à chaque fois.




Figure IV.13. Probabilités inférées pour le scénario 1.

En outre, nous disposons dans la base des données de test, des observations réelles sur les variables RC_i et FM_i . Ce qui nous a permis de calculer les probabilités conditionnelles réelles de ces variables en fonction des $Para_j$. Nous avons pu comparer par la suite les probabilités inférées des variables RC_i et FM_i avec leurs probabilités conditionnelles réelles. Les premiers résultats de la comparaison sont prometteurs, étant donné que l'estimation (ou la prédiction) de probabilité donné par la simulation est très proche de ce que les données de test ont révélé réellement.

IV.4.2. Validation en mode dégradé

Pour ce deuxième scénario, nous allons simuler une dérive d'un composant du réacteur pendant une opération de préparation du four (ou qualification) avant le chargement des lots par le *boat*. Il s'agit d'une dégradation au niveau du corps de chauffe. Nous considérons que le dispositif de chauffage comporte un système de régulation permettant de réagir en cas de problème. En effet, les résistances sont placées autour de la paroi du tube vertical. Si l'une tombe en panne avec des lots chargés, la température délivrée par l'ensemble du dispositif augmente légèrement afin d'assurer l'uniformité nécessaire à l'intérieur de l'enceinte en *quartz*. Par conséquent, la panne d'un élément redondant au sein du réacteur n'implique pas forcément l'arrêt d'urgence (instantané) de l'équipement, l'activité de production continue normalement avec basculement en mode de fonctionnement dégradé. Il est donc possible de faire fonctionner le réacteur en mode dégradé, au prix d'une baisse de performance. À titre indicatif, la valeur de l'*EHF* pour ce cas de figure doit afficher un niveau « moyen » traduisant le fait que l'équipement n'est pas dans ses meilleures conditions mais peut assurer sa mission.




Figure IV.14. Probabilités inférées pour le scénario 2.

Pour simuler ce scénario de fonctionnement, nous avons donc suivi la même démarche appliquée dans le cas précédent (mode normal). La figure IV.14 montre les distributions des probabilités inférées pour RCH_1 , FM_1 et FM_2 en fonction des états que peuvent prendre les variables de mesure des températures $Para_1$, $Para_2$ et $Para_3$ (bonne, dégradée et mauvaise respectivement). En comparant ces calculs avec les résultats réels estimés à partir de la base de données de test, les quantifications des FM_1 et FM_2 sont en général dans les bonnes spécifications. À travers ces interrogations, l'approche basée sur les réseaux Bayésiens permet donc d'effectuer un diagnostic sur le réacteur. En effet, si nous examinons l'évolution des probabilités a posteriori du nœud RCH_1 (deuxième ligne de la figure IV.14), nous pouvons envisager de maintenir la partie défaillante de l'élément de chauffage concerné.

IV.4.3. Validation en mode dysfonctionnement

Le troisième scénario de validation a pour objectif d'illustrer la prise en compte d'une défaillance critique au sein du réacteur de dépôt thermique. Il s'agit d'un niveau limite de vieillissement du *quartz* et d'un mauvais ajustement d'un paramètre de vitesse. Nous considérons que les autres fonctionnalités sont garanties (haute température, basse pression et bons débits de gaz). Ce scénario consiste donc à simuler non seulement l'usure du tube étanche (*flaking quartz*) mais également la dérive de rotation du *boat*. Si le modèle fonctionne conformément à ce qui est attendu, il devrait cette fois afficher un niveau rouge « mauvais » pour l'état de santé du réacteur. Pour interroger le modèle construit à partir des données de test, nous rendons les états des paramètres 8 et 10 tous les deux mauvais. L'analyse des différentes probabilités a posteriori $P(X_i/Para_8 \text{ et } Para_{10})$ permet de localiser les causes les plus probables et d'évaluer l'occurrence des deux modes de défaillance en question, nous les affichons dans la figure IV.15.

Pour résumer, le modèle issu du formalisme Bayésien permet de qualifier les RC_i puis propage l'information vers les autres nœuds du réseau. Autrement dit, selon les observations sur les paramètres de mesures, le modèle permet de repérer les causes de défaillance et ensuite prédire les modes de défaillance. Là encore, les résultats donnés par le moteur d'inférence sont satisfaisants et le modèle par réseau Bayésien accomplit l'objectif attendu, à savoir l'évaluation de l'état de santé du réacteur en estimant les probabilités d'occurrence des modes de défaillance.




Figure IV.15. Probabilités inférées pour le scénario 3.

IV.4.4. Exploitation des résultats pour la prise de décision

Pour supporter les résultats méthodologiques ainsi que ceux de la modélisation, nous avons développé un outil de simulation pour le test et la validation des différentes instances du modèle *EHF*. Nous avons pour cela utilisé la *Graphical User Interface (GUI)* du logiciel *Matlab*© (cf. figure IV.16).




Figure IV.16. Interface utilisateur graphique.

Si nous considérons les résultats de prédiction du modèle *EHF* par réseau Bayésien d'un point de vue décisionnel, nous constatons qu'ils permettent de représenter l'évolution du système entre deux modes de fonctionnement : normal et anormal. Afin d'élargir l'utilisation de ce modèle (planification, analyse et évaluation), il est nécessaire d'utiliser une représentation pour l'analyse de fiabilité (Zio, 2009). Pour notre étude, nous proposons l'utilisation des réseaux de Petri (*RdP*) pour analyser et évaluer le comportement des équipements de production et apporter de la pertinence à la prise de décision. Les réseaux de Petri sont un outil mathématique capable de décrire des activités, des ressources et des états d'un système dynamiques, ils sont largement utilisés à cause de leur aspect graphique, leur facilité de simulation et de leurs extensions possibles (David et Alla, 1992). Un masque de *RdP* est une sous-partie d'un réseau de grande taille. Nous utilisons ici un masque de *RdP* pour caractériser les états du système (équipement de production dans l'industrie semi-conducteur) à partir des estimations de l'*EHF* (Bouaziz et al., 2012a).

Pour un système donné, le nombre de modes de fonctionnement (états) dépend du niveau de complexité du système. En se basant sur une analyse des modes de marches et d'arrêts, (Mendez-Azua et al., 2005) ont proposé un ensemble d'activités de référence pour les systèmes à événements discrets *SED*. Nous avons retenu huit modes de fonctionnement pour cette étude (figure IV.17), ils représentent les états d'un équipement de production.




Figure IV.17. Modes de marche et d'arrêt de l'équipement.

Ces modes sont les états du *RdP* et les transitions entre ces états sont calculées par le modèle *EHF* Bayésien. Nous considérons trois classes de probabilité de l'*EHF* : bonne *G* (vert), moyenne *O* (orange) et mauvaise *R* (rouge). Quant à l'état réel de l'équipement, il est défini par le marquage des places. La figure IV.18 montre le modèle de suivi résultant.




Figure IV.18. *RdP pour le suivi de l'équipement en intégrant les indications de l'EHF.*

Compte tenu des résultats des deux analyses de performance (*RB* et *RdP*), les priorités sur la maintenance prédictive *PdM* peuvent être définies et des activités de maintenance préventive vont être redéfinies afin d'améliorer la disponibilité de l'équipement de production ainsi que sa fiabilité.

IV.5. Conclusion

Dans ce chapitre, nous avons testé notre approche de modélisation sur une application issue de l'industrie du semi-conducteur. Il s'agit notamment de prouver les capacités du modèle de calcul de l'état de santé d'un équipement. Dans un premier temps, nous avons pu apprécier l'apport des outils de sélection de variables *CEP* (*Complex Event Process*) et *VIP* (*Verification and Identification Protocol*) à la construction d'un modèle avec un nombre de nœuds réduit. Il convient de souligner en particulier le caractère important de l'outil *VIP* malgré le fait qu'il soit testé sur des données simulées. Dès lors, nous avons décrit deux voies pour définir les variables du modèle *EHF*, soit des variables identifiées manuellement (spécifications au départ du projet) ou bien de manière automatique. La deuxième voie nous semble la mieux adaptée au contexte de fabrication en semi-conducteur. Pour des futures études d'intégration, nous suggérons l'utilisation d'une des

extensions proposées à partir du modèle naïf (temporel ou optimal) associée à une étude de performance des résultats obtenus. Néanmoins, cette modélisation implique une redondance au niveau de l'apprentissage paramétrique et par conséquent au niveau du temps de calcul. Les tables de probabilités associées aux nœuds sélectionnés sont apprises à deux reprises, lors de leur identification par le modèle de classification puis lors de leur instanciation dans le modèle de prédiction. Ce problème peut être évité en fusionnant la phase de classification des causalités avec la phase de prédiction des modes de défaillance.

Nous avons proposé par la suite un cas d'étude basé sur l'exploitation des réseaux Bayésiens. La modélisation issue du formalisme Bayésien présente de nombreux intérêts dans ce domaine où d'une part les données sont souvent incomplètes, censurées ou encore non représentatives et où d'autre part la connaissance humaine est fortement mise en avant. L'élaboration des algorithmes et le développement des outils ont été mis en œuvre grâce à la bibliothèque *BNT de Matlab*©.

Enfin, trois scénarios de validation du modèle ont été proposés. Comme nous avons pu le constater, ces scénarios, nous ont permis de vérifier la conformité du modèle *EHF* construit à partir des données. En support des résultats de modélisation, un outil de simulation et de test a été développé. Il permet à la fois de centraliser les différents modèles et résultats développés ainsi que de suivre l'évolution de l'occurrence des causes de défaillances pour un équipement donné, pour un parc d'équipements similaires ou pour les différentes fonctionnalités des équipements de production. Ces résultats sont des éléments d'aide à la décision pour l'optimisation des interventions de maintenance et l'amélioration de la disponibilité des équipements.

Conclusion générale

Les travaux que nous avons présentés dans ce document traitent de l'estimation de l'état de santé des équipements de production dans le contexte des ateliers semi-conducteurs. Ils prennent place au sein du projet Européen *IMPROVE* et ont été développés en collaboration étroite avec nos partenaires industriels *STMicroelectronics*, *Probayes* et *LFoundry*.

Ils font suite à ceux déjà réalisés par (Deschamps, 2007) et (Mili, 2009) dans ce domaine au sein des équipes Gestion et Conduite des Systèmes de Production (*GCSP*) et Système d'Information et REPrésentation multiple du produit (*SIREP*) du Laboratoire des Sciences pour la Conception, l'Optimisation et la Production de Grenoble (*G-SCOP*).

La contribution de nos travaux est double. Elle a non seulement porté sur la proposition d'une méthodologie pour appréhender un procédé industriel complexe et également à la proposition d'un modèle (appelé *Equipment Health Factor EHF*) pour l'estimation de l'état de santé d'un équipement de production complexe.

Le formalisme de modélisation que nous avons proposé s'appuie sur une classe des modèles graphiques probabilistes à savoir les réseaux Bayésiens (*RB*), outils largement utilisés dans les domaines de la maintenance, de l'analyse de risques et de la sûreté de fonctionnement. De nombreux avantages découlent de ce formalisme pour couvrir nos besoins.

- les *RB* peuvent être utilisés pour apprendre des dépendances causales et pour modéliser les phénomènes aléatoires,

- un *RB* est une représentation graphique compacte et synthétique qui facilite l'acquisition et l'utilisation de la connaissance,
- pour l'aspect utilisation, leur flexibilité permet d'interroger le même modèle graphique pour des objectifs différents tels que la prédiction ou le diagnostic,
- pour les applications industrielles, la qualité de l'offre en matière d'algorithmes et d'outils rend les *RB* de plus en plus séduisants...

Fort d'un tel formalisme, nous avons ensuite proposé une méthodologie générique pour le développement d'un modèle *EHF*. Cette approche part d'une description détaillée du contexte de l'étude qui intègre la variété des données rendues disponibles, pour aboutir à la proposition d'un outil d'aide à la décision pour les interventions de maintenance et de métrologie. Avec le souci constant d'une intégration en ligne de la solution développée, différentes configurations ont été proposées afin de répondre aux besoins des industriels.

De ce point de vue, l'approche proposée, véritablement novatrice dans le domaine, a donné lieu à des résultats significatifs. Ils se caractérisent comme suit :

- 1) Une méthodologie progressive, complète et accompagnée permettant d'appréhender le procédé réel et de proposer des solutions adaptées.
- 2) La démarche proposée permet d'associer plusieurs sources d'informations : données historiques et connaissances humaines.
- 3) Les configurations du modèle proposées permettent de donner des réponses adaptées aux problèmes et aux principaux besoins des industriels.
- 4) Afin d'adresser les dérives majeures rencontrées dans les ateliers de production, un outil *CEP* pour l'identification des risques prioritaires est proposé.
- 5) Afin de s'affranchir du problème de la complexité lié à la taille des modèles, nous avons proposé un outil *VIP* support pour la classification des causalités pertinentes.
- 6) En présence d'un ou plusieurs modes de défaillance, le modèle *EHF* proposé permet de diagnostiquer les causes à l'origine de la dérive observée.
- 7) En évaluant les paramètres mesurés, le modèle *EHF* est capable d'estimer (dans le cas statique) la probabilité de l'occurrence d'un ou de plusieurs modes de défaillance et de prédire (dans le cas temporel) la probabilité d'une dérive future.
- 8) Un modèle graphique pour le suivi des modes de fonctionnement de l'équipement est proposé afin de mettre en perspective un outil incontournable d'aide à la prise de décision.

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 années.

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

Dans un premier temps nous envisageons une finalisation de l'interface graphique de calcul de l'*EHF* (cf. figure IV.16 page 118). Elle devra rapidement intégrer et centraliser les configurations à ce jour développées à part. Ceci pourra faire l'objet d'un développement plus fin dans le cadre d'une collaboration avec les développeurs du service informatique du laboratoire *G-SCOP* et des services d'intégration de *STMicroelectronics* et de *Probayes*.

Deuxièmement et sur la base d'un tel outil finalisé, une intégration sur site réel devra être envisagée de manière à valider in situ et donc à échelle réelle notre approche. L'approche d'intégration devra être progressive en testant tout d'abord les instances du modèle sur des modules d'équipements pour aller ensuite vers le complexe, comme par exemple les équipements de l'atelier *ETCH*, de l'atelier *CMP*, etc.

Troisièmement, nous devons envisager de lever l'hypothèse de bon fonctionnement systématique des machines de métrologie. En effet, ces dernières ne sont pas exemptes de défaillances, en particulier au niveau du système de captage. Sachant que des maintenances préventives sont régulièrement effectuées, il serait pertinent d'envisager une amélioration de notre processus d'apprentissage en ne conservant que les données de métrologies restituées dans la zone temporelle de confiance de la machine (cf. courbe de Weibull) (Corset, 2003).

Quatrièmement, il nous semble intéressant de lancer une étude comparative de l'approche que nous proposons avec d'autres centrées sur le calcul de la confiance qui peut être accordée aux informations issues des équipements de production. En effet, ce dernier type d'approche permettant d'étendre les bases de données avec un indice de confiance, cela permettrait d'apporter une information précieuse au calcul de l'*EHF*.

A moyen terme, nous pouvons mettre en évidence au moins quatre orientations de recherches possibles.


Premièrement, rappelons que notre approche est basée sur un apprentissage lié à l'historique d'un équipement. Le fait même d'introduire notre outil de calcul d'*EHF* dans l'atelier aura nécessairement pour effet de modifier la vie de ce même équipement. Le modèle initialement appris se verra donc dans le temps ne plus représenter la « nouvelle » vie de l'équipement. La problématique d'estimation de la date de « péremption » du modèle devra donc être posée et traitée. Dans cette perspective, deux voies pourront être a minima investiguées. Dans un premier temps, des mises à jour planifiées pourront être envisagées avec cependant un manque évident d'optimalité et de pertinence, comme c'est le cas dans le cadre des maintenances préventives « inutiles ». Une deuxième voie serait d'optimiser les phases de réapprentissage et donc de définir et de calculer les dates précises caractérisant la péremption du modèle d'*EHF*. Les analyses de performance du modèle Bayésien pourraient en ce sens être mises à profit.

Deuxièmement, comme nous avons pu le mentionner dans les sections III.3.4 et IV.3.4, l'apprentissage est une phase qui peut rapidement devenir lourde pour l'expert en salle blanche (définition de la structure), d'autant plus si l'équipement considéré est complexe ou pire encore si l'expert veut considérer l'*EHF* d'une ligne complète de production. Dans de telles perspectives, notre approche atteindra rapidement des limites sur le plan de l'apprentissage et de la construction du modèle. Des extensions devront dans ce cas être envisagées comme par exemple le recours aux classes de réseaux Bayésiens Hiérarchiques (Zhang, 2003) ou Orientés Objets (Weber, 2004).

Troisièmement, la discrétisation des mesures continues implique une perte d'informations. Il serait alors intéressant d'étudier les performances du modèle en présence des variables continues. Pour cela, il est envisageable d'étendre la modèle Bayésien discret vers des modèles de type Gaussien (Neil et al., 2008).

Quatrièmement, nous proposons d'étendre notre approche vers la proposition d'un mécanisme d'évaluation de l'*EHF* d'un ensemble d'équipements de production pouvant par exemple correspondre à une route prédéfinie. Ceci aurait pour principal intérêt de mettre à la disposition d'un industriel du domaine un outil amont capable de simuler puis d'évaluer telle ou telle route selon le critère *EHF*, et donc l'impact du choix d'une route sur un *EHF*. Muni d'un tel nouvel indicateur, l'approche globale de choix d'une route serait ici étendue à la prise en compte de l'*EHF*.

Sur le plan de la démarche à adopter pour cette recherche nous proposons quelques pistes que nous avons synthétisées dans le schéma ci-après. Aussi, proposons-nous dans un premier temps d'utiliser (1) les outils de simulation d'ateliers tels que : *ARENA*, *LabView*... afin de reproduire (2) un cycle de production d'un lot de *wafers*. À partir d'une telle simulation, il s'agirait ensuite d'en extraire les données correspondant à la vie des équipements considérés afin de construire (3) le modèle *EHF* que nous avons proposé dans ce mémoire. La sortie d'un tel module serait ensuite considérée pour évaluer (4) les performances de la route simulée au sein d'un diagramme d'influence ou d'un réseau de Petri : le temps de la productivité, le temps d'attente, le taux d'exploitation, les tâches de maintenance, les coûts de maintenance, etc. En fonction des performances évaluées, il s'agira de motiver ou non via une interface homme machine l'affinement de la route proposée ou bien d'en imaginer une autre.



Probabilités des RB et propriétés des RdP pour les activités PdM.

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'hospitalier, l'aéronautique, le nucléaire, l'énergie, l'automobile, etc.

A _____

- AFNOR. (2001). *NF EN 13306/X 60-319 : Terminologie de la maintenance*. Association Française de Normalisation, Paris.
- Al-Najjar, B., Alsyouf, I. (2004). Enhancing a company's profitability and competitiveness using integrated vibration-based maintenance: A case study. *European Journal of Operational Research*, 157. pp 643 – 657.
- Antonucci, A., Zaffalon, M. (2008). Decision-theoretic specification of credal networks: A unified language for uncertain modeling with sets of Bayesian networks. *International Journal of Approximate Reasoning*, vol. 49, p. 345-361.

B _____

- Bangso, O., Willemin, P.-H., (2000). *Object Oriented Bayesian Networks: A framework for topdown specification of large Bayesian networks and repetitive structures*, Technical Report CIT-87.2-00-obphw1, Department of Computer Science, University of Aalborg.
- Bansal, D., Evans, D.-J. Jones, B., (2005). Application of a real-time predictive maintenance system to a production machine system. *International Journal of Machine Tools and Manufacture*, vol. 45, n°10, pp. 1210-1221, ISSN 0890-6955.
- Bassetto, S. (2005). *Contribution à la qualification et à l'amélioration des moyens de production, de manière opérationnelle, dynamique, en supportant les connaissances métier*. Thèse de doctorat. CER ENSAM de Metz, France.
- Bayes, T. (1763). An Essay towards solving a Problem in the Doctrine of Chances. *Philosophical Transactions of the Royal Society of London*, vol. 53, pages 370-418.
- Becker, A., Naïm, P. (1999). *Les Réseaux Bayésiens : Modèles graphiques de connaissance*. Editions Eyrolles, Paris.
- Ben Salem A., Muller A., Weber P. (2006). Dynamic Bayesian Networks in system reliability analysis. 6th IFAC Symposium on Fault Detection, Supervision and Safety of technical processes, 481-486.
- Bettayeb, B. (2012). *Conception et évaluation des plans de surveillance basés sur le risque*, Thèse de doctorat, Université de Grenoble, Grenoble INP Institut Polytechnique de Grenoble, France.
- Bouaziz, M.-F., Zamaï, E., Duvivier, F., Hubac, S., (2011a). Dependability of complex semiconductor systems: Learning Bayesian Networks for decision support. 3rd International Workshop on Dependable Control of Discrete System (DCDS'11), Saarbrücken, Germany, pp 09–14.
- Bouaziz, M.-F., Zamaï, E., Monot, S., Duvivier, F., Hubac, S. (2011b). Towards Bayesian Network methodology to improve maintenance of semiconductor systems. *Proceedings of European Safety & Reliability Conference (ESREL'11)*, Bérenguer, Grall & Guedes Soares (eds) © 2012 Taylor & Francis Group, London, UK. ISBN 978-0-203-13510-5, Troyes, France, pp 116–123.
- Bouaziz, M.-F. Sahnoun, M., Zamaï, E., Hubac, S. (2012a). Decision making based on the EHF integration in a complex semiconductor manufacturing. *Proceedings of 12th*

- European Advanced Process Control and Manufacturing Conference (APCM'12), paper N°306, MINATEC Grenoble, France.
- Bouaziz, M.-F. Zamaï, E. (2012b). Réseaux Bayésiens pour la classification des causes de défaillances: Application aux systèmes à événements discrets complexes », 6èmes Journées Francophones sur les Réseaux Bayésiens (JFRB'12), îles Kerkennah, Tunisie.
- Bouaziz, M.-F., Zamaï, E. (2012c). Equipment Health Factor prediction for complex semiconductor manufacturing facility. Proceedings of 4th IFAC Symposium on Information Control Problems in Manufacturing (IFAC INCOM'12), paper N°377. DOI: 10.3182/20120523-3-RO-2023.00377, Bucharest, Romania. pp 98 – 103.
- Bouaziz, M.-F., Zamaï, E., Hubac, S. (2012d). Modélisation de l'état de santé d'un équipement de fabrication par une method probabiliste, Proceedings of 9th International Conference on Modeling, Optimization & SIMulation (MOSIM'12), paper N°141, 10p, Bordeaux, France.
- Boudali, H., Dugan, J.-B. (2005). A discrete-time Bayesian network reliability modeling and analysis framework. *Reliability Engineering and System Safety*. 87(3), 337-349.
- Bouillaut, L., Leray, P., Aknin, P., François, O., Dubois, S. (2008). Dynamic Bayesian Networks Modelling Maintenance Strategies: Prevention of Broken Rails. WCCR'08 World Congress on Railway Research, Séoul.
- Byington, C.-S., Roemer, M.-J., Kacprzyński, G.-J., Galie, T., (2002). Prognostic Enhancements to Diagnostic Systems for Improved Condition-Based Maintenance. 2002 IEEE Aerospace Conference, volume 6, pp. 2815-2824, Big Sky, USA.

C_____

- Chen, A., Blue, J., (2009). Recipe-independent Health Indicator for Tool Predictive Maintenance and Fault Diagnosis,” *IEEE Transactions on Semiconductor Manufacturing*, vol. 22, no. 4, pp. 522-535.
- Chen, P., Wu, S., Lin, J., Ko, F., Lo, H., Wang, J., et al. (2005). Virtual metrology: A solution for wafer to wafer advanced process control. In Proceedings of IEEE international symposium on semiconductor manufacturing (ISSM'05). San Jose, CA, USA. doi:10.1109/ ISSM.2005.1513322.
- Clemen, R., Reilly, T. (2001). *Making hard decisions with Decision Tools*, Edition Duxbury Thomson Learning.
- Cocheteux, P. (2010). *Contribution à la maintenance proactive par la formalisation du processus de pronostic des performances de systèmes industriels*. Thèse de doctorat, Université Henri Poincaré, Nancy I, France.
- Combacau, M., Berruet, P., Zamaï, E., Charbonnaud, P., Khatab, A. (2000). Supervision and monitoring of production systems. In Proc of MCPL, 6, Grenoble, July 5–8. N°. 00160.
- Cooper, G. (1990). Computational complexity of probabilistic inference using Bayesian belief networks. *Artificial Intelligence*, 42(2): 393–405.

Correa, M., Bielza, C., Pamies-Teixeira, J. (2009). Comparison of Bayesian networks and artificial neural networks for quality detection in a machining process. *Expert Systems with Applications*, vol. 36, n° 3, p. 7270-7279.

Corset, F. (2003). *Aide à l'optimisation de maintenance à partir de réseaux Bayésiens et fiabilité dans un contexte doublement censuré*. Doctorat de l'université Joseph Fourier Grenoble. France.

D_____

Darwiche, A. (2010). What are Bayesian networks and why are their applications growing across all fields? *Comm. ACM*, vol. 53, no. 12, 80–90.

David, P. (2009). *Contribution à l'analyse de sûreté de fonctionnement des systèmes complexes en phase de conception : application à l'évaluation des missions d'un réseau de capteurs de présence humaine*. Thèse de doctorat, université d'Orléans, France.

David, R., Alla, H. (1992). *Du Grafcet aux réseaux de Petri*. Hermès, 2ème édition revue et augmentée.

Dawid, A.-P. (1979). Conditional Independence in statistical theory. *Journal of the Royal Statistical Society*, vol. 41, pages 1-31.

Dauzere-Peres, S., Rouveyrol, J.-L., Yugma, C., Vialletelle, P. (2010). A smart sampling algorithm to minimize risk dynamically, ASMC'10 21th Annual IEEE/SEMI Advanced Semiconductor Manufacturing Conference, pp. 307-310, San Francisco, USA.

Dempster, A.-P., Laird, N.-M. Rubin, D.-B. (1977). Maximum likelihood from incomplete data via the EM algorithm. *Journal of the Royal Statistical Society*, B 39, 1–38.

Deschamps, E. (2007). *Diagnostic de services pour la reconfiguration dynamique de systèmes à événements discrets complexes*. Thèse de doctorat, Université de Grenoble, Grenoble INP Institut Polytechnique de Grenoble, France.

Deschamps, E., Zamai, E. (2007). Diagnosis for control system reconfiguration. In IFAC Conference on Management and Control Production and Logistics, MCPL'07, 377–382, Sibiu, Roumanie.

Despujols, A., (2005). Méthodes d'optimisation des stratégies de maintenance. *Techniques de l'ingénieur*, dossier MT9050.

Ditmore, D., Stewar, J., Dudley, R., Bright, N. (1989). Achieving semiconductor equipment reliability. 7th IEEE/CHNT International, IEMT Symposium: 5–7. San Francisco, CA. doi: 10.1109/EMTS.1989.68943.

Djurdjanovic, D., Liu, Y. (2006). *Survey of Predictive Maintenance Research and Industry Best Practice*, "University of Michigan, Ann Arbor.

D.O.D (Department of Defense). (1980). *Military standard: Procedures for performing a failure mode and effects and criticality analysis*, MILSTD 1629A, United State of America.

Druzdel, M., Van, der Gaag, L., Henrion, M., Jensen, F. (2000). Building probabilistic networks: “where do the numbers come from?”. guest editors introduction. *IEEE Transactions on Knowledge and Data Engineering*, 12(4) :481–486.

E _____

- El Aoufir, H., Bouami, D. (2003). Place des modèles d'optimisation dans le processus d'aide à la décision en maintenance. *Revue française de gestion industrielle*, 22(3) :61–76.
- El Koujok, M. (2010). *Contribution au pronostic industriel : intégration de la confiance à un modèle prédictif neuro-flou*. Doctorat de l'Université de Franche-Comté. France.

F _____

- Faucher, J. (2004). *Pratique de l'AMDEC*. Donod-Editions, Paris, France.
- Favaro ,M., Monteau, M. (1990). Bilan des méthodes d'analyse a priori des risques : 2. Principales méthodes de la sécurité des systèmes. *Cahiers de Notes Documentaires - Hygiène et sécurité du travail*. (139) : 363-389.
- Ferreira, A., Roussy, A., Kernaflen, C., Gleispach, D., Hayderer, G., Gris, H., Besnard. (2011). Virtual Metrology Models for Predicting Average PECVD Oxide Film Thickness. *ASMC'11*. 22th Annual IEEE/SEMI Advanced Semiconductor Manufacturing Conference. Saragota, NY.
- Flaus, J.-M. (2013). *Risk Analysis: Socio-technical and Industriel Systems*. e-Books Wiley, Online Library, ISBN: 9781848214927, UK.
- François, O. (2006) *De l'identification de structure de réseaux bayésiens à la reconnaissance de formes à partir d'informations complètes où incomplètes*. Thèse de Doctorat, Institut National des Science Appliquées de Rouen. France.
- Friedman, N., Geiger, D., Goldszmidt, M. (1997). Bayesian network classifiers. *Machine Learning*, 29 (2-3): 131-163.
- Friedman, N., Murphy, K., and Russell, S. (1998). Learning the structure of dynamic probabilistic networks. In *UAI'98*, 139–147, Madison, WI.

G _____

- Goh K.-M., Tjahj, B., Baines, T., Subramaniam, S. (2006). A Review of Research in Manufacturing Prognostics. *Proceedings of the IEEE International Conference on Industrial Informatics*, New York. USA, pp. 412-422.
- Greiner, R., Grove, A., Schuurmans, D. (1997). Learning Bayesian nets that performwell. In *Proceedings of the Thirteenth Annual Conference on Uncertainty in Artificial Intelligence (UAI-97)*, pages 198–207, San Francisco, CA, Morgan Kaufmann Publishers.
- Gucik-Derigny, D. (2011). *Contribution au pronostic des systèmes à base de modèles : théorie et application*. Thèse de doctorat, Université Paul Cézanne Aix Marseille III, France.
- Guide-LPCVD. (2003). Guide technique et pratique : Soutien Engineering LPCVD. Section: Fours Poly ou Amorphe, Rapport technique, Lfoundry Rousset (ex-ATMEL).

H _____

- Hadden, G.-D., Bergstrom, P., Bennett, B.-H., Vachtsevanos, G.-J., Van Dyke, J. (2002). Distributed Multi-Algorithm Diagnostics and Prognostics for US Navy Ships. In: *2002 AAAI Spring Symposium*, Stanford University, Palo Alto, USA.
- Harding, J.-A., Shahbaz, M., Srinivas, S., Kusiak, A. (2006). Data Mining in Manufacturing: A Review. *Journal of Manufacturing Science and Engineering*, Volume 128, Issue 4, 969, 8 pages.
- Heckerman, D. (1998). *A Tutorial on Learning with Bayesian Network*, Jordan M. I., Ed., Learning in Graphical Models, 301-354 Cambridge, MA: MIT Press.
- Heng, A., S. Zhang, A.-C. Tan, C., Mathew, J. (2009). Rotating machinery prognostics: State of the art, challenges and opportunities, *Mechanical Systems and Signal Processing*, vol. 23 (3), pp. 724-739.
- Henry, S., Zamaï, E., Jacomino, M. (2012). Logic control law design for automated manufacturing systems. *Engineering Applications of Artificial Intelligence EAAI journal*, Volume 25, Issue 4, pages 824–836.
- Hess, A. (2005). Real Prognostics—Challenges, Issues, and Lessons Learned: Chasing the Big 'P'. First International Forum on Integrated System Health Engineering and Management in Aerospace, NASA, Napa Valley, CA.
- Hohmann, C. (2009). *Techniques de productivité : Comment gagner des points de performance*, Éditions d'organisation, ISBN13 : 978-2-212-54295-0.
- Hubac, S. Advanced Process Control APC and Corrective, Preventive and then Predictive maintenance. (2012). Proceedings of 12th European Advanced Process Control and Manufacturing Conference (APCM'12), Tutorial 2 Part 2, MINATEC Grenoble, France.

I _____

- IEC. (1990). *Norme IEC réf. 191-07-22* : ensemble des opérations effectuées pour la détection de panne, la localisation de panne et l'identification de la cause de la panne. Commission Electrotechnique Internationale.
- ISO. (1999). *Norme ISO 14644-1*: Salles propres et environnements maîtrisés apparentés – Partie 1 : Classification de la Propreté Particulaire de l'Air. International Organization for Standardization.
- ISO. (2004). *Norme ISO 13381-1*: Condition monitoring and diagnostics of machines – Prognostics– Part1: General guideline. International Organization for Standardization. 1st ed. International Standard, TC/SC: ISO/TC 108/SC 5, ICS: 17.160.
- Iung, B., Morel, G., Leger, J.-B. (2003). Proactive maintenance strategy for harbour crane operation improvement. *Robotica*, 21, p. 313-324.
- Iung, B., Marquez, A.-C., (2006). Special issue on e-maintenance. *Computers in Industry*, 57(6), 473-475.

J _____

- Jardine A.K.-S., Lin, D., Banjevic, D. (2006). A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing*, vol. 20, pp. 1483-1510.
- Jensen, F.-V. (1996). *Introduction to Bayesian networks*. UCL Press, London.
- Jensen, F.-V., Nielsen, T.-D. (2007). *Bayesian networks and decision graphs*. Published by Springer Verlag. page 447.
- Jordan, M.-I. (1999). editor. *Learning in Graphical Models*. The MIT press.

K _____

- Kalgren, P., Byington, C., Roemer, M., Watson, M. (2006). Defining PHM, A Lexical Evolution of Maintenance and Logistics. IEEE Autotestcon 2006 Conference Record, Anaheim, California, pp. 353–358.
- Kappen, H., (2002). *The cluster variation method for approximate reasoning in medical diagnosis*. Eds., Modeling Bio-medical signals, World-Scientific.
- Kohli, H. (2002). Conversion cost reduction using advanced process control (SPC) and real-time data analysis with ERP linkage. International Symposium on Electronic Materials and Packaging, 2002. Page(s): 89 – 93.
- Koller, D., Pfeffer, A. (1997). Object-oriented Bayesian networks. Dans Proceedings of the UAI-97, pages 302-313.

L _____

- Langley, P., Iba, W., Thompson, K. (1992). An analysis of Bayesian classifiers. In Proceedings of the Tenth National Conference on Artificial Intelligence, pages 223-228, AAAI Press, San Jose, CA.
- Lebold, M., Thurston, M. (2001). Open standards for condition-based maintenance and prognostic systems. In Proceedings of the 5th Annual Maintenance and Reliability Conference (MARCON 2001), Gatlinburg, USA.
- Lebold, M., Reichard, K., Byington, C.-S. (2002). OSA-CBM Architecture Development with Emphasis on XML Implementations. in Maintenance and Reliability Conference (MARCON).
- Lee, J. (1998). Teleservice engineering in manufacturing: challenges and opportunities. *International Journal of Machine Tools and Manufacture*, vol. 38(8), pp. 901-910.
- Léger, J.-B. (1999). *Contribution méthodologique à la maintenance prévisionnelle des systèmes de production : Proposition d'un cadre Formel de Modélisation*. Doctorat de l'Université Henri Poincaré, Nancy 1.
- Leroy, A. (1992). *Le risque technologique*. Presses universitaires de France.
- Liu, Y. (2008). *Predictive modeling for intelligent maintenance in complex semiconductor manufacturing processes*. PhD Thesis, University of Michigan, USA.

M_____

- Mathur, A., Cavanaugh, K., Pattipati, K., Willet, P., Galie, T. (2001). Reasoning and Modeling Systems in Diagnosis and Prognosis. In: SPIE Aerosense Conference, Orlando, USA.
- Mazouni, M.-H. (2009). *Pour une meilleur Approche du management des risques*. Thèse de doctorat, Institut Polytechnique de Lorraine INPL, France.
- Medina-oliva, G., Weber, P., Iung, B. (2013). PRM-Based patterns for knowledge of industrial systems to support maintenance assessment. *Reliability Engineering and System Safety*. Volume 116, Pages 38-56.
- Mendez-Azua, H. (2002). *Synthèse de lois de surveillance pour les procédés industriels complexes*. Doctorat de l'Institut Polytechnique de Grenoble. France.
- Mendez-Azua, H., Zamaï, E., Descotes-Genon, B. (2005). A methodology to synthesize monitoring laws by using quality, security, ecology and productivity criteria. *Quality Engineering*, Vol. 17, N° 4, pp. 659-668. ISSN 0898-2112 print / 1532-4222 online, published By Taylor & Francis, *an official journal of the American Society for Quality (ASQ)*.
- Mili, A., Hubac, S., Bassetto, S., Siadat, A. (2008). New approach for Risk update based on maintenance events. IFAC World Congress, Séoul, Corea.
- Mili, A., Hubac, S., Bassetto, S., Siadat, A., Tollenaere, M. (2009). Dynamic risk management unveils productivity improvements. *Journal of Loss Prevention in the Process Industries*, ed Elsevier, 22 (1), p.25-34.
- Mili, A. (2009). *Vers des Méthodes Fiables de Control des Procédés par la Maîtrise du Risque*. Thèse de doctorat, Grenoble INP Institut Polytechnique de Grenoble, France.
- Military Standard: MIL-STD-2173., (1986). *Reliability-Centered Maintenance Requirements for Naval Aircraft, Weapons Systems and Support Equipment*, United States Department of Defense.
- Montgomery, S. (2000). Higher profits from intelligent semiconductor equipment maintenance. *Future Fab Intl.*, vol. 8, 2000.
- Moyne, J., Del Castillo, E., Max Hurwitz, A. (2000). *R2R control in semiconductor manufacturing*. CRC press LLC, 368 pages
- Muller, A. (2005). *Contribution à la maintenance prévisionnelle des systèmes de production par la formalisation d'un processus de pronostic*. Doctorat de l'Université Henri Poincaré, Nancy 1. France.
- Muller, A., Crespo-Marquez A., Iung, B. (2008). On the concept of e-maintenance : Review and current research. *Reliability Engineering and System Safety*, Volume 93, Issue 8, August 2008, Pages 1165–1187.
- Murphy, K. (2001). The BayesNet Toolbox for Matlab. *Computing Science and Statistics: Proceedings of Inference*, vol. 33: 1-20.
- Murphy, K. (2002). *Dynamic Bayesian Networks: Representation, Inference and Learning*, Phd thesis. University of California, Berkeley, USA,

N_____

- Naim, P., Wuillemin, P.-H., Leray, P., Pourret, O. (2007). *Réseaux bayésiens*. Eyrolles (eds), 3^e édition. France.
- Nakagawa, T., Mizutani, S. (2009). A summary of maintenance policies for a finite interval. *Reliability Engineering and System Safety*, 94(1), Pages 89-96.
- Neal, R.-M. (1993). *Probabilistic inference using Markov chain Monte Carlo methods*. Technical report CRG-TR-93-1, Department of Computer Science, University of Toronto.
- Neal, R.-M., Hinton, G.-E., (1998). *A View of the EM algorithm that justifies incremental, sparse and other variants*. Jordan M. I., 144, Ed., Learning in Graphical Models, Kluwer Academic Publishers, Boston.
- Neil M., Tailor M., Marquez D., Fenton N., Hearty P. (2008). Modeling dependable systems using hybrid Bayesian networks. *Reliability Engineering and System Safety*. Volume 93, Issue 7, Pages 933-939.

P_____

- Pampuri, S., Schirru, A., De Nicolao, G., De Luca, C. (2011). Proportional Hazard Model with L1 Penalization applied to Predictive Maintenance in Semiconductor Manufacturing. 7th Annual IEEE Conference on Automation Science and Engineering.
- Pearl, J. (1988). *Probabilistic reasoning in intelligent systems: Networks of plausible inference*. Morgan – Kaufmann, San diego.
- Pearl, J., Paz, A. (1985). Graphoids : *A graph-based logic for reasoning about relevance relations*. Technical Report, R-53, CSD-850038. Cognitive Systems Laboratory, University of California, Los Angeles.
- Peysson, F. (2009). *Contribution au pronostic des systèmes complexes*. Thèse de doctorat, Université Paul Cézanne Aix Marseille III, France.
- Pinjal, K., Pintelon, L., Vereecke, A. (2005). An empirical investigation on the relationship between business and maintenance strategies, *International Journal of Production Economics*, Volume 104, p. 214-229.

R_____

- Rasovska, I., Chebel-Morello, B., Zerhouni, N. (2007). *Classification des différentes architectures en maintenance*. 7e Congrès international de génie industriel, Trois-Rivières, Québec (Canda), 23 :1–12.
- Rao, B., (1996). *Handbook of Condition Monitoring*. Amsterdam: Elsevier Advanced Technology, Oxford, UK.
- Renooij, S., (2001). Probability Elicitation for Belief Networks: Issues to Consider, *Knowledge Engineering Review*, vol. 16, no3, p. 255-269.
- Ribot, P. (2009). *Vers l'intégration diagnostic/pronostic pour la maintenance des systèmes complexes*. Thèse de doctorat, Université Toulouse 3 Paul Sabatier (UT3 Paul Sabatier), Laboratoire D'Analyse et d'Architecture des Systèmes, France.

- Robert, R. (1994). *The Bayesian Choice: a decision-theoretic motivation*. Springer, New York.
- Robinson, R.-W. (1977). Counting unlabeled acyclic digraphs. In C.H.C. Little Ed, Combinatorial Mathematics V, volume 622 of *Lecture Notes in Mathematics*, p. 28–43, Berlin : Springer.
- Roemer, M.-J., Nwadiogbu, E.-O., Bloor, G. (2001). Development of diagnostic and prognostic technologies for aerospace health management applications. In IEEE Proceedings on Aerospace Conference, volume 6, pages 3139–3147.
- Russell, S., Norvig, P., (2003). *Artificial Intelligence: A modern approach*. Prentice Hall, Pearson Education, 2nd Edition.

S _____

- Scanlan, J., O'Leary, K. (2003). Knowledge based process control for FDC. Proceedings SPIE, Advanced Process Control and Automation, Volume 5044. 139-149.
- Schutz, J. (2009). *Contribution à l'optimisation des plans d'exploitation et de maintenance, selon une approche basée sur le pronostic : Application au domaine naval*. Doctorat de l'Université Paul Verlaine. France.
- SEMI. (2001). *Norme SEMI E133-0212 : Specification for Automated Process Control Systems Interface*. Semiconductor Equipment and Materials International.
- Shachter, R., Kenley, C., (1989). *Gaussian Influence Diagrams*. Management Science.
- Shahzad, M.-K. (2012). *Exploitation dynamique des données de production pour améliorer les méthodes DFM dans l'industrie microélectronique*. Thèse de doctorat, Université de Grenoble, Grenoble INP Institut Polytechnique de Grenoble, France.
- Sheppard, J.-W., Kaufman, M.-A., Wilmer, T.-J. (2009). IEEE Standards for Prognostics and Health Management, *Aerospace and Electronic Systems Magazine*, IEEE. Volume: 24, Issue: 9, p.34 – 41.
- Sienou, A. (2009). *Proposition d'un cadre méthodologique pour le management intégré des risques et des processus d'entreprise*. Thèse de doctorat en Systèmes industriels de l'Institut National Polytechnique de Toulouse.
- Simeu-Abazi, Z. (1998). *Sur la sûreté de fonctionnement des systèmes de production*. Habilitation à diriger des recherches HDR, INP de Grenoble, France.
- Swearingen, K., Majkowski, W., Bruggeman, B., Gilbertson, D., Dunsdon, J., Sykes. B. (2007). An open system architecture for condition based maintenance overview. IEEE Conference on Aerospace, pages 1–8.

T _____

- Thieullen, J. Pinaton, M. Ouladsine. (2012). A Survey of Health Indicators and Data-Driven Prognosis in Semiconductor. 8th IFAC Symposium SafeProcess'12. Mexico City. Mexico. Volume 8, Part 1, 19-24.
- Tixier, J., Dusserre, G., Salvi, O., Gaston, D. (2002). Review of 62 risk analysis methodologies of industrial plants. *J. Loss Prevent. Process Ind.* 15, pp. 291–303.

- Thomas, E., (2009). *Contribution à la prise de décision dynamique en maintenance prévisionnelle par formalisation d'un principe d'opportunité*. Doctorat de l'Université Henri Poincaré, Nancy 1.
- Tobon-Mejia, D-A., Medjaher, K., Zerhouni, N., Tripot, G. (2011). Estimation of the Remaining Useful Life by using Wavelet Packet Decomposition and HMMs. IEEE Aerospace Conference AIAA, Big Sky - Montana, United States.
- Turing, A.-M. (1950). Computing machine and intelligence. *Review: Mind*, Vol LIX, 433-460.

V_____

- Vasile, O.-E. (2008). *Contribution au pronostic de défaillances par réseau neuro-flou : maîtrise de l'erreur de prédiction*. Doctorat de l'Université de Franche Comté. France.
- Velarde-Suarez, S., Ballesteros-Tajadura, R., Hurtado-Cruz, J.-P. (2006). A predictive maintenance procedure using pressure and acceleration signals from a centrifugal fan," *Applied Acoustics*, vol. 67, issue 1, pp. 49-61.
- Verma, T., Pearl, J. (1991). Equivalence and Synthesis of Causal Models. In M. Henrion, *Proceedings of the Sixth Conference on Uncertainty in AI*, pages 220-227, San Francisco.
- Verron, S. (2007). *Diagnostic et surveillance des processus complexes par réseaux Bayésiens*. Thèse de Doctorat, Université d'Angers.
- Villemeur, A. (1988). *Sûreté de fonctionnement des systèmes industriels, fiabilité – facteurs humains – information*. Paris : Eyrolles, Collection de la Direction des Etudes et Recherches d'Electricité de France, n° 67.

W_____

- Wang, P., Youn, B.D., Hu, C. (2012). A Generic Probabilistic Framework for Structural Health Prognostic and Uncertainty Management. *Mechanical Systems and Signal Processing*, Vol. 28, pp. 622–637.
- Weber, P., Suhner, M.-C., Iung, B. (2001). System approach-based Bayesian Network to aid maintenance of manufacturing process. 6th IFAC Symposium on Cost Oriented Automation, Low Cost Automation. Berlin, Germany, 33-39, October 8-9.
- Weber, P., Jouffe, L. (2003). Reliability modeling with Dynamic Bayesian Networks. In 5th IFAC Symposium on Fault Detection and Safety of Technical Processes (SafeProcess'03), Washington, D.C., USA.
- Weber, P., Munteanu, P., Jouffe, L. (2004). Dynamic Bayesian Networks modelling the dependability of systems with degradations and exogenous constraints. 11th IFAC Symposium on Information Control Problems in Manufacturing (INCOM'04). Salvador-Bahia, Brazil, April 5-7th.
- Weber, P., Suhner, M.-C. (2004). Modélisation de processus industriels par réseaux bayésiens orientés objet (RBOO) : Application à l'analyse des performances d'un processus industriel. *Revue d'Intelligence Artificielle*, 18 :299-326.

Weber, P., Jouffe, L. (2006). Reliability modeling with Dynamic Bayesian Networks. *Reliability Engineering and System Safety*. Vol. 91, No. 2, pp. 149-162.

Weber, P., Medina Oliva, G., Simon, C., Iung, B. (2012). Overview on Bayesian networks applications for dependability, risk analysis and maintenance areas. *Engineering Applications of Artificial Intelligence EAAI journal*, ed Elsevier. Vol. 25, Issue 4, pp 671-682.

Y_____

Yugma, C., Dauzère-Pérès, S., Artigues, C., Derreumaux, A., Sibille, O.(2012). A Batching and Scheduling Algorithm for the Diffusion Area in Semiconductor Manufacturing, *International Journal of Production Research* 50 (8): 2118-2132.

Z_____

Zaarour, I., Heutte, L., Leray, P., Labiche, J., Eter, B., Mellier, D. (2004). Clustering and bayesian network approaches for discovering handwriting strategies of primary school children. *International Journal of Pattern Recognition and Artificial Intelligence*, 18(7): 1233–1251.

Zafra-Cabeza, A., Ridao, M.A. & Camacho, E.F. (2008). Using a risk-based approach to project scheduling: A case illustration from semiconductor manufacturing. *European Journal of Operational Research*, 190(3): 708-723.

Zamaï, E., Chaillet-Subias, A., Combacau, M. (1998). An Architecture for Control and Monitoring of Discrete Events systems. *Computers in Industry*, March, Vol. 36: 95-100.

Zhang, N.-L. (2002). Hierarchical latent class models for cluster analysis,” In Proceedings of AAAI’02, pp. 230–237.

Zhang, N.-L. (2003). *Structural EM for hierarchical latent class model*, Technical report, HKUST-CS03-06.

Zille, V. (2009). *Modélisation et évaluation des stratégies de maintenance complexes sur des systèmes multi-composants*. Doctorat de l’Université Technologie de de Troyes. France.

Zio, E., (2009). Reliability engineering: Old problems and new challenges. *Reliability Engineering and System Safety*, Vol. 94, pp. 125-141.

Zwingelstein, G. (1995). *Diagnostic des défaillances : Théorie et pratique pour les systèmes industriels*, Hermes.

Annexes

A. Définitions liées à la notion de « Failure ».....	142
B. Formalisation de la connaissance.....	144
C. Four de traitement thermique.....	145
D. Table AMDEC fonctionnelle.....	146
E. Définition des priorités par l’outil CEP.....	147

Annexe A

Définitions liées à la notion de « Failure »

Dans le cadre du projet européen *IMPROVE*, différents concepts associés à la notion de défaillance ont été définis. Ceci a pour objectif de réduire les interprétations possibles. Ce travail de nomenclature a été réalisé sur la base d'une synthèse des définitions issues de la littérature et celles proposées par les partenaires industriels.

A.1. Process Health Factor PHF

The Process Health Factor (PHF) is the result of a probability calculation used to forecast Product behaviour and quality as well as optimizing Control Plan based on the analysis of equipment parameters, maintenance and product historical operating data.

- A Goodness Of Fit (GOF = confidence interval) is associated to the *PHF* value.
- *PHF* should be available at appropriate time during productive processing for process control needs.
- Recommendation: *PHF* should be a normalized continuous number [0,100%].

A.2. Equipment Health Factor EHF

The Equipment Health Factor (EHF) is the result of a probability calculation used to forecast equipment behaviour and optimize control plan, based on the analysis of equipment parameters, maintenance, and product & quality historical operating data.

- A Goodness Of Fit (GOF = confidence interval) is associated to the *EHF* value.
- In any case, the *EHF* should be available at appropriate time versus equipment control needs.
- It can be employed to assess future status of the equipment/process or one of its components. Also it can be used to take decisions about maintenance scheduling, and as information for dynamic sampling plans.
- Recommendation: *EHF* should be a normalized continuous number [0,100%].

A.3. Cause Diagnosis Probability CDP

The Cause Diagnosis Probability (CDP) is the result of a calculation that defines the probability for a cause to be associated with one or several failure(s). It is used to associate the appropriated actions to equipment or product failure(s) cause(s).

A.4. Equipment Failure

Equipment Failure corresponds to the equipment not being available to produce parts at specified conditions when scheduled, or not being able to produce parts or perform scheduled operations in regards to specifications.

A.5. Equipment Failure Mode

Equipment Failure Mode defines the manner in which a component, subsystem, or a system (potentially) fails. The (Potential) Failure Mode may also be the Cause of a (Potential) Failure Mode in a higher level subsystem, system, or component or be the Effect of a (Potential) Failure Mode in a lower level component. A Failure Mode can have one or more sources.

A.6. Equipment Failure Effect

Equipment Failure Effect is the immediate consequence of an equipment (Potential) failure. An Effect is an adverse consequence that the Customer might experience. The Customer could be the next operation, subsequent operations, or the end user.

- Local effect: The Failure effect as it applies to the item under analysis.
- Next higher level effect: The Failure effect as it applies at the next higher indenture level.
- End effect: The failure effect at the highest indenture level or total system.

A.7. Equipment Failure Cause

Equipment Failure Cause is the defect in equipment parts, process recipe design or usage conditions which are the underlying causes of the (Potential) failure mode or which initiate a process which leads to failure. A cause is a mean by which a particular element of the equipment results in a failure. A Root Cause(s) is below the first level cause.

Annexe B

Formalisation de la connaissance

Ici nous présentons un extrait d'un compte rendu réalisé suite à une réunion de travail entre partenaires du *WP3* dans le cadre du projet *IMPROVE*.

Grenoble INP – GSCOP

Compte rendu de réunion

Page : 1/2

Objet : Meeting IMPROVE WP3 – G-scop & STM Crolles		Réunion du : 22/09/2010 à 11H (Crolles).	
Présents : S. Hubac (STM) M.-F. Bouaziz (G-scop)	Dest. pour info : STM Crolles (Hubac et Shazad) Probayes (Duvivier et Monot) G-scop (Zamaï et Bouaziz)	Rédacteur : M.-F. Bouaziz.	
		Prochaine réunion : Mardi 28/09/2010 à 11H (Crolles).	
Ordre du jour - sujets abordés - actions lancées		Qui	Quand
I. <u>Ordre du jour :</u> 1- Démarche de Modélisation : discussion 2- Identification des variables potentielles à adresser. 3- Preprocessing de la TGV data-set. 4- Questions/Réponses sur les données.		→ Ok → Ok → Ok → Ok	
II. <u>Points abordés :</u> ○ Démarche générale du calcul d'EHF. ○ Structure actuel du modèle et configuration. ○ Validation des variables. (Fig. 1) ○ Exemple de table : après jointure et preprocessing. (Fig. 2)		M.-F. B et S. M M.-F. B et S. M M.-F. B et S. M	
III. <u>Actions lancées :</u> ○ Compte rendu réunion. ○ Répondre aux différentes questions posées. ○ Travailler une table de données suivant une chronologie d'événements. « vie de l'équipement ». ○ Présentation pour le F2F WP3 à Padue.			→ 23/09 → 23/09
<u>Séries de questions techniques</u>			
Q1) : Dans la colonne N°5 / BD, comment est-elle calculer la valeur du 'Recipe' ? Q2) : Comment on définit les 5 points de mesure sur le moniteur ? Q3) : Y a-t-il un impact d'une variable sur une autre ? Influence ? Q4) : Quel est l'impact du nombre de run sur les RC liées au quartz ? Q5) : comment différencier les données FDC-capteurs dans le data-set ? Q6) : Définition de la table TGV (entrées/sorties) ? Q7) : Accès aux informations relatives à la table FMEA-Maint ? Q8) : Classifier les maintenances correctives et préventives dans une BD ? Q9) : Décrire tous le parcours d'une recette ? sa gestion ? Q10) : Analyser la liste des FM dans le Pareto → validation ? Q11) : Extraire les FM potentiels dans la TGV data-set ? Q12) : Liste des causes 'expertes' associées ? Q13) : Liste des causes dans la TGV data-set ? → comparer si possible ?			
<u>Informations complémentaires</u>			
Initialement, nous avons deux modes de défaillance (four LPCVD)			

Liste des Root Cause et Variables					
Faillure Mode	FM N°1 : Defectivity				
Root Cause	N°1: Flaking du dépôt	N°2: ED-RD Flaking	N°3: Abort	N°4: Wafer Breakage	N°5: Robot Handling
Définition	* Particules de quartz qui se composent *	* Demise: lots supplémentaire qui complète la production *	* Un Equipement qui plante complètement *	* Casse d'un Wafer *.	* Liée à la manipulation des Wafer par les robots *
Paramètres permettant d'évaluer une Root cause	1) Durée de vie du quartz.	1) Gérer par l'équipement.	1) Back streaming.	1) Produit à processor.	1) Analyse des alarmes.
	2) Vieillessement.	2) Info de l'événement " demise en alarme ".	2) Lié à plusieurs root cause différentes et inconnues.	2) Choc Thermique d'un wafer fragile.	2) Manipulation des plaques.
	3) Maintenances.	3) Cyclicité du flaking ed-rd.	3) Mesure de run sur place.	3) Maîtriser par l'opérateur.	
	4) Cyclicité du flaking.			4) Mesures conservatoires.	
	5) Changement du quartz.				

Fig. 1. Variables pour FM N°1 : Defectivity

Fig. 1. Variables pour FM N°1 : Defectivity

improve - Compte rendu de réunion

Annexe C

Four de traitement thermique




Figure C.1. Équipement de production : four thermique.

- Ce sont des fours verticaux qui peuvent traiter plusieurs plaquettes simultanément (contrairement aux équipements dits « single wafer »).
- Chaque four est composé de deux tubes indépendants où se déroule le procédé et d'un unique module de transfert des plaques. Il existe en quelque sorte deux fours dans chaque équipement.
- Le four possède un « stocker », sorte de module de rangement où peuvent être rangées plusieurs lots.
- Le four peut être pourvu d'un module de métrologie intégrée (mesure épaisseur, lecteur du wafer ID...)




Figure C.2. Modules de l'équipement.

Annexe D
Table AMDEC fonctionnelle

 POTENTIAL FAILURE MODE AND EFFECTS ANALYSIS (PROCESS FMEA)								
Process Function/ Requirement	Potential Failure Mode	Potential Effects of Failure	Potential Cause(s) / Mechanism(s) of Failure	Current Process Controls	S	O	D	RPN
Teos deposition	Thickness out of range	Etch-Strip / Low Yield	Recipe change	Thickness on 3 Pilots every run, UV	4	2	1	8
			Temperature drift	Thickness on 3 Pilots every run, UV	4	2	1	8
			MFC drift	Thickness on 3 Pilots every run, UV-SMC	4	2	1	8
			Valve issue	Thickness on 3 Pilots every run, UV	4	2	1	8
			Abort	Thickness on 3 Pilots every run, UV, SMC	3	2	1	6
			Automation issue	Thickness on 3 Pilots every run, UV	2	3	2	12
	Boat Uniformity	Etch-Strip / Low Yield	Temp drift	Thickness on 3 Pilots every run, UV, SMC	3	2	1	6
Teos deposition	Contamination	Defectvity / Low Yield	ED-RD Flaking	D0 on 3 Pilots every run, SP1	4	2	1	8
			Abort with back streaming	D0 on 3 Pilots every run, SP1	4	2	1	8
			Wafers breakage	D0 on 3 Pilots every run, SP1	4	2	1	8
			Flaking	D0 on 3 Pilots every run, SP1	4	2	1	8
			Robot-Handling issue	D0 on 3 Pilots every run, SP1	4	2	1	8
Teos deposition	Thermal budget out of range, Salicide oxydation, mainly PMD Liner	E test- Yield	Recipe modification	frozing production recipes in the recipe editor (Semy-automation)	4	1	3	12
			Increase of pumping time (change of SSV valve setting, vacuum line blocking...)	Check of "Slow Vacuum" step time by SEMY SMC control	4	1	3	12
			Loading issue with ambient air- Salicide ox	Tool abort- JT measurement	4	3	1	12
			Unloading issue- Thermal budget	Overall run time control SMC control to be implemented	4	1	3	12

Table D.1. Structure générique d'une « Grille AMDEC » LFoundy (ex-ATMEL).

Annexe E

Définition des priorités par l'outil CEP

A.1. Résumé

The aim of this technical annex is to present the work performed by Probayes in close collaboration with *ST Crolles* and *G-SCOP*. It describes the main steps which drive us to *CEP* (Complex Event Process).

Main preliminary issues are:

- The *FM* variable used in *EHF* context doesn't exist anywhere (info is spread into equipment and lot history).
- The most important problem is multiple asynchronous event dataset.
- The target is to provide a unique ordered event dataset and build new variables (*FM...*) from context.
- The extract is compound of two files, one from equipment database and other from lot production database.

A.2. Description

Here we propose to illustrate the qualitative step of our proposed approach through a case study. For this, the first works performed focus on the data extraction from semiconductor fab. During the preliminary study of the model, we identified distinct required data sources to be merged to build equipment, lot, failure and maintenances events histories. The merge of all these data required the development of a *CEP* tool to build the continuous status of the equipment from all these unsynchronized events. The aim of *CEP* is to apply rules provided by manufacturing expertise to merge and synchronize data and to perform identification phases an automatic mode. It generates two files data:

- *Equipment life file.*
- *EHF model data used to learning model.*

Several variables are also defined:

- *FM type variable,*
- *Maintenance type variable,*
- *Root Cause type variable,*
- *Weariness type variable.*

A.3. Résultats graphiques

Several plot types are generated:

- To display Equipment life file: like UP/DOWN graphs, event equipment/days...
- To display *EHF* Model data file: like *FM* Occurrence and time graphs...

For *EHF* model design purpose, a key play is the Pareto of Failure Mode detected by occurrence and by cumulative time (cf. figure IV.2). It allows identifying in the most accurate way the main down time *FM* contributors in order to assist the semiconductor expert to set up priorities.

The following figures represent the equipment time line status (in production, idle, stopped, *CM*, *PM*) for one furnace (per *week* and per *month*) and for all furnaces (we observe six furnaces during 270 hours).




Figure E.1. Status distribution per week.




Figure E.2. Status distribution per month.




Figure E.3. Time line equipment status for all furnaces.

Contribution à la modélisation Bayésienne de l'état de santé d'un système complexe : Application à l'industrie du semi-conducteur

Résumé:

Pour maintenir leur compétitivité, les industries du semi-conducteur doivent être en mesure de produire des circuits intégrés en technologies avancées, avec des temps de cycle de plus en plus courts et à des coûts raisonnables. Un des axes d'amélioration réside dans le traitement des défaillances des équipements de production tenus responsables de plus de 50% des rejets produits. Cette thèse se fixe comme objectif de contribuer au développement d'une boucle réactive partant d'une dérive produit à la mise en place d'une solution appropriée tout en assurant un meilleur compromis entre disponibilité des équipements, coûts d'exploitation, qualité et compétitivité du produit.

Joignant l'expertise humaine et les événements réels, nous nous sommes proposé ici de développer une méthodologie générique permettant de construire un modèle d'estimation du comportement des équipements de production (Equipment Health Factor EHF) à partir d'un raisonnement mathématique centré sur un formalisme probabiliste. L'approche a été amenée à sa validation expérimentale sur des outils, à base de réseaux Bayésiens, que nous avons développés. Les résultats obtenus amènent des éléments de décision permettant à l'industriel d'intervenir au plus tôt pour envisager par exemple de maintenir l'équipement avant qu'il n'ait dérivé. Cette thèse a été préparée dans le cadre du projet européen IMPROVE en collaboration avec STMicroelectronics, Lfoundry et Probayes.

Mots-clés :

Maintenance prédictive (PdM), Pronostic et gestion de la santé (PHM), Réseaux Bayésiens, Procédés semi-conducteurs complexes, Aide à la décision.

Abstract:

Today, the semiconductor industry must be able to produce Integrated Circuit (IC) with reduced cycle time, improved yield and enhanced equipment effectiveness. Besides these challenges IC manufacturers are required to address the products scrap and equipment drifts in a complex and uncertain environment which otherwise shall severely hamper the maximum production capacity planned. The objective of this thesis is to propose a generic methodology to develop a model to predict the Equipment Health Factor (EHF) which will define decision support strategies on maintenance tasks to increase the semiconductor industry performance. So, we are interested here to the problem of equipment failures and drift. We propose a predictive approach based on Bayesian technique allowing intervene early to maintain, for example, the equipment before its drift. The study presented in this thesis is supported by the IMPROVE European project.

Keywords:

Predictive maintenance, Prognostic and health management, Bayesian networks, Complex semiconductor systems, Decision support.

