

Année : 2010

# THÈSE

**Version finale**

*présentée à*

**L'U.F.R. DES SCIENCES ET TECHNIQUES  
DE L'UNIVERSITÉ DE FRANCHE-COMTÉ**

*pour obtenir le*

**GRADE DE DOCTEUR DE L'UNIVERSITÉ  
DE FRANCHE-COMTÉ**

*en* **AUTOMATIQUE**

*(Ecole Doctorale Sciences Physiques pour l'Ingénieur et Microtechniques)*

## **Contribution au pronostic industriel : intégration de la confiance à un modèle prédictif neuro-flou**

*par*

**Mohamed EL KOUJOK**

Soutenue le 17/09/2010 devant la Commission d'Examen :

Rapporteurs :

**M. Michel COMBACAU**

Professeur, Université Paul Sabatier  
Laboratoire LAAS, Toulouse

**Mme. SIMEU-ABAZI ZINEB**

Maître de Conférences HDR, Université Joseph Fourier  
Laboratoire G-SCOP, Grenoble

Examineurs :

**M. Dimitris KIRITSIS**

Maître d'enseignement et de recherche  
École Polytechnique Fédérale de Lausanne

**M. Nasr-Eddine BERRACHED**

Professeur, Université Mohamed Boudiaf-USTO  
Laboratoire LARESI, Oran-Algérie

**M. Noureddine ZERHOUNI**

Professeur, ENSMM Besançon  
Institut Femto-st, Département AS2M

**M. Rafael GOURIVEAU**

Maître de Conférences, ENSMM Besançon  
Institut Femto-st, Département AS2M



*Dédicace.*

A mes parents et à toute ma  
famille,



# Remerciements

Je tiens tout d'abord à remercier Monsieur Noureddine ZERHOUNI, de m'avoir accueilli au sein de son équipe. Je lui suis sincèrement reconnaissant pour son encadrement et ses précieux conseils.

Je souhaite aussi remercier Monsieur Rafael GOURIVEAU, qui m'a beaucoup aidé, sans relâche et sans limite. En effet, je lui exprime ma profonde gratitude pour son encadrement, sa disponibilité et son dévouement. Je le remercie de m'avoir toujours poussé vers l'avant et d'avoir eu confiance en moi. Cette confiance m'a permis d'acquérir une riche expérience durant ma thèse. Je le remercie pour son amitié et ses précieuses qualités humaines.

Mes remerciements s'adressent ensuite aux membres du jury qui me fait l'honneur de participer à ma soutenance. Je remercie sincèrement Madame Zineb SIMEU-ABAZI et Monsieur Michel COMBACAU pour avoir accepté d'évaluer mes travaux en qualité de rapporteurs. Mes remerciements s'adressent également à Monsieur Dimitris KIRITSIS et Monsieur Nasr-Eddine BERRACHED pour leur participation au jury en tant qu'examineurs.

Je remercie également, et sans exception, l'ensemble du personnel du Département Automatique et Systèmes Micro-Mécatroniques (AS2M, Institut Femto-st) pour l'excellente ambiance qui y règne. Ces années de thèse ont été pour moi l'occasion de connaître des personnes exceptionnelles qui m'ont offert leur amitié et avec qui j'ai partagé d'agréables moments. Je remercie très chaleureusement Brahim, Karim, François, Hafida, Lisa, Kharboutly, Mika, Diego pour tout ce que nous avons vécu ensemble.

Je ne peux terminer sans avoir une pensée pour ma famille. Sans elle, je n'aurais jamais pu arriver jusque là et atteindre mes objectifs. Un grand merci à mes parents (Halima et Safoit) pour leur soutien indéterminé.



# Table des matières

Glossaire des abréviations	vii
Introduction Générale	1
<b>I Le pronostic industriel</b>	<b>5</b>
I.1 Introduction	6
I.2 Émergence du pronostic dans l'activité de maintenance	6
I.2.1 La maintenance industrielle : définitions et prérogatives	6
I.2.1.1 <i>Maintenance et sûreté de fonctionnement</i>	6
I.2.1.2 <i>Nouveaux enjeux et évolutions de la fonction maintenance</i>	7
I.2.2 Vers une anticipation des phénomènes de défaillance	9
I.2.2.1 <i>Cartographie des formes de maintenance</i>	9
I.2.2.2 <i>Maintenances corrective et préventive</i>	10
I.2.2.3 <i>Maintenances conditionnelle et prévisionnelle</i>	11
I.2.3 Maintenance prévisionnelle et pronostic	12
I.2.3.1 <i>Diagnostic vs pronostic</i>	12
I.2.3.2 <i>Architecture CBM</i>	13
I.3 Le pronostic industriel	15
I.3.1 Quoi : définition et mesures	15
I.3.1.1 <i>Le concept de pronostic</i>	15
I.3.1.2 <i>Métriques du pronostic</i>	16
I.3.2 Comment : les approches du pronostic	19
I.3.2.1 <i>Classification des approches de pronostic</i>	19
I.3.2.2 <i>Approches basées sur un modèle physique</i>	21
I.3.2.3 <i>Approches guidées par les données</i>	23
I.3.2.4 <i>Approches basées sur l'expérience</i>	26
I.3.3 Synthèse	28
I.4 Cadre de travail	28
I.4.1 Approche locale : pronostic d'éléments critiques	28
I.4.2 Approche guidée par les données	30

I.4.2.1	<i>Processus de défaillance progressif : par dégradation</i>	30
I.4.2.2	<i>Pronostic à base de données sans connaissance a priori</i>	31
I.4.3	Orientations de travail	31
I.5	Conclusion	32
<b>II</b>	<b>Proposition d'un modèle de prédiction basé sur une approche neuro-floue</b>	<b>33</b>
II.1	Introduction	34
II.2	Vers les systèmes prédictifs issus de l'intelligence artificielle	34
II.2.1	Une typologie des systèmes de prédiction	34
II.2.2	Critères de choix d'un système prédictif orienté données	35
II.2.2.1	<i>Contraintes industrielles</i>	35
II.2.2.2	<i>Caractéristiques souhaitables</i>	35
II.2.3	Choix d'une famille d'approches	36
II.3	Systèmes neuro-flous pour la prédiction de séries temporelles	37
II.3.1	Réseaux de neurones et prédiction	38
II.3.2	Combinaison des réseaux de neurones et de la logique floue	39
II.4	Représentation d'un système Takagi-Sugeno	41
II.5	Vers une stratégie évolutionniste d'identification d'un modèle NF-TS	43
II.5.1	Identification d'un système Takagi Sugeno	43
II.5.1.1	<i>Mosaïque (en anglais, Mosaic or table lookup)</i>	44
II.5.1.2	<i>Descente de gradient</i>	44
II.5.1.3	<i>Coalescence floue (Clustering flou)</i>	45
II.5.1.4	<i>Stratégie évolutionniste</i>	46
II.5.2	Discussion et choix d'une méthode d'identification	47
II.6	Le système évolutif exTS comme outil de prédiction	48
II.6.1	Système exTS : objectif fondamental	48
II.6.2	Algorithme d'apprentissage en ligne du TS	49
II.6.2.1	<i>La procédure de base</i>	49
II.6.2.2	<i>Algorithme de clustering évolutionnaire et en ligne</i>	51
II.6.2.3	<i>Moindres Carrés Récursifs, MCR</i>	54
II.7	Conclusion	55
<b>III</b>	<b>Génération automatique d'un système prédictif du type exTS : un compromis performance / complexité</b>	<b>57</b>
III.1	Introduction	58
III.2	Performance versus complexité : un problème d'identification	58
III.2.1	Explicitation du problème	58
III.2.1.1	<i>Approximation, généralisation et complexité</i>	58
III.2.1.2	<i>Critères influents</i>	59
III.2.2	Un problème d'identification	60
III.2.2.1	<i>Procédure d'identification d'un système TS</i>	60
III.2.2.2	<i>Influence de l'utilisateur dans l'identification d'un exTS</i>	62

III.3	Proposition d'une procédure d'identification d'un système exTS basée sur un critère de parcimonie . . . . .	63
III.3.1	Principe et grandeur de parcimonie . . . . .	63
III.3.1.1	<i>Principe</i> . . . . .	63
III.3.1.2	<i>Critères de parcimonie</i> . . . . .	63
III.3.2	Procédure d'identification proposée . . . . .	65
III.3.2.1	<i>Choix du critère de parcimonie</i> . . . . .	65
III.3.2.2	<i>Génération automatique du système prédictif exTS</i> . . . . .	66
III.4	Validation de la démarche . . . . .	66
III.4.1	Choix d'indicateurs de performance . . . . .	67
III.4.1.1	<i>Mesures d'erreur de prédiction</i> . . . . .	67
III.4.1.2	<i>Choix de métriques de comparaison</i> . . . . .	69
III.4.2	Validation 1 : l'exTS comme système prédictif . . . . .	70
III.4.2.1	<i>Objectif et plan de simulation</i> . . . . .	70
III.4.2.2	<i>Résultats et discussion</i> . . . . .	71
III.4.3	Validation 2 : procédure de recherche d'un compromis performance / complexité . . . . .	74
III.4.3.1	<i>Objectif et plan de simulation</i> . . . . .	74
III.4.3.2	<i>Résultats et discussion</i> . . . . .	76
III.5	Conclusion . . . . .	78
<b>IV</b>	<b>Pronostic de dégradation - intégration de la confiance au système prédictif</b>	<b>81</b>
IV.1	Introduction . . . . .	82
IV.2	Impact de la confiance sur l'estimation du <i>RUL</i> . . . . .	82
IV.3	Estimation de la confiance du système prédictif . . . . .	84
IV.3.1	Estimation de la confiance dans la zone d'apprentissage . . . . .	84
IV.3.1.1	<i>Dimensionnement de l'erreur de prédiction</i> . . . . .	85
IV.3.1.2	<i>Densité de prédiction et intervalle de confiance</i> . . . . .	87
IV.3.2	Estimation de la confiance dans la zone de prédiction . . . . .	89
IV.3.2.1	<i>Dimensionnement de l'erreur de prédiction</i> . . . . .	89
IV.3.2.2	<i>Densité de prédiction et intervalle de confiance</i> . . . . .	93
IV.3.3	Synthèse . . . . .	94
IV.4	Validation de l'approche par simulation . . . . .	94
IV.4.1	Description du plan de simulation . . . . .	94
IV.4.2	Évaluation de la confiance dans la prédiction . . . . .	95
IV.4.3	Estimation du <i>RUL</i> en intégrant la confiance . . . . .	97
IV.5	Conclusion . . . . .	98
	<b>Conclusion et perspectives</b>	<b>101</b>
	<b>Annexe A</b>	<b>105</b>
A	Éléments de logique floue . . . . .	105

<b>Annexe B</b>	<b>111</b>
B Réseaux de Neurones . . . . .	111
<b>Annexe C</b>	<b>118</b>
C Algorithmes des Moindres Carrés . . . . .	118
<b>Annexe D</b>	<b>119</b>
D Algorithme de Rétro-Propagation du gradient (RP) . . . . .	119
<b>Annexe E</b>	<b>120</b>
E Méthode de «Subtractive Clustering» (SC) . . . . .	120
<b>Bibliographie</b>	<b>120</b>

# Table des figures

I.1	Performance globale de l'entreprise [Rey03] . . . . .	8
I.2	Architecture du concept de s-maintenance [Ras06] . . . . .	9
I.3	Formes de maintenance [NFE01] . . . . .	10
I.4	Complémentarité des activités de détection, diagnostic et pronostic . . . . .	13
I.5	Architecture OSA/CBM séquentielle [LT01] . . . . .	14
I.6	Architecture OSA/CBM distribuée [LRB03] . . . . .	14
I.7	(a) Le pronostic comme l'estimation du <i>RUL</i> , (b) de probabilités d'états	15
I.8	Mesures de pronostic : <i>RUL</i> et confiance . . . . .	17
I.9	Mesures de performances du système de pronostic : (a) « <i>accuracy</i> » et « <i>precision</i> », (b) « <i>timeliness</i> » . . . . .	19
I.10	Taxonomie des approches de pronostic [LT01] . . . . .	20
I.11	Exemple de pronostic basé sur un modèle [LPQC03] : (a) modèle physique de suspension d'une voiture, (b) approche de pronostic déployée . . . . .	24
I.12	Exemple de pronostic guidé par les données [WGI04] : estimation de l'état futur d'une machine tournante par approche neuro-floue (ANFIS) . . . . .	26
I.13	Exemple de pronostic basé sur l'expérience : estimation de la date de remplacement d'un composant électronique d'une cellule d'avion par ex- ploitation des historiques de vol [RBKV05] . . . . .	27
I.14	Cadre de travail : pronostic d'éléments critiques à partir de données de surveillance . . . . .	29
I.15	Formes d'apparition d'une défaillance selon [Zwi99] . . . . .	30
I.16	Exemples de tendances de dégradation [ME98] . . . . .	30
I.17	Le pronostic comme un processus de prédiction et d'évaluation . . . . .	32
II.1	Techniques de prédiction . . . . .	35
II.2	Matrice de choix d'un outil de prédiction basé sur les séries temporelles . .	37
II.3	Vers les systèmes hybrides d'après [GKZ07] . . . . .	38
II.4	Structure d'un système Takagi-Sugeno . . . . .	42
II.5	Algorithme d'apprentissage hybride de l'ANFIS . . . . .	44
II.6	Système ANFIS à deux entrées, une sortie et deux fonctions d'apparte- nance par entrées . . . . .	45

II.7	Corrélation des méthodes d'identifications avec les critères de choix . . . .	47
II.8	La procédure d'un algorithme d'apprentissage évolutionnaire et en ligne d'un TS [Ang02] . . . . .	50
II.9	Mécanisme d'innovation et de modification des règles à travers les données	53
III.1	Illustration du compromis «performance de prédiction / complexité» . . .	59
III.2	Procédure générale d'identification d'un système prédictif TS . . . . .	61
III.3	Procédure d'identification d'un système exTS sans connaissance <i>a priori</i> .	64
III.4	Évolution des critères de parcimonie <i>AIC</i> , <i>MDL</i> et <i>FPE</i> . . . . .	65
III.5	Procédure pour construire automatiquement un exTS . . . . .	66
III.6	Typologie des mesures d'erreur . . . . .	67
III.7	Évolution des clusters pour $k = 1 \rightarrow 3$ . . . . .	72
III.8	Évolution des règles floues durant la phase d'apprentissage ( $k = 1 \rightarrow 150$ )	73
III.9	Les trois courbes (exTS, ANFIS, Réel ) dans la zone de prédiction . . . .	75
III.10	Température du système de chauffe - résultats de prédiction avec les struc- tures les moins complexes . . . . .	78
III.11	Performances de prédiction et complexité des systèmes $ARX_{pmin}$ , $exTS_{pmin}$ , $ARX_{MSEtrain}$ , $exTS_{MSEtrain}$ , $ARX_{R2test}$ et $exTS_{R2test}$ . . . . .	79
III.12	Pdf du pourcentage de l'erreur de prédiction dans la phase de test des modèles $exTS_{R2test}$ et $exTS_{AIC}$ . . . . .	79
IV.1	Le RUL dans une intervalle de prédiction . . . . .	82
IV.2	Prédiction et modélisation de la fiabilité . . . . .	84
IV.3	Erreur de Prédiction dans la zone d'apprentissage . . . . .	86
IV.4	Erreur de prédiction à l'instant $t$ . . . . .	88
IV.5	Incertitude de l'exTS (zone d'apprentissage) . . . . .	89
IV.6	exTS avec 2 régresseurs et 2 règles . . . . .	90
IV.7	Évolution de la quantité de chlorure de cuivre . . . . .	95
IV.8	Plusieurs scénarios avec des différentes conditions . . . . .	95
IV.9	Organisation de la base de données . . . . .	96
IV.10	Pourcentage des points à l'intérieur de l'intervalle prédiction pour les 20 dégradations de test . . . . .	97
IV.11	Modélisation de la fiabilité en ligne et <i>RUL</i> . . . . .	98
A1	Comparaison d'un ensemble classique et d'un ensemble flou . . . . .	105
A2	(a) fonction caractéristique, (b) fonction d'appartenance . . . . .	106
A3	Fonction d'appartenance, variable et terme linguistique . . . . .	107
A4	Formes typiques représentatives des fonctions d'appartenance . . . . .	107
A5	Opérateurs entre ensemble flous . . . . .	108
A6	Représentation interne d'un modèle flou . . . . .	109
B1	Neurone biologique . . . . .	113
B2	Neurone formel (artificiel) . . . . .	113

B3	Différents types de fonctions de transfert pour le neurone artificiel : a) fonction à seuil du neurone de Mc Culloch et W. Pitts (1949), b) linéaire par morceaux du modèle Adaline de Widrow et Hoff (1960), c) sigmoïde dun réseau Perceptron Multi Couches de Rosenblatt (1962), d) gaussienne du réseau RFR de Moody et Darken (1989) , [ZEM03] . . . . .	113
B4	Réseau monocouche . . . . .	114
B5	Réseau Multicouches . . . . .	115
B6	Réseau à connexion complète . . . . .	115



# Liste des tableaux

I.1	Approches de pronostic et type d'information nécessaire [RBKV05]	21
II.1	Avantages et inconvénients des RNs et de la LF	40
III.1	Prédictions de la série Sunspot-Conditions de test	71
III.2	Mesures d'erreurs dans la zone de prédiction (151 → 289)	74
III.3	Prédiction de la température d'un système de chauffe - résultats de simulation	77
IV.1	Conditions de simulation	97



# Abréviations

---

Liste des abréviations par ordre alphabétique

---

<b>STIC</b>	: Sciences et Technologies de l'Information et de la Communication
<b>ANFIS</b>	: Adaptive Neuro Fuzzy Inference System
<b>AR</b>	: Auto Regressive model
<b>ARMA</b>	: Auto Regressive Moving Average model
<b>ARIMA</b>	: Auto Regressive Integrated Moving Average model
<b>ARX</b>	: Auto Regressive model with eXogenous variables
<b>CBM</b>	: Condition Based Maintenance
<b>eTS</b>	: evolving Takagi Sugeno
<b>exTS</b>	: evolving eXtended Takagi-Sugeno
<b>IHM</b>	: Interface Homme-Machine
<b>IA</b>	: Intelligence Artificielle
<b>LF</b>	: Logique Floue
<b>MCO</b>	: Maintien en Condition Opérationnelle
<b>MCR</b>	: Moindres Carrés Récursifs
<b>MI</b>	: Maintenance Intelligente
<b>NF</b>	: Neuro-Flou
<b>OSA/CBM</b>	: Open System Architecture for Condition Based Maintenance
<b>PHM</b>	: Prognostics and Health Management
<b>RUL</b>	: Remaining Useful Life
<b>RN</b>	: Réseau de Neurones

<b>RP</b>	: Retro-Propagation
<b>SAI</b>	: Système adaptif intelligent
<b>TTF</b>	: Time To Failure
<b>TS</b>	: Takagi-Sugeno

# Publications personnelles

---

- Ces travaux ont fait l'objet de diverses communications. Les publications correspondantes apparaissent comme suit dans ce manuscrit de thèse :

- Chapitre **2** : [7],
  - Chapitre **3** : [1], [2], [4], [6]
  - Chapitre **4** : [3], [5],
- 

## - Journaux internationaux à comité de lecture

[1] - **Mohamed El Koujok**, Rafael Gouriveau, Nouredine Zerhouni. Reducing arbitrary choices in model building for prognostics : an approach by applying parsimony principle on an evolving neuro-fuzzy system. *Microelectronics Reliability Journal*, Available online 12 october 2010, DOI 10.1016/j.microrel.2010.09.014.

## - Conférences internationales avec actes et à comité de lecture

[2] - **Mohamed El Koujok**, Rafael Gouriveau, Nouredine Zerhouni. A Neuro-Fuzzy Self Built System For Prognostics : a Way To Ensure Good Prediction Accuracy by Balancing Complexity and Generalization. *IEEE :Prognostics and System Health Management Conference (PHM)*, Macau, Chine, du 12-14 janvier 2010.

[3] - **Mohamed El Koujok**, Rafael Gouriveau, Nouredine Zerhouni. Error estimation of a neuro-fuzzy predictor for prognostic purpose. *7th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes SAFEPROCESS '09'*, Barcelone, Espagne, du 30 juin au 3 juillet 2009.

[4] - **Mohamed El Koujok**, Rafael Gouriveau, Nouredine Zerhouni. Development of a prognostic tool to perform reliability analysis. *European Safety and Reliability and Risk Analysis Conference, ESREL'08', 17th SRA-EUROPE*, Valence, Espagne, du 22 au 25 septembre 2008.

[5] - **Mohamed El Koujok**, Rafael Gouriveau, Nouredine Zerhouni. From monitoring data to remaining useful life : an evolving approach including uncertainty. *34th ESReDA European Safety Reliability Data Association Seminar and 2nd Joint ESReDA/ESRA Seminar on Supporting Technologies for Advanced Maintenance Information Manage-*

*ment*, Saint-Sebastian, Espagne, du 13 au 14 mai 2008.

[6] - **Mohamed El Koujok**, Rafael Gouriveau, Nouredine Zerhouni. Towards a Neuro-Fuzzy System for Time Series Forecasting in Maintenance Applications. *17th IFAC World Congress*, Séoul, Corée, du 6 au 11 Juillet 2008.

- **Conférences nationales à comité de lecture**

[7] - Rafael Gouriveau, **Mohamed El-Koujok**, Nouredine Zerhouni. Spécification d'un système neuro-flou de prédiction de défaillances à moyen terme. *Rencontres Francophones sur la Logique Floue et ses Applications LFA '2007*, Nîmes, France, du 22 au 23 Novembre 2007.

# Introduction Générale

Actuellement, dans les entreprises, les concepts traditionnels de maintenance préventive et corrective sont peu à peu complétés par de nouvelles formes de maintenance : plutôt que de comprendre *a posteriori* un phénomène qui vient de se manifester (défaillance), il est opportun d'en «anticiper» l'apparition afin de recourir à des actions protectrices en conséquence. Un tel type de maintenance a pour objectif d'assurer la sûreté de fonctionnement des systèmes industriels et d'augmenter leur disponibilité à moindre coût : l'estimation du temps résiduel avant défaillance d'un équipement doit permettre d'éviter des dépenses de maintenance inutiles. Aussi, le pronostic industriel se révèle être une activité clé, prometteuse pour ne pas engager de frais de maintenance inopportuns. Il devient une thématique de recherche à part entière et tend à être de plus en plus visible au sein de la communauté scientifique. A titre illustratif, la «IEEE Reliability Society» vient d'organiser la seconde conférence internationale sur ce thème : Frontiers of Prognostics and Health Management PHM 10, en janvier 2010.

L'objectif principal du pronostic est d'estimer le temps résiduel avant défaillance d'un équipement (*RUL*, Remaining Useful life), indicateur permettant *in fine* d'optimiser les stratégies de maintenance. Pour ce faire, trois approches de pronostic ont été proposées dans la littérature : les approches basées sur un modèle physique, les approches guidées par les données et les approches basées sur l'expérience. Les systèmes industriels étant généralement complexes, il est souvent difficile de construire un modèle formel de pronostic. En revanche, les technologies de mesure (capteurs) permettent aujourd'hui de récupérer en temps réel les données de fonctionnement des équipements.

Par suite, nous avons choisi d'orienter le travail sur une approche guidée par les données. De ce point de vue, le processus de pronostic peut être décomposé en deux sous-activités : la *prédiction* de la dégradation d'un bien, et l'*évaluation* de son état de dégradation. La *prédiction* est ainsi une étape critique du pronostic. Plus encore, il convient d'être à même de caractériser l'erreur de prédiction afin de fiabiliser les décisions découlant du processus de pronostic. C'est ce qui fait l'objet de cette thèse : proposer une méthode de pronostic intégrant une estimation de la confiance en la prédiction. Plus particuliè-

rement, le travail porte sur la construction d'un système prédictif neuro-flou adaptatif, pour lequel aucune hypothèse quant à la structure du modèle n'est nécessaire, et pour lequel l'erreur de prédiction peut être dimensionnée *a priori*. Le mémoire est organisé en quatre chapitres.

**Le premier chapitre** est consacré à l'émergence de l'activité de pronostic dans les stratégies de la maintenance. Nous présentons les nouveaux enjeux industriels qui ont fait évoluer la fonction maintenance. Nous montrons ainsi la mutation de la maintenance traditionnelle vers la maintenance prévisionnelle dans laquelle le pronostic joue un rôle majeur. Le concept de pronostic ainsi qu'un état de l'art des approches du pronostic sont également présentés. Au-delà de la vue d'ensemble (concept et approches), ce chapitre a pour objet de situer et limiter le cadre de nos travaux. Ce cadre est défini par la *prédiction* de l'état d'un bien (un composant) qui se dégrade progressivement, et pour lequel aucune connaissance *a priori* sur sa loi de dégradation n'est disponible.

L'objectif du **deuxième chapitre** consiste à choisir le système prédictif adéquat dans un contexte industriel complexe. Nous introduisons les différentes techniques de prédiction (qualitative et quantitative) et mettons en évidence les contraintes industrielles en limitant l'applicabilités et les performances. Sur cette base, les méthodes de prédiction basées sur les données (ou séries temporelles) sont privilégiées et plus précisément les réseaux adaptatifs. L'analyse bibliographique fait apparaître les réseaux de neurones comme étant l'une des plus avantageuses des ces méthodes. Nous proposons un historique de l'utilisation des réseaux de neurones pour la prédiction. Il en ressort que les réseaux neurones, malgré leur capacité à apprendre des séries temporelles non-linéaires, présentent de meilleures performances lorsqu'ils sont associés à la logique floue. Notre choix se porte ainsi sur l'utilisation des réseaux neuro-flous de type Takagi-Sugeno (TS) comme outil de prédiction de séries temporelles non-linéaires et dynamiques. Nous sélectionnons et présentons un algorithme évolutif pour apprendre les paramètres d'un tel réseau.

**Le troisième chapitre** vise à générer un système prédictif adéquat tout en minimisant l'influence de l'intervention humaine. L'algorithme évolutif choisi présente l'intérêt d'adapter à la fois la structure et les paramètres du système prédictif (neuro-flou Takagi-Sugeno) en ligne, à mesure que de nouvelles données sont disponibles. En revanche, l'absence de connaissance *a priori* rend difficile le choix des entrées du système prédictif par l'homme. Ainsi, dans ce chapitre, nous proposons une procédure d'identification d'un système de type Takagi-Sugeno basée sur un critère de parcimonie. L'objectif est de trouver un modèle réalisant un compromis entre complexité et performance de prédiction, et permettant de s'affranchir de l'intervention humaine. Nous illustrons cette procédure et validons le choix de l'exTS (evolving eXtended Takagi-Sugeno) comme outil de prédiction par des exemples numériques.

**Le quatrième chapitre** porte sur l'intégration de la confiance au système prédictif dans l'objectif d'estimer le *RUL* (Remaining Usful life - objectif du pronostic). Ce chapitre

est naturellement basé sur l'utilisation du modèle prédictif choisi au chapitre II et pour lequel une procédure de génération automatique visant à obtenir un compromis complexité/performance de prédiction a été proposée au chapitre III. Nous proposons dans ce chapitre une méthode visant à estimer l'erreur de prédiction *a priori* afin de construire un intervalle de confiance pour borner la date de défaillance. L'approche est basée sur l'adaptation de méthodes statistiques de construction d'intervalles de confiance pour les systèmes linéaires. Nous validons finalement cette proposition par des simulations numériques relatives au pronostic de défaillance d'un circuit imprimé.

Dans une **conclusion générale**, nous repositionnons l'ensemble de nos développements au regard de l'objectif initial de l'étude : "*Contribution au pronostic industriel : intégration de la confiance à un modèle prédictif neuro-flou*". Nous résumons les principaux résultats de notre travail et nous abordons enfin une discussion sur les perspectives de travail qui découlent de cette thèse.



Chapitre **I**

## **Le pronostic industriel**

## I.1 Introduction

L'un des enjeux les plus importants de l'industrie concerne aujourd'hui la sûreté de fonctionnement des systèmes industriels et la recherche de l'augmentation de leur disponibilité à moindre coût. Aussi, l'activité de maintenance prend une part croissante dans les entreprises et tend à évoluer pour des besoins de réactivité et de coût notamment. Une évolution particulière porte sur la manière d'appréhender les phénomènes de défaillance : peu à peu les industriels tendent, non seulement à les anticiper afin de recourir à des actions préventives, mais en plus à le faire de manière la plus juste possible dans un objectif de réduction des coûts et des risques. Cette évolution a donné une part grandissante au processus de pronostic qui est aujourd'hui considéré comme un des principaux leviers d'action dans la recherche d'une performance globale.

Ce chapitre vise à présenter l'émergence du pronostic, à décrire en quoi il vient compléter les activités traditionnelles de maintenance, et à décrire les bénéfices pouvant être attendus de la mise en œuvre de systèmes de pronostic dans l'industrie. De manière plus ciblée, le concept de pronostic ainsi que les outils et techniques de pronostic sont également présentés. L'ensemble permet de montrer la diversité des approches envisageables et de définir un cadre de travail plus restreint pour cette thèse.

## I.2 Émergence du pronostic dans l'activité de maintenance

### I.2.1 La maintenance industrielle : définitions et prérogatives

#### I.2.1.1 *Maintenance et sûreté de fonctionnement*

Selon la norme [NFE01] la maintenance peut être définie comme :

*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.*

La maintenance industrielle comprend ainsi un ensemble d'actions de dépannage, de réparation, de contrôle et de vérification des équipements matériels, et doit contribuer à l'amélioration des processus industriels. Dans la vision traditionnelle, la fonction maintenance permet de garantir les caractéristiques de sûreté de fonctionnement des matériels, notamment la disponibilité. Selon la norme [NFE01] les principaux termes permettant d'en apprécier l'objectif sont les suivants.

*Sûreté de fonctionnement : ensemble des propriétés qui décrivent la disponibilité et les facteurs qui la conditionnent : fiabilité, maintenabilité, et logistique de maintenance.*

*Disponibilité* : aptitude d'un bien à être en état d'accomplir une fonction requise dans des conditions données, à un instant donné ou durant un intervalle de temps donné, en supposant que la fourniture des moyens extérieurs nécessaires est assurée.

*Bien* : tout élément, composant, mécanisme, sous-système, unité fonctionnelle, équipement ou système qui peut être considéré individuellement.

*Fiabilité* : aptitude d'un bien à accomplir une fonction requise, dans des conditions données, durant un intervalle de temps donné.

*Défaillance* : cessation de l'aptitude d'un bien à accomplir une fonction requise.

Ainsi, la maintenance vise globalement à appréhender les phénomènes de défaillance et à agir en conséquence, afin d'assurer que le système (le bien) soit à même de remplir la fonction pour laquelle il a été conçu (Maintien en Condition Opérationnelles, MCO). Mais, les missions de la fonction maintenance ne se limitent plus à la mise en œuvre des moyens permettant d'assurer le «service des biens». Des exigences de qualité, de sécurité et de coût sont apparues, et les enjeux et prérogatives de la fonction maintenance ont évolué ces vingt dernières années.

### **I.2.1.2 Nouveaux enjeux et évolutions de la fonction maintenance**

#### *A- Nouveaux enjeux*

Le contexte industriel actuel permet d'expliquer l'évolution de la fonction maintenance. D'abord, les équipements industriels sont de plus en plus complexes, et donc exigent une compétence en maintenance accrue. Ensuite, l'entreprise évolue dans un environnement concurrentiel fort et les préoccupations financières sont très prononcées. La maintenance n'échappe ainsi pas à la règle de réduction des coûts. A un autre niveau, depuis quelques années, les responsables industriels sont devant des contraintes environnementales et sociales plus marquées. Il n'est plus suffisant de se satisfaire d'une performance technique et économique, mais il devient nécessaire, voire obligatoire, de prendre en compte les «contraintes» environnementales : une usine laisse des déchets, pollue et contribue à l'effet de serre. A ceci s'ajoute le respect de la dignité humaine qui constitue une contrainte sociale. Ces derniers aspects ont récemment conduit à l'élaboration de textes de loi qui incitent fortement les entreprises à intégrer la notion de développement durable dans leur stratégie [EUR01]. Cela se traduit concrètement par la recherche d'une triple performance où certes le rendement de l'entreprise reste indispensable, mais auquel s'ajoutent de nouvelles exigences sur le plan humain/social et environnemental [Rey03] (figure I.1).

Les prérogatives de la fonction maintenance se sont ainsi étendues :

- elle vise à augmenter la disponibilité des équipements tout en réduisant les coûts directs d'exploitation (technique et économique),
- elle doit assurer un fonctionnement sûr des équipements, c'est à dire permettre d'éviter les accidents jugés néfastes pour l'environnement (environnemental),

- elle est garante de conditions de travail satisfaisantes et de la sécurité des hommes (social).

La fonction maintenance a du évoluer en regard de ces enjeux croissants.

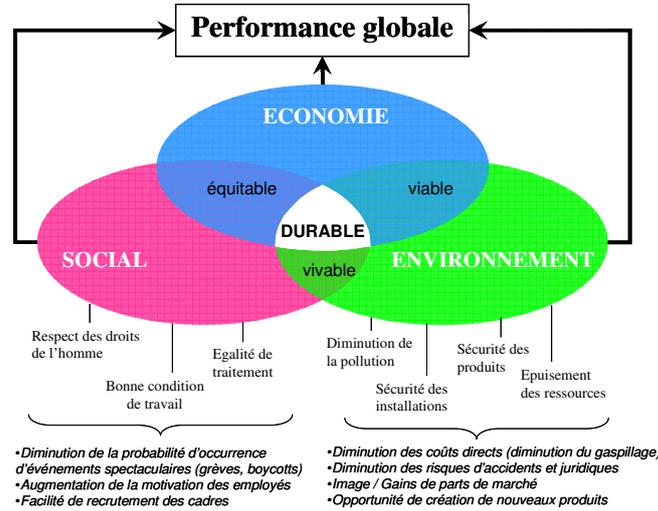


FIG. I.1 – Performance globale de l'entreprise [Rey03]

### B- Évolutions de la fonction maintenance

Compte tenu des exigences chaque fois plus grandes, les coûts de maintenance ont augmenté rapidement au cours des dernières années. A titre d'exemple, on estime que les coûts de maintenance aux États-Unis étaient de 200 milliards de dollars en 1979, et qu'ils ont subi une croissance de l'ordre de 10% à 15% dans les années qui suivirent [Ben04]. Une partie importante de ce coût de maintenance pourrait pourtant être évitée : une mauvaise planification se traduit par du gaspillage en heures supplémentaires de maintenance, et cela éventuellement sur des équipements qui n'ont pas un grand rôle dans la continuité de la production.

Cette augmentation des coûts ne justifie pas à elle seule le besoin de remettre en cause les approches traditionnelles de maintenance. D'abord, les systèmes de production évoluent en permanence et de nouvelles techniques de production sont apparues, notamment du fait de l'automatisation (les machines pouvant assurer la production sans intervention humaine). Ensuite, les entreprises cherchent davantage à adapter rapidement la quantité et la qualité de la production en fonction de la variation de la demande des clients, ce qui nécessite un haut niveau de flexibilité des équipements industriels. Par conséquent, même si l'activité de maintenance est aujourd'hui considérée comme une activité à part entière, les entreprises n'hésitent plus à l'externaliser afin de bénéficier des compétences métiers fortes de prestataires de service [Tar05]. Cette évolution est en grande partie due

au développement des sciences et technologies de l'information et de la communication (STIC). A un autre niveau, depuis quelques années, de nouvelles architectures de maintenance sont apparues (figure I.2), [Ras06], la plus récente étant celle de s-maintenance («s» pour sémantique). Cette dernière englobe le concept de e-maintenance et se base sur le principe de partage et de génération de connaissances formalisées en ontologie [KMCZ09].

Mais en amont du développement d'architectures de maintenance visant à réduire la distance entre acteurs, ce sont les stratégies de maintenance elles-mêmes qui évoluent. En effet, les mainteneurs souhaitent aujourd'hui aller au delà de la maintenance statique (sans anticipation de l'évolution de l'état des équipements), et mettre en œuvre des stratégies de maintenance plus «dynamiques». La section suivante est consacrée à l'analyse de cette évolution.

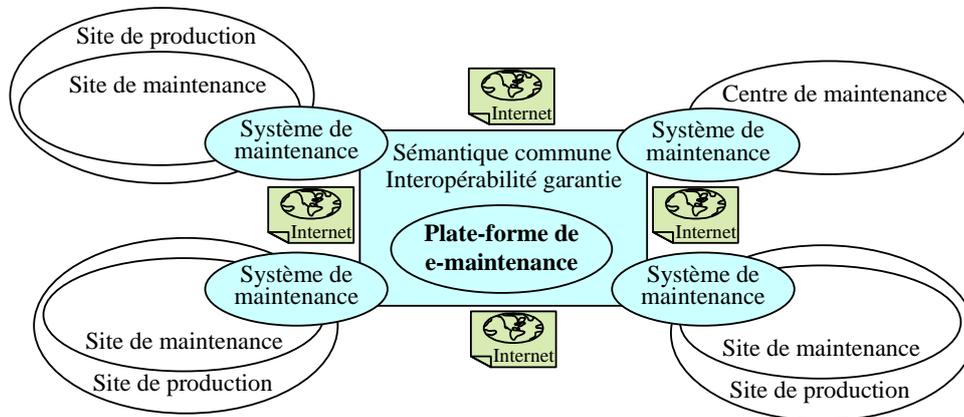


FIG. I.2 – Architecture du concept de s-maintenance [Ras06]

## I.2.2 Vers une anticipation des phénomènes de défaillance

### I.2.2.1 Cartographie des formes de maintenance

Avant les années 60, le service maintenance d'une entreprise avait pour principale mission d'intervenir sur les équipements en panne afin de les réparer le plus tôt possible. Ce type de maintenance, dite corrective, a ensuite été peu à peu complété par une approche plus anticipative des phénomènes de défaillance, c'est à dire par une maintenance réalisée avant que la défaillance ne se produise. Cette deuxième forme de maintenance, dite préventive, a été initialement mise en œuvre lors du développement du Boeing 747 en 1960 [Ben04].

Ces deux grands types de maintenance, corrective et préventive, présentent certaines variantes exposées ci-après. La figure I.3 en donne une articulation globale [NFE01].

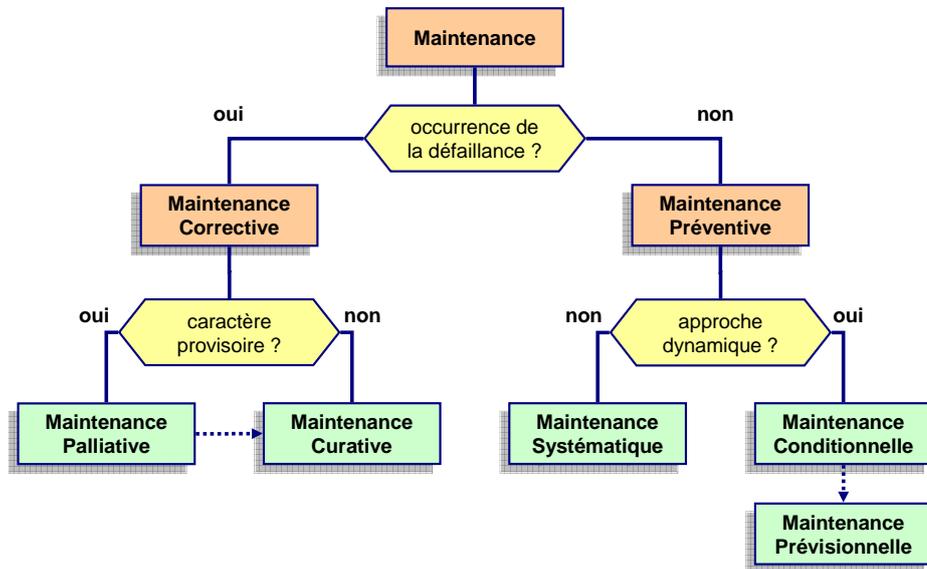


FIG. I.3 – Formes de maintenance [NFE01]

### I.2.2.2 Maintenances corrective et préventive

#### A- La maintenance corrective

La norme [NFE01] définit la maintenance corrective comme une :

*maintenance exécutée après détection d'une panne et destinée à remettre un bien dans un état dans lequel il peut accomplir une fonction requise.*

La maintenance corrective est généralement adoptée pour les équipements pour lesquels :

- les conséquences de la panne ne sont pas critiques,
- la réparation est facile et ne nécessite pas beaucoup de temps,
- les coûts d'investissements sont faibles.

Deux formes de maintenance correctives peuvent être distinguées. Lorsque l'intervention de maintenance a un caractère provisoire, on parle de *maintenance palliative*. Si les travaux sont définitifs, on parle de *maintenance curative*.

#### B- La maintenance préventive

La maintenance préventive vise à réduire les risques d'occurrence d'une défaillance. La norme [NFE01] la définit comme suit :

*maintenance exécutée à des intervalles prédéterminés ou selon des critères prescrits et destinée à réduire la probabilité de défaillance ou la dégradation du fonctionnement d'un bien.*

Lorsque l'intervention de maintenance est exécutée à intervalles fixes et prédéfinis, on parle de *maintenance préventive systématique*. Ce type de maintenance est déclenché suivant un échéancier (heures de travail, kilomètres effectués, etc.) et se traduit par le remplacement périodique de pièces, sans contrôle préalable et quelque soit l'état de dégradation des biens.

La maintenance préventive systématique peut conduire à du sur-entretien c'est à dire à un excès d'interventions inutiles, et donc à des gaspillages financiers pour l'entreprise. Pour palier cela, d'autres formes de maintenance préventive, basées sur la surveillance de l'état réel des biens sont apparues : les *maintenances conditionnelle et prévisionnelle*.

### **I.2.2.3** *Maintenances conditionnelle et prévisionnelle*

La maintenance conditionnelle est définie selon la norme [NFE01], comme :

*une maintenance préventive basée sur une surveillance du fonctionnement du bien et/ou des paramètres significatifs de ce fonctionnement intégrant les actions qui en découlent.*

Cette stratégie de maintenance repose ainsi sur l'analyse des données en temps réel des équipements industriels (par exemple les vibrations, la température, etc.). Elle vise la détection d'anomalies dans le fonctionnement des machines industrielles : la découverte de changements dans leurs caractéristiques préfigure à court terme d'une défaillance à venir.

La maintenance conditionnelle permet de mieux tenir compte des conditions d'utilisation d'un équipement que la maintenance systématique traditionnelle. Ceci étant, elle ne permet pas de dimensionner avec certitude les politiques de maintenance : la date d'occurrence de la défaillance reste incertaine. La maintenance prévisionnelle vise à palier ce manque de connaissance. Elle est définie comme suit [NFE01] :

*la maintenance prévisionnelle est une maintenance conditionnelle exécutée en suivant les prévisions extrapolées de l'analyse et de l'évaluation de paramètres significatifs de la dégradation du bien.*

L'idée est de projeter l'état actuel du bien dans le futur, afin d'estimer le temps de fonctionnement avant la défaillance, et donc de mieux dimensionner les politiques de maintenance. La maintenance prévisionnelle est ainsi plus dynamique. Elle prend en compte les conditions actuelles des équipements et tente de prévoir l'évolution dans le temps de l'état des biens. Les interventions de maintenance étant planifiées avec davantage de précision, la maintenance prévisionnelle doit permettre de faire des économies

substantielles et fait l'objet d'une attention grandissante depuis quelques années. Les bénéfices attendues sont effectivement nombreux :

- réduction du nombre des pannes,
- fiabilisation des productions,
- amélioration de la sécurité du personnel et de l'image de l'entreprise,
- réduction des périodes d'immobilisation des équipements (coûteuses),
- augmentation du rendement de l'entreprise.

La section suivante présente les grandes lignes de cette stratégie et permet de souligner l'importance du **pronostic** dans cette démarche.

### I.2.3 Maintenance prévisionnelle et pronostic

#### I.2.3.1 *Diagnostic vs pronostic*

L'activité de maintenance fait traditionnellement appel à différents processus métiers visant d'abord, à « percevoir » certains phénomènes (détection), ensuite, à les « comprendre » (diagnostic), et enfin, à « agir » en conséquence (choix d'actions de maîtrise). Aussi, plutôt que de comprendre *a posteriori* un phénomène qui vient de se manifester (défaillance), il peut être opportun d'en « anticiper » l'apparition afin de recourir à des actions protectrices en conséquence : c'est ce qui peut être entendu sous l'étiquette « pronostic de défaillances ». Le positionnement relatif de ces processus de « détection », « diagnostic » et « pronostic » est schématisé sur la figure I.4.a. D'un point de vue phénoménologie, leur complémentarité peut être expliquée comme suit [MZ09] (figure I.4.b) :

- la **détection** vise à identifier le mode de fonctionnement du système, son état,
- lorsqu'une défaillance est apparue, le **diagnostic** permet d'isoler et d'identifier le composant qui a cessé de fonctionner (propagation arrière : des effets vers les causes),
- le **pronostic** vise la prédiction des états futurs du système (propagation avant : des causes vers les effets).

Ainsi, les principales activités de maintenance industrielle énumérées ici se complètent parfaitement (ce point est légèrement développé par la suite). Elles reposent cependant naturellement sur une bonne compréhension des phénomènes de défaillances. Ceci peut être délicat lorsque la dynamique des équipements est marquée ou lorsque leurs conditions d'utilisation sont variables : la modélisation des phénomènes peut parfois être difficilement assurée par un expert et il convient d'instrumenter les systèmes afin de recueillir des données terrains permettant à terme de déployer les différents processus de maintenance. Aussi, il apparaît que le processus de pronostic, bien qu'indispensable pour déployer une stratégie de maintenance prévisionnelle (des causes vers les effets), ne doit pas être considéré de manière isolée, mais doit être vu comme une partie d'un processus plus global.

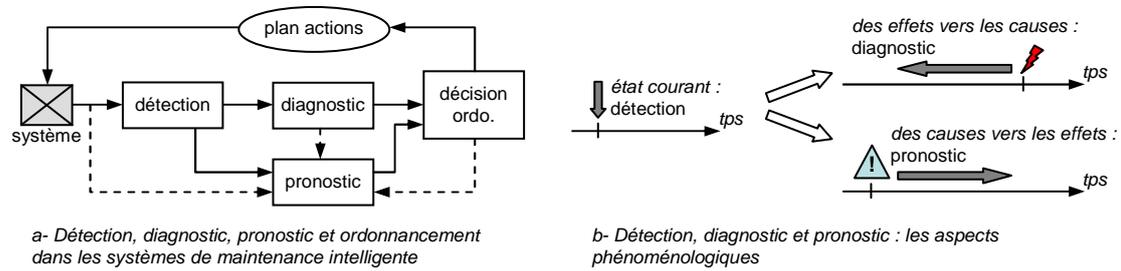


FIG. I.4 – Complémentarité des activités de détection, diagnostic et pronostic

### I.2.3.2 Architecture CBM

La nécessité d'une maintenance prévisionnelle forme désormais l'unanimité, et elle fait l'objet d'un intérêt grandissant dans la communauté scientifique. Un grand nombre de travaux sont ainsi apparus récemment pour proposer des architectures de maintenance prévisionnelle complètes, intégrant les activités traditionnelles de maintenance telles que la surveillance, le diagnostic et la logistique de maintenance ([LT01], [VW01], [DLN03], [CB04], [Orc07], [Ald07]).

Dans ces travaux, les différences n'apparaissent qu'à un niveau de détail relativement petit, et portent essentiellement sur la forme des architectures logicielles à mettre en œuvre (locale, distribuée, par modules, etc). Dans l'ensemble, l'architecture proposée par [LT01] et diffusée par le groupe MIMOSA<sup>1</sup> s'avère fédératrice. Il s'agit de la OSA/CBM (Open System Architecture for Condition Based Maintenance). Cette architecture est constituée de 7 couches fonctionnelles pouvant être considérées comme séquentielles (figure I.5) ou distribuées dans un réseau (figure I.6).

**Couche 1** Module capteurs. Ce module fournit au système des données numériques issues de capteurs ou de transducteurs.

**Couche 2** Module traitement du signal. Ce module reçoit les données à partir des capteurs ou transducteurs ou d'autres processeurs de signaux et réalise des transformations de signaux et des extractions de caractéristiques ou de descripteurs.

**Couche 3** Module de surveillance. Le module de surveillance compare les données en ligne avec certaines valeurs attendues ou connues ; il doit également être capable de générer des alertes en fonction de seuils préalablement fixés.

**Couche 4** Module de diagnostic. Ce module détermine si l'état du système, sous-système ou composant surveillé est dégradé ou non et suggère les défaillances probables.

<sup>1</sup>[www.mimosa.org](http://www.mimosa.org). Mimosa est une association à but non lucratif visant à développer et à encourager l'utilisation d'architectures de données ouvertes. Le consortium Mimosa a notamment proposé un standard d'architecture de données pour supporter les stratégies de maintenance conditionnelle et prévisionnelle (OSA-CBM).

**Couche 5** Module de pronostic. Ce module prédit l'état futur du système, sous-système ou composant surveillé. Le module s'appuie sur les données issues des modules précédents.

**Couche 6** Module d'aide à la décision. Sa fonction principale est de recommander des actions de maintenance ou d'autres alternatives pour continuer à faire fonctionner le système jusqu'à l'accomplissement de sa mission.

**Couche 7** Module de présentation. Ce module reçoit les informations de tous les modules précédents. Il peut être construit sous forme d'une IHM (Interface Homme-Machine).

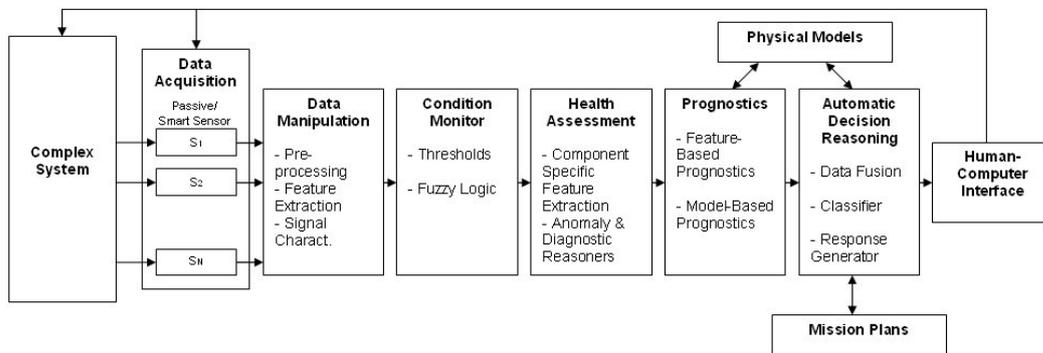


FIG. I.5 – Architecture OSA/CBM séquentielle [LT01]

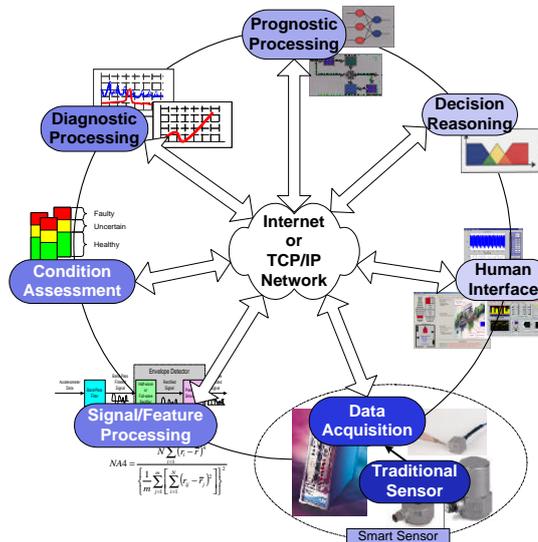


FIG. I.6 – Architecture OSA/CBM distribuée [LRB03]

En synthèse, l'anticipation des défaillances nécessaire pour une stratégie de maintenance prévisionnelle ne peut se faire que si les phénomènes de dégradation sont correctement appréhendés (acquisition de données, extraction de descripteurs, détection/surveillance, diagnostic). Aussi, le pronostic n'est pas une fin en soi. Il doit en revanche permettre de mettre en œuvre des politiques de réaction adéquates (aide à la décision).

## I.3 Le pronostic industriel

### I.3.1 Quoi : définition et mesures

#### I.3.1.1 *Le concept de pronostic*

Il y a longtemps que l'homme cherche à anticiper les phénomènes dans l'objectif de voir aboutir ses projets sans risque d'échec. Aussi, le terme pronostic provient du grec «*progignôskein*» signifiant «*connaître à l'avance*». Il a ensuite été essentiellement utilisé en médecine où il désigne une prévision établie suite à un diagnostic : le pronostic médical porte d'une part sur l'évaluation du degré de gravité d'une pathologie, et d'autre part, sur l'estimation de l'évolution ultérieure de la maladie. Dernièrement, ce terme a été transposé au monde industriel. Le patient est «*remplacé*» par une machine ou une installation industrielle et l'objectif est de prédire l'état de fonctionnement futur de l'équipement concerné. C'est à ce cadre là que nous nous intéressons.

Beaucoup de définitions du terme pronostic ont été proposées ([MCP+01], [WV99], [BRKG02], [MSI03]) et il n'en existe pas de totalement consensuelle. Un trait marquant peut cependant être identifié : le pronostic est souvent assimilé à un processus de prédiction (une situation future doit être appréhendée). Par suite, deux grandes acceptations du pronostic peuvent être considérées comme fédératrices : le pronostic désigne selon les cas un processus visant à déterminer la durée de vie restante d'un système, c'est à dire son *RUL* (Remaining Useful Life) [JLB06] (figure I.7.a), ou la probabilité pour que le système fonctionne durant un certain temps [LM03] (figure I.7.b).

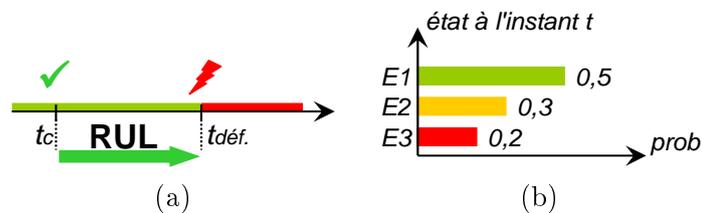


FIG. I.7 – (a) Le pronostic comme l'estimation du *RUL* , (b) de probabilités d'états

Le pronostic est généralement efficace pour les modes de défaillance présentant des caractéristiques de détérioration connues, liées à l'âge ou progressives, les plus simples étant linéaires. Une défaillance doit donc être définie en termes de paramètres ou de descripteurs surveillés. Ceci suppose évidemment que la situation courante peut être saisie (pratiquement, le pronostic est la synthèse d'un procédé de détection et des données mesurées du système). Par ailleurs, le concept même de défaillance implique que le pronostic doit être associé à un degré d'acceptabilité (un système doit exécuter une fonction exigée). Nous considérons ainsi que le pronostic devrait être basé sur les critères d'évaluation, dont les limites dépendent du système lui-même et des objectifs d'exécution. Tout ceci nous conduit à retenir la définition proposée par la norme [ISO04] :

*le pronostic est l'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.*

Notons que le diagnostic est, par nature, rétrospectif et focalisé sur des données existant à un instant donné. Cependant, le pronostic est focalisé sur l'avenir et, de ce fait, doit prendre en compte les aspects suivants [ISO04] :

- les modes de défaillance existants et les taux de détérioration,
- les critères de déclenchement de futurs modes de défaillance,
- le rôle des modes de défaillance existants dans le déclenchement de futurs modes de défaillance,
- l'influence entre les modes de défaillance existants et les modes futurs et leurs taux de détérioration,
- la sensibilité à la détection et aux modifications des modes de défaillance existants et futurs du fait des techniques de surveillance actuelles,
- la conception et les changements de stratégies de surveillance afin de s'adapter à tous les éléments ci-dessus,
- l'effet des actions de maintenance et/ou des conditions d'exploitation,
- les conditions ou les hypothèses dans lesquelles les pronostics restent valables.

### **I.3.1.2 Métriques du pronostic**

La définition d'un ensemble de métriques appropriées pour des applications de pronostic fait l'objet de travaux de chercheurs ainsi que d'industriels travaillant dans le domaine de la CBM [VLR+06]. Plusieurs mesures émergent de la littérature et sont présentées ci-après.

Deux classes de métriques au moins sont d'intérêt [DGZ08] :

1. l'objectif principal du pronostic est de fournir l'information permettant de prendre de bonnes décisions, c'est-à-dire le choix d'actions de maintenance. Ainsi, un premier ensemble de métriques est celui qui permet de quantifier les risques encourus

par le système surveillé. Ce type de métriques correspond aux **mesures de pronostic**,

2. compte tenu que le pronostic est par essence un processus incertain, il est intéressant de pouvoir juger de sa qualité dans le but d'imaginer des actions plus adéquates. Dans ce sens, plusieurs indicateurs peuvent être construits. Ce sont les **mesures de performance du système de pronostic**.

#### A- Mesures de pronostic

Comme mentionné précédemment, la principale métrique de pronostic recherchée est le temps restant avant défaillance (appelé en anglais Time To Failure :  $TTF$  ou encore  $RUL$ ). En outre, une mesure de confiance peut être construite pour indiquer le degré de certitude du temps avant défaillance prédit. Par extension, et en considérant que les utilisateurs peuvent être intéressés par l'évaluation du système au regard de limites de performance, le  $RUL$  et la confiance peuvent être généralisés : sur la figure I.8,  $TT_{xx}$  est le temps restant pour dépasser la limite de performance  $Perf/xx$ , et  $Conf/xxT$  est la confiance avec laquelle l'indication  $TT_{xx}/T > T$  peut être prise.

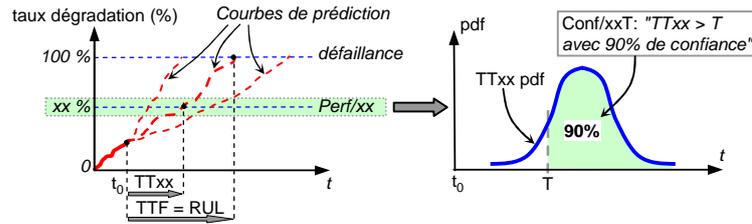


FIG. I.8 – Mesures de pronostic :  $RUL$  et confiance

#### B- Mesures de performances du système de pronostic

##### Accuracy (exactitude)

«L'accuracy» mesure la proximité de la date de défaillance prévue avec la date de défaillance réelle. Le calcul de cette métrique représente un point critique dans le processus de pronostic. Le calcul de cette grandeur s'appuie sur l'existence de données historiques sur plusieurs composants tombés en panne suite à des sollicitations subies tout au long d'une période de temps connue, ce qui n'est pas toujours possible (matériel unique).

Si un ensemble de  $N$  systèmes sont tombés en panne (avec les pronostics associés), l'exactitude est définie comme suit [VLR<sup>+</sup>06].

$$Accuracy = \frac{1}{N} \sum_{i=1}^N e^{-\frac{D_i}{D_0}} \quad (I.1)$$

Avec,

$$- D_i = |\hat{t}_{fail}(i) - t_{fail}(i)| \text{ la distance entre les instants prévus et réels de défaillance,}$$

- $D_0$  une constante de normalisation dont la valeur est basée sur l'importance de la valeur réelle dans l'application.

La fonction exponentielle est employée ici pour donner une courbe lisse monotoniquement décroissante. La valeur de  $e^{\frac{D_i}{D_0}}$  représente la décroissance de l'exactitude. Autrement dit, l'exactitude est grande (proche de 1) quand la valeur prévue est identique à la valeur réelle et diminue quand la valeur prévue dévie de la valeur réelle. La fonction exponentielle a également le taux de décroissance le plus grand quand  $D_0$  est proche de 0. Une illustration de cette métrique est proposée en figure I.9.a.

### *Precision*

La précision est une mesure de dispersion des prédictions. Elle permet d'évaluer comment les valeurs prédites sont groupées autour de l'intervalle dans lequel survient la défaillance (figure I.9.a). La précision dépend fortement du niveau de confiance et de la distribution des prédictions. L'équation de précision est la suivante :

$$Precision = \left( \frac{1}{N} \sum_{i=1}^N e^{-\frac{R_i}{R_0}} \right) e^{\frac{\sigma^2}{\sigma_0}} \quad (I.2)$$

Avec,

- $E_i = \hat{t}_{fail}(i) - t_{fail}(i)$ ,
- $\bar{E} = \frac{1}{N} \sum_{i=1}^N E_i$ , et  $\sigma^2 = \frac{1}{N} \sum_{i=1}^N (E_i - \bar{E})^2$ ,
- $\sigma_0$  et  $R_0$  des facteurs de normalisation, et  $R_i$  l'intervalle de confiance de la prédiction pour l'expérimentation  $i$ .

De même, une fonction exponentielle est employée ici pour définir les relations entre l'écart type de la prédiction, l'intervalle de confiance et la précision. La précision a une valeur entre 1 et 0 (1 indiquant la précision la plus élevée et 0 la plus basse). La complémentarité de l'exactitude et de la précision est illustrée dans la figure I.9.a.

### *Timeliness*

Le timeliness est la position relative de la fonction de densité de probabilité (pdf : probability density function) du modèle de pronostic par rapport à l'apparition de l'événement de défaillance. Cette mesure évolue à mesure que les données sont disponibles et permet de juger du moment adéquat pour effectuer la maintenance (figure I.9.b). [GB05] préconise de définir des limites au plus tôt et au plus tard au delà desquelles la valeur prédite doit être considérée comme inacceptable d'un point de vue performance. Ces deux limites sont la conséquence du fait que l'erreur de prédiction n'est pas systématiquement centrée par rapport à zéro (où l'erreur est définie comme la différence entre la vie restante réelle et la vie restante estimée). Par exemple, si la prédiction est «trop tôt», l'alarme résultante sollicite trop tôt l'intervention pour vérifier le potentiel d'apparition d'une défaillance, pour surveiller les diverses variables de processus et pour effectuer une modalité de reprise. Dans l'autre cas, si la défaillance est prévue «trop tard», cette erreur réduit

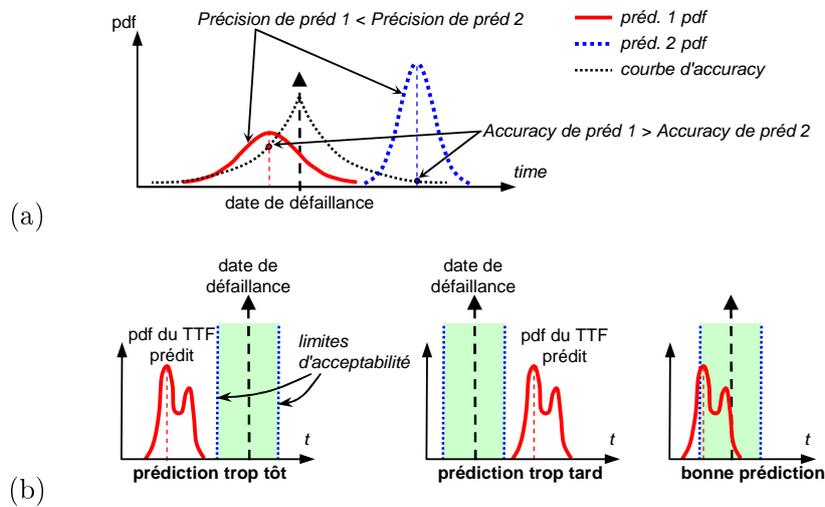


FIG. I.9 – Mesures de performances du système de pronostic : (a) «accuracy» et «précision», (b) «timeliness»

le temps disponible pour évaluer la situation et réagir en conséquence. La situation devient catastrophique quand la défaillance se produit avant qu'une prévision ne soit faite. Par conséquent, il est dans la plupart des situations préférable d'avoir une polarisation positive des erreurs (prévisions tôt), plutôt que négative (prévisions en retard). Naturellement, il est nécessaire de définir des limites d'acceptabilité pour le *timeliness* (trop tôt, ou trop tard) (figure I.9.b). Toute prédiction en dehors des limites est considérée comme inappropriée.

### I.3.2 Comment : les approches du pronostic

#### I.3.2.1 Classification des approches de pronostic

De nombreux outils et méthodes de pronostic de défaillance ont été proposés durant la dernière décennie. Les méthodes de pronostic diffèrent généralement par le type d'application considérée, alors que les outils mis en œuvre dépendent principalement de la nature des données et connaissances disponibles pour construire un modèle de comportement du système réel incluant le phénomène de la dégradation. Aussi, ces méthodes et outils peuvent être regroupés dans un nombre limité d'approches.

Le premier classement des approches de pronostic a été proposé par [LT01]. Dans leur papier, les auteurs suggèrent une classification pyramidale à trois niveaux des approches de pronostic (figure I.10) : les approches basées sur l'expérience, les approches guidées par les données, et les approches basées sur les modèles. Pour dissocier ces trois types

approches, les critères suivants sont considérés : le coût et la complexité de mise en œuvre, la précision des résultats obtenus, et l'applicabilité des approches.

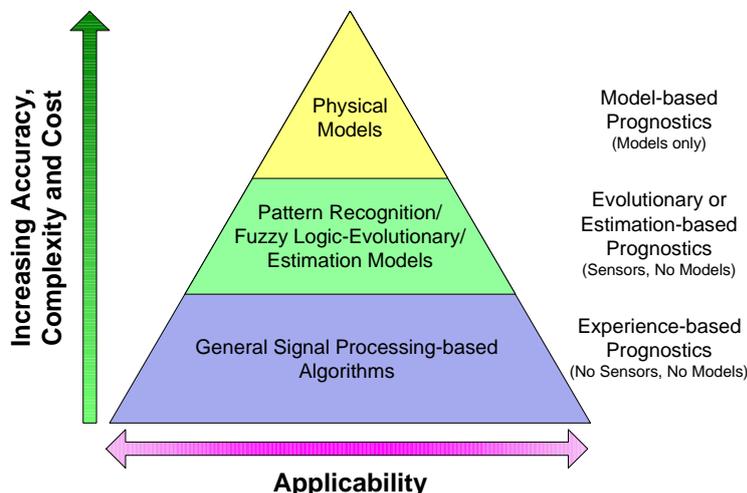


FIG. I.10 – Taxonomie des approches de pronostic [LT01]

En 2006, [JLB06] a proposé une nouvelle taxonomie des méthodes de pronostic, en distinguant deux grandes catégories de méthodes. La première regroupe les méthodes portant sur l'estimation de l'état futur du composant, sous-système, ou système (estimation du *RUL* ou du *TTF*), et la seconde catégorie concerne les méthodes permettant de déterminer le *RUL* tout en intégrant le contexte de fonctionnement du système (actions de maintenance et conditions d'exploitations).

Récemment, [HM09] a proposé une nouvelle classification basée sur les trois approches suggérées par [LT01] auxquelles a été ajoutée une quatrième classe qualifiée «d'intégrée». Les auteurs suggèrent alors de considérer les approches de pronostic selon le type de données et de connaissances disponibles. En ce qui concerne le premier type d'approches, ils proposent de regrouper les méthodes qui utilisent les données de retour d'expérience. Le deuxième type d'approches correspond aux méthodes qui emploient les données de surveillance (principalement celles fournies par des capteurs installés sur le système) comme informations d'entrée des algorithmes de pronostic. Ces méthodes peuvent être divisées en deux sous-catégories, celles fondées sur des modèles mathématiques et celles exploitant exclusivement les données de surveillance. Le dernier type d'approches correspond aux méthodes fusionnant des données de fiabilité et de surveillance.

La classification des approches de pronostic n'est pas une fin en soi et il apparaît que la vision pyramidale de [LT01] fait aujourd'hui référence. Nous choisissons ainsi pour la suite de distinguer les approches basées sur un modèle physique, les approches guidées

par les données, et les approches basées sur l'expérience.

De point de vue applicatif, les informations requises pour déployer les approches de pronostic sont de nature diverses : modèles d'ingénierie, données, historiques de défaillance, sollicitations du système, conditions de fonctionnement, etc. [LT01] donne une généralisation de ce que pourrait être l'ensemble des entrées et sorties d'un modèle de pronostic. Les principales entrées et leur intérêt dans chacune des 3 approches de pronostic peuvent être schématisé tel que proposé dans le tableau I.1 [RBKV05]. Bien entendu, les sorties attendues sont essentiellement celles permettant de juger de l'état futur de système, c'est à dire les métriques présentés en section I.3.1.2.

	<b>Approches</b>		
	<b>Basée sur les modèles</b>	<b>Guidées par les données</b>	<b>Basées sur l'expérience</b>
<b>Modèle du système</b>	Nécessaire	Utile	Pas nécessaire
<b>Historique des défaillances</b>	Utile	Pas nécessaire	Nécessaire
<b>Conditions passés</b>	Nécessaire	Pas nécessaire	Utile
<b>Conditions actuelles</b>	Nécessaire	Nécessaire	Utile
<b>Méthodes de reconnaissance des défaillances</b>	Nécessaire	Nécessaire	Pas nécessaire
<b>Historique de maintenance</b>	Utile	Pas nécessaire	Utile
<b>Général</b>	Capteurs et modèle	Capteurs, pas de modèle	Pas de capteur, pas de modèle

TAB. I.1 – Approches de pronostic et type d'information nécessaire [RBKV05]

### **I.3.2.2 Approches basées sur un modèle physique**

La mise en œuvre de ce type d'approches s'appuie généralement sur une représentation mathématique du mécanisme de dégradation. Les relations causales issues des lois de la physique sont utilisées pour modéliser les interactions entre les entités du système. Ainsi, les résidus sont employés comme instruments mathématiques. De gros résidus dénotent la présence de défauts de fonctionnement, et des petits la présence de perturbations normales comme les bruits ou les erreurs de modélisation. L'utilisation de méthodes de pronostic basées sur un modèle implique des connaissances spécifiques liées à la défaillance ainsi qu'au mode de fonctionnement du système analysé.

### *A- Principe de fonctionnement, avantages et inconvénients*

Le principe du pronostic basé sur les modèles physiques est de déterminer le niveau de dégradation courant du système (grâce aux processus de surveillance et de diagnostic) et d'évaluer le temps restant avant la défaillance en utilisant la courbe d'évolution de la dégradation en fonction de la sollicitation du système.

Les principaux avantages de cette approche sont :

- la flexibilité : si une des propriétés du système ou de la dégradation change, le modèle peut être réajusté pour prendre en compte cette modification,
- l'interprétabilité : la connaissance de la structure du modèle permet de relier la variation d'indicateurs à une modification de paramètre.

Les principaux inconvénients du pronostic basé sur les modèles physiques sont :

- le développement des modèles est extrêmement coûteux. Cela nécessite un niveau de qualification élevé et une expérience certaine,
- il est difficile de construire un modèle global pour les systèmes complexes : complexité de modélisation des interactions entre les différents mécanismes, difficultés de calcul associées à la résolution d'un système d'équations différentielles (explosion des temps de calcul pour une simulation de Monte Carlo),
- il peut être impossible de généraliser une approche basée sur un modèle physique orientée «composant» à un niveau «système»,
- il est nécessaire de connaître les mécanismes de dégradation et les facteurs influents sur celle-ci.

### *B- Techniques et outils*

Les techniques appartenant à cette approche de pronostic sont basées sur les outils suivants : l'espace de parité, observateurs (filtres de Kalman) et estimation paramétrique.

#### *Espace de parité*

Un espace de parité est une relation de redondance analytique représentée par une équation dans laquelle toutes les variables sont connues. La génération de telles relations permet d'engendrer des résidus. Un résidu est un signal temporel, fonction des entrées et des sorties du processus, indépendant (le plus possible) du point de fonctionnement de la présence de défauts. En l'absence de défaut, le résidu est statistiquement nul. Lors de l'apparition d'un défaut, son amplitude évolue de manière significative.

#### *Observateurs*

La génération de résidus à l'aide d'une estimation d'état consiste à reconstruire l'état ou, plus généralement, la sortie du processus à l'aide d'observateurs, et à utiliser l'erreur d'estimation comme résidu. Cette méthode s'est beaucoup développée car elle donne lieu à la conception de générateurs de résidus flexibles.

*Estimation paramétrique*

L'approche par estimation paramétrique considère que l'influence de défauts se reflète sur les paramètres et non pas uniquement, comme c'est le cas des observateurs, sur les variables du système physique. Le principe de cette méthode consiste à estimer en continu les paramètres du procédé en utilisant les mesures d'entrée/sortie et en évaluant la distance qui les sépare des valeurs de référence de l'état normal du procédé. L'estimation paramétrique possède l'avantage d'apporter de l'information sur l'importance des déviations. Toutefois, un des inconvénients majeurs de cette méthode réside dans la nécessité d'avoir un système physique excité en permanence. Ceci pose donc des problèmes d'ordre pratique dans le cas de procédés dangereux, coûteux ou fonctionnant en mode stationnaire.

*C- Applications*

[LNP<sup>+</sup>] a introduit le concept de pronostic basé sur un modèle physique en utilisant des résidus générés par simulation d'un modèle de suspension de voiture (en mode nominal et en mode dégradé) (figure I.11).

[CC03] a proposé une méthodologie pour la modélisation de la perte progressive de tension d'une pile 9V dans un oscillateur électromécanique en construisant un modèle d'évolution dynamique observable «fast-time» du système couplé avec un modèle d'évolution «slow-time» de la dégradation. [HS03] ont pronostiqué la durée de vie restante de circuits imprimés et de pipelines soumis à des phénomènes de corrosion. Pour cela, ils ont déployé une méthodologie basée sur des modèles stochastiques de dégradation dont les paramètres sont incertains. [KPM02] a proposé une approche de pronostic basée sur la fusion des aspects physique du système (un hélicoptère dont la vitesse est pronostiquée avec les informations issues du diagnostic des parties modélisées. [Ray99] a adopté le modèle stochastique de fatigue de Newman pour planifier les interventions de maintenance (surveillance et réparation) sur des structures mécaniques. [LBZ<sup>+</sup>99] et [LKL00] ont présenté deux modèles de propagation de défauts par l'intermédiaire du mécanisme de défaillance employé pour évaluer le *RUL* de roulements. [ME98] a proposé un modèle de modification de lois de dégradation en fonction de deux types de facteurs influents : ceux qui appartiennent au composant en lui-même (état initial de dégradation, caractéristiques géométriques, chimiques) et ceux qui relèvent des conditions opérationnelles et environnementales d'utilisation (mode de fonctionnement, température, humidité, etc.).

**I.3.2.3 Approches guidées par les données**

Le pronostic guidé par les données s'appuie sur le constat suivant : les mesures (entrées/sorties) constituent souvent la plus forte et la plus sûre source d'information pour comprendre les phénomènes de dégradation. Ce type d'approches vient ainsi à apprendre (par les exemples) le phénomène de dégradation, et à capturer les relations subtiles

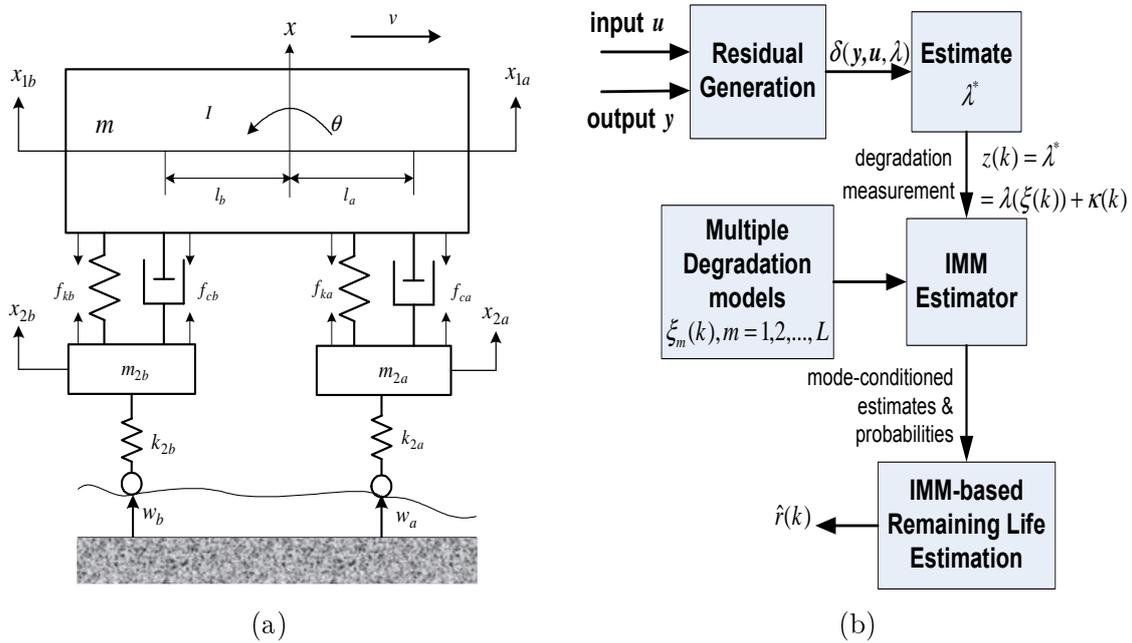


FIG. I.11 – Exemple de pronostic basé sur un modèle [LPQC03] : (a) modèle physique de suspension d’une voiture, (b) approche de pronostic déployée

entre données, même si ces relations sont inconnues ou difficile à décrire.

#### A- Principe de fonctionnement, avantages et inconvénients

Le pronostic guidé par les données exploite les données des indicateurs de dégradation ou d’intervention de maintenance délivrés respectivement par le processus de surveillance et d’aide à la décision (données calorimétriques de calibrage, données spectrométriques, puissance, vibration, température, pression, débris d’huile, tension, etc.). Ce type de pronostic se fonde sur l’hypothèse que les caractéristiques statistiques des données sont relativement inchangées à moins qu’un défaut de fonctionnement ne se produise dans le système.

La mise en œuvre d’une approche « guidée par les données » est relativement simple car elle ne requiert pas la connaissance formelle des mécanismes de dégradation. Elle permet de transformer simplement des données bruitées en informations pertinentes pour des décisions de pronostic. En outre, cette approche peut être adaptée à tout type d’application disposant de données suffisantes en quantité et qualité. En revanche, c’est là également sa principale limite : l’efficacité d’une approche de pronostic guidée par les données dépend fortement de l’existence de ces données opérationnelles. Par ailleurs, le processus de surveillance conditionne également la justesse du pronostic par sa capacité à fournir une estimation fiable et précise de l’état de santé courant du système.

### *B- Techniques et outils*

Lorsque les seules informations disponibles sur le système sont les variables mesurables et que l'on ne peut utiliser la redondance physique, l'approche usuelle consiste à apprendre le comportement du système à l'aide de l'historique des données (les données d'apprentissage), le principe étant qu'une même cause aura toujours les mêmes effets. Dans cette optique, deux catégories de techniques sont distinguées dans la littérature : celles issues de l'intelligence artificielle (IA) et les techniques statistiques.

#### *Techniques de l'intelligence artificielle*

Les réseaux de neurones (RN) et les réseaux d'ondelettes (le perceptron multi couches, les réseaux de neurones probabilistes, les réseaux d'ondelettes à auto organisation, etc.) sont les principales classes d'outils de ce type. Leur force réside dans l'aptitude à apprendre et à capturer les relations subtiles entre données, même si ces relations sont inconnues ou difficile à décrire [VSU98]. En revanche, leur principal inconvénient réside dans l'acquisition et la couverture des données d'apprentissage.

#### *Techniques statistiques*

Les techniques statistiques les plus populaires sont les techniques de lissage (tel que le lissage exponentiel) et les modèles de régression, notamment les modèles AR (AutoRegressive models) et ARMA (AutoRegressive Moving Average models). Ces techniques présentent l'intérêt d'être simple à programmer. Cependant, elles supposent que la dégradation du système est monotone, et ne permettent pas d'intégrer les variations de conditions d'utilisation du système : l'évolution de la dégradation à venir doit être similaire à celle qui a été apprise.

### *C- Applications*

#### *Pronostic par analyse de tendance*

La gamme des outils utilisés dans cette catégorie inclut les outils de prévision de série temporelles (Box Jenkins, régression linéaire, lissage exponentiel) et les modèles de classification multivariable plus perfectionnés (analyse en composantes principales, discrimination linéaire et quadratique...) [ATP02]. [GP02] ont développé pour l'armée américaine, un système embarqué de pronostic par analyse de tendance. Son fonctionnement repose sur une méthode de régression mise en œuvre sur l'évolution de l'indicateur FOM (Figure Of Merit). Le nombre de points utilisés par la fonction de régression varie afin que la prévision reste cohérente avec les dernières mesures. Cette notion de réactivité est également présente dans les travaux de [YLK02] où le pronostic est réalisé par un modèle de prédiction ARMA dont les paramètres sont remis à jour en ligne.

#### *Pronostic par apprentissage*

Les applications récentes exploitent des réseaux de neurones sous toutes leurs formes : réseaux de neurones à ondelettes dynamiques [WYKL02], réseaux de neurones à fonctions de base radiales [ZRZ06] ou réseaux neuro-flous [WGI03]. L'intégration de la logique

floue dans la construction du modèle permet de définir la structure du modèle et d'assurer la convergence de l'apprentissage des paramètres. Ces méthodes d'apprentissage automatique ont donné lieu à de multiples applications :

- pronostic de la propagation de la détérioration de machines tournantes, avant qu'elles atteignent un niveau critique [WGI04] (figure I.12),
- pronostic de défaillances de roulements à billes [WV99].

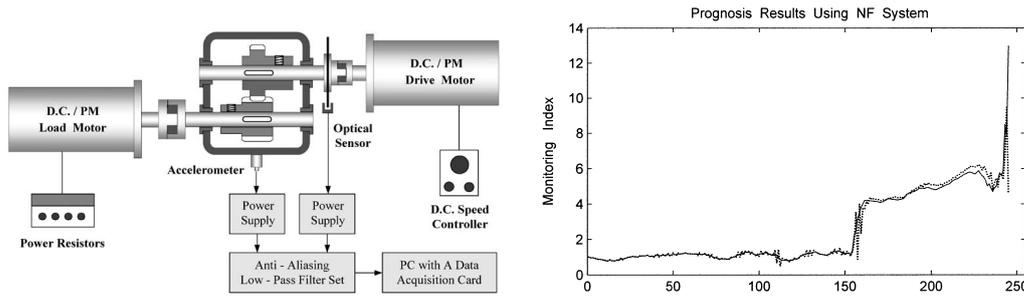


FIG. I.12 – Exemple de pronostic guidé par les données [WGI04] : estimation de l'état futur d'une machine tournante par approche neuro-floue (ANFIS)

### I.3.2.4 Approches basées sur l'expérience

#### A- Principe de fonctionnement, avantages et inconvénients

Les approches de pronostic basées sur l'expérience se fondent sur la modélisation stochastique des phénomènes de dégradation (loi de fiabilité, processus markoviens, ou non-markoviens). Ces modèles peuvent être construits sur la base d'expériences similaires passées (figure I.13).

Le principal avantage de ce type d'approches est qu'elles ne nécessitent pas de connaissance pointue du (des) mécanismes physique(s) de dégradation. Aussi, elles sont relativement simples à mettre en œuvre et peu coûteuses.

Les principales limites des approches basées sur l'expérience sont les suivantes :

- il existe fréquemment un décalage entre les modèles mis au point (mono-composant à 2 états) et la réalité industrielle (système multi-composants à multi-états),
- il est difficile de disposer d'un historique d'expérience passées représentatif de toutes les conditions d'utilisation des systèmes

#### B- Techniques et outils

Les approches basées sur l'expérience sont principalement issues des méthodes traditionnelles de modélisation et de traitement fiabilistes. Le pronostic est en ce sens assimilé à une étude de fiabilité prévisionnelle, l'objectif étant d'identifier les paramètres d'une distribution aléatoire décrivant le phénomène de dégradation ou de défaillance (loi de

poisson, loi exponentielle, loi de weibull, loi log-normal). Dans cet ensemble, la loi de weibull reste la plus répandue [SSR03]. De plus, l'utilisation d'un modèle fiabiliste évolutif de type ALM (Accelerated Life Model), PHM (Proportional Hazard Model), ou la mise en œuvre d'une démarche bayésienne permettant d'actualiser les paramètres de la loi de dégradation à chaque nouvelle information disponible peut également représenter une solution. La simulation de Monte Carlo permet de combiner différents phénomènes aléatoires mais est confrontée au problème d'explosion du temps de simulation.

### *C- Applications*

Parmi les travaux récents dans le domaine du pronostic basé sur l'expérience, nous pouvons mentionner les suivants.

[JB04] a proposé le logiciel EXAKT pour optimiser le remplacement d'équipements critiques (turbine, vanne, moteur...). La méthodologie proposée combine le suivi du taux de défaillance obtenu par un modèle de Weibull et la prévision de l'évolution de covariables suivant un processus markovien discret non homogène.

[CLOP04] a proposé la suite logicielle IBTV d'EDF en intégrant une méthodologie originale de pronostic où la stratégie de maintenance repose sur le déclenchement d'interventions suite à la détection du vieillissement d'un composant (vanne, relais électrique, structure mécanique, par exemple). L'approche est basée sur une démarche bayésienne avec une modélisation *a priori* du comportement du taux de défaillance (composition loi exponentielle / Weibull). De plus, l'efficacité des actions de maintenance est prise en compte suivant l'avis d'expert.

[Ram04] a optimisé la périodicité d'interventions préventives sur des ventilateurs. [NK04] a modélisé la durée de vie de ponts en béton pour améliorer leur coût de maintenance et de remplacement. [Mij03] a calculé la disponibilité moyenne d'un disjoncteur à air comprimé soumis à deux modes de défaillances.

### **I.3.3 Synthèse**

Le pronostic est aujourd'hui considéré comme un processus clef dans les stratégies de maintenance. L'estimation du temps résiduel avant défaillance d'un équipement (*RUL*) et la confiance pouvant être associée à cet indicateur doivent en effet permettre d'éviter des dépenses de maintenance inutiles, et le pronostic connaît un intérêt croissant ces 10 dernières années. De nombreuses approches ont été proposées pour supporter cette activité, tel qu'en témoigne la taxonomie des méthodes et outils présentée ci-avant.

Ceci étant, la distinction entre classes d'outils n'est pas évidente. A titre d'exemple, un réseau Bayésien peut être utilisé pour générer un modèle dynamique d'un système et suivre l'évolution des caractéristiques dans le temps (approche basée sur un modèle). Pour cela il est possible d'utiliser un ensemble d'algorithmes permettant d'apprendre la structure et les paramètres du réseau (approche guidée par les données). Mais ces paramètres peuvent également être estimés statistiquement à partir d'une base d'historique disponible (approche basée sur l'expérience). Le message n'est bien entendu pas ici de

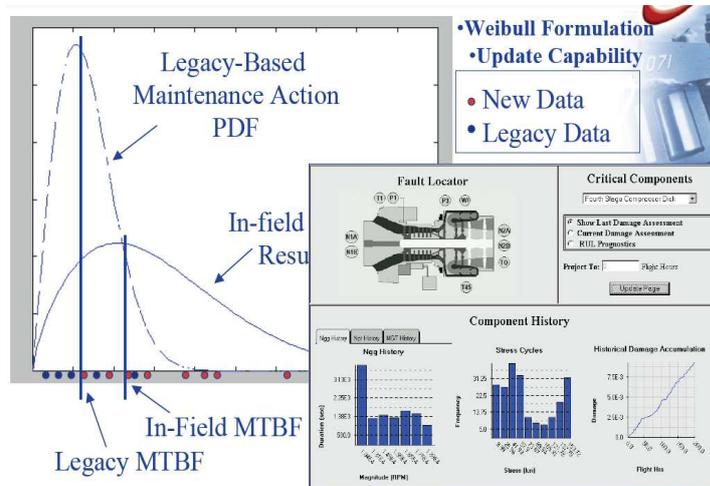


FIG. I.13 – Exemple de pronostic basé sur l’expérience : estimation de la date de remplacement d’un composant électronique d’une cellule d’avion par exploitation des historiques de vol [RBKV05]

dire que la classification des approches de pronostic est fautive, mais davantage qu’elle doit être considérée avec précaution si elle n’est pas associée aux explications des auteurs. A un autre niveau, il apparaît qu’aucune approche de pronostic n’est universelle et que le choix d’une technique adéquate dépend de contraintes classiques limitant l’applicabilité des outils : disponibilité des données et/ou connaissances et/ou expériences, dynamique et complexité des systèmes réels, contraintes d’implémentation (précision, temps de calcul, etc.), possibilités de mesures (capteurs, système SCADA, etc.), etc. Aussi, l’objet de la section suivante est de restreindre le cadre d’étude de cette thèse.

## I.4 Cadre de travail

### I.4.1 Approche locale : pronostic d’éléments critiques

Généralement, une analyse de système est réalisée en exploitant différents modèles : un modèle fonctionnel pour décrire les fonctions à fournir par le système, un modèle structurel pour décrire l’architecture permettant la réalisation de ces fonctions, et un modèle événementiel pour décrire le comportement. Chaque composant d’un système peut être considéré comme un système simple impliqué dans l’évolution du processus. Ceci étant, du point de vue de la sûreté de fonctionnement, il peut être difficile d’identifier les rapports existant entre fonctions, structures et comportement (complexité du processus, manque de connaissance, relations causales compliquées, etc.). Ces considérations rendent l’étape de modélisation difficile, voire impossible dans certains cas, ce qui est

valable dans la perspective de bâtir des systèmes de pronostic de défaillance. Aussi, nous choisissons dans cette thèse de centrer le travail sur le pronostic de certains composants du système : approche «locale». Le lecteur intéressé par une approche plus «système» peut notamment se référer à [Rib09].

Dans la pratique, il est alors nécessaire de définir une stratégie d'identification des composants sur lesquels réaliser un pronostic de défaillance. Nous proposons de suivre un synoptique tel que celui proposé en figure I.14. L'explicitation globale de cette figure requiert d'aller plus en avant dans la présentation du cadre de travail (section I.4.2). Retenons à ce stade que cette thèse est consacrée au développement d'une approche de pronostic pour des équipements jugés critiques (point 1 sur la figure), et donc pour lesquels les stratégies traditionnelles de maintenance peuvent se montrer limitées en terme de gains attendus.

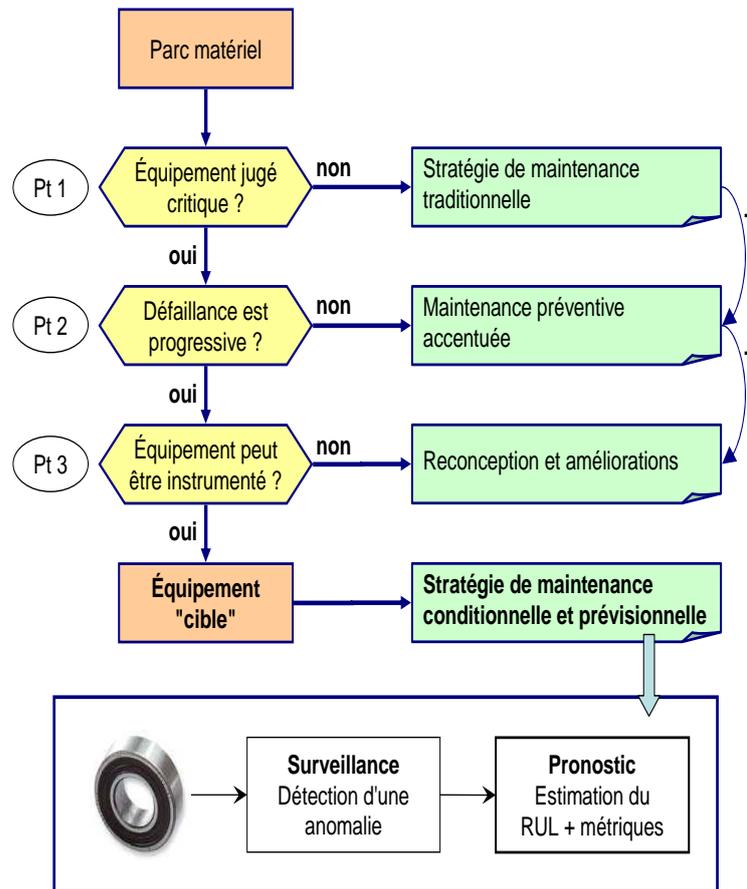


FIG. I.14 – Cadre de travail : pronostic d'éléments critiques à partir de données de surveillance

## I.4.2 Approche guidée par les données

### I.4.2.1 *Processus de défaillance progressif : par dégradation*

Revenons au phénomène de défaillance, objet du processus de pronostic. Tel que spécifié en section I.2.1.1, une défaillance est *la cessation de l'aptitude d'un bien à accomplir une fonction requise*. Ce passage d'un état de fonctionnement normal à un état défaillant peut se faire en fonction du temps de manière progressive, soudaine ou encore de façon aléatoire [Zwi99] (figure I.15). Une défaillance progressive résulte d'un processus de dégradation physico-chimique du composant tel que le frottement, la déformation plastique, la corrosion, etc. Les principales formes de dégradation sont données en figure I.16. Dans le cadre de cette thèse, nous choisissons de restreindre l'analyse au pronostic de défaillances progressives par dégradation (point 2 sur la figure I.14). Ce type de défaillance est généralement précédé de symptômes avant-coureurs permettant d'envisager une stratégie de maintenance plus «dynamique» qu'une maintenance préventive systématique.

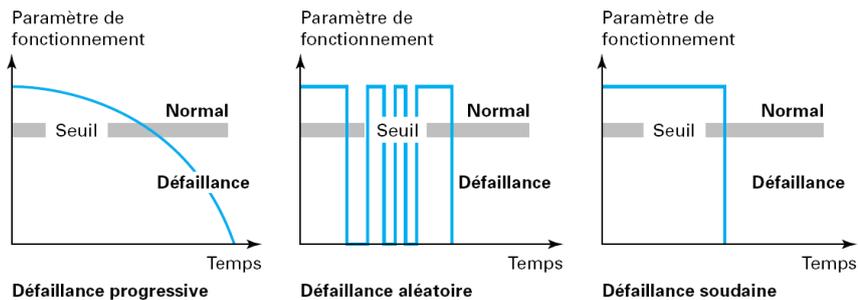


FIG. I.15 – Formes d'apparition d'une défaillance selon [Zwi99]

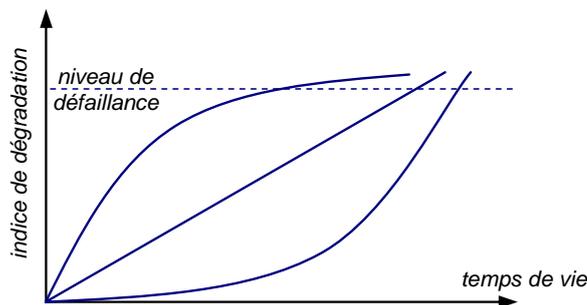


FIG. I.16 – Exemples de tendances de dégradation [ME98]

### I.4.2.2 *Pronostic à base de données sans connaissance a priori*

Les équipements industriels actuels ont une grande complexité technique, sont en évolution permanente, et peuvent être sollicités de manières très différentes. Aussi, la modélisation mathématique des phénomènes de dégradation peut s'avérer très délicate ou nécessiter des historiques de défaillance très conséquents. Par suite, nous considérons dans cette thèse qu'aucun modèle *a priori* de la dynamique des dégradations n'est disponible.

Si aucune formulation mathématique des phénomènes de dégradation n'est disponible, il n'en reste pas moins qu'il faut être en mesure de les approximer. Nous supposons ainsi que des indicateurs de dégradation peuvent être construits à partir de grandeurs physiques mesurées sur le composant analysé. Cela suppose bien entendu d'une part, que le composant peut être instrumenté de capteurs (vibration, émission acoustique, température, etc.), et d'autre part, que des processus de traitement des données brutes existent (nettoyage de signal, extraction et sélection de caractéristiques). Ces deux prérequis correspondent aux couches 1 et 2 de l'architecture CBM présentée en section I.2.3.2, et constituent de nouvelles hypothèses de travail pour cette thèse (point 3 sur la figure I.14). Elles ne sont pas aberrantes compte tenu des avancées actuelles tant en terme de nouvelles technologie de capteurs (micro-capteurs, capteurs à ultrasons, etc.), que en terme de systèmes d'acquisition et de stockage de données du type SCADA.

### I.4.3 Orientations de travail

En synthèse, l'approche de pronostic développée dans cette thèse se fonde sur les principales hypothèses décrites ci-avant :

- d'abord, nous ne nous intéressons qu'aux composants jugés critiques : **approche «locale»** du pronostic,
- ensuite, les défaillances considérées résultent d'un processus de **dégradation** pour lequel **aucun modèle a priori** n'est disponible. Le pronostic consiste ainsi à déterminer le temps résiduel avant que l'état de dégradation du bien ne permette plus de satisfaire une certaine exigence de performance,
- enfin, l'état de santé de l'équipement critique peut être décrit par un ou plusieurs descripteurs de dégradation construits sur la base de **données capteurs**. L'approche de pronostic développée est donc guidée par les données.

Par suite, le processus de pronostic peut être décomposé en deux sous-activités qui constituent le cœur de cette thèse (figure I.17) :

1. une première visant à prédire l'évolution d'une situation à un instant donné,
2. une seconde permettant d'évaluer la situation prédite en regard d'un référentiel de performance.

En complément, nous avons choisi de considérer que le processus de dégradation est inconnu *a priori*. La phase de prédiction est alors critique et l'approche de pronostic développée doit permettre de tenir compte de l'incertitude inhérente à cette étape afin de construire les indicateurs de confiance permettant de prendre les décisions.

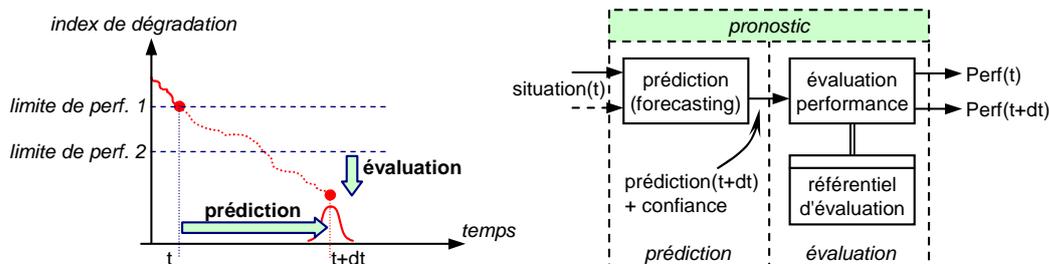


FIG. I.17 – Le pronostic comme un processus de prédiction et d'évaluation

## I.5 Conclusion

Le maintien en condition opérationnelle des systèmes industriels à moindre coût est devenu un facteur critique quant à la performance des entreprises et les concepts traditionnels de maintenance préventive et corrective sont peu à peu complétés par une prise en compte plus réactive et proactive des défaillances. Aussi, le pronostic se révèle être une activité tout à fait prometteuse pour ne pas engager de frais de maintenance inopportuns. Il fait l'objet d'une norme internationale récente et est aujourd'hui considéré comme un processus clef dans les stratégies de maintenance.

L'analyse de la littérature permet de constater que beaucoup d'alternatives existent *a priori* pour supporter l'activité de pronostic : approches basées sur un modèle, approches guidées par les données, approches basées sur l'expérience. Nous ne souhaitons pas dépendre d'un modèle de pronostic dont la couverture sera nécessairement limitée par sa capacité à prendre en compte la variabilité des conditions d'utilisation des systèmes industriels. Par ailleurs, ce travail s'inscrit dans un contexte industriel tel qu'il est difficile de disposer de connaissance sur les phénomènes de dégradation complexes, ou encore de suffisamment d'expériences passées pour déployer des approches statistiques significatives en regard de cette variabilité de conditions d'usage et de détérioration. A l'opposé, acquérir des données sur un équipement n'est plus un verrou technologique fort. Tout ceci nous conduit à privilégier une approche de pronostic guidée par les données.

Enfin, un problème central peut être tiré de cela. L'utilité d'un système de pronostic est intimement liée à sa faculté à approximer et à prédire la dégradation d'un équipement. La phase de prédiction est ainsi critique et le chapitre suivant lui est consacré.

Chapitre **II**

**Proposition d'un modèle de prédiction  
basé sur une approche neuro-floue**

## II.1 Introduction

L'étude menée au chapitre I nous a permis de mettre en relief la variété des outils utilisables pour supporter l'activité de pronostic. Cependant il n'existe pas une manière unique et universelle d'envisager le processus de pronostic, ce qui nous a conduit à définir un cadre d'étude : cette thèse a comme objectif de développer un outil de pronostic «local», basé sur l'exploitation des données de surveillance, et visant principalement à prédire l'évolution d'une dégradation au cours du temps (dégradation pour laquelle il n'existe pas de modèle *a priori*). Cette phase de prédiction a par ailleurs été jugée comme critique compte tenu de l'incertitude qui la caractérise. Par suite, l'objectif de ce chapitre est de dégager une approche de prédiction en accord avec le cadre de travail fixé. La démarche suivie consiste à définir des critères de choix d'un outil, et à discuter des approches de prédiction en regard de ces critères. Sur cette base, nous retenons les systèmes neuro-flous évolutifs comme technique fondatrice pour notre outil de pronostic.

## II.2 Vers les systèmes prédictifs issus de l'intelligence artificielle

### II.2.1 Une typologie des systèmes de prédiction

La prédiction (Forecasting en anglais) est le processus d'estimation de situations inconnues dans le futur. Les domaines d'application sont donc larges : inondations se produisant sur une période donnée, planification de la demande dans les entreprises manufacturières, prévision météorologique, prédiction dans le monde financière, etc. La prédiction joue un rôle essentiel pour prendre une décision, que cela concerne la sécurité ou bien le capital de l'entreprise. Traditionnellement, la prédiction est l'estimation d'une valeur dans l'avenir par l'analyse des données du passé, ou de manière plus informelle, par expertise. Deux familles de méthodes [Fre01] existent pour réaliser la tâche de prédiction (figure II.1) :

1. qualitative : ce type de technique utilise l'expérience et le jugement pour établir les comportements futurs.
2. quantitative : ce type de technique utilise des données historiques pour établir des relations et des tendances qui peuvent être projetées dans l'avenir.

Pour sélectionner la bonne méthode, il est obligatoire de tenir compte du contexte auquel est appliqué l'outil de prédiction. Les sections suivantes portent sur les critères permettant de choisir un système prédictif, à savoir les contraintes industrielles et la performance d'un modèle prédictif.

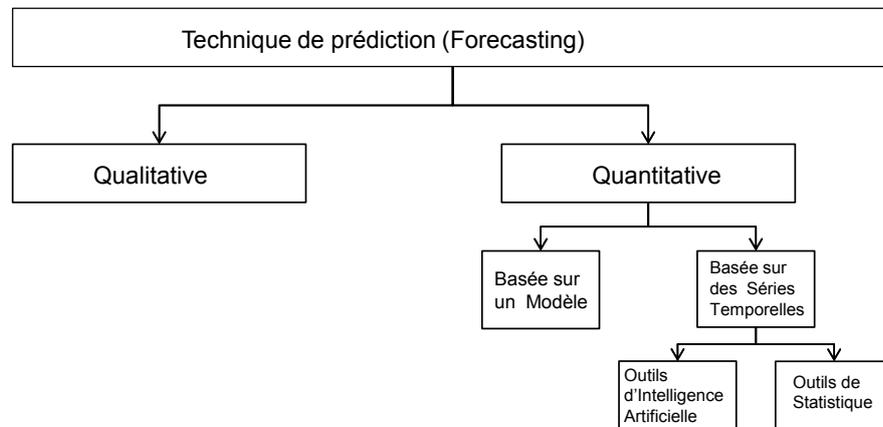


FIG. II.1 – Techniques de prédiction

## II.2.2 Critères de choix d'un système prédictif orienté données

### II.2.2.1 Contraintes industrielles

L'évolution de la technologie et son incorporation dans les équipements industriels a complexifié ces derniers. L'objectif est de rendre les équipements performants et fiables. Ces équipements sont devenus de plus en plus complexes, et ils évoluent dans un contexte environnemental dynamique et non-linéaire. Qui plus est, les opérateurs ont des difficultés à en comprendre le fonctionnement et à les piloter. En effet ce contexte complexe et évolutif complique la tâche de prédiction. Toutefois, dans le monde industriel, la chaîne d'acquisition des données est généralement opérationnelle et permet de mesurer différentes grandeurs avec précision, ainsi que de collecter et de distribuer un grand volume d'informations en temps réel. Au final, le monde industriel présente les spécificités suivantes :

- *équipements complexes,*
- *environnement dynamique/non-linéaire,*
- *pas de connaissance du comportement,*
- *beaucoup des données.*

### II.2.2.2 Caractéristiques souhaitables

Un point important pour choisir un outil de prédiction est la possibilité de l'intégrer à notre approche du pronostic, qui consiste d'abord, à détecter une anomalie surveillée par une grandeur physique ou un indice de dégradation et ensuite à en prédire l'évolution future. Il en découle certaines exigences quant au choix d'une technique de prédiction :

- **application en temps réel** : le système prédictif doit être utilisé et évoluer avec l'équipement réel,
- **flexibilité** : l'outil de prédiction doit pouvoir être adapté sur plusieurs applications et ne pas être limité à des conditions environnementales particulières. De plus, il faut que ce système de prédiction réagisse suivant les différents comportements du bien (non-linéaires, dynamique, non-stationnaire, etc.),
- **interprétabilité** : il faut que l'outil de prédiction garde un niveau minimum de transparence afin qu'un expert puisse intervenir pour modifier les paramètres,
- **ouvert** : un système ouvert est un système évolutif auquel on peut ajouter des paramètres en cours d'exécution.

### II.2.3 Choix d'une famille d'approches

Cette partie a pour objectif d'argumenter le choix d'un outil de prédiction sur la base des contraintes industrielles et des caractéristiques souhaitables identifiées précédemment d'un part, et d'autre part, des limites de cette thèse (approche locale, par prédiction de la dégradation sans connaissance *a priori*). Revenant, sur les méthodes de prédiction (figure II.1), l'utilisation d'une approche *qualitative* ou *basée sur un modèle* (approche quantitative) n'est pas adaptée : cela nécessiterait un raisonnement, ou une maîtrise du comportement de l'équipement observé, ce qui n'est pas toujours disponible dans le contexte industriel actuel. Les techniques basées sur les séries temporelles partent du constat suivant : les mesures (entrées/sorties) constituent souvent la plus forte et la plus sûre source d'information pour comprendre les phénomènes de dégradation. On distingue dans la littérature, les techniques statistiques et les techniques d'intelligence artificielle (IA). La force de ce type de méthodes réside dans leur aptitude à apprendre (par les exemples) et à capturer les relations subtiles entre données, sachant que ces relations sont inconnues ou difficile à décrire.

*Choix d'un outil de prédiction :*

Pour choisir une technique adéquate (IA ou statistique<sup>1</sup>), le tableau de la figure II.2 révèle les points forts et faibles conformément aux contraintes industrielles et aux caractéristiques d'un système prédictif souhaitables. Le problème de choix se présente, dans notre cas comme une matrice où chaque colonne correspond à une des techniques de prédiction et chaque ligne à un critère. Au croisement des lignes et des colonnes, chaque case exprime l'adéquation de la technique aux critères à respecter. Le signe «++» présente une bonne corrélation entre la technique et le critère, le signe «+-» présente une corrélation avec limites, et le signe «-» signifie qu'aucune corrélation n'existe entre la technique et le critère.

---

<sup>1</sup>Les outils statistiques sont parmi les plus populaires pour prédire des séries chronologiques (Auto-Regressive (AR) , Auto-Regressive Moving Average (ARMA), Autoregressive Integrated Moving Average (ARIMA)),[PP05].

		<b>Méthodes de prédiction basées sur les données (ou séries temporelles)</b>		
		<i>Outils d'IA</i>	<i>Outils Statistiques</i>	
<b>Critères de Choix</b>	<b>Contraintes Industrielles</b>	<b>Équipements Complexes</b>	++	+-
		<b>Environnements Dynamiques/non-linéaires</b>	++	+-
		<b>Pas de connaissance <i>a priori</i></b>	++	++
		<b>Beaucoup de données</b>	++	++
	<b>Caractéristiques souhaitables</b>	<b>Application temps réel</b>	++	++
		<b>Flexible</b>	++	+-
		<b>Ouvert</b>	++	+-
		<b>Interprétable</b>	+-	+-

FIG. II.2 – Matrice de choix d'un outil de prédiction basé sur les séries temporelles

Il apparaît en figure II.2 que les outils statistiques ne sont pas totalement en adéquation avec les critères de choix. En effet les techniques de l'IA devraient être privilégiées ; différentes techniques d'IA ont été testées sur des problèmes de prédiction et ont montré de meilleures performances que celles des méthodes «conventionnelles» [Rid05]. Dans l'ensemble, les réseaux adaptatifs sont particulièrement appropriés. La section suivante leur est consacrée.

### II.3 Systèmes neuro-flous pour la prédiction de séries temporelles

Depuis les années 80 les réseaux adaptatifs sont utilisés pour la prédiction de séries temporelles [PP05]. L'objectif d'introduire un tel type de systèmes est de rationaliser le processus décisionnel des décideurs pour aboutir à de meilleurs résultats. Historiquement, ce sont les réseaux de neurones (RNs) qui ont été utilisés pour prédire des séries chronologiques. Ensuite, l'idée est venue de les combiner avec le principe de la logique floue. Dans le paragraphe suivant, nous présentons un historique de l'utilisation des RNs dans la prédiction en montrant les avantages de les combiner avec les systèmes basés sur la logique floue.

### II.3.1 Réseaux de neurones et prédiction

Les réseaux de neurones constituent un cas particuliers de réseaux adaptatifs. Ils ont eu un succès fort de par leurs caractéristiques : ils peuvent «modéliser» et «reproduire» des phénomènes non-linéaires sans connaissance *a priori* et sont à même de «saisir» les relations cachées entre entrées et sorties. Du point de vue opérationnel, ce sont des systèmes rapides (Annexe B).

L'idée d'utiliser les RNs pour la prédiction date de 1964 : Hu utilisa le réseau adaptatif de Widrow afin de réaliser des prédictions climatologiques. Le manque d'algorithmes d'apprentissage limita la poursuite de ce type d'études. Depuis les années 80, la recherche dans le domaine est relancée. Nous en retraçons ci-après l'évolution (figure II.3) [GKZ07]. En 1987, Lapedes et Farber réalisent le premier travail montrant la possibilité d'identifier et de prédire des séries temporelles chaotiques déterministes à l'aide du perceptron multicouches. Cet article a lancé plusieurs applications sur des données réelles. H.White (1988) a étudié le cas de la prévision des retours de stock pour IBM. Cet effort a été suivi par Sharda et Patil (1990), ce qui a conduit à des compétitions de prévision entre les réseaux de neurones et les techniques traditionnelles : sur 75 séries testées, les réseaux de neurones ont été plus performants pour 39 séries.

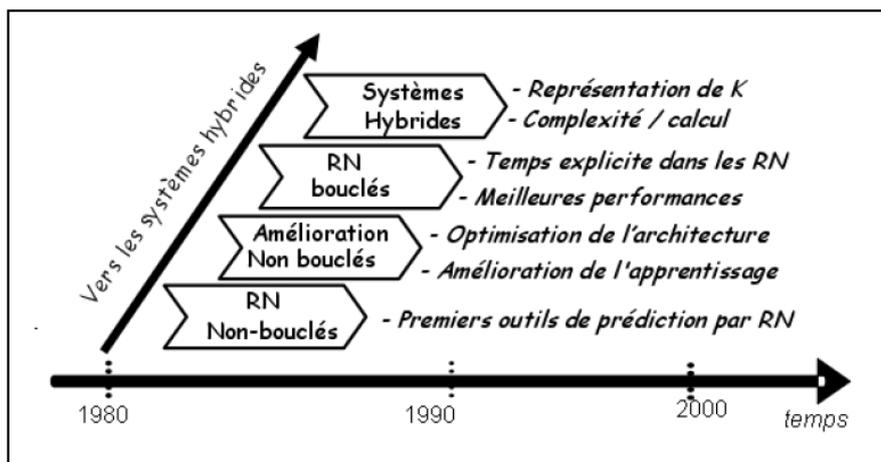


FIG. II.3 – Vers les systèmes hybrides d'après [GKZ07]

Nous proposons ci-après une synthèse sur l'utilisation des RNs pour la prédiction.

**Phase 1** : les réseaux non-bouclés, une des premières applications des RN pour la prédiction date de 1987. Lapedes et Farber construisirent un RN permettant d'approximer un signal chaotique [ZPH98]. Par suite, les RNs non bouclés associés à l'algorithme de rétropropagation (introduit à cette époque) se montrèrent plus performants que les modèles classiques d'autorégression pour la prédiction de séries temporelles non linéaires [YTLT01].

**Phase 2** : amélioration de l'apprentissage et du paramétrage des RNs, beaucoup de facteurs influent sur la performance des RNs (nombre d'entrées et de sorties, nombre de couches, fonctions d'activation, choix de la base de tests, algorithmes d'apprentissage) et la définition d'un RN adapté à un problème donné n'est pas une tâche aisée. Aussi, depuis les années 90, beaucoup de développements sont menés pour améliorer la précision des prédictions réalisées par les RNs tout en diminuant la complexité des modèles et le temps de calcul. Ces travaux visent la proposition de «guides» pour l'optimisation des architectures des RNs et des algorithmes d'apprentissage [HPS01].

**Phase 3** : les réseaux récurrents, afin de prendre en compte de manière explicite le temps, les architectures de réseaux récurrents ont été développées et comparées aux autres techniques de prédiction de séries temporelles non linéaires. Les résultats montrent que ces RNs présentent de meilleures performances que celles des méthodes classiques et plus encore, que celles des réseaux non bouclés [YTLT01].

**Phase 4** : vers les systèmes hybrides, il ressort que les RNs ont été utilisés avec succès pour supporter l'activité de prédiction. Cependant, certains auteurs restent sceptiques : d'abord, l'optimisation d'un RN est plus un art qu'une science, ensuite, les RNs sont des boîtes noires et il n'est pas possible d'explicitier et d'analyser les relations entre entrées et sorties. Ainsi, des travaux insistent sur l'intérêt des systèmes hybrides afin de pallier cette faiblesse des RNs (en préservant leur capacité d'apprentissage, voire en réduisant la complexité des modèles). Dans cet objectif, la recherche se dirige vers la combinaison des RNs avec d'autres principes d'IA notamment la logique floue (Annexe A).

### II.3.2 Combinaison des réseaux de neurones et de la logique floue

Le concept de modélisation dite « floue » trouve ses origines dans la théorie des ensembles flous proposée en 1965 par Zadeh [Zad65], comme une manière de traiter l'incertitude, fondée sur l'idée de définir des ensembles pouvant contenir des éléments de façon graduelle. Cette théorie introduit une manière de formaliser les méthodes humaines de raisonnement en utilisant des bases de règles et des variables linguistiques pour la représentation de connaissances [Zad73]. La plupart des applications développées dans les années 80-90 avaient pour cadre une démarche «basée connaissance» reposant sur l'expertise d'un opérateur pour un problème donné et de complexité limitée. Lorsqu'on a voulu passer à des problèmes plus complexes, il était difficile d'écrire (même pour un expert) des bases de règles volumineuses et l'approche basée connaissance n'était plus appropriée. Dans le but de faire face à ce problème, on peut tirer profit d'un type de connaissance [BT03] qui constituent les nombreuses données entrées-sorties sur le procédé. Ainsi, la solution consiste à utiliser les propriétés des RNs afin «d'apprendre à partir des données (entrées /sorties)» la structure floue et d'en adapter les paramètres en conséquence.

L'utilisation conjointe des réseaux de neurones et de la logique floue, permet de tirer les avantages des deux méthodes : les capacités d'apprentissage de la première et la lisibilité et la souplesse de la seconde. Afin de résumer l'apport du neuro-flou, le tableau II.1 regroupe les avantages et inconvénients des réseaux de neurones et de la logique floue.

Réseaux de Neurones	Logique floue
Avantages	
Guidés par les données	Pas de modèle mathématique
	Interprétabilité
Algorithme d'apprentissage	
Inconvénients	
Modèle boîte noire	Ajustement par tâtonnement
	Nécessité de posséder les règles

TAB. II.1 – Avantages et inconvénients des RNs et de la LF

Les règles floues codées dans un système neuro-flou représentent les échantillons imprécis et peuvent être vues en tant que prototypes imprécis des données d'apprentissage. Un système Neuro-Flou (NF) ne doit par contre pas être vu comme un système expert (flou), et il n'a rien à voir avec la logique floue dans le sens strict du terme. On peut aussi noter que les systèmes neuro-flous peuvent être utilisés comme des approximateurs universels [LW01].

Une définition des systèmes neuro-flous est donnée dans [NK97] et reprise dans [Rac06] selon laquelle :

*Les systèmes neuro-flous sont des systèmes flous formés par un algorithme d'apprentissage inspiré de la théorie des réseaux de neurones. La technique d'apprentissage opère en fonction de l'information locale et produit uniquement des changements locaux dans le système flou d'origine.*

Donc, l'intérêt est de construire un système prédictif prenant appui sur l'intégration des réseaux de neurones et des systèmes d'inférence floue (SIF) ; l'intégration du à leur complémentarité. Les réseaux neuro-flous remplacent les différentes couches cachées des réseaux de neurones par des règles floues (i.e. règles linguistiques). Ils utilisent ensuite des algorithmes d'apprentissage pour définir et optimiser ces paramètres. Des développements actuels montrent leur efficacité pour prédire des séries temporelles non-linéaires dans plusieurs travaux de recherche [WGI04]. En outre, ils montrent que la performance d'un NF dépassent celles d'autres méthodes aussi bien en termes de décision que d'efficacité d'apprentissage. Enfin, les modèles NF sont très prometteurs dans les cas où les données disponibles sont limitées [MF06].

Un certain nombre d'architectures de type de modèle hybride ont été proposées, telles que la logique floue à base de neurones [PLR95], fuzzy neurones [RG94], etc. Ces architectures

ont été couronnées de succès dans la résolution de diverse problèmes réels. Nous nous sommes intéressés au système neuro-flou utilisant le *modèle Takagi-Sugeno (TS)* comme *inférence floue* parce qu'il assure les trois points suivants [DaRS98] :

- c'est un outil de modélisation des systèmes non-linéaires,
- il est considéré comme un approximateur universel,
- il est possible d'identifier les paramètres du TS basé sur les données et pas seulement sur la connaissance d'un expert.

De plus, un système du TS est considéré comme une approche de modélisation multi-linéaires, qui peut résoudre un problème complexe de modélisation en le décomposant en plusieurs sous-problèmes plus simples. Un TS est un système composé de règles floues liées à des sous-systèmes linéaires, ce qui facilite la tâche d'identification. Par ailleurs la structure d'un NF-TS est prometteur et reste transparente. A l'opposé, les RNs sont des systèmes de type boîtes-noires dans lesquelles il est difficile d'intégrer le raisonnement humain.

Dans la suite, nous focalisons notre attention sur le modèle Neuro-Flou basé sur le Takagi-Sugeno. Nous n'introduisons pas ici l'ensemble des concepts relatifs à la logique floue. Le lecteur peut se référer à l'annexe A.

## II.4 Représentation d'un système Takagi-Sugeno

Un modèle NF du type TS du premier ordre constitue un outil efficace pour approximer une fonction de transfert non-linéaire. Notons que, ce modèle est Multi-Entrées, Multi-Sorties (MEMS). Mais dans notre étude, on ne s'intéresse qu'à une seule variable à la sortie (l'indice de dégradation). Le NF-TS est basé sur une décomposition floue de l'espace des entrées. Pour chaque partie de cet espace, une règle floue peut être construite afin de faire une approximation linéaire de la sortie. La sortie globale est obtenue par combinaison de l'ensemble des règles construites, et le modèle TS peut ainsi être vu comme une structure multi-modèles constituée de différents modèles linéaires qui ne sont pas nécessairement indépendants [AF04]. Considérons la figure II.4 décrivant l'architecture d'un NF-TS pour expliquer le mécanisme d'inférence.

D'une manière générale, un modèle de type Takagi-Sugeno est basé sur une collection de règles du type :

$$R_i : \text{Si } x_1 \text{ est } A_i^1 \text{ et } \dots \text{ et } x_n \text{ est } A_i^n \text{ Alors } \Upsilon_i = a_{i0} + a_{i1}x_1 + \dots + a_{in}x_n \quad (\text{II.1})$$

Avec

- $R_i$  la  $i^{\text{ème}}$  règle floue,
- $R$  le nombre de règles,
- $X = [x_1, x_2, \dots, x_n]^T$  le vecteur de  $n$  entrées,
- $A_i^j$  les ensembles flous antécédents ( $j = [1, n]$ ),
- $\Upsilon_i$  la sortie du  $i^{\text{ème}}$  sous-système linéaire,

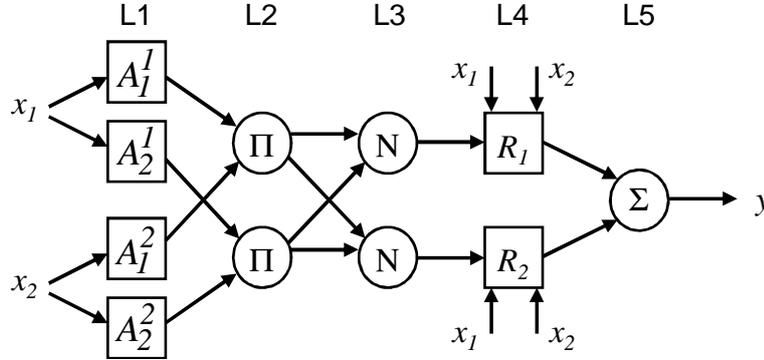


FIG. II.4 – Structure d'un système Takagi-Sugeno

–  $a_{iq}$  les paramètres conséquents ( $q = [0, n]$ ).

Les fonctions d'appartenance sont représentées par des gaussiennes qui assurent la meilleure généralisation possible (permet de couvrir l'ensemble du domaine des variables) :

$$\mu_{A_i}^j = \exp[-4\|x_j - x_i^{j*}\|/(\sigma_i^j)]^2 \quad (\text{II.2})$$

Avec

- $i$  le nombre de fonctions d'appartenance pour chaque entrée,
- $c_i^{j*}$  le point focal (centre) de la  $i^{\text{ème}}$  fonction d'appartenance,
- $\sigma_i^j$  la variance de la fonction d'appartenance.

Par suite, le degré d'activation de chaque règle peut être obtenu par le produit cartésien des ensembles flous relatifs à la règle :

$$\tau_i = \mu_i^1 \times \dots \times \mu_i^n \quad (\text{II.3})$$

Le degré d'activation normalisé de la de  $i^{\text{ème}}$  règle est :

$$\lambda_i = \frac{\tau_i}{\sum_{i=1}^R \tau_i} \quad (\text{II.4})$$

La sortie du modèle TS est finalement calculée par la moyenne pondérée des contributions des règles du système :

$$y = \sum_{i=1}^R \lambda_i \Upsilon_i = \sum_{i=1}^R \lambda_i x_e^T \pi_i \quad (\text{II.5})$$

Avec

- $\pi_i = [a_{i0}, a_{i1}, \dots, a_{in}]$  le vecteur des paramètres du  $i^{\text{ème}}$  sous-modèle ou règle,
- $x_e = [1 \ X^T]$  le vecteur étendu des variables d'entrées.

Un modèle TS a deux types de paramètres. Les paramètres non-linéaires sont ceux inhérents aux fonctions d'appartenance (une gaussienne telle que dans l'éq. II.2 a deux paramètres : son centre ( $x^*$ ) et son écart type ( $\sigma$ )). Ces paramètres sont qualifiés de prémisses ou antécédents. Les paramètres de la seconde classe sont linéaires par rapport à la sortie du modèle. Ce sont ceux qui forment la partie conséquente de chaque règle ( $a_{iq}$ ).

Si la structure et le réglage des paramètres de ce NF (Type TS) sont convenablement choisis, ce modèle peut correctement approximer tout système non-linéaire à l'aide de données numériques d'entrées-sortie. C'est l'objet de l'étape d'identification discutée ci-après.

## II.5 Vers une stratégie évolutionniste d'identification d'un modèle NF-TS

Un système du type NF-TS est une technique adéquate pour la prédiction de séries temporelles. Mais, afin d'obtenir un système même de prédire, il faut résoudre le problème d'identification du modèle, ce qui se divise en deux étapes : la première est la détermination de la structure, et la deuxième est l'estimation des paramètres. Cette section vise à présenter les procédures pour trouver la structure et adapter les paramètres d'un réseau et à les discuter afin de choisir une approche adéquate en regard des critères cités dans la paragraphe II.2.2.

### II.5.1 Identification d'un système Takagi Sugeno

Dans le contexte industriel actuel où les équipements sont de plus en plus complexes et dur à appréhender, il est difficile d'avoir une connaissance approfondie sur le comportement de ses fonctions. Force est de constater que la mise en place d'un système neuro-flou et particulièrement l'identification de sa structure nécessite la connaissance préalable des experts, qui est impossible à acquérir. Toutefois, le grand volume quantitatif de données disponibles à travers des capteurs peut nous aider à exploiter des stratégies d'identification convenables avec ce genre de données. Dans la littérature, quatre stratégies sont proposées pour identifier ce type de système. L'objectif de ces quatre stratégies est de déterminer la structure et d'ajuster les paramètres (antécédents et conséquents, voir II.4) en les estimant à partir de données. Ces stratégies sont fondées sur un objectif unique, qui est de réduire au minimum l'erreur d'approximation entre la valeur réelle mesurée et la valeur donnée par le NF (type TS). Les quatre familles de méthodes d'identification sont : Mosaïque (en anglais, Mosaic or table lookup), Descente d'un gradient, Coalescence floue (Clustering flou), Stratégie Évolutionniste.

### II.5.1.1 *Mosaïque (en anglais, Mosaic or table lookup)*

Cette méthode nécessite la présence d'un expert qui doit définir les fonctions d'appartenance, c'est à dire choisir le nombre des fonctions d'appartenance par entrée ( $nbFA$ ) et en trouver la bonne répartition pour couvrir l'espace des entrées. Notons, que dans cette méthode, le réseau est complètement connexionniste : les règles sont générées de façon à assurer toutes les combinaisons possibles ( $R = nbFA^n$ ). Les paramètres non-linéaires sont fixés par le choix de la répartition des fonctions d'appartenances. Par contre, les paramètres linéaires ne sont pas ajustés manuellement. Pour les ajuster, on peut utiliser l'algorithme des *Moindres Carrés* (MC) (Annexe C) (il faut une base de données sous forme entrées/sortie).

### II.5.1.2 *Descente de gradient*

Cette méthode a le même principe que la précédente en ce qui concerne la définition du nombre de fonctions d'appartenance, et du nombre de règles. Avec cette méthode il faut initialiser les paramètres antécédents et conséquents, puis lancer la descente de gradient qui est un algorithme d'optimisation capable d'ajuster les paramètres non-linéaires du système NF-TS. L'utilisation de la descente de gradient est justifiée par le fait que la fonction de coût (équation II.6) contient les paramètres non-linéaires.

$$E = \frac{1}{2} \sum_{k=1}^S [y^k - f(X^k, \lambda^k, \theta)] = \frac{1}{2} \sum_{k=1}^S [y^k - \sum_{i=1}^R (\lambda_i^k x_e^{Tk} \pi_i)] \quad (\text{II.6})$$

Par suite, il est possible d'utiliser l'algorithme des moindres carrés pour ajuster les paramètres conséquents. Le système NF-TS le plus populaire est basé sur une méthode d'identification. Il s'agit d'un système ANFIS (Adaptive Neuro Fuzzy Inference System) proposé [JS95]. La figure II.6 résume les caractéristiques de ce processus d'identification.

algo appr. hybride	paramètres prémisses	paramètres conséquents
propagation avant	fixés	moindres carrés
propagation arrière	descente gradient	fixés

FIG. II.5 – Algorithme d'apprentissage hybride de l'ANFIS

L'ANFIS de la figure II.6 a deux fonctions d'appartenance (Petite ( $Pt$ ), Grande ( $Gr$ )) pour chaque entrée. C'est un système complètement connexionniste, donc on a  $R =$

$(nbFA^n) = 2^2 = 4$  règles :

$$R_1 : \text{Si } x_1 \text{ est } Pt_1 \text{ et } x_2 \text{ est } Pt_2 \text{ Alors } \Upsilon_1 = \lambda_1(a_{10} + a_{11}x_1 + a_{12}x_2)$$

$$R_2 : \text{Si } x_1 \text{ est } Pt_1 \text{ et } x_2 \text{ est } Gr_2 \text{ Alors } \Upsilon_2 = \lambda_2(a_{20} + a_{21}x_1 + a_{22}x_2)$$

$$R_3 : \text{Si } x_1 \text{ est } Pt_2 \text{ et } x_2 \text{ est } Gr_1 \text{ Alors } \Upsilon_3 = \lambda_3(a_{30} + a_{31}x_1 + a_{32}x_2)$$

$$R_4 : \text{Si } x_1 \text{ est } Pt_2 \text{ et } x_2 \text{ est } Gr_2 \text{ Alors } \Upsilon_4 = \lambda_4(a_{40} + a_{41}x_1 + a_{42}x_2)$$

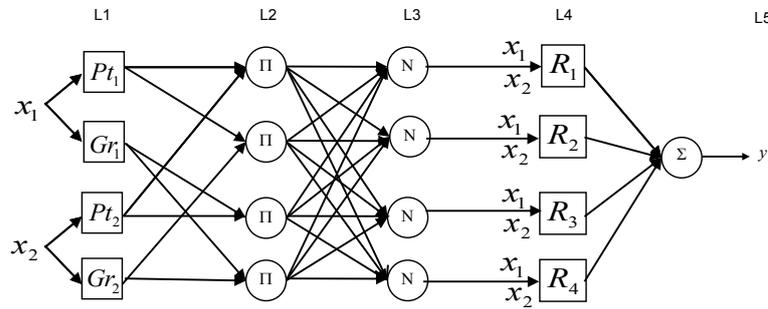


FIG. II.6 – Système ANFIS à deux entrées, une sortie et deux fonctions d'appartenance par entrées

Cette structure est composée de 5 couches. Chaque couche contient différents nœuds. Nous notons  $Sn_{u,v}$  la sortie du nœud  $u$  de la couche  $v$ . Les sorties des nœuds de la *couche 1* sont calculés par l'équation II.2, les sorties des nœuds de la *couche 2* sont calculés par l'équation II.3, les sorties des nœuds de la *couche 3* sont calculés par l'équation II.4, la *couche 4* est celle des règles, et la *couche 5* contient un seul nœud dont la sortie est l'agrégation des règles (éq. II.5). Cette structure est vue comme un réseau de neurones d'où l'idée d'utiliser l'algorithme de rétro-propagation du gradient (Annexe D).

### II.5.1.3 Coalescence floue (Clustering flou)

Cette méthode d'identification est différente par rapport aux autres méthodes citées auparavant. Cette approche permet de spécifier la structure et de générer automatiquement l'espace de partition des ensembles flous afin d'ajuster les paramètres prémisses (paramètres non-linéaires). Donc, on n'a pas besoin d'un expert ou de connaissance *a priori* pour construire la structure de NF-TS et ajuster les paramètres non-linéaires. Par suite, les paramètres linéaires peuvent être ajustés à l'aide de MC.

La méthode de *Coalescence floue* (Fuzzy clustering) est inspirée des méthodes de classification. L'idée est de décomposer la base de données en un nombre déterminé de clusters (groupes), et d'associer à chaque entrée du NF-TS le même nombre de cluster trouvé. Chaque cluster a un centre et un rayon ( ce dernier représente la dispersion des éléments au sein du cluster). Les centres et les rayons des clusters ( $x_i^{j*}, \sigma_i^j$ ) sont ceux des fonctions d'appartenances du NF-TS, et le nombre de règles du NF-TS est le nombre de clusters.

Plusieurs méthodes de coalescence floue sont utilisées comme par exemple : «C-Moyennes Floues [Bez81]», «Gustafson-Kessel (GK) [GK79]», et « Subtractive Clustering [Chi94]», etc. Contrairement aux techniques de regroupement par «c-moyennes floues» et «Gustafson-Kessel (GK)», le « Subtractive Clustering» (Annexe E) n'est pas basé sur la minimisation d'une fonction et son principal avantage est que le nombre de groupes (en général inconnu) n'a pas à être spécifié.

#### II.5.1.4 Stratégie évolutionniste

Les algorithmes évolutionnistes utilisés s'inspirent de la théorie darwinienne de l'évolution des espèces. L'utilisation de ces algorithmes a été orientée vers la recherche des paramètres de plusieurs fonctions, et ils ont été employé pour identifier le modèle NF-TS. L'objectif de ces algorithmes est de construire le modèle NF-TS (préciser le nombre de fonctions d'appartenance et le nombre de règles) et d'ajuster ces paramètres en essayant d'atteindre un bon niveau de performance d'un coté, et limiter la complexité d'un autre coté.

Contrairement à d'autres algorithmes qui, partant d'une solution singulière, cherchent à remonter un gradient de performances, les algorithmes évolutionnistes se basent sur l'idée d'adaptabilité : les entités (dans ce cas l'entité est la fonction d'appartenance) dépendent de l'environnement les entourant et s'adaptent pour rester vivants (principe de Darwin). Adapté signifie la possibilité d'augmenter le nombre d'entités ou de modifier des caractères à l'intérieur de ces entités en fonction de nouveaux changements d'environnement.

Traditionnellement, ce sont les algorithmes génétiques qui sont les plus employés [Gol89]. Pour, plus de détails sur le concept de ces algorithmes voir [EVW05]. Récemment, et toujours dans le principe évolutionniste, Angelov a proposé un algorithme qui vise à déterminer les paramètres (nombre de fonctions d'appartenances et leurs distributions) de NF-TS d'une manière évolutionniste [Ang02]. Le principe est celui du Clustering (Subtractive Clustering) mais en ligne. Notons, que l'algorithme *Moindres Carrées Récurifs* pour ajuster les paramètres conséquents (linéaires). Cette approche d'identification ne nécessite pas de connaissance *a priori* : l'algorithme démarre avec une seule fonction d'appartenance, la structure du système NF-TS se construit progressivement lors de

l'apprentissage en ligne. Cette technique d'identification a les caractéristiques suivantes :

1. évolutive : elle permet de faire évoluer la structure du NF-TS simultanément avec les paramètres,
2. autonome : elle évolue automatiquement (sans expert),
3. réactive : elle permet de prendre en compte les nouvelles observations sans phénomène d'oubli,
4. accumulative : elle peut accumuler de l'expérience.

### II.5.2 Discussion et choix d'une méthode d'identification

Après la présentation de l'état de l'art des méthodes d'identification d'un NF-TS, l'objectif est ici de trouver la méthode la plus convenable en regard des critères nécessaires et souhaitables. Nous présentons un tableau de comparaison de ces méthodes en fonction des contraintes industrielles (la complexité de l'équipements, le type d'environnement dynamique/non-linaire, la connaissance *a priori*, et la quantité de données disponible) et en fonction des 3 critères souhaitables (l'ouverture du système, sa flexibilité et son application en temps réel).

		Méthodes d'identifications d'un NF-TS				
		Mosaïque	Descente de Gradient (ANFIS)	Coalescence Floue	Stratégie évolutionnaire	
					Algorithmes Génétiques	eTS (evolving Takagi-Sugeno)
Conditions Industrielles	Équipements Complexes	++	++	++	++	++
	Environnements Dynamiques/non-linéaires	++	++	++	++	++
	Pas de connaissance <i>a priori</i>	--	+-	+-	++	++
	Beaucoup des données	++	++	++	++	++
Critères Souhaitables	Application temps réel	++	++	++	++	++
	Flexible	++	++	++	++	++
	Ouvert	--	--	--	--	++

FIG. II.7 – Corrélation des méthodes d'identifications avec les critères de choix

Revenant au problème de pronostic par prédiction d'un phénomène de dégradation, laisser l'entière construction du modèle prédictif à un expert n'est pas très approprié (il

peut être difficile d'appréhender le comportement de l'équipement surveillé). Les approches par descente du gradient ou algorithmes génétiques, certes permettent la mise à jour des paramètres du modèle par un processus d'apprentissage, mais sont basées sur une structure d'inférence fixe, ce qui suppose qu'un expert doit être en mesure d'indiquer l'architecture adéquate du système. A l'opposé, les approches dites par «*clustering*» nécessitent moins d'informations *a priori* quant à la structure du modèle prédictif (le nombre de fonctions d'appartenance et de règles est déterminé automatiquement). Cependant, le processus d'apprentissage n'est efficace que si les données disponibles sont suffisantes : le modèle obtenu étant fixe, si le comportement de l'équipement surveillé évolue (comme dans un processus de dégradation), les prédictions peuvent souffrir d'un manque de données représentatives lors de l'apprentissage.

Compte tenu des restrictions applicatives que suppose la mise en œuvre d'un outil de pronostic, les modèles TS évolutifs semblent être les plus prometteurs. D'abord, l'intervention d'expert n'est pas nécessaire pour mettre à jour les paramètres du modèle. Ensuite, l'apprentissage se fait en ligne et l'architecture du modèle prédictif est flexible. La structure évolue à mesure que de nouvelles données sont recueillies sur l'équipement (collectées en continu) : modification ou création de nouvelles règles. Ce point est très intéressant pour tenir compte des phénomènes progressifs de dégradation, et au final, les modèles TS évolutifs s'avèrent bien appropriés pour une application orientée «prédiction de séries temporelles dans un environnement dynamique et non-linéaire». Un modèle particulier est l'exTS (evolving eXtended Takagi-Sugeno) proposé par Angelov [AZ06] (section suivante).

## II.6 Le système évolutif exTS comme outil de prédiction

### II.6.1 Système exTS : objectif fondamental

L'objectif fondamental dans le développement de cette approche a été de construire un mécanisme simple et efficace permettant l'enrichissement de la structure du modèle, plutôt que de faire une adaptation simple des paramètres, comme cela est fait très souvent [Ang02]. Cette nouvelle méthode d'identification des modèles non-linéaires est fondée sur un algorithme de clustering en ligne qui est responsable de la construction de la structure du modèle (définir le nombre des règles). Cette méthode est inspirée de la méthode de substructive clustering. Elle calcule d'une manière récursive le potentiel des nouvelles données, c'est à dire, la capacité des nouvelles données à représenter un ensemble de données passées. Par suite, l'évolution des règles se fait en comparant le potentiel de la nouvelle donnée avec les autres potentiels. L'objectif principal de cet algorithme en ligne est :

- d'adapter, modifier, et innover non seulement sur les paramètres du modèle, mais également sur sa structure. Dans le même temps, cela ne devrait pas se

- produire très souvent pour éviter une surcharge des règles voir même éventuellement une redondance entre les règles,
- d’enrichir la structure du modèle (et pas seulement modifier une règle, mais en ajouter une si nécessaire),
  - de simplifier le plus possible l’apprentissage (la structure doit être aussi minime que possible, appliquer des techniques non-itératives, lorsque c’est possible) sans perte de précision,
  - de faire évoluer, cela ne signifie pas nécessairement d’utiliser des algorithmes dites évolutionnaires, y compris les algorithmes génétiques. Cela signifie plutôt d’assumer une structure croissante et d’assurer la construction du modèle prédictif durant l’utilisation de l’équipement réel.

Ces propriétés sont particulièrement appropriées pour la robotique, la détection de pannes et le diagnostic d’après [Ang02]. Nous considérons que ce type de modèle est aussi approprié pour un système prédictif.

## II.6.2 Algorithme d’apprentissage en ligne du TS

En mode en ligne, les données sont collectées de façon continue, et ne sont pas stockées dans des bases de données de manière statistique. Certains des nouveaux échantillons reçus viennent renforcer et confirmer les informations contenues dans les données précédentes. D’autres échantillons toutefois apportent de nouvelles informations, ce qui peut indiquer un changement dans les conditions d’utilisation de l’équipement ou signifier une modification de la dynamique du processus. En conséquence, il est nécessaire d’adapter en conséquence la structure du modèle prédictif : de nouvelles informations peuvent induire la construction d’une nouvelle règle ou la modification d’une existante [AF03].

### II.6.2.1 La procédure de base

L’algorithme évolutionniste proposé par [Ang02] et adopté par nous pour être la base du modèle prédictif est une technique d’identification et a les caractéristiques suivantes : en ligne, non itérative (récursive) et en temps réel. Il peut démarrer avec deux possibilités :

1. un expert peut initialiser la structure et déploiement de la technique,
2. démarrage de zéro (aucune information sur la structure) la structure ne démarre qu’avec une seule règle.

C’est le deuxième point qui nous intéresse parce que nous supposons qu’on n’a pas d’information *a priori* permettent d’initialiser la structure. Par contre, un flux d’échantillons de données est disponible. Voici les étapes qui composent cette technique :

**Etape 1** : initialisation de la première règle floue avec l’arrivée du premier échantillon. les échantillons sont des mesures des capteurs en temps réel. De plus un potentiel est accordé à cet échantillon (à chaque règle on accorde un potentiel).

- Etape 2** : lecture en ligne de l'échantillon suivant (deuxième échantillon),
- Etape 3** : calcul d'une manière récursive du potentiel de ce nouvel échantillon en comptant l'ensemble des données collectées (l'information de la nouvelle donnée est enregistrée sous forme d'un potentiel).
- Etape 4** : ajustement récursif des potentiels des règles existantes compte tenu de l'influence de la nouvelle donnée. A l'arrivée du deuxième échantillon, une seule règle existe avec son potentiel.
- Etape 5** : modification, ajout ou révision des règles de la structure. Cette étape est considérée comme l'étape d'innovation. La décision de modification, ajout ou de simple révision de la structure sera faite en comparant le potentiel de la nouvelle donnée (le dernier échantillon) avec les potentiels existants des règles (on détaillera cette partie dans la section suivante).
- Etape 6** : calcul des paramètres conséquents par un moindre carré récursif.
- Etape 7** : prédiction d'un horizon bien défini : sortie du NF-TS.

Après l'étape 7, l'algorithme continue l'exécution en retournant à l'étape 2 (figure II.8). Avec ce type d'algorithme, on n'a pas seulement une bonne adaptation des paramètres,

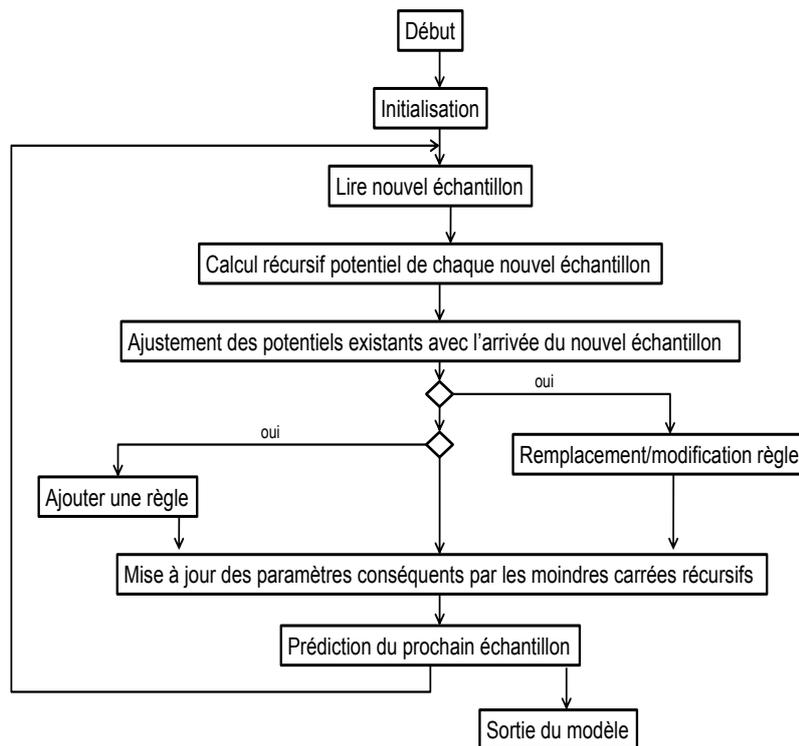


FIG. II.8 – La procédure d'un algorithme d'apprentissage évolutionnaire et en ligne d'un TS [Ang02]

mais également un modèle dont la structure évolue en temps réel. Rappelant que l'apprentissage se fait en ligne, la structure et les paramètres de TS restent proches du phénomène réel et s'adaptent automatiquement. Ces critères rendent le modèle prédictif plus robuste en temps réel. Par ailleurs, le calcul récursif est un gage d'applicabilité de l'outil (temps de calcul réduit). Comme le TS se décomposent en modèles locaux dans lesquels on trouve deux types des paramètres (les paramètres antécédents non-linéaires, les paramètres conséquents linéaires, l'apprentissage en ligne sera assuré par deux algorithmes :

1. un algorithme évolutionniste permettant de modifier progressivement les règles floues et d'ajuster les paramètres non-linéaires),
2. un algorithme des moindres carrés récursifs afin d'estimer les paramètres linéaires.

### II.6.2.2 Algorithme de clustering évolutionnaire et en ligne

Rappelons que les données sont collectées en continue, sans que la structure ne soit définie en préalable. L'étape de clustering en ligne vise à construire la structure floue (dans cette structure, le nombre de fonctions d'appartenance pour chaque entrée est égal au nombre de règles ( $R$ ) d'inférence floue). Ensuite, la détermination du *nombre de fonctions d'appartenance* et la distribution de chacune d'elle est faite par l'élaboration de  $R$  et l'ajustement des paramètres prémisses  $(\mu_i^j, \sigma_i^j)$ .

*A- Construire la structure et ajuster les  $\mu_i^j$  des fonctions d'appartenance*

La structure commence à se construire à l'arrivée du premier échantillon ( $Z^{k=1} = [X^{k=1}, y^{k=1}]$ ). La structure de départ a une seule règle (cluster). A chaque entrée du TS n'est associée qu'une seule fonction d'appartenance. Le centre  $(c_1^j, j = 1, \dots, n)$  de chaque fonction d'appartenance est l'entrée correspondante. Le premier échantillon contient donc les points focaux ou les centres des fonctions d'appartenances.

Pour résumer, la **première étape** de cet algorithme consiste à associer à chaque entrée ( $n$  entrées) un *cluster*, ce cluster est caractérisé par trois éléments :

- $c_{i=1}^j = X^*(j)$  est le centre (le point focal) de ce cluster,
- $\sigma_{i=1}^j$  est le rayon de ce cluster et il est égal à 1,
- $P_{i=1}^*$  est le potentiel de ce cluster et il est égal à un.

Où  $i$  est le *i<sup>ème</sup>* est le numéro de la règle, et  $j$  le numéro de l'entrée du système TS.

La **deuxième étape** de cet algorithme commence avec l'arrivée du deuxième échantillon ( $k = 2$ ). A chaque nouvel échantillon, un nouveau potentiel peut être calculé récursivement en utilisant la fonction de Cauchy :

$$P^k(Z^k) = \frac{1}{1 + \frac{1}{k-1} \sum_{g=1}^{k-1} \sum_{j=1}^{n+1} (d_g^{jk})^2}; \quad k = 2, 3, \dots \quad (\text{II.7})$$

Où  $P^k(Z^k)$  est le potentiel de l'échantillon  $Z^k$  à l'instant  $k$ . Par suite,  $d_g^{jk} = Z_g(j) - Z^k(j)$ , et  $\sum_{g=1}^{k-1} \sum_{j=1}^{n+1} (d_g^{jk})^2$  représente la *distance euclidienne* entre  $Z^k$  et tous les anciens échantillons.

Notons que la formule II.7 peut être transformée en une formule récursive, parce que le calcul récursif est nécessaire en apprentissage en ligne afin de ne pas avoir stocker les échantillons du passé [AF03]. Par conséquent, le potentiel du nouvel échantillon  $Z^k$  calculé récursivement est le suivant :

$$P^k(Z^k) = \frac{k-1}{(k-1)(1+\alpha^k) + \beta^k - 2\gamma^k} \quad (\text{II.8})$$

Avec

$$\begin{aligned} - \alpha^k &= \sum_{j=1}^{n+1} (Z^k(j))^2 \\ - \beta^k &= \beta^{k-1} + \sum_{j=1}^{n+1} (Z^{k-1}(j))^2 \\ - \gamma^k &= \sum_{j=1}^{n+1} Z^k(j) \cdot \Gamma^{jk}; \Gamma^{jk} = \Gamma^{jk-1} + Z^{k-1}(j) \end{aligned}$$

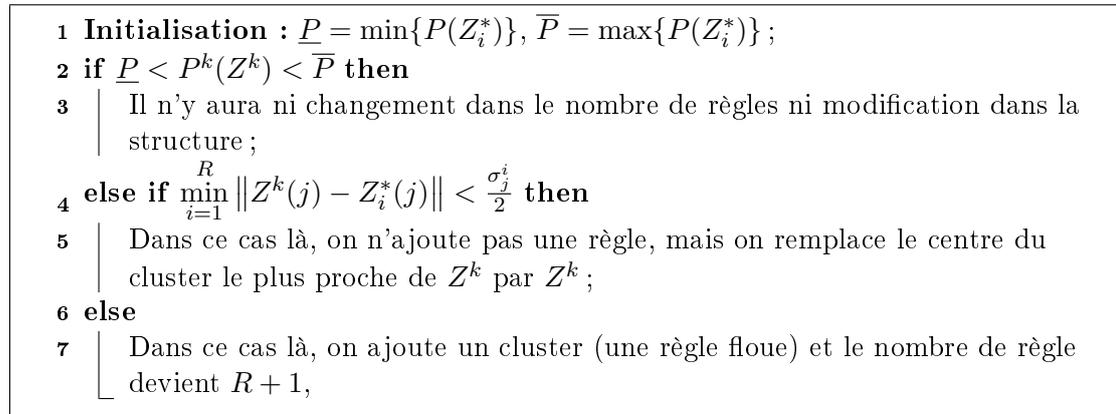
Quand le nouvel échantillon est disponible en ligne, une influence certaine sur les potentiels des clusters existe (à chaque cluster correspond un potentiel). Si on considère qu'on a  $R$  clusters ( $R$  règles) à l'instant  $k-1$ . Alors  $R$  potentiels doivent être réadaptés avec l'arrivée du nouvel échantillon à l'instant  $k$  (**quatrième étape**). Donc, la formule récursive qui permet de réadapter les potentiels des points focaux existants ( $Z_i^*$ ,  $i = 1 \rightarrow R$ ) est la suivante :

$$P^k(Z_i^*) = \frac{(k-1)P^{k-1}(Z_i^*)}{k-2 + P^{k-1}(Z_i^*) \sum_{j=1}^{n+1} (d^{jk(k-1)})^2}, \quad i = 1, \dots, R \quad (\text{II.9})$$

Avec  $d^{jk(k-1)} = Z_i^{*k}(j) - Z^k(j)$  est la *distance euclidienne* entre le point focal  $Z_i^{*k}$  et le nouvel échantillon  $Z^k(j)$ .

Après le calcul du potentiel concernant du nouvel échantillon et l'ajustement des potentiels des anciens clusters, la **cinquième étape** peut commencer par l'étude de l'évolution des règles. C'est en cela que cet algorithme diffère des autres : c'est la structure qui s'adapte au changement environnemental.

Ce mécanisme d'adaptation (figure II.9) des règles est fondée sur le calcul des potentiels des échantillons des données. Dans cette étape, il est possible d'ajouter une règle floue, de modifier une règle déjà existante ou de garder le même nombre de règles (sans ajouter aucune évolution). Trois choix d'évolution sont donc possible. La sélection d'un de ces trois choix est liée au potentiel du nouvel échantillon et aux potentiels des règles existantes. Plusieurs scénarios peuvent être imaginés. Nous adoptons le scénario proposé par [AZ06] (voir Algorithme 1).

**Algorithm 1:** Trois cas d'évolution*B- Adapter les  $\sigma_i^j$  des fonctions d'appartenances*

Dans les algorithmes du clustering les  $\sigma_i^j$  de chaque fonction d'appartenance sont fixés à l'avance, et toutes les fonctions d'appartenance ont le même rayon. Par contre, ce n'est pas tout à fait logique. En effet, à chaque entrée un espace bien défini lui correspond et chaque fonction d'appartenance a son propre rayon. Angelov a proposé un moyen pour spécifier à chaque fonction d'appartenance un rayon adaptable avec l'arrivée des nouvelles données. Cette dernière permet de rendre le système TS plus adaptable à l'environnement.

Si la **cinquième étape** se finit par un ajout de règle, aucune modification sur le nombre d'éléments des clusters n'est nécessaire et les rayons de chaque cluster restent les mêmes. Chaque cluster ajouté a un rayon égal à «1».

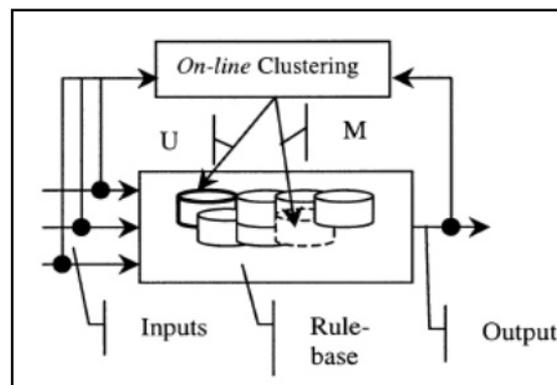


FIG. II.9 – Mécanisme d'innovation et de modification des règles à travers les données

En cas de modification ou de mise à jour des règles, le nouvel échantillon doit être affecté à un des clusters et le nombre d'éléments du cluster doit être mis à jour. Par conséquent une adaptation du rayon du cluster est nécessaire. Voici comment adapter récursivement le rayon du cluster :

$$\sigma_l^{jk} = \rho \sigma_l^{j_{k-1}} + 0.5 \sqrt{D_l^{jk}}, \quad l = \min_{i=1}^R \left\| Z^k(j) - Z_i^*(j) \right\|_{j=1, \dots, n} \quad (\text{II.10})$$

Avec  $D_l^{jk}$  (éq. II.11) est la dispersion locale (en anglais local scatter),  $\rho$  est une constante permettant la régulation de la compatibilité de la nouvelle information avec l'ancienne.

$$D_l^{jk} = \frac{1}{S_l^k} \sum_{v=1}^{S_l^k} \left\| Z^k(j) - Z^v(j) \right\|^2; \quad D_l^{j0} = 1 \quad (\text{II.11})$$

Notons que lorsque l'on ajoute une règle, le nombre de règles devient  $(R + 1)$ , une dispersion locale correspond à cette nouvelle règle, l'initialisation de cette dispersion est calculée par la formule suivante :

$$D_{R+1}^{jk} = \frac{1}{R} \sum_{i=1}^R D_i^{j_{k-1}} \quad (\text{II.12})$$

En intégrant l'adaptabilité, le TS devient un exTS (**e**volving **e**xtended **T**akagi-**S**ugeno, selon Angelov). En conséquent, c'est l'exTS qu'on adoptera comme outil de prédiction.

### II.6.2.3 Moindres Carrés Récursifs, MCR

Pour finir l'adaptation des paramètres du NF-TS, il ne reste qu'à ajuster les paramètres conséquents. Lorsque les paramètres antécédents sont ajustés, le NF-TS est un système linéaire par rapport aux paramètres conséquents. L'algorithme des moindres carrés récursifs (MCR) permet d'adapter ses paramètres. Par contre, la structure incrémentale pose un problème pour ajuster les paramètres, parce que normalement les règles sont fixes et par suite le nombre de paramètres antécédents est constant. Dans, ce type d'apprentissage évolutionniste le nombre de règles s'incrémente avec le temps, donc le nombre de paramètres antécédents change parallèlement avec le nombre de règles. Pour résoudre ce problème, Angelov a proposé une initialisation des paramètres ajoutés et leur matrice de covariance. En effet, la sortie du NF-TS en fonction des paramètres antécédents (connus) et les paramètres conséquents (à estimer par le MCR) est :

$$y^{k+1} = \sum_{i=1}^R \lambda_i \Upsilon_i = \psi_k \theta_k \quad (\text{II.13})$$

Avec  $\theta_k = [\pi_1^T, \pi_2^T, \dots, \pi_R^T]$  est le vecteur qui contient les paramètres linéaires ( $T$  est le transposé d'un vecteur),  $\psi_k = [\lambda_1 x_e, \lambda_2 x_e, \dots, \lambda_R x_e]$  est le vecteur des entrées pondérées par les degrés d'activation des règles.

Donc la procédure de MCR est la suivante :

$$\hat{\theta}_k = \hat{\theta}_{k-1} + C_k \psi_k (y_{k+1} - \psi_k^T \hat{\theta}_{k-1}), \quad k = 2, 3, \dots \quad (\text{II.14})$$

$$C_k = C_{k-1} - \frac{C_{k-1} \psi_k \psi_k^T C_{k-1}}{1 + \psi_k^T C_{k-1} \psi_k} \quad (\text{II.15})$$

Avec  $C$  la matrice de covariance des paramètres linéaires.

Mais lorsqu'il y a génération d'une règle, des nouveaux paramètres linéaires sont ajoutés, paramètres devant être initialisés. Pour prendre en compte cela, il faut utiliser la formule suivante :

$$\hat{\pi}_{R+1}^k = \sum_{i=1}^R \lambda_i \hat{\pi}_{R+1}^{k-1} \quad (\text{II.16})$$

$$\hat{\theta}_k = [\hat{\pi}_{1(k-1)}^T, \hat{\pi}_{2(k-1)}^T, \dots, \hat{\pi}_{R(k-1)}^T, \hat{\pi}_{R+1(k)}^T] \quad (\text{II.17})$$

Ensuite, la matrice de covariance est adaptée de la manière suivante :

$$\begin{bmatrix} r\xi_{11} & \dots & r\xi_{1R(n+1)} & 0 & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots & \dots \\ r\xi_{R(n+1)1} & \dots & r\xi_{R(n+1)R(n+1)} & 0 & \dots & 0 \\ 0 & 0 & 0 & \Omega & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & 0 & 0 & \Omega \end{bmatrix}$$

Avec  $\xi_{uw}$  ( $u = 1, \dots, R \times n + 1, w = 1, \dots, R \times n + 1$ ) est l'élément de matrice de covariance,  $r = \frac{R^2+1}{R^2}$ .

Notons que s'il y a une modification de l'une des règles ou non dans la structure la matrice de covariance garde la même dimension.

## II.7 Conclusion

Ce chapitre est une étape importante pour mettre en œuvre notre concept de pronostic. Notre concept nécessite de rechercher un modèle de prédiction capable de réagir dans

des contextes industrielles spécifiques.

Les contextes industriels actuels présentent des comportements dynamiques et non-linéaires sur leur équipements industriels de plus en plus complexes. En outre, il manque des connaissances sur le fonctionnement de ces équipements. Par contre, avec l'arrivée des STIC<sup>2</sup> se présente la possibilité d'avoir une énorme quantité de données. Un modèle de prédiction doit ainsi être appliqué en ligne (en temps réel). Ce modèle doit garder un degré d'adaptabilité c'est à dire doit être capable d'être lié en permanence avec le changement de l'environnement.

Tout d'abord, avec ce contexte industriel, nous avons choisi un outil de prédiction basé sur des séries chronologiques. Notre modèle doit utiliser les données disponibles dans l'objectif de comprendre le phénomène de dégradation de l'équipement et d'en prédire l'évolution (la première sous activité de pronostic). Plusieurs modèles de prédiction existent dans la littérature. Notre choix s'est porté sur les systèmes d'IAs. Ces sont des systèmes considérés comme des systèmes «soft computing», capables de manipuler d'une manière rapide des informations (les données) et d'extraire des connaissances qui aide les opérateurs ou les experts à prendre des décisions. De plus, ils ne supposent aucune hypothèse sur le type des données. Ces types de systèmes ont été privilégiés par rapport aux autres systèmes classiques.

Parmi, les nombreux systèmes d'IAs proposés dans la littérature, les RNs sont les plus populaires pour prédire des séries chronologiques. Mais, ils représentent des inconvénients. Alors, une idée est de fusionner cette technique avec une autre technique d'IAs qui est la logique floue (capacité de raisonnement). La technique NF-TS est très intéressante pour prédire des séries chronologiques. Plusieurs méthodes d'identification de NF-TS existent. La méthode la plus convenable avec les critères nécessaires et souhaitables est celle proposée par Angelov. Cette méthode présente plusieurs caractéristiques dont le monde industriel a besoin, comme l'auto-conception, l'auto-enrichissement et l'application en temps réel. En effet, nous adopterons le modèle exTS proposé par Angelev [AZ06] comme modèle prédictif adéquat avec le contexte actuel : l'algorithme évolutif proposé par Angelov [AZ06] ne nécessite aucune connaissance *a priori* pour définir la structure du système flou et peut adapter la structure et ajuster les paramètres en ligne. Un tel système prédictif (exTS, evolving extend Takagi-Sugeno) correspond à nos critères de choix.

L'exTS est un système prédictif adéquat pour prédire des séries chronologiques non-linéaires. Cependant, le nombre d'entrées n'est pas facile à déterminer dans un contexte complexe. Ce facteur a un impact direct sur la complexité et la performance du système prédictif. Dans cet objectif, nous consacrons le chapitre III à la proposition d'une procédure de génération automatique du système prédictif choisi.

---

<sup>2</sup>Sciences et Technologies de l'Information et de la Communication

Chapitre **III**

**Génération automatique d'un système  
prédictif du type exTS : un compromis  
performance / complexité**

## III.1 Introduction

Le caractère évolutif du système exTS lui confère de bonnes capacités d'approximation de fonctions. De plus, son aptitude à apprendre de manière incrémentale (à mesure que de nouvelles données sont disponibles) en fait un outil adapté à une utilisation en ligne. Il nous est ainsi apparu comme un système adéquat pour supporter l'activité de prédiction du processus de pronostic.

Sur cette base, l'objet de ce chapitre est de proposer une procédure de génération automatique d'un système exTS prédictif, adaptée à notre problématique de pronostic sans connaissance *a priori*. L'idée sous-jacente est de tâcher de construire un modèle neuro-flou présentant de bonnes performances de prédiction, tout en ayant une structure suffisamment légère pour éviter les problèmes de sur-apprentissage. Pour ce faire, nous discutons d'abord le problème du compromis «performance de prédiction / complexité» et montrons où l'utilisateur influe dans la construction du système prédictif. Nous proposons ensuite une démarche permettant de s'affranchir de l'intervention de l'homme. Enfin, nous validons cette proposition par simulation.

## III.2 Performance versus complexité : un problème d'identification

### III.2.1 Explicitation du problème

#### III.2.1.1 *Approximation, généralisation et complexité*

Les réseaux neuro-flous du type Takagi-Sugeno sont des approximateurs universels, c'est à dire des systèmes à même d'approximer n'importe quelle fonction de transfert entre un ensemble d'entrées et un ensemble de sortie, avec une certaine précision (arbitraire). L'utilisateur peut être tenté de construire un réseau qui «reproduise» au mieux possible la relation cachée entre entrées et sorties de la base d'apprentissage. Cependant, il existe un point au delà duquel l'augmentation de la complexité du réseau ne se traduit que par des gains marginaux en terme de performance dans l'approximation. Plus encore, un modèle trop proche des données d'apprentissage peut avoir de mauvaises capacités de généralisation dans la mesure où il ne sera à même de reproduire que ce qu'il a bien appris. Il est donc nécessaire de préserver une structure de modèle aussi simple que possible tant que les performances du réseau neuro-flou sont satisfaisantes. C'est ce qui peut être exprimé comme la recherche d'un compromis «performance / complexité», et cela reste valable si la fonction d'approximation consiste à réaliser une prédiction.

Considérons la figure III.1 pour illustrer ce problème de compromis. Dans cette figure, les courbes de distributions de probabilité (probability density function, pdf) du pourcentage de l'erreur de prédiction de deux systèmes sont présentées. Le premier (en bleu,

trait discontinu) présente une pdf à faible dispersion et correspond à un réseau à forte complexité (beaucoup de règles, beaucoup de paramètres). Ce système prédictif est donc un bon approximateur. Le second réseau lui est de structure beaucoup plus légère mais présente des performances de prédiction moins bonnes : la pdf des erreurs de prédictions est beaucoup plus dispersée que dans le cas du premier réseau. En revanche, ce réseau ne tendant pas à systématiquement avoir une erreur de prédiction nulle, il est probablement beaucoup plus à même de ne pas donner de résultats complètement aberrants si une nouvelle entrée lui est présentée, différente de celles qu'il a déjà apprises (capacité de généralisation).

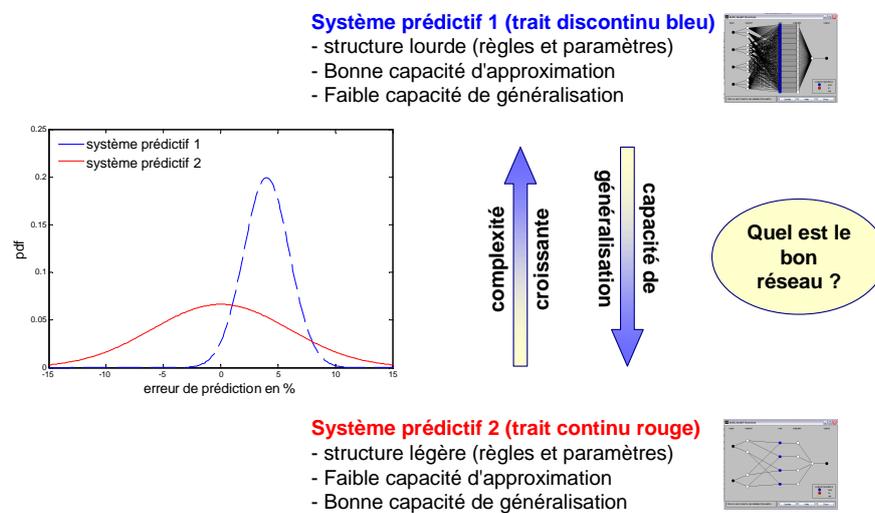


FIG. III.1 – Illustration du compromis «performance de prédiction / complexité»

### III.2.1.2 Critères influents

La performance d'un réseau neuro-flou dépend donc de la complexité de celui-ci. Cette dernière découle d'un grand nombre de paramètres : nombre d'entrées du réseau, nombre de fonctions d'appartenances, nombre de règles, algorithme d'apprentissage, etc. L'influence de chacun de ces critères sur les performances du réseau ne peut être établie *a priori*, et les utilisateurs adoptent généralement une stratégie de «essais - erreur» pour construire le système prédictif, ce qui peut être long, ou encore demander une certaine expertise pour converger rapidement vers un système satisfaisant. L'objet des sections suivantes est ainsi de proposer une approche pour palier ce problème.

## III.2.2 Un problème d'identification

### III.2.2.1 Procédure d'identification d'un système TS

Dans la pratique, la structure et les paramètres d'un système d'inférence floue doivent être définis afin que le système soit à même de correctement approximer la fonction de transfert «entrées - sorties» recherchée (une fonction de prédiction dans notre cas). Ceci est connu sous le nom d'identification du modèle et peut être formulé comme suit.

Considérons que nous disposons d'une ensemble de données d'apprentissage ( $B^S$ ) composé de  $S$  couples entrées-sortie récoltés au cours du temps :

$$B^S = [y_d(1), U(1), \dots, y_d(S), U(S)] \quad (\text{III.1})$$

avec,

- $y \in \mathfrak{R}$ , la grandeur d'intérêt (la sortie),
- $U \in \mathfrak{R}^{nn}$ , les grandeurs explicatives ( $nn$  désigne leur nombre),
- $S$ , le nombre d'échantillons récoltés.

Le système prédictif vise, à l'instant  $t$ , à approximer la fonction permettant de corréler une sortie future  $y(t+h)$  (où  $h$  est l'horizon de prédiction) avec les observations disponibles jusqu'ici ( $B^t$ ). Ce problème dépend des paramètres du système :

$$\hat{y}(t+h, \Gamma) = f(B^t, \Gamma) \quad (\text{III.2})$$

avec,

- $f(\cdot)$ , la fonction d'approximation inconnue,
- $\hat{y}(t+h)$ , la prédiction de la sortie pour l'instant  $t+h$ ,
- $\Gamma$ , le vecteur des paramètres du système TS.

Compte tenu que  $B^t$  grandit à mesure que de nouvelles données sont disponibles, le problème d'identification peut être reformulé avec un ensemble de dimension fixe composé de quelques données passées :

$$\hat{y}(t+h, \Gamma) = f(E(t+h), \Gamma) \quad (\text{III.3})$$

où,  $E(t+h)$  est connu comme l'ensemble des régresseurs.

Sur cette base, l'identification d'un modèle prédictif présente 5 phases que nous décrivons ci-après. Une vision d'ensemble est proposée en figure (III.2).

#### 1. Extraction de descripteurs

Cette phase consiste à trouver les  $nn$  variables explicatives permettant d'approximer la sortie. Ceci peut être réalisé grâce à un expert ou en utilisant des techniques de fouille de données. Dans le cas particulier du pronostic (et tel que décrit dans la section I.2.3.2),

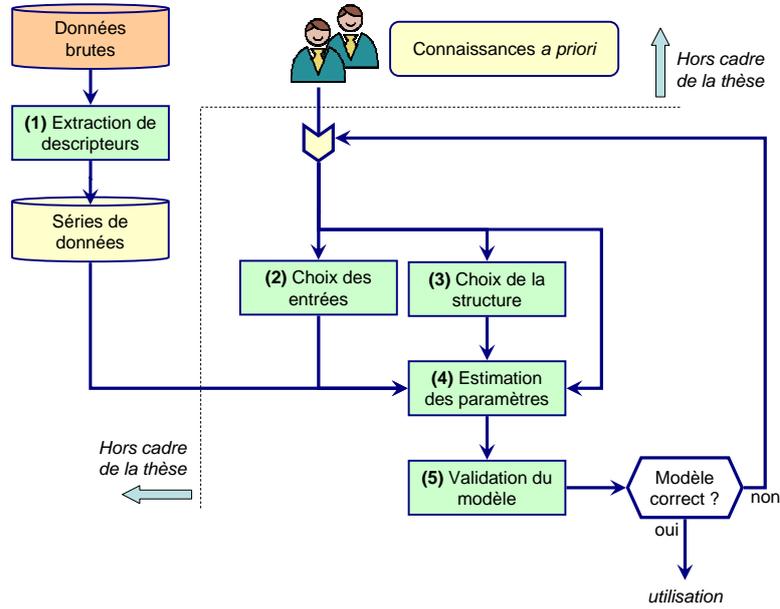


FIG. III.2 – Procédure générale d'identification d'un système prédictif TS

cette étape correspond aux premières couches de l'architecture CBM (chapitre I) visant à acquérir les données, à les nettoyer, à extraire et à sélectionner des descripteurs. Nous avons par ailleurs considéré que ce travail était hors du cadre de notre étude (considéré comme réalisé).

### 2. Choix des entrées

A partir de l'ensemble  $B^S$  composé des variables explicatives et de la variable d'intérêt, cette phase vise à construire l'ensemble des régresseurs potentiellement nécessaires à la prédiction. Conformément aux notations adoptées dans l'équation éq. III.3, nous avons :

$$E(t+h) = \begin{bmatrix} y(t-1) & \cdots & y(t-q_y) \\ x_1(t-1) & \cdots & x_1(t-p_{x_1}) \\ \cdots & & \\ x_{nn}(t-1) & \cdots & x_{nn}(t-p_{x_{nn}}) \end{bmatrix} \quad (\text{III.4})$$

où  $q_y, p_{x_1}, \dots, p_{x_{nn}}$  désignent le nombre de données passées des séries de données de la grandeur d'intérêt et des grandeurs explicatives qui seront retenues au maximum. Il convient ensuite éventuellement de restreindre l'ensemble  $E$  afin de définir les  $n$  entrées du système d'inférence floue (sous-ensemble  $S_E \in E$  avec  $n = \dim(S_E)$ ).

### 3. Choix de la structure du système flou

L'objet de cette étape est de définir la structure mathématique du système d'inférence floue  $f(\cdot)$ . Il est donc nécessaire de choisir le nombre et la forme des fonctions d'appar-

tenance pour chacune des entrées (couche 1 de la figure A6), et le nombre de règles (qui lui même dépend du nombre de connexions entre les couches 2 et 3).

#### 4. Estimation des paramètres

Cette étape consiste à définir les paramètres de la fonction  $f(\cdot)$  afin de satisfaire un critère de performance donné. Si aucun expert n'est à même de paramétrer la structure d'inférence floue, cette étape est réalisée par apprentissage et différents algorithmes peuvent être utilisés. La plupart sont basés sur la minimisation d'une fonction coût décrivant une distance entre les prédictions du système flou et les valeurs réelles attendues. Si  $k$  couples entrées-sortie sont disponibles pour l'apprentissage, le vecteur des paramètres estimés  $\hat{\Gamma}$  est obtenu comme suit :

$$\begin{aligned}\hat{\Gamma}_k &= \operatorname{argmin}_{\Gamma} [V_k(S_E^k, \Gamma)] \\ V_k(S_E^k, \Gamma) &= \frac{1}{k} \sum_{t=1}^k d(\varepsilon(t+h, \Gamma))\end{aligned}\tag{III.5}$$

avec  $V_k$  une fonction coût,  $\varepsilon(t+h, \Gamma)$  l'erreur de prédiction, et  $d(\cdot)$  une mesure de distance. L'erreur quadratique est généralement utilisée car elle permet d'estimer simplement les paramètres linéaires de la structure floue (algorithmes des moindres carrés) :

$$V_k(S_E^k, \Gamma) = \frac{1}{2k} \sum_{t=1}^k [y(t+h) - \hat{y}(t+h, \Gamma)]^2\tag{III.6}$$

#### 5. Validation du modèle

La validation du modèle vise à tester les performances du système prédictif construit en utilisant des données autres que celles utilisées lors de la phase d'apprentissage. Cette étape peut bien entendu amener l'utilisateur à remettre en question le système prédictif construit (et à faire de nouveaux choix).

### III.2.2.2 Influence de l'utilisateur dans l'identification d'un exTS

Il apparaît que l'identification du système prédictif est une procédure relativement flexible. Pourtant, les choix faits à chacune des étapes ont une influence directe sur les performances du système prédictif et sur sa complexité. Aussi, il est bien difficile de construire directement une structure adéquate. Relativement au cadre d'étude de cette thèse, ceci pose le problème de l'influence de l'utilisateur : nous nous sommes proposés de construire un système de prédiction (et de pronostic) sans qu'aucune connaissance *a priori* ne soit nécessaire... Revenons sur cette procédure et discutons la en regard du système prédictif exTS que nous avons choisi [KGZ10a].

L'étape 1 (extraction des descripteurs) étant considérée comme «hors thèse», nous ne la considérons pas ici. Les caractéristiques évolutives du système exTS permettent de s'affranchir de choix arbitraires pour définir la structure du système prédictif, pour en

initialiser les paramètres, et pour les ajuster à mesure que de nouvelles données sont disponibles. Les étapes 3 et 4 définies précédemment peuvent donc être réalisées sans l'intervention de l'homme. En revanche, lors de la construction d'un système exTS, l'utilisateur doit définir les entrées du système (étape 2, choix d'entrées), c'est à dire choisir le sous-ensemble de régresseurs. L'objet de la partie suivante est ainsi de proposer une approche pour automatiser ce choix.

### III.3 Proposition d'une procédure d'identification d'un système exTS basée sur un critère de parcimonie

#### III.3.1 Principe et grandeur de parcimonie

##### III.3.1.1 *Principe*

Nous proposons de définir les entrées du système prédictif de manière guidée par les données, et en regard des caractéristiques de performance et de complexité du système (étape de validation 5). Comme nous avons pu le décrire en section III.2, il n'est pas possible d'obtenir un système prédictif qui présente de bonnes capacités d'approximation (précision des prédictions) tout en ayant une structure légère (complexité du système). L'approche est ainsi basée sur l'utilisation d'un critère de parcimonie permettant de corréler ces deux grandeurs afin de rechercher un compromis «performance / complexité». Le principe de cette démarche est illustré en figure III.3.

##### III.3.1.2 *Critères de parcimonie*

###### *Complexité d'un exTS*

Le nombre de paramètres d'un système prédictif peut être interprété comme une grandeur de complexité du modèle. Pour un système de type Takagi-Sugeno, il est donc nécessaire de calculer le nombre de paramètres linéaires et non-linéaires de la structure d'inférence floue.

- Le système exTS étant un modèle TS du premier ordre, le nombre de paramètres linéaires peut être déterminé par la relation :  $nb_l = R \times (n + 1)$ , où  $R$  est le nombre des règles floues et  $n$  le nombre d'entrées.
- Le système exTS est singulier en ceci que le nombre de règles est égal au nombre de fonctions d'appartenance par entrée. Par suite, et compte tenu que l'algorithme de clustering évolutif de l'exTS est basé sur des fonctions d'appartenance de type gaussiennes, le nombre de paramètres non-linéaires est exprimé par la relation :  $nb_{nl} = 2 \times n \times R$ .

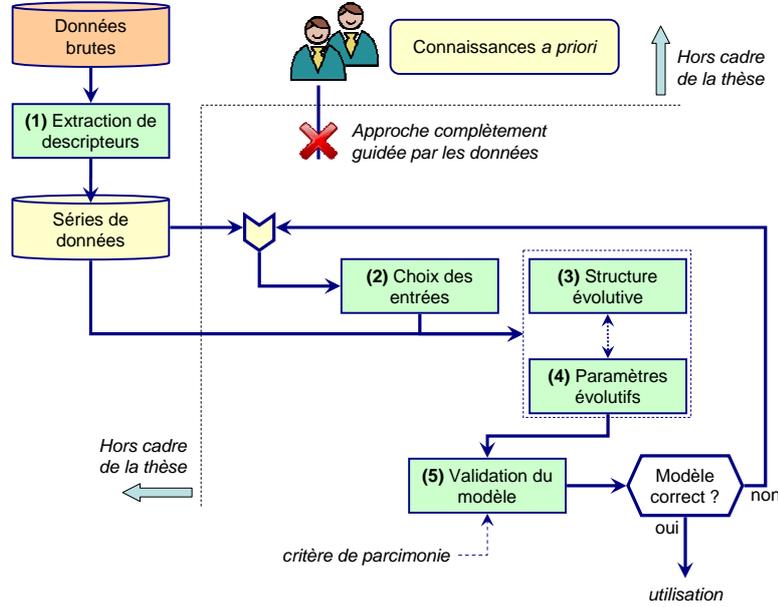


FIG. III.3 – Procédure d’identification d’un système exTS sans connaissance *a priori*

Au final, une mesure de complexité d’un système exTS est donc la suivante :

$$p = nb_l + nb_{nl} = R \times (n + 1) + 2 \times n \times R = R \times (3 \times n + 1) \quad (\text{III.7})$$

#### *Critère de parcimonie*

Une critère de parcimonie est une formulation mathématique du compromis entre la complexité et la qualité des prédictions d’un modèle [Aka74]. Ce type de critère est donc basé d’une part, sur le nombre de paramètres à ajuster ( $p$ ), et d’autre part, sur une mesure permettant de quantifier la précision des prédictions réalisées ( $L$  comme *likelihood*). Si  $S$  désigne le nombre d’échantillons utilisés lors de la phase d’apprentissage, la mesure de précision des approximations la plus usuelle est l’erreur quadratique moyenne ( $MSE$ ) :

$$L = \frac{1}{S} \sum_{g=1}^S (y_d - \hat{y})^2 \quad (\text{III.8})$$

Différents critères de parcimonie sont proposés dans la littérature, tels que le critère *AIC* (Akaike Information Criterion), le critère de Rissanen *MDL* (Minimum Description Length), ou le critère *FPE* (Final Prediction Error). Ces critères sont définis tels que présentés dans l’équation III.9. Ils sont construits de manière à décroître lorsque la complexité ( $p$ ) du système prédictif diminue et/ou lorsque la performance des prédictions ( $L$ ) augmente. Une illustration est proposée en figure III.4.

$$\begin{aligned} AIC &= S \times \log(L) + 2 \times p \\ MDL &= (1 + [p \times \log(L)]/S) \times L \\ FPE &= [(S + p)/(S - p)] \times L \end{aligned} \quad (\text{III.9})$$

Sur cette base, plusieurs modèles prédictifs peuvent être construits et classés en fonction de leur critère de parcimonie, le plus adéquat étant celui dont le critère de parcimonie est le plus faible (adéquat dans le sens de recherche d'un compromis entre performance et complexité). C'est cette propriété que nous proposons d'utiliser pour automatiser la construction du système exTS. Notons enfin que ces critères peuvent être construits sans l'intervention humaine.

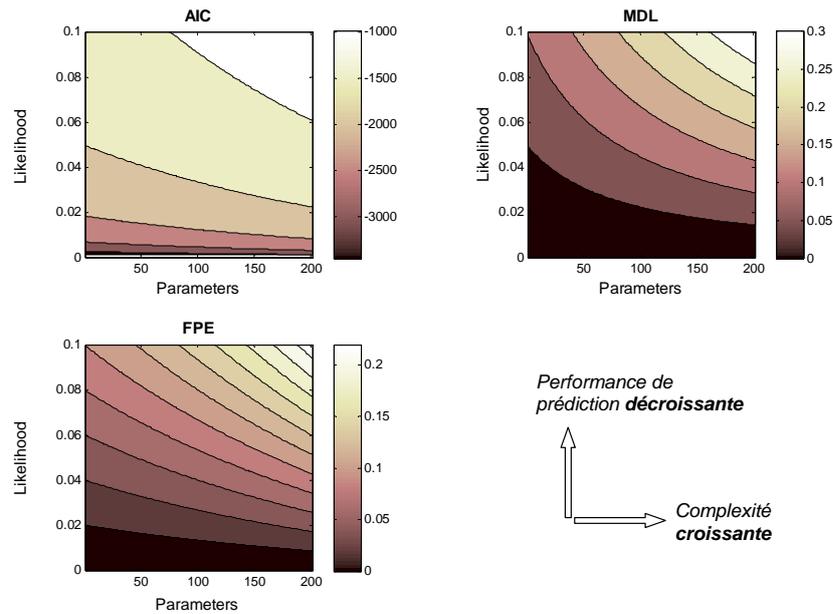


FIG. III.4 – Évolution des critères de parcimonie  $AIC$ ,  $MDL$  et  $FPE$

### III.3.2 Procédure d'identification proposée

#### III.3.2.1 Choix du critère de parcimonie

En général, le critère  $MDL$  est utilisé lorsque peu de données d'apprentissage sont disponibles. A l'opposé, lorsque le nombre de données d'apprentissage est grand, le critère  $FPE$  ne semble pas le plus pertinent dans la mesure où il ne pénalise pas suffisamment la complexité du modèle ( $FPE$  est faible dès lors que les performances de prédiction sont bonnes, et cela quel que soit le nombre de paramètres nécessaires). Pour la suite des développements, nous retenons finalement le critère  $AIC$ .

### III.3.2.2 Génération automatique du système prédictif *exTS*

Notre proposition d'une procédure de génération automatique du système prédictif est illustrée en figure III.5. L'identification d'un système prédictif guidée par les données se base sur l'utilisation de l'ensemble des régresseurs potentiellement (éq. III.3 et éq. III.4) utilisables ( $E$ ) pour la variable d'intérêt et les variables explicatives. De manière pratique, cela consiste à choisir les entrées du système prédictif. Sur la base de cet ensemble  $E$ , il est possible de générer de manière automatique un grand nombre de modèles en faisant varier le nombre de régresseurs sur chaque variable (et donc le nombre d'entrées). Chaque modèle est ainsi construit grâce à un sous ensemble  $S_E$  d'ordre  $O = \{p_{x_1}, p_{x_2}, \dots, p_{x_{nn}}, q_y\}$  et présente après apprentissage des mesures de complexité et de performance de prédiction propres ( $p$  et  $L$ ). Pour chacun, il est ainsi possible de calculer le critère de parcimonie ( $AIC$ ), afin de finalement choisir celui dont le critère est le plus faible : ce modèle est celui qui présente le meilleur compromis «performance - complexité».

Cette procédure peut être totalement automatisée (algorithme suivant). Ceci, combiné aux caractéristiques évolutives de l'*exTS* permet de générer un système prédictif sans qu'aucun connaissance *a priori* ne soit nécessaire [KGZ10b].

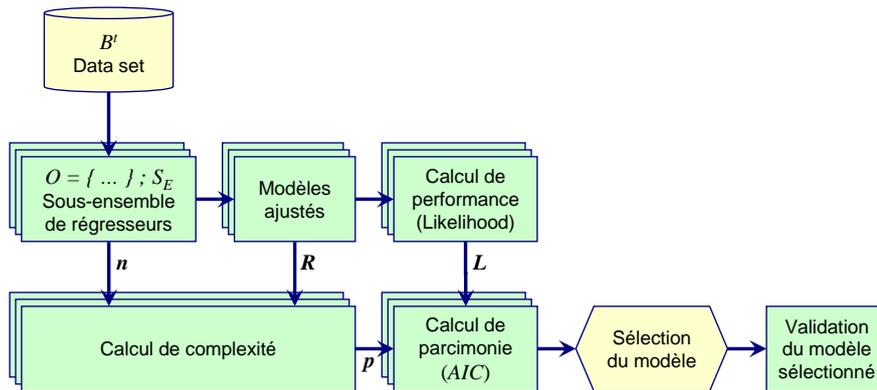


FIG. III.5 – Procédure pour construire automatiquement un *exTS*

## III.4 Validation de la démarche

L'objet de cette partie est de valider par la simulation l'utilisation du système *exTS* comme outil de prédiction. Deux aspects sont discutés : d'abord, les performances de l'*exTS* en tant que système prédictif, ensuite l'intérêt de la démarche de génération automatique du modèle *exTS* proposée dans ce chapitre. En amont, nous proposons des métriques d'erreur de prédiction afin de pouvoir étayer les conclusions tirées des tests.

```

1 Initialisation :  $E$  : échantillons pour l'apprentissage ;
2 Pour  $i_1 = 1$  à  $p_{x_1}$  faire
    |
    |
    |
3   Pour  $i_n = 1$  à  $p_{x_{nn}}$  faire
4     Pour  $j = 1$  à  $p_y$  faire
5       construction de  $S_E \in E$ 
6        $n = i_1 + \dots + i_{nn} + j$  : nombre d'entrées de l'exTS
7       Apprentissage du modèle exTS - donne le nombre de règles  $R$ 
8       Calcul de complexité  $p = R \times (3 \times n + 1)$ 
9       Calcul de performance  $L$  sur la base des prédictions :
10       $\hat{y}(k+h)_{1,\dots,S} = f(S_E, \Gamma)$ 
11      Calcul de parcimonie :  $AIC(p, L)$ 
    |
    |
    |
    Choisir le  $S_E$  qui donne le plus petit  $AIC$  :  $Arg \min_{S_E}(AIC)$ 

```

**Algorithm 2:** Procédure d'automatisation basée sur un critère de parcimonie

### III.4.1 Choix d'indicateurs de performance

#### III.4.1.1 Mesures d'erreur de prédiction

Dans la littérature cinq familles de mesures d'erreur sont proposées pour évaluer et/ou comparer les performances de systèmes prédictifs (figure III.6). Nous les présentons brièvement ci-après. Définissons d'abord l'erreur de prédiction comme la différence entre la sortie désirée  $y_d$  et la valeur prédite  $\hat{y}$ . Pour un horizon de prédiction égal à  $h$ , nous avons donc :

$$e(t+h) = y_d(t+h) - \hat{y}(t+h) \tag{III.10}$$

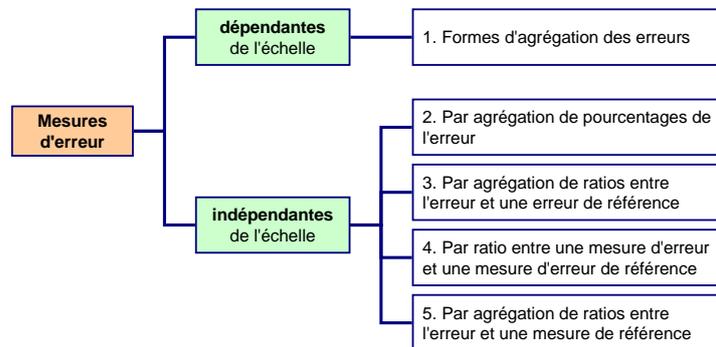


FIG. III.6 – Typologie des mesures d'erreur

### 1. Mesures par agrégation des erreurs

Ces mesures visent à agréger l'ensemble des erreurs de prédictions réalisées jusqu'à un instant donné. Elles sont donc dépendantes de l'échelle de la série de données considérées : par exemple, une erreur de une unité d'échelle correspond à des performances de prédiction bien différentes si la série varie entre 0 et 1 ou entre 0 et 100.

Historiquement, l'erreur quadratique moyenne (Mean Square Error *MSE*), et la racine de l'erreur quadratique moyenne (Root Mean Square Error *RMSE*) sont les plus utilisées par les statisticiens ([CA82], [NK99]). Ces mesures sont simples à calculer.

### 2. Mesures basées sur le pourcentage de l'erreur

Ces mesures sont construites à partir de l'ensemble des pourcentages d'erreur de prédiction  $e_{\%}(t+h) = 100 \times (e(t+h)/y(t+h))$ . Elles sont donc indépendantes de l'échelle de la série de données et peuvent être utilisées afin d'étudier les performances d'un même système prédictif sur différents problèmes de prédiction. Leur calcul peut cependant être problématique si la série oscille autour de zéro (problème de division).

Dans cette famille de mesures, la plus largement répandue est la moyenne des pourcentage d'erreur de prédiction (Mean Absolute Percentage Error *MAPE*) [AC92].

### 3. Mesures par agrégation de ratios entre l'erreur et une erreur de référence

Ces mesures sont indépendantes de l'échelle de la série de données. Elles sont construites à partir de l'ensemble des ratios entre l'erreur de prédiction du modèle, et l'erreur obtenue par un modèle de référence :  $r(t+h) = e(t+h)/e^*(t+h)$ . Ce modèle de référence est généralement bâti sur le principe du «pas aléatoire» (Walk Random) ([HK06]). L'utilisation de ce type de mesures d'erreur est recommandée par [AC92]. Elles permettent de comparer un système prédictif à un modèle de référence et présentent l'avantage d'être interprétables : si la mesure d'erreur est inférieure à «1», alors le système prédictif utilisé est plus performant que la méthode standard.

### 4. Mesures par ratios entre une mesure d'erreur et une mesure d'erreur de référence

Ces mesures sont bâties sur un principe similaire aux mesures précédentes, à ceci près qu'il ne s'agit pas d'agréger des ratios d'erreur, mais de calculer un ratio de mesures d'erreur. A titre d'exemple, la mesure relative  $RelMSE = MSE_a/MSE_{ref}$  permet de comparer un système prédictif «a» à un autre de référence : si  $RelMSE < 1$  alors le système prédictif a est plus performant que le système de référence.

### 5. Mesures par agrégation de ratios entre l'erreur et une mesure d'erreur de référence

Ces mesures sont construites par une approche «hybride» entre les mesures de types 3 et 4 : il s'agit d'agréger un ensemble de ratios entre l'erreur de prédiction du système étudié, et une mesure d'erreur agrégée d'un modèle de référence. Une telle mesure a été définie par [HK06] : le *MASE* (Mean Absolute Scaled Error). Pour construire cette mesure, [HK06] propose de calculer, à chaque prédiction, le ratio entre l'erreur de prédiction du système étudié et la moyenne des valeurs absolues des erreurs d'un prédicteur naïf (c'est

à dire un prédicteur qui considère que la valeur à prédire est égale à la valeur actuelle) :

$$q(t) = \frac{e(t+h)}{\frac{1}{t-1} \sum_{i=2}^t |y_d(i) - y_d(i-1)|} \quad MASE = \text{mean}(|q(t)|)$$

Cette mesure est également interprétable : si  $MASE < 1$ , le système construit est plus performant que la méthode naïve.

### III.4.1.2 Choix de métriques de comparaison

L'intérêt des différentes mesures d'erreurs a largement été discuté dans la littérature ([GH06]). Il en ressort qu'il n'existe pas de mesure universelle, satisfaisant à la fois des critères de pertinence, de facilité de calcul et de limites d'utilisation. Nous proposons de retenir les mesures suivantes, définies en posant  $N$  le nombre total de prédictions réalisées.

Le  $RMSE$ , bien que dépendant de l'échelle de la série de données, reste la mesure d'erreur la plus utilisée. Le système prédictif est d'autant meilleur que le  $RMSE$  calculé est faible :

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N [y_d(t+h) - \hat{y}(t+h)]^2} \quad (\text{III.11})$$

Le  $MAPE$  permet de s'affranchir de l'ordre de grandeur des données mais ne peut être utilisé si la série de données comporte des valeurs proches de 0 :

$$MAPE = \sum_{t=1}^N \left[ 100 \times \frac{|y_d(t+h) - \hat{y}(t+h)|}{y_d(t+h)} \right] \quad (\text{III.12})$$

Le  $MASE$  est applicable pour tout type de série de données (autre que constante) et permet de comparer le système prédictif au modèle de référence naïf. En revanche, les performances de deux modèles prédictifs ne peuvent être ordonnées en regard de leur  $MASE$  respectifs :

$$MASE = \frac{1}{N} \sum_{t=1}^N \left[ \frac{|y_d(t+h) - \hat{y}(t+h)|}{\frac{1}{t-1} \sum_{i=2}^t |y_d(i) - y_d(i-1)|} \right] \quad (\text{III.13})$$

Nous proposons également de retenir le coefficient de détermination  $R^2$  qui permet de considérer l'erreur autrement que par des calculs de moyenne : ce coefficient permet de

mesurer la variabilité des erreurs de prédiction en regard de la variabilité de la série de données. Plus  $R^2$  est proche de 1, plus le système prédictif est pertinent.

$$R^2 = 1 - \frac{\sum_{t=1}^N (y_d(t+h) - \hat{y}(t+h))^2}{\sum_{t=1}^N (y_d(t+h) - \bar{y}_d)^2} \quad (\text{III.14})$$

Nous définissons enfin une mesure par agrégation de ratios d'une forme d'erreur indépendante de l'échelle : le Geometric Mean of Degradation of the Error by Interval  $GMDEI$ . Cette mesure est sans échelle et ne pose pas de problème de division par 0. Elle est interprétable. En adoptant les notations de l'équation (éq. III.15), si  $GMDEI < 1$  alors le système prédictif  $A$  est meilleur que le  $B$ .

$$DEI(t+h) = \frac{e(t+h)}{\frac{Max(y_d|_{t=1,\dots,N}) - Min(y_d|_{t=1,\dots,N})}{y_{d\max} - y_{d\min}}} = \frac{y_d(t+h) - \hat{y}(t+h)}{y_{d\max} - y_{d\min}}$$

$$GMDEI = \prod_{k=1}^N \left( \left| \frac{DEI_A(k)}{DEI_B(k)} \right| \right)^{\frac{1}{N}} \quad (\text{III.15})$$

## III.4.2 Validation 1 : l'exTS comme système prédictif

### III.4.2.1 Objectif et plan de simulation

Ce premier plan de tests vise d'une part, à illustrer le caractère évolutif du système exTS, et d'autre part, à valider le choix de ce système comme outil de prédiction en discutant ses performances de prédiction. Pour ce faire, nous comparons le système exTS au réseau neuro-flou ANFIS proposé par [JS95] (section II.5.1.2) et très largement utilisé dans des applications de prédiction. Le modèle ANFIS s'est avéré à même de «capturer» le comportement de systèmes non-linéaires rapidement et précisément, et cela, mieux encore que d'autres méthodes, réseaux de neurones inclus ([MF06], [JLA<sup>+</sup>03]). Il compte parmi les modèles les plus utilisés pour prédire des séries chronologiques [WGI04] et constitue ainsi une bonne base de comparaison [KGZ08a], [KGZ08c].

Les tests de prédiction ont été réalisés sur la série mono-variable «Sunspot». Cette série de données<sup>1</sup> est un «benchmark» de prédiction usuel qui porte sur le nombre moyen de tâches solaires observées de 1700 à 1988 (289 données).

Conformément à l'équation III.3, un modèle prédictif se construit sur la base d'un ensemble de régresseurs sur les variables explicatives et d'intérêt. S'agissant ici d'une série de données mono-variable, l'ensemble des régresseurs porte sur la variable d'intérêt, notons la  $Sp$ . Nous avons choisi de réaliser des prédictions à  $t+1$  (one step ahead) avec 4 entrées ( $Sp(t-3)$ ,  $Sp(t-2)$ ,  $Sp(t-1)$ ,  $Sp(t)$ ). Ce choix détermine complètement la

<sup>1</sup>Disponible en ligne : <http://amath.colorado.edu/computing/mmm/data/>

structure du réseau ANFIS, alors que celle de l'exTS dépend de la phase d'apprentissage (section II.6.2.2). L'ensemble de données est divisé en deux : les 150 premiers échantillons sont utilisés lors de la phase d'apprentissage, et les 139 restants lors de la phase de test. L'ensemble des conditions de test est résumé dans le tableau III.1.

Système prédictif	ANFIS	exTS
Horizon de prédiction	$t + 1 : Sp(t + 1)$	$t + 1 : Sp(t + 1)$
Entrées	$n = 4$	$n = 4$
Type des fonctions d'appartenance	Gaussienne	Gaussienne
Nb de fonct° d'appartenance par entrée	$nbFA = 2$	évolutif
Nombre de règles	$R = 16$	évolutif
T-norme	produit	produit
Type d'inférence	linéaire - Sugeno	linéaire - Sugeno
Taille apprentissage / test	150 / 139	150 / 139

TAB. III.1 – Prédictions de la série Sunspot-Conditions de test

### III.4.2.2 Résultats et discussion

#### A- Caractère évolutif de l'exTS

Si la structure du système ANFIS est complètement définie dès lors que le nombre d'entrées et le type de fonction d'appartenance sont choisis, ce n'est pas le cas pour le système exTS. L'objet est ici d'illustrer le caractère évolutif de l'exTS. Nous reprenons ainsi les premières étapes de l'algorithme d'apprentissage de l'exTS présenté en section II.6.2.2. Afin de simplifier les notations, considérons qu'à chaque itération d'apprentissage  $k$ , les entrées  $Sp(k - 3)$ ,  $Sp(k - 2)$ ,  $Sp(k - 1)$  et  $Sp(k)$  forment un vecteur :  $[x_1 \ x_2 \ x_3 \ x_4]$ .

Le nombre de règles d'un exTS est égal au nombre de fonctions d'appartenance par entrées ( $nbFA$ ), lequel est adapté lors de la phase de clustering de l'apprentissage.

A l'instant  $k = 1$ , les entrées sont  $[x_1^1 \ x_2^1 \ x_3^1 \ x_4^1] = [58 \ 29 \ 20 \ 10]$  et la structure de l'exTS est composée d'une seule règle.

$$\begin{aligned}
 R_1 : & \text{Si } x_1^1 \text{ est } A_1^4(c_1^1, r_1^1) \text{ et } x_2^1 \text{ est } A_1^4(c_1^2, r_1^2) \text{ et } x_3^1 \text{ est } A_1^4(c_1^3, r_1^3) \text{ et } x_4^1 \text{ est } A_1^4(c_1^4, r_1^4) \\
 & \text{alors } \Upsilon_1 = a_{10} + a_{11}x_1^1 + a_{12}x_2^1 + a_{13}x_3^1 + a_{14}x_4^1
 \end{aligned}
 \tag{III.16}$$

où  $(c_i^j, r_i^j)$  désignent les centres et rayons des fonctions d'appartenances des entrées. A cet instant  $k = 1$ , chaque entrée n'a qu'une seule fonction d'appartenance dont les centres sont les valeurs des entrées, et dont les rayons sont initialisés à «1» (figure III.7). A ce stade, l'exTS contient donc 4 fonctions d'appartenances :

$$A_1^1(c_1^1 = x_1^1 = 58, r_1^1 = 1), A_1^2(c_1^2 = x_2^1 = 29, r_2^1 = 1) \\ A_1^3(c_1^3 = x_3^1 = 20, r_3^1 = 1), A_1^4(c_1^4 = x_4^1 = 10, r_4^1 = 1)$$

Une fois les paramètres non-linéaires ( $c_i^j, r_i^j$ ) fixés, les paramètres linéaires sont ajustés par la méthode des moindres carrés récursif ( $a_{10}, a_{11}, a_{12}, a_{13}$ ).

A l'instant  $k = 2$ , les équations II.8 et II.9 permettent de déterminer si il est nécessaire d'augmenter le nombre de règles, de modifier la règle existante ou encore de garder la structure d'inférence floue courante. Ici, la simulation montre qu'il n'est pas nécessaire de modifier la structure. En revanche, le point appris doit être intégré au calcul des potentiels des clusters dont il faut adapter les rayons (éq. II.10). Les distributions des fonctions d'appartenance sont modifiées en conséquence (figure III.7).

A l'instant  $k = 3$  la même procédure amène à augmenter le nombre de règles. Le système exTS est alors constitué de deux règles floues, et chaque entrée a deux fonctions d'appartenance (figure III.7). Notons, que les centres des nouvelles fonctions d'appartenance sont les entrées à l'instant  $k = 3$ , et les rayons sont initialisés à «1».

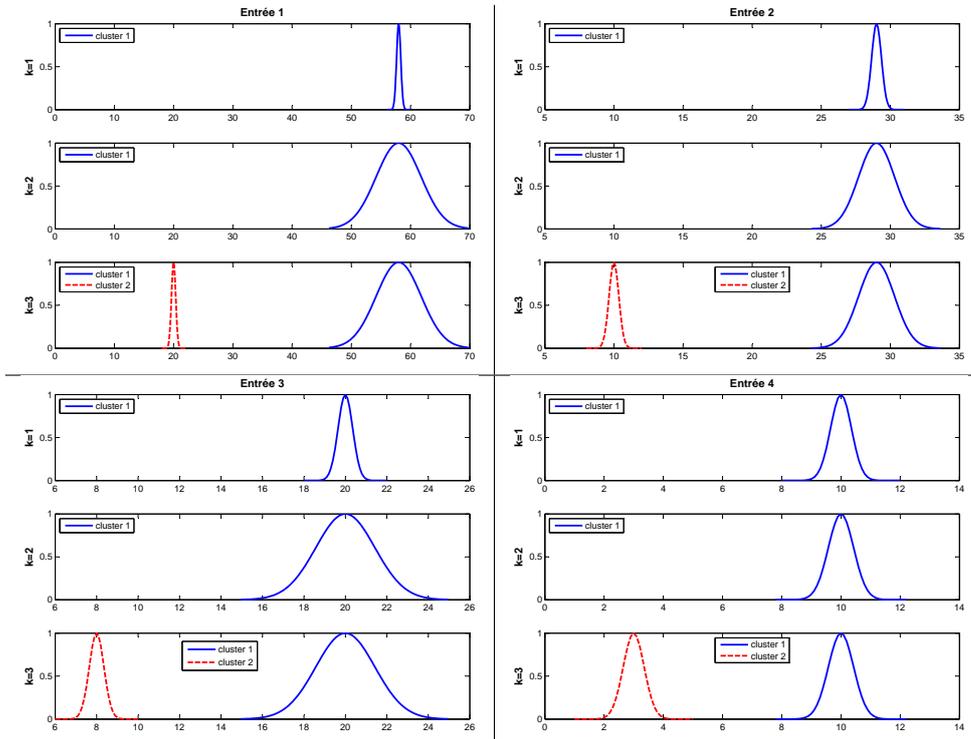


FIG. III.7 – Évolution des clusters pour  $k = 1 \rightarrow 3$

L'évolution du nombre de règles durant les 150 échantillons d'apprentissage est présentée en figure III.8. Cette figure illustre le caractère évolutif du système prédictif exTS : l'exTS est à même d'adapter sa structure à mesure que de nouvelles données apparaissent. Cette particularité en fait un outil particulièrement intéressant pour des applications en ligne : elle permet d'éviter de devoir reprendre à zéro l'apprentissage si de nouvelles données viennent à être disponibles (c'est le cas de l'ANFIS).

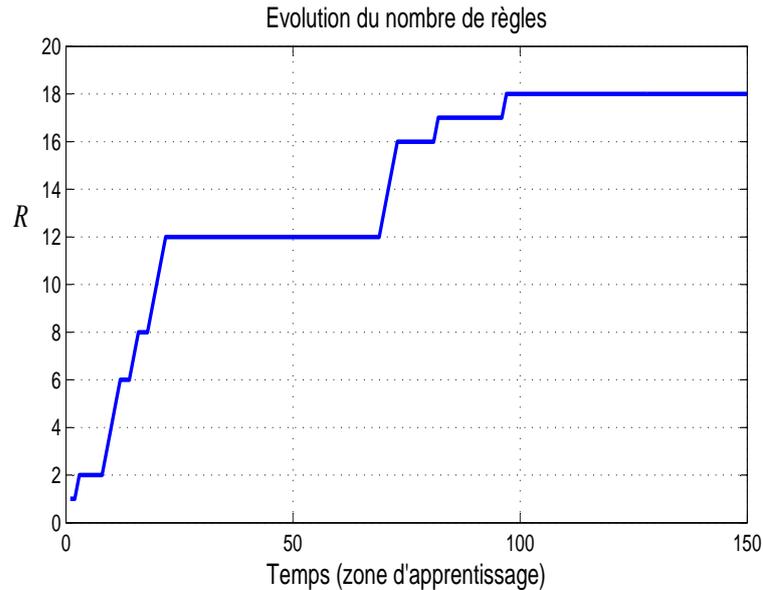


FIG. III.8 – Évolution des règles floues durant la phase d'apprentissage ( $k = 1 \rightarrow 150$ )

### B- Performances de prédiction du système exTS

Une fois la phase d'apprentissage réalisée, les 139 derniers échantillons sont utilisés afin de mesurer les performances de prédiction de chacun des deux systèmes : ANFIS et exTS.

L'analyse des mesures d'erreur retenues en section III.4.1.2 et rapportées dans le tableau III.2 est sans ambiguïté : quelle que soit la métrique de comparaison ( $RMSE$ ,  $MAPE$ ,  $MASE^2$ ,  $GMDEI$ ), le système bâti sur un modèle exTS présente toujours de meilleures performances de prédiction que celui construit à partir d'un modèle ANFIS. Cette conclusion est renforcée par l'observation de la figure III.9 qui présente les courbes de prédiction obtenues (série de données réelles, prédictions avec l'ANFIS, prédictions avec l'exTS). De manière intuitive, l'exTS réalise manifestement de meilleures prédic-

<sup>2</sup>Conformément aux commentaires de l'équation III.13, le fait que le  $MASE$  du système ANFIS soit inférieur à celui de l'exTS ne signifie pas que le système ANFIS est un meilleur prédicteur que le exTS. En revanche, les deux sont plus performants qu'une méthode de prédiction naïve car ayant un  $MASE < 1$ .

tions que le système ANFIS. Sa courbe de prédiction reste très proche de la série de données réelles, et cela tout au long de la zone de prédiction.

Lors de la construction d'un modèle prédictif, les choix de structure réalisés par l'utilisateur en amont de la phase d'apprentissage sont déterminants en regard des performances de prédiction. Pour ce faire, il n'existe malheureusement pas de méthode formelle, et c'est ce qui a été le principal argument de choix de l'exTS comme système prédictif : l'utilisation d'un système évolutif permet de prendre en compte la dynamique des signaux au cours du temps et de réaliser les modifications de structure de manière automatique si nécessaire. Les performances de prédictions sont meilleures en conséquence. Reste malgré tout le problème du choix du nombre d'entrées du système prédictif que nous proposons d'automatiser grâce au principe de parcimonie. C'est ce qui fait l'objet des tests suivants.

Système prédictif	ANFIS	exTS
<i>RMSE</i>	127.9817	18.6283
<i>MAPE</i>	126.0198	51.5788
<i>MASE</i>	0.0236	0.0484
$R^2$	-7.2672	0.8249
<i>GMDEI</i> (A=ANFIS, B=exTS)	1.9325	

TAB. III.2 – Mesures d'erreurs dans la zone de prédiction (151 → 289)

### III.4.3 Validation 2 : procédure de recherche d'un compromis performance / complexité

#### III.4.3.1 Objectif et plan de simulation

Ce plan de tests vise à discuter l'intérêt de notre contribution de ce chapitre (la démarche de génération du système prédictif), c'est à dire la procédure de sélection automatique des entrées (du nombre de régresseurs). Rappelons que l'idée de cette proposition est de directement aller vers une structure prédictive présentant un compromis entre performances et complexité.

La procédure a été appliquée sur la base de données «Air temperature in a mechanical system» mise à disposition par W. Favoreel de l'Université de Kuleuven [Hai09]. L'objectif de la prédiction est d'approximer la température de l'air d'un appareil de chauffe en utilisant les mesures de tension recueillies en ligne au cours du temps. Ce problème de prédiction comporte donc une variable exogène  $x$  (grandeur explicative), et une variable endogène  $y$  (grandeur intérêt) :

- $x$  : tension de l'appareil de chauffe,

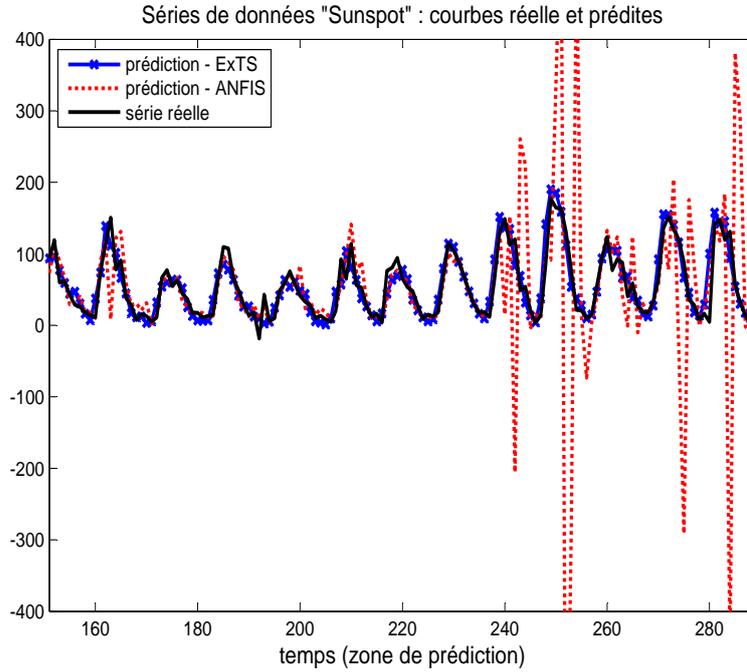


FIG. III.9 – Les trois courbes (exTS, ANFIS, Réel ) dans la zone de prédiction

–  $y$  : température de l'air.

L'ensemble des données est constitué de 1000 échantillons. La phase d'apprentissage a été limitée aux 500 premiers, et les 500 restants ont été utilisés pour le test, avec un horizon de prédiction  $t + 1$  (one-step-ahead). La performance d'apprentissage a été évaluée par le calcul de l'erreur quadratique moyenne ( $MSE_{train}$ ), et celle du test par le coefficient de détermination ( $R2_{test}$ ).

A titre comparatif, un modèle auto-régressif du type ARX (AutoRegressive model with eXogenous variables) a également été utilisé. Ce modèle présente plusieurs caractéristiques justifiant ce choix. D'abord, c'est l'un des modèles de régression linéaire les plus largement utilisés par les statisticiens pour prédire des séries temporelles. Ensuite, ce modèle a une structure simple et ne pose ainsi pas de problème si le nombre d'entrées est grand. Enfin, la structure d'un système ARX est parfaitement définie par le nombre d'entrées, ce qui est nécessaire pour discuter les résultats de test sur la procédure proposée dans ce chapitre. Le modèle ARX peut être formulé comme suit :

$$\begin{aligned}
 A(\varpi) \cdot \hat{y}(t) &= \sum_{i=1}^n B_i(\varpi) \cdot x_i(t) \\
 A(\varpi) &= 1 + \alpha_1 \varpi^{-1} + \dots + \alpha_{q_y} \varpi^{-q_y} \\
 B_i(\varpi) &= \beta_1^i \varpi^{-1} + \dots + \beta_{p_{x_i}}^i \varpi^{-p_{x_i}} \\
 \varpi^{-\tau} \cdot x(t) &= x(t - \tau)
 \end{aligned} \tag{III.17}$$

### III.4.3.2 Résultats et discussion

Pour les deux modèles ARX et exTS, la procédure de sélection des entrées basée sur le critère de parcimonie ( $AIC$ ) a été appliquée afin d'identifier les bonnes structures *a priori*, c'est à dire celles présentant un compromis entre performance de prédiction et complexité.

Afin, de tirer des conclusions plus solides des simulations, nous avons également recherché les structures les plus simples, celles présentant les meilleures performances de prédiction dans la zone d'apprentissage, et celles présentant les meilleures performances de prédiction dans la zone de test. Ces systèmes ont été cherchés en examinant l'ensemble des régresseurs possibles (cf. éq. III.4). Sur chacun des deux modèles, nous retenons ainsi 4 systèmes prédictifs :

- les moins complexes : ceux qui ont le moins de paramètres -  $ARX_{pmin}$  et  $exTS_{pmin}$ ,
- les plus performants lors de l'apprentissage : ceux dont l'erreur quadratique moyenne est la plus faible (cf. éq. III.8) -  $ARX_{MSEtrain}$  et  $exTS_{MSEtrain}$ ,
- les plus performants lors du test : ceux dont le coefficient de détermination est le plus proche de 1 -  $ARX_{R2test}$  et  $exTS_{R2test}$ ,
- les plus intéressants *a priori* : ceux présentant la plus faible mesure de parcimonie -  $ARX_{AIC}$  et  $exTS_{AIC}$ .

Les résultats de simulation sont présentés dans le tableau III.3.

#### A- ARX versus exTS

Quelle que soit la structure prédictive considérée (la plus simple, la plus performante dans l'apprentissage, etc.), le système exTS présente systématiquement de meilleurs résultats de prédiction que le système ARX. Un exemple est donné en figure III.10 illustrant les résultats de prédiction pour les modèles les moins complexes ( $ARX_{pmin}$ ,  $exTS_{pmin}$ ).

Revenant à l'objectif applicatif final (le pronostic de défaillance), ceci est de bonne augure : non seulement l'exTS s'avère être une nouvelle fois un bon outil de prédiction, mais il est de plus à même de prendre en compte l'aspect dynamique du comportement des équipements réels sans connaissance *a priori*, ni intervention humaine.

#### B- Performance et complexité

Les résultats permettent de remarquer que, quel que soit le modèle de prédiction (ARX ou exTS), la performance de prédiction augmente avec la complexité du modèle (figure III.11) : plus le coefficient  $R2test$  est proche de «1», plus le modèle a de paramètres. Ceci confirme que performance et complexité sont corrélées, et qu'il n'est pas possible de maximiser la satisfaction de ces deux critères.

Par ailleurs, il est intéressant de noter que le système le plus performant en apprentissage n'est pas nécessairement le plus performant dans la phase de test, et que ce dernier n'est pas non plus nécessairement celui dont la structure est la plus complexe. Ce constat met

Systèmes prédictifs	ARX	exTS
LES MOINS COMPLEXES ( $ARX_{pmin}, exTS_{pmin}$ )		
$O = \{p_x, q_y\}$	{1, 1}	{1, 1}
<i>nb. paramètres</i>	$p = 2$	8 règles, $p = 56$
<i>MSEtrain</i>	0,8200	0,1179
<i>R2test</i>	0,4354	0,9397
PLUS PERFORMANTS DANS L'APPRENTISSAGE ( $ARX_{MSEtrain}, exTS_{MSEtrain}$ )		
$O = \{p_x, q_y\}$	{4, 3}	{1, 5}
<i>nb. paramètres</i>	$p = 7$	10 règles, $p = 190$
<i>MSEtrain</i>	0,1540	0,0848
<i>R2test</i>	0,9782	0,9850
PLUS PERFORMANTS DANS L'APPRENTISSAGE ( $ARX_{R2test}, exTS_{R2test}$ )		
$O = \{p_x, q_y\}$	{85, 1}	{4, 3}
<i>nb. paramètres</i>	$p = 86$	11 règles, $p = 242$
<i>MSEtrain</i>	0,1603	0,1069
<i>R2test</i>	0,9894	0,9974
PRÉSENTANT UN COMPROMIS «PERFORMANCE - COMPLEXITÉ»		
<i>AIC</i>	-918,6320	-972,5249
$O = \{p_x, q_y\}$	{4, 4}	{1, 2}
<i>nb. paramètres</i>	$p = 8$	8 règles, $p = 80$
<i>MSEtrain</i>	0,1542	0,1038
<i>R2test</i>	0,9784	0,9827

TAB. III.3 – Prédiction de la température d'un système de chauffe - résultats de simulation

une nouvelle fois en avant l'intérêt de rechercher un compromis «performance - complexité».

### C- Intérêt de la procédure

Examinons les résultats obtenus pour les systèmes prédictifs les plus performants dans le test, et ceux construits sur la base de la procédure de recherche d'un compromis «performance - complexité». Alors que les systèmes les plus performants ( $ARX_{R2test}$  et  $exTS_{R2test}$ ) ont beaucoup plus de paramètres que ceux obtenus par compromis ( $ARX_{AIC}$  et  $exTS_{AIC}$ ), le gain en terme de performance de prédiction s'avère être marginal. La figure III.12 permet d'illustrer ce point : les distributions de probabilité (pdf) du pourcentage de l'erreur de prédiction des modèles  $exTS_{R2test}$  et  $exTS_{AIC}$  sont très similaires, la principale différence résidant dans le fait que l'écart type de la pdf de la «structure à compromis» est légèrement plus grand que celui du «meilleur prédicteur». Ceci confirme l'intérêt et l'efficacité de la procédure proposée dans ce chapitre. Au final, le système exTS peut être complètement généré à partir des données, sans que l'utilisateur n'ait à faire de choix.

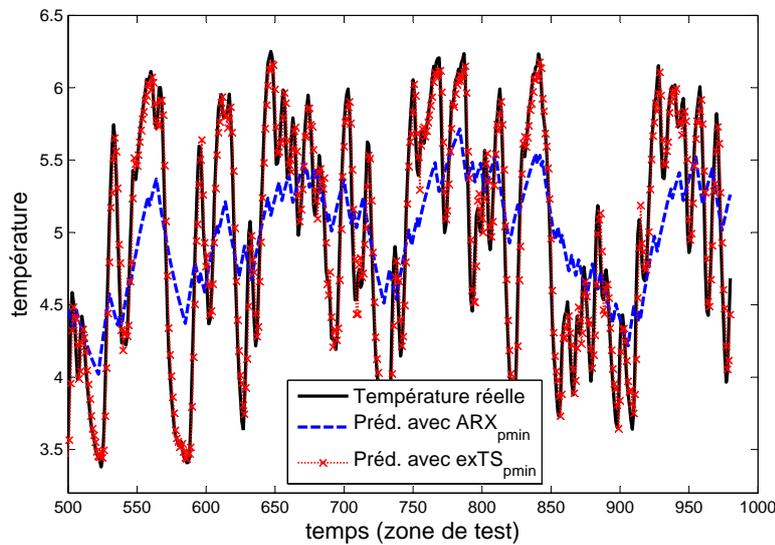


FIG. III.10 – Température du système de chauffe - résultats de prédiction avec les structures les moins complexes

### III.5 Conclusion

Le pronostic de défaillance nécessite de disposer d'un outil permettant de prédire de manière efficace les phénomènes de dégradation à partir de données recueillies en ligne sur les équipements. Pour répondre à ce problème jugé critique, nous avons proposé dans le chapitre II d'utiliser le système neuro-flou exTS. Au delà de sa faculté à approximer une fonction de transfert inconnue, ce système est évolutif et est donc à même de s'enrichir de manière incrémentale à mesure que de nouvelles données sont disponibles.

Ceci étant, le fait de savoir qu'une technique de prédiction peut être intéressante ne signifie pas pour autant que la déployer soit facile. L'objet de ce chapitre est ainsi de montrer comment utiliser le système exTS dans des applications de prédiction de séries temporelles, sans connaissance *a priori*. Plus précisément, ce chapitre porte sur la proposition d'une procédure de génération automatique du système prédictif.

La proposition est fondée sur le constat suivant. Performance de prédiction et complexité du système prédictif sont corrélées. Cependant, il existe un stade au delà duquel, le fait de construire un système prédictif plus complexe ne permet d'améliorer les prédictions que de façon marginale. Plus encore, cela peut amener à des situations dans lesquelles le système prédictif perd toute capacité de généralisation. Il convient donc davantage de rechercher un compromis «performance-complexité». Pour ce faire, nous avons analysé le processus d'identification du système d'inférence flou de l'exTS afin, d'une part, d'identifier quelles étapes impactent à la fois les performances de prédiction et la complexité du système, et d'autre part, afin de déterminer à quel niveau l'utilisateur peut avoir

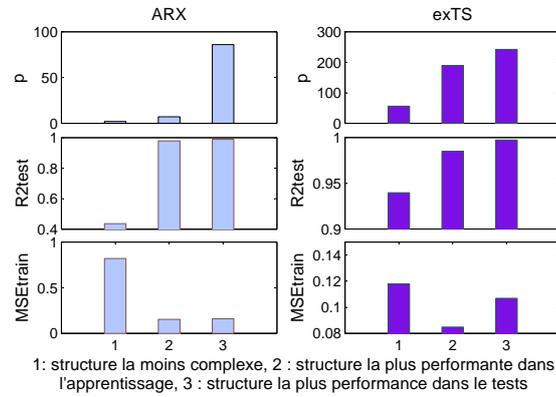


FIG. III.11 – Performances de prédiction et complexité des systèmes  $ARX_{pmin}$ ,  $exTS_{pmin}$ ,  $ARX_{MSEtrain}$ ,  $exTS_{MSEtrain}$ ,  $ARX_{R2test}$  et  $exTS_{R2test}$

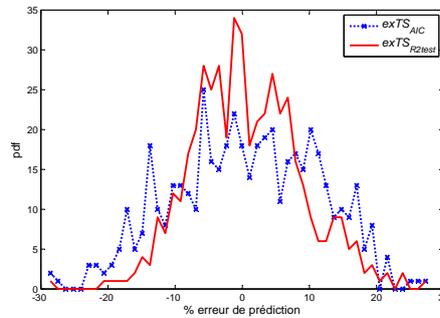


FIG. III.12 – Pdf du pourcentage de l'erreur de prédiction dans la phase de test des modèles  $exTS_{R2test}$  et  $exTSAIC$

une influence critique. Il apparait que l'intervention humaine ne se fait qu'au moment du choix des entrées du système prédictif (choix des régresseurs). Nous avons ainsi proposé d'automatiser ce choix. La démarche est basée sur la construction d'une mesure de parcimonie permettant d'agréger les mesures de performance et de complexité en un seul critère. Ce critère peut alors être utilisé afin de rechercher une structure optimale en terme de compromis «performance - complexité». Au final, la procédure permet de générer un système prédictif directement à partir des données, en s'affranchissant de l'intervention de l'utilisateur.

Ce travail s'inscrit dans notre ambition de réaliser du pronostic de dégradation sans connaissance ou expertise *a priori*. Cependant, si nous disposons d'un bon outil prédictif et d'une manière de le déployer, il nous est encore nécessaire d'intégrer la confiance à l'activité de prédiction afin de pouvoir, non seulement prédire une dégradation, mais également apprécier la qualité de cette prédiction afin d'estimer le *RUL*. C'est ce qui fait l'objet du chapitre suivant.



Chapitre **IV**

**Pronostic de dégradation - intégration de la confiance au système prédictif**

## IV.1 Introduction

Les chapitres II et III ont été consacrés à la définition d'un outil support à une activité clé du processus de pronostic : la prédiction. En revanche, nous jugeons qu'il est nécessaire d'évoluer l'incertitude de cette prédiction. Ceci est en effet particulièrement intéressant afin de pouvoir associer un intervalle de confiance à l'estimation du *RUL*. L'objectif de ce chapitre est ainsi de proposer une méthode d'estimation *a priori* de l'erreur de prédiction, et d'illustrer comment cette proposition permet de faire du pronostic.

## IV.2 Impact de la confiance sur l'estimation du *RUL*

La formalisation du processus de pronostic en deux activités («prédiction + évaluation») a pour objectif d'estimer le *RUL*. En effet, la prédiction de la dégradation n'est pas certaine, et par suite, celle de la date d'occurrence de la défaillance non plus. Déterminer l'incertitude de prédiction permettrait de dimensionner la bande où se trouve la défaillance, le *RUL* appartenant à cette bande (figure IV.1).

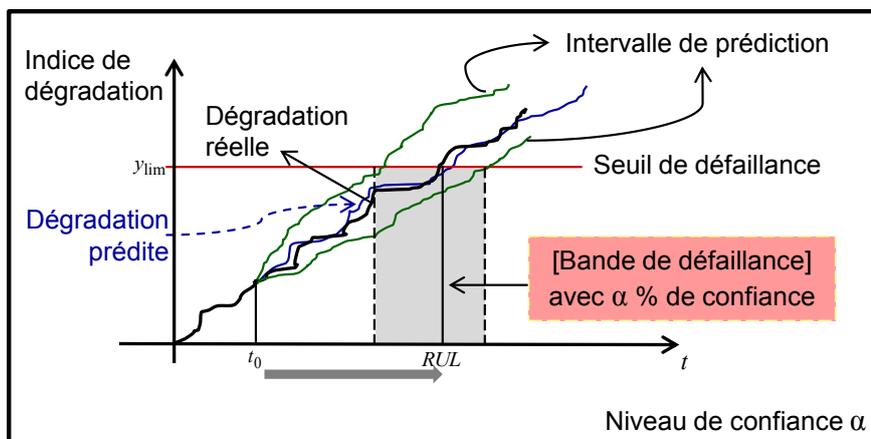


FIG. IV.1 – Le *RUL* dans une intervalle de prédiction

Rappelons, qu'un modèle de pronostic vise à calculer le *RUL* en temps réel, c'est à dire, qu'il doit déterminer le *RUL* en se basant sur les conditions actuelles d'un équipement en opération. Ensuite, la détermination de l'incertitude ne suffit pas pour avoir le *RUL*, elle permet juste de trouver dans quelle bande se trouve le *RUL*. Alors, nous proposons d'introduire la notion de fiabilité pour estimer le *RUL*. Historiquement, la fiabilité correspond à une dérive du mot français «fiable». Au début des années 60, le terme de «fiabilité» a été choisi pour traduire son homologue anglais «Reliability». A l'époque, la

définition a été proposée par [Vil88] :

*Grandeur caractérisant la sécurité de fonctionnement, ou mesure de la fiabilité de fonction d'un appareillage selon des normes prescrites.*

Dernièrement, la norme [AFNOR01] a défini la fiabilité comme :

*L'aptitude d'un bien à accomplir une fonction requise, dans des conditions données, durant un intervalle de temps donné.*

Au sens mathématique, la fiabilité mesure la probabilité pour que le dispositif accomplisse une ou plusieurs fonctions requises, dans des conditions données, pendant une durée donnée. Concrètement, la fiabilité  $R(t)$  (éq. IV.1) est la probabilité pour qu'une défaillance ne se produise pas avant l'instant  $t$  dans le temps. Considérons que la défaillance peut être représentée par une variable aléatoire  $\vartheta$ , de distribution de probabilité  $f_{\vartheta}(t) = Pr(\theta)$  (appelle aussi fonction de densité de défaillance), et de fonction cumulative de distribution  $F_{\vartheta}(t) = Pr(\vartheta \leq t)$ . La formulation mathématique de la fiabilité est la suivante :

$$R(t) = 1 - F_{\vartheta}(t) = 1 - \int_0^t f_{\vartheta}(u).du \quad (IV.1)$$

Supposons maintenant que la défaillance n'est pas caractérisée par une variable aléatoire mais résulte du fait qu'un signal ( $y$ ) de dégradation dépasse une certaine limite ( $y_{lim}$ ) pris comme la limite entre le bon fonctionnement du bien l'état de panne, et que ce signal de dégradation peut être prédit ( $\hat{y}$ ) avec un certain degré d'incertitude (voir figure IV.2). A tout instant  $t$ , la probabilité de défaillance peut être exprimée :

$$F(t) = Pr[\hat{y} \geq y_{lim}] \quad (IV.2)$$

Notons  $g(\hat{y}/t)$  la fonction de densité de probabilité de la prédiction à l'instant  $t$ . Alors, par analogie avec la théorie de fiabilité, la modélisation de la fiabilité prévisionnelle est décrite par la formule suivante :

$$R(t) = 1 - Pr[\hat{y}(t) \geq y_{lim}] = 1 - \int_{y_{lim}}^{\infty} g(\hat{y}/t).dy \quad (IV.3)$$

Le temps résiduel avant défaillance du système (*RUL*) peut finalement être exprimé par la durée entre l'instant de prédiction ( $t_p$ ) et l'instant auquel la fiabilité limite acceptable est atteinte ( $R_{lim}$ ) (figure IV.2) [KGZ09].

Cette approche permet de calculer la fiabilité en ligne d'un bien : le *RUL* est estimé pendant l'usage du composant. A l'opposé les méthodes statistiques de fiabilité sont basées sur des estimations hors ligne et sur une population de test recueillie dans des conditions de travail particulières.

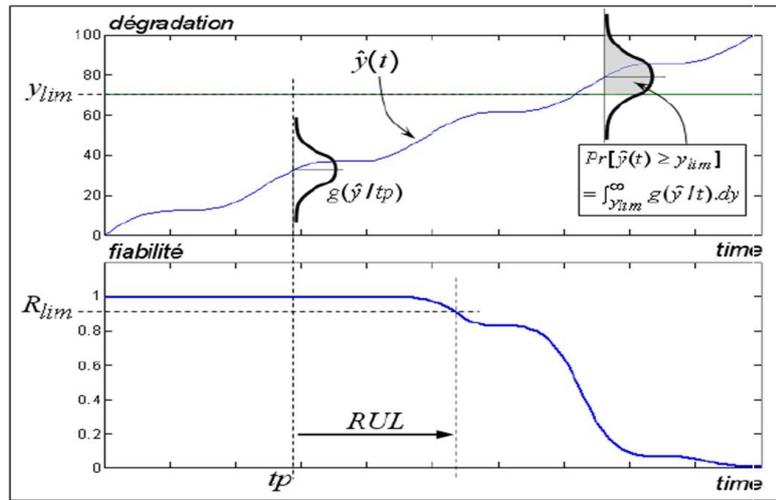


FIG. IV.2 – Prédiction et modélisation de la fiabilité

### IV.3 Estimation de la confiance du système prédictif

La confiance se présente dans ce rapport comme la *distribution de la prédiction* : chaque prédiction doit être accompagnée d'une distribution de l'erreur permettant de mesurer l'incertitude de prédiction. Cette distribution n'est pas accessible par l'exTS (système prédictif) : l'exTS a la capacité d'estimer une valeur de la prédiction, mais ne donne aucune information sur le niveau de confiance de cette prédiction. .

Nous proposons ainsi d'étendre cet outil qu'il soit à même de donner une distribution de prédiction. Pour se faire, nous distinguons deux grandes phases de prédiction. Dans la zone d'apprentissage (avant l'instant  $t = t_p$ ), la dégradation est connue. Il est donc possible de quantifier l'erreur de prédiction. Dans la seconde zone (après l'instant  $t = t_p$ ), aucune information n'est disponible puisqu'il s'agit du futur. L'estimation de l'erreur de prédiction sera ainsi faite de manière distincte. Nous développons ci-après ces 2 aspects.

#### IV.3.1 Estimation de la confiance dans la zone d'apprentissage

Comme mentionné dans le paragraphe précédent, l'exTS ne peut pas fournir la distribution de la prédiction. L'exTS est capable de prédire la valeur d'un seul pas (one-step-ahead). Pour estimer une dispersion de prédiction, l'idée de départ est que la valeur cible est connue dans la zone d'apprentissage, et l'exTS peut être vu comme un ensemble de modèles linéaires. Sur cette base, nous proposons d'adapter des approches statistiques au modèle exTS, afin de déterminer la dispersion de l'erreur dans la zone d'apprentissage.

### IV.3.1.1 Dimensionnement de l'erreur de prédiction

La construction d'un modèle prend appui sur le principe que les entrées-sorties sont liées par une relation déterministe. La sortie étant la dégradation d'un équipement industriel, elle est représentée par une série temporelle. Le modèle prédictif de ce comportement (souvent non-linéaire et dynamique) et peut s'écrire sous la forme suivante :

$$y_d(k+h) = f^*(X(k), \Gamma) + \xi(k+h) \quad (\text{IV.4})$$

où :

- $y_d(k+h)$  est la sortie du système à l'instant  $k+h$ ,
- $h$  est l'horizon de prédiction. Prenons  $h=1$ ,
- $f^*$  est une fonction déterministe,
- $\Gamma$  représente les paramètres de  $f^*$ ,
- $X(k)$  est un vecteur dont les éléments sont des entrées externes et internes du système réel à l'instant  $t$ ,
- $\xi$  est une variable aléatoire de moyenne nulle et de variance  $s^2$  représentent le bruit, (*Hypothèse 1*).

Le modèle choisi pour prédire la série chronologique est l'exTS. L'équation IV.4 devient ainsi :

$$y_d(k+1) = f^*(X(k), \lambda^*, \theta^*) + \xi(k+1) \quad (\text{IV.5})$$

où :

- $\lambda^*$  est le vecteur des degrés d'activation normalisés des règles optimaux, dépendant des paramètres non-linéaires,
- $\theta^*$  est le vecteur des paramètres linéaires optimaux.

Rappelons que  $f^*(X, \lambda^*, \theta^*)$  est un modèle non-linéaire parce qu'il y a une combinaison non-linéaire entre  $\lambda^*$  et  $\theta^*$ .

Tout d'abord, pour ajuster les paramètres de l'exTS, la processus d'identification est basé sur la minimisation de l'erreur de prédiction (figure IV.3). Cet erreur est :

$$e(k+1) = y_d(k+1) - \hat{y}(k+1) \quad (\text{IV.6})$$

En combinant les équations IV.5 et IV.6, on obtient :

$$\begin{aligned} e(k+1) &= f^*(X(k), \lambda^*, \theta^*) + \xi(k+1) - \hat{y}(k+1) \\ &= f^*(X(k), \lambda^*, \theta^*) + \xi(k+1) - f(X(k), \lambda(k), \theta(k)) \end{aligned} \quad (\text{IV.7})$$

Où  $\hat{y}(k+1)$  est la sortie de l'exTS.

Compte tenu que le vecteur  $\lambda$  est ajusté lors de la phase de clustering, et qu'il n'est pas ajusté par l'algorithme MCRs, nous pouvons considérer que les fonctions  $f^*$  et  $f$  sont

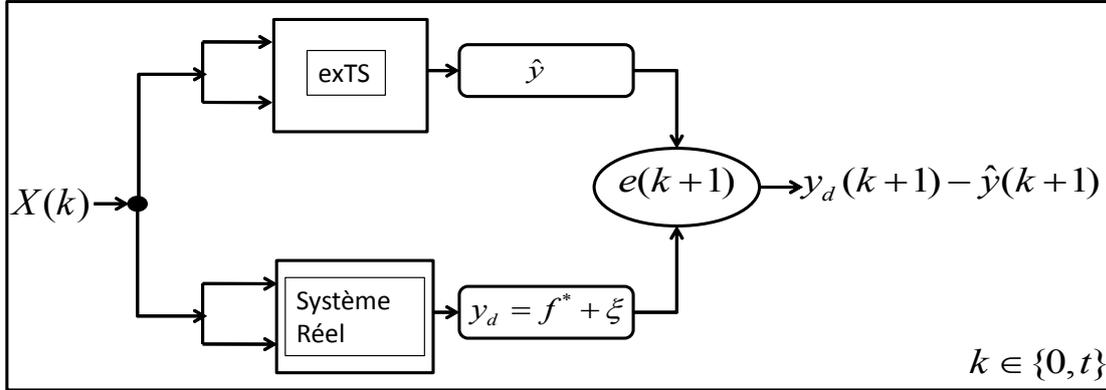


FIG. IV.3 – Erreur de Prédiction dans la zone d'apprentissage

linéaires (voir chapitre III) par rapport aux paramètres conséquents  $(\theta^*, \theta)$ .  $\theta$  est en réalité le vecteur des paramètres estimés, notons le  $\hat{\theta}$ . En se basant sur l'équation II.13, l'erreur de prédiction est la suivante :

$$e(k+1) = \psi_k^T \theta^* + \xi(k+1) - \psi_k^T \hat{\theta}_k \quad (\text{IV.8})$$

Les expérimentations montrent que l'erreur de prédiction de l'exTS converge vers un bruit blanc ( $\nu$ ) et suit une loi normale (*Hypothèse 2*). Il nous faut ainsi déterminer la moyenne et la variance de cette erreur de prédiction.

*Moyenne :*

$$\begin{aligned} \mu_{[e(k+1)]} &= \mu_{[\psi_k^T \theta^* + \xi(k+1) - \psi_k^T \hat{\theta}_k]} \\ &= \mu_{[\psi_k^T \theta^*]} + \mu_{[\xi(k+1)]} - \mu_{[\psi_k^T \hat{\theta}_k]} \end{aligned} \quad (\text{IV.9})$$

Selon l'*hypothèse 1*, la moyenne de  $\xi$  est égale à zéro. Ainsi, compte tenu que  $\theta^*$  et  $\psi_k^T$  ne sont pas des variables aléatoires,

$$\begin{aligned} \mu_{[e(k+1)]} &= \mu_{[\psi_k^T \theta^*]} - \mu_{[\psi_k^T \hat{\theta}_k]} \\ &= \psi_k^T \theta^* - \psi_k^T \mu_{[\hat{\theta}_k]} \end{aligned} \quad (\text{IV.10})$$

Et la moyenne de  $\hat{\theta}_k$  est  $\theta^*$ , donc  $\mu_{[e(k+1)]} = 0$ . L'exTS est donc un modèle prédictif *sans biais*.

*Variance :*

$$\sigma_{[e(k+1)]}^2 = \sigma_{[f^* + \xi(k+1) - f(k+1)]}^2 = \sigma_{[f^* + \xi(k+1)]}^2 + \sigma_{[f]}^2 + 2.Cov(f^* + \xi(k+1), f(k+1)) \quad (\text{IV.11})$$

Compte tenu que  $f^*$  n'est pas une variable aléatoire, et en remplaçant  $f(k+1)$  par  $\hat{y}(k+1)$ , l'équation IV.11 devient :

$$\sigma_{[e(k+1)]}^2 = \sigma_{[\xi(k+1)]}^2 + \sigma_{[\hat{y}(k+1)]}^2 + 2.Cov(\xi(k+1), \hat{y}(k+1)) \quad (IV.12)$$

En supposant que  $\xi(k+1)$  et  $\hat{y}(k+1)$  ne sont pas corrélés :

$$\begin{aligned} \sigma_{[e(k+1)]}^2 &= \sigma_{[\xi(k+1)]}^2 + \sigma_{[\hat{y}(k+1)]}^2 \\ &= \sigma_{[\xi(k+1)]}^2 + \sigma_{[\psi_k^T \hat{\theta}_k]}^2 \end{aligned} \quad (IV.13)$$

En outre, le vecteur  $\psi_k^T$  est certain, ainsi :

$$\sigma_{[e(k+1)]}^2 = \sigma_{[\xi(k+1)]}^2 + \psi_k^T \sigma_{[\hat{\theta}_k]}^2 \psi_k \quad (IV.14)$$

Rappelons que le vecteur  $\hat{\theta}_k$  contient les paramètres linéaires estimés, donc,  $\sigma_{[\hat{\theta}_k]}^2 = C_k$  (voir l'équation II.15). Et par suite la variance de l'erreur de prédiction est :

$$\begin{aligned} \sigma_{[e(k+1)]}^2 &= \sigma_{[\xi(k+1)]}^2 + \psi_k^T C_k \psi_k \\ &= s^2 + \psi_k^T \left( C_{k-1} + \frac{C_{k-1} \psi_k \psi_k^T C_{k-1}}{1 + \psi_k^T C_{k-1} \psi_k} \right) \psi_k \end{aligned} \quad (IV.15)$$

L'erreur de prédiction se présente finalement comme une distribution normale :

$$e_{k+1} : N[0, \sigma^2 = s^2 + \psi_k^T C_k \psi_k] \quad (IV.16)$$

### IV.3.1.2 Densité de prédiction et intervalle de confiance

Ce paragraphe est destiné à calculer la densité de prédiction de la sortie de l'exTS, afin de quantifier la performance du modèle prédictif. De plus, cela nous permet d'estimer un intervalle de prédiction.

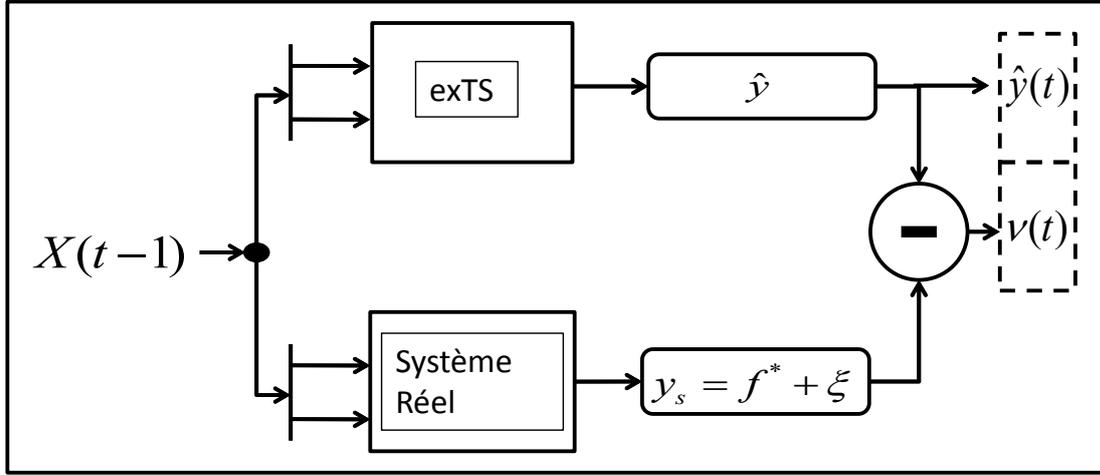
#### Densité de prédiction

A l'instant  $t$ , l'erreur de prédiction ( $e(t+1)$ ) converge vers un bruit blanc  $\nu(t)$  (*Hypothèse 2*, voir figure IV.4). Donc,

$$(t) = \nu(t) : N(0, \sigma^2 = s^2 + \psi_{t-1}^T C_{t-1} \psi_{t-1}) \quad (IV.17)$$

Si la variance  $s^2$  est inconnue, elle peut être estimée par l'équation suivante :

$$s = \sqrt{\frac{\left[ \sum_{k=1}^t y(k) - \hat{y}(k) \right]^2}{t-p}} \quad (IV.18)$$

FIG. IV.4 – Erreur de prédiction à l'instant  $t$ 

où  $p$  est le nombre des paramètres conséquents ( $\dim(\hat{\theta})$ ).

Nous pouvons ainsi poser que la sortie du modèle prédictif suit une distribution normale (voir figure IV.5) de moyenne  $\hat{y}$ , la sortie calculée de l'exTS, et de variance celle de  $e(t)$  [KGZ08b] :

$$\tilde{y}(t) : N(\hat{y}(t), \sigma^2 = s^2 + \psi_{t-1}^T C_{t-1} \psi_{t-1}) \quad (\text{IV.19})$$

#### Intervalle de prédiction

Le paragraphe précédent a permis d'estimer une distribution de prédiction de l'exTS. Sur la base de l'équation IV.19, nous pouvons calculer un intervalle de prédiction reflétant le niveau de confiance. L'intervalle de prédiction de l'exTS pour un niveau de confiance de  $\alpha$  est donné par :

$$y_t \in [\psi_k^T \hat{\theta}_k \pm t_{k-p}(1 - \frac{\alpha}{2}) \sqrt{s^2 + \psi_{t-1}^T C_{t-1} \psi_{t-1}}] \quad (\text{IV.20})$$

où :

- $\alpha$  est le seuil de confiance.
- $t_{k-p}(1 - \frac{\alpha}{2})$  est le quantile de la loi de Student à  $k - p$  degrés de liberté.

Les deux indicateurs cités ci-dessus (Densité de prédiction, Intervalle de prédiction) constituent un outil pour évaluer la capacité de modélisation de notre modèle de prédiction. Cette évaluation nous permet de mesurer à l'instant  $t$  (instant actuel) l'incertitude qui accompagne notre modèle de prédiction dans la zone d'apprentissage. Quand on projette dans le futur, la prédiction est incertaine et aucune connaissance *a priori* n'existe pour estimer l'incertitude. La prochaine section vise à définir comment évaluer l'incertitude dans la zone de prédiction, ce qui permettra finalement de prendre des décisions.

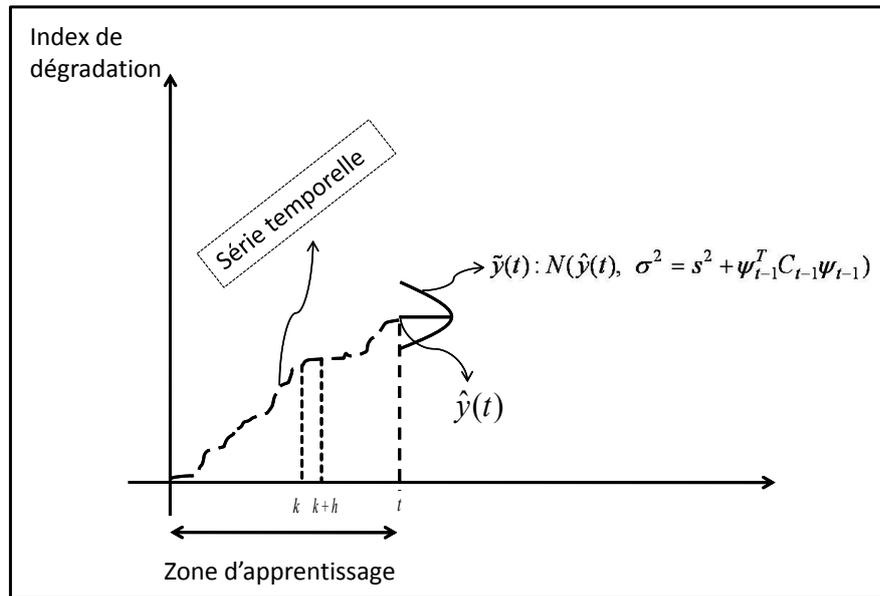


FIG. IV.5 – Incertitude de l'exTS (zone d'apprentissage)

### IV.3.2 Estimation de la confiance dans la zone de prédiction

Dans la zone d'apprentissage, le modèle prédictif a appris à prédire par une étape de prédiction one step ahead. On s'intéresse à généraliser cette étape par une prédiction multi-step-ahead, dans la zone de prédiction. Notre intérêt se porte sur une méthode permettant de prédire du multi-step-ahead, avec détermination de la distribution de prédiction et de son intervalle.

#### IV.3.2.1 Dimensionnement de l'erreur de prédiction

Rappelons que les paramètres linéaires et non-linéaires sont identifiés dans la zone d'apprentissage. Ils sont donc connus dans cette zone. Dans la zone de prédiction, il n'est pas possible d'identifier l'erreur de prédiction : aucune connaissance sur l'évolution future de la série temporelle (dégradation) n'existe. L'idée est ainsi d'utiliser l'incertitude connue à l'instant  $t$  (voir IV.19), et de la propager sur l'ensemble de l'horizon de prédiction. Cette propagation dépend du modèle prédictif utilisé (exTS). Le problème est que l'exTS est un modèle non-linéaire. Par contre, un avantage est que l'exTS a une structure composée de règles floues dans laquelle à chaque règle correspond un sous-modèle linéaire. Par conséquent, en déterminant l'espace flou, l'exTS devient un mutli-modèles constitué de plusieurs modèles linéaires. Une fois déterminés, les paramètres non-linéaires (avec l'algorithme de clustering), l'exTS peut se voir comme un modèle linéaire. Nous nous inspirons ainsi d'une technique employée pour estimer l'erreur de prédiction dans des systèmes linéaires [GM95] afin d'estimer la propagation de l'erreur de prédiction et éva-

luer l'incertitude à chaque pas de prédiction.

*exTS multi-modèles linéaires*

Afin d'illustrer comment transformer un exTS en un modèle linéaire, considérons un modèle construit avec deux régresseurs et composé de règles floues (IV.6). La sortie résulte de la somme de deux sous-modèles linéaires (eq. IV.21).

$$\begin{aligned}
 \hat{y}(t) &= \text{exTS}(y(t-1), y(t-2), t, \hat{\theta}, \lambda) \\
 &= \lambda_1 \hat{a}_1 y(t-1) + \lambda_1 \hat{b}_1 y(t-2) + \lambda_1 \hat{c}_1 + \lambda_2 \hat{a}_2 y(t-1) + \lambda_2 \hat{b}_2 y(t-2) + \lambda_2 \hat{c}_2 \\
 &= \lambda_1 \hat{c}_1 + \lambda_2 \hat{c}_2 + (\lambda_1 \hat{a}_1 + \lambda_2 \hat{a}_2) y(t-1) + (\lambda_1 \hat{b}_1 + \lambda_2 \hat{b}_2) y(t-2) \\
 &= \mu + \phi_1 y(t-1) + \phi_2 y(t-2)
 \end{aligned}
 \tag{IV.21}$$

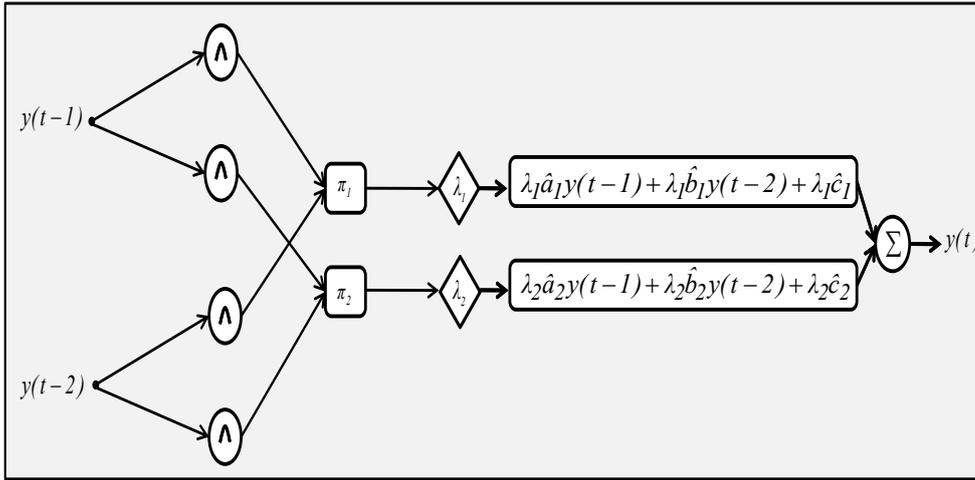


FIG. IV.6 – exTS avec 2 régresseurs et 2 règles

L'équation IV.21 décrit l'exTS sous forme d'une équation linéaire en fonction de  $y(t-1)$  et  $y(t-2)$ ,  $\mu$ ,  $\phi_1$  et  $\phi_2$  étant des paramètres estimés. Alors, la densité de prédiction de modèle prédictif est :

$$\tilde{y}(t) = \mu + \phi_1 y(t-1) + \phi_2 y(t-2) + \nu_t
 \tag{IV.22}$$

Pour généraliser, l'exTS avec  $n$  régresseurs devient le suivant :

$$\tilde{y}(t) = \mu + \phi_1 y(t-1) + \dots + \phi_n y(t-n) + \nu_t
 \tag{IV.23}$$

*exTS et combinaison linéaire de bruits blancs*

En utilisant un opérateur de retard<sup>1</sup> ( $L$ ), on peut représenter l'équation IV.23 sous une autre forme :

$$\begin{aligned}
\tilde{y}(t) &= \mu + \phi_1 y(t-1) + \phi_2 y(t-2) + \nu_t \\
\tilde{y}(t) &= \mu + \phi_1 y(t-1) + \dots + \phi_n y(t-n) + \nu_t \\
\tilde{y}(t) &= \mu + \phi_1 y(t-1) + \dots + \phi_n y(t-n) + \nu_t \Leftrightarrow \\
\tilde{y}(t) - \phi_1 y(t-1) - \dots - \phi_n y(t-n) &= \mu + \nu_t \Leftrightarrow \\
\tilde{y}(t) - \phi_1 L \tilde{y}(t) - \dots - \phi_n L^n \tilde{y}(t) &= \mu + \nu_t \Leftrightarrow \\
(1 - \phi_1 L - \dots - \phi_n L^n) \tilde{y}(t) &= \mu + \nu_t \\
\Phi(L) \tilde{y}(t) &= \mu + \nu_t
\end{aligned} \tag{IV.24}$$

où,

-  $\Phi(L)$  est polynôme de degré  $n$  fonction de  $L$ .

En multipliant par l'inverse du polynôme  $\Phi(L)$ , l'équation IV.24 devient :

$$\begin{aligned}
\tilde{y}(t) &= \Phi(L)^{-1} \mu + \Phi(L)^{-1} \nu(t) \\
&= K + \Phi(L)^{-1} \nu(t) \\
&= K + \omega(L) \nu(t)
\end{aligned} \tag{IV.25}$$

$\omega(L)$  est l'inverse du polynôme  $\Phi(L)$ . Il existe une série entière  $\omega(z) = \sum_{i=0}^{\infty} \omega_i z^i$ , avec  $z$  est un opérateur de retard, donc l'équation (IV.25) devient :

$$\tilde{y}_t = K + \left( \sum_{i=0}^{\infty} \omega_i z^i \right) \nu_t = K + \sum_{i=0}^{\infty} \omega_i \nu_{t-i} \tag{IV.26}$$

où  $\omega_0$  est égale à 1.

L'exTS est une combinaison linéaire de bruit blancs indépendants de forme  $N(0, \sigma^2)$  (eq. IV.17). Une fois déterminés les paramètres ( $\omega_i$ ), il est possible de calculer la valeur de  $\tilde{y}(t)$ .

*Multi-step ahead prédiction*

Au rang 1 :

$$\tilde{y}(t+1) = \mu^1 + \phi_1^1 y(t) + \phi_2^1 y(t-1) + \dots + \phi_n^1 y(t-n+1) + \nu(t+1) \tag{IV.27}$$

Au rang 2 :

$$\tilde{y}(t+2) = \mu^2 + \phi_1^2 \tilde{y}(t+1) + \phi_2^2 y(t) + \dots + \phi_n^2 y(t-n+2) + \nu(t+2) \tag{IV.28}$$

---

<sup>1</sup>  $L^m y(t) = y(t-m)$

Au rang  $H$  où  $H$  désigne l'horizon de prédiction :

$$\tilde{y}(t+H) = \mu^H + \phi_1^H \tilde{y}(t+H-1) + \dots + \phi_n^1 y(t+H-n) + \nu(t+H) \quad (\text{IV.29})$$

Les valeurs futurs de la série peuvent être estimés par la forme générale :

$$\tilde{y}(t+H) = K^H + \sum_{i=1}^{H-1} \phi_i^H \tilde{y}(t+i) + \sum_{i=H}^{H+n} \phi_i^H y(t+H-n) \quad (\text{IV.30})$$

En regardant l'équation IV.25 et IV.26, on peut décrire l'équation IV.29 sous forme d'une combinaison linéaire de bruits blancs :

$$\tilde{y}(t+H) = K^H + \sum_{i=0}^{+\infty} \omega_i^T \nu(t+H-i) \quad (\text{IV.31})$$

Avec  $\omega_0 = 1$ .

La prédiction optimale à  $t+H$  est :

$$y^*(t+H) = K^H + \sum_{i=H}^{+\infty} \omega_i^H \nu(t+H-i) \quad (\text{IV.32})$$

*Erreur de prédiction*

On définit l'erreur de prédiction à l'horizon  $H$  comme :

$$e(t+H) = \tilde{y}(t+H) - y^*(t+H) \quad (\text{IV.33})$$

Basé sur les équations IV.31 et IV.32, l'équation IV.33 est la suivante :

$$e(t+H) = \sum_{i=0}^{H-1} \omega_i^H \nu(t+H-i) \quad (\text{IV.34})$$

Rappelant que  $\nu(t+H)$  ( $\forall H$ ) est un bruit blanc avec une moyenne 0 et une variance  $\sigma$  (eq. IV.17). Donc, la moyenne de l'erreur de prédiction est égale à zéro. De plus, l'équation qui donne la variance de l'erreur de prédiction est la suivante :

$$\sigma_{e(t+H)}^2 = \sigma^2 \sum_{i=0}^{H-1} (\omega_i^H)^2 \quad (\text{IV.35})$$

L'erreur de prédiction a un horizon  $H$ , il a cette distribution normale :

$$e(t+H) \approx N [0, \sigma_{e(t+H)}^2] \quad (\text{IV.36})$$

Afin de déterminer les paramètres  $\omega_i$  (seuls éléments inconnus) à l'horizon  $H$ , nous avons choisi une méthode récursive (facile à programmer). Cette méthode est basée sur l'exploitation de la relation  $\Phi(L).\omega(z) = 1$ . En identifiant les coefficients des termes de même de degré, on obtient un système d'équations en  $\omega_i$  pouvant être résolu de façon récursive :

$$\begin{cases} \omega_0 = 1 \\ \omega_1 + \phi_1 = 0 \\ \omega_2 + \phi_1.\omega_1 + \phi_2 = 0 \\ \vdots \\ \omega_n + \phi_1.\omega_{n-1} + \dots + \phi_{n-1}.\omega_1 + \phi_n = 0 \\ \vdots \\ \omega_{H-1} + \phi_{H-1}.\omega_{H-2} + \dots + \phi_{H-2}.\omega_{H-n} + \phi_n.\omega_{H-1} = 0 \end{cases} \quad (\text{IV.37})$$

#### IV.3.2.2 Densité de prédiction et intervalle de confiance

Revenant à notre objectif qui est la détermination de la distribution et l'intervalle de prédiction de la sortie de l'exTS, il nous faut encore déterminer la densité de prédiction et l'intervalle de prédiction qui en découle.

*La densité de prédiction*

Compte tenu que  $e(t+H)$  suit une loi normale de moyenne égale à zéro, la sortie de l'exTS est *sans biais*. La densité de prédiction de la sortie de l'exTS est donc la suivante :

$$\hat{y}(t+H) \approx N[\hat{y}(t+H), \sigma_{e(t+H)}^2 = \sigma^2 \sum_{i=0}^{H-1} (\omega_i^H)^2] \quad (\text{IV.38})$$

*Intervalle de prédiction*

L'intervalle de prédiction de la sortie de l'exTS au niveau de confiance de  $1 - \alpha$  est donné par :

$$\hat{y}(t+H) \pm u_{1-\frac{\alpha}{2}} \sigma \sqrt{\sum_{i=0}^{H-1} (\omega_i^H)^2} \quad (\text{IV.39})$$

où :

-  $u_{1-\frac{\alpha}{2}}$  est le quantile d'ordre  $1 - \alpha$  la loi normale.

### IV.3.3 Synthèse

L'exTS est système d'inférence floue (partie non-linéaire) obtenue par combinaison de sous-modèles linéaires. Une fois les paramètres non-linéaires déterminés (par l'algorithme évolutif), l'exTS peut donc être considéré comme un modèle linéaire. Sur cette base, nous proposons deux méthodes pour déterminer la confiance (densité de prédiction, intervalle de prédiction). La proposition de deux méthodes se justifie par le fait que l'information sur la dégradation n'est pas la même avant et après l'instant  $t$ , *actuel*. La première est basée sur le calcul de l'erreur entre la valeur réelle  $y_d$  et la valeur estimée  $\hat{y}$ . Par contre, la deuxième est basée sur la propagation de l'erreur à partir de l'instant  $t$  sur un certain horizon de la prédiction. Dans, les deux cas, nous utilisons des outils de statistique spécifiques aux modèles linéaires.

## IV.4 Validation de l'approche par simulation

Le but de cette partie est d'illustrer notre proposition : estimer le temps avant la défaillance (*RUL*) d'un bien. Le *RUL* est déterminé par la modélisation de la fiabilité en ligne. Cette modélisation est construite par l'évaluation de la dégradation en regard d'un seuil de défaillance.

### IV.4.1 Description du plan de simulation

La simulation est basée sur un phénomène de dégradation réel. La dégradation est une réaction chimique du premier ordre proposée par [ML95]. L'augmentation avec le temps de la quantité de chlorure de cuivre (*ChC*) dans un circuit qui provoque une défaillance par court circuit. L'équation qui décrit l'évolution du chlorure de cuivre est la suivante :

$$ChC(t) = Ch(0)[1 - \exp(-r_1.t)] \quad (IV.40)$$

Avec  $Ch(0)$  la quantité de chlore initiale nécessaire pour déclencher le phénomène de dégradation,  $r_1$  taux de transformation. Cette dégradation est une série temporelle de type mon-variable, la seule grandeur étant l'indice de la dégradation ( $ChC(t)$ ). L'objectif est de créer plusieurs scénarios en utilisant l'équation IV.40 représentatifs de différentes vitesses de dégradation possibles du système (en fonction du contexte d'utilisation). Une partie de cette base de données est utilisée pour tester la performance de prédiction de l'exTS.

Cette base de données est composée de 40 dégradations générées à partir de différentes conditions initiales. Changer les conditions initiales, c'est pour se rapprocher des cas réels, dont plusieurs paramètres (humidité, température, etc.) a une influence sur la

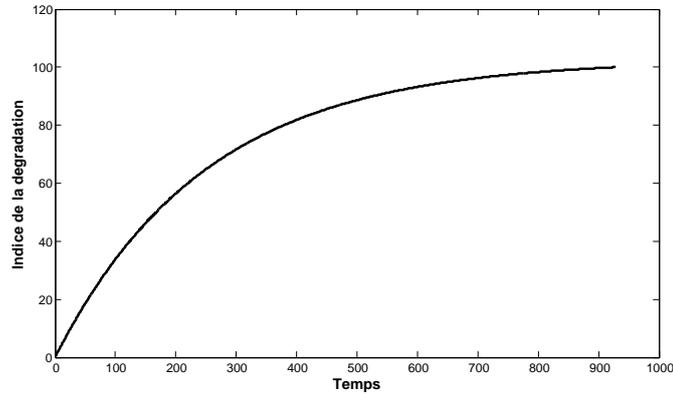


FIG. IV.7 – Évolution de la quantité de chlorure de cuivre

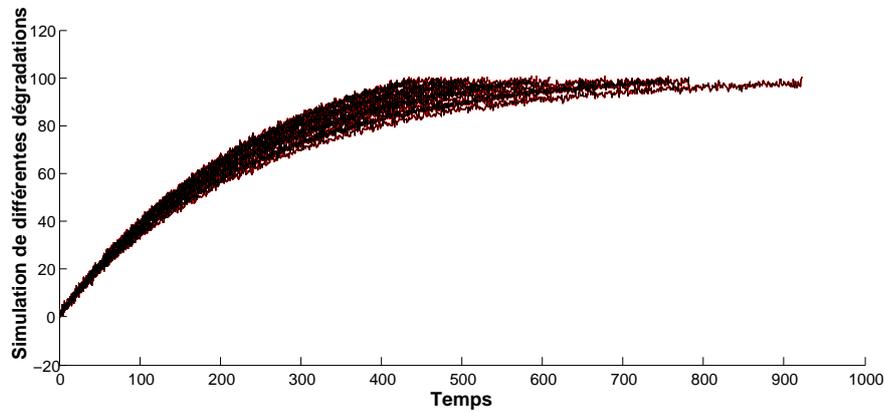


FIG. IV.8 – Plusieurs scénarios avec des différentes conditions

dégradation. Vingt de ces dégradations sont utilisées pour ajuster le modèle de l'exTS (le nombre d'entrées du système prédictif est fixé à 2). Les 20 dégradations restantes sont utilisées pour le test (IV.9).

#### IV.4.2 Évaluation de la confiance dans la prédiction

##### *Zone d'apprentissage*

Les deux entrées choisies sont le  $ChC(k)$  et le  $ChC(k-1)$  pour prédire le  $ChC(k+1)$ . La taille de la base d'apprentissage a été prise de façon variable entre une seule dégradation et 20 dégradations, contenant chacune un nombre différents d'échantillons. Dans chaque cas, le modèle est construit en utilisant l'algorithme évolutionnaire présenté au Chapitre III. Enfin d'apprentissage, les paramètres de l'exTS sont ajustés et

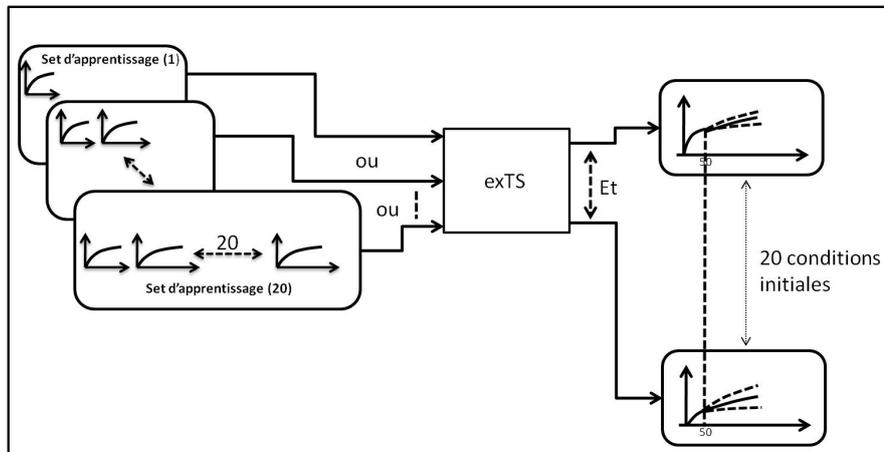


FIG. IV.9 – Organisation de la base de données

le modèle est prêt pour réaliser des prédictions.

#### *Zone de prédiction*

Pour cette zone, 20 dégradations différentes ont été utilisées, afin de tester les performances de prédiction de l'exTS. Rappelons que notre objectif est de prédire en ligne (durant l'opération du composant), l'état de dégradation du composant, c'est à dire l'indice de dégradation. Les prédictions ont été réalisées à partir de l'instant  $k = 50$ . Ces prédictions se font en utilisant le principe multi-step-ahead (section IV.3). A chaque prédiction, le niveau de confiance (95%) est estimé tel que proposée en section IV.3.2, ainsi que l'intervalle correspondant. Cet intervalle est utilisé pour évaluer l'appartenance des valeurs réelles à cet intervalle.

Pour démontrer la capacité de l'exTS à réaliser de bonnes prédictions, nous avons choisi de déterminer le pourcentage de points à l'extérieur et à l'intérieur de l'intervalle de prédiction comme un indicateur. Pour les 20 séries de dégradations de test (figure IV.9). Le résultat est illustré sur la figure IV.10. On constate que le pourcentage croit avec le nombre de dégradations utilisées pour l'apprentissage : la précision des prédictions augmente avec la taille de l'ensemble d'apprentissage. Mais, pour un nombre de dégradations bien déterminé, l'indicateur de pourcentage se stabilise autour 94%. Ceci illustre qu'à un moment donné, l'exTS a appris le phénomène de dégradation, et que s'il y a certains changements environnementaux (conditions initiales différentes), il est capable de s'adapter et de prédire avec un niveau de confiance de 95%.

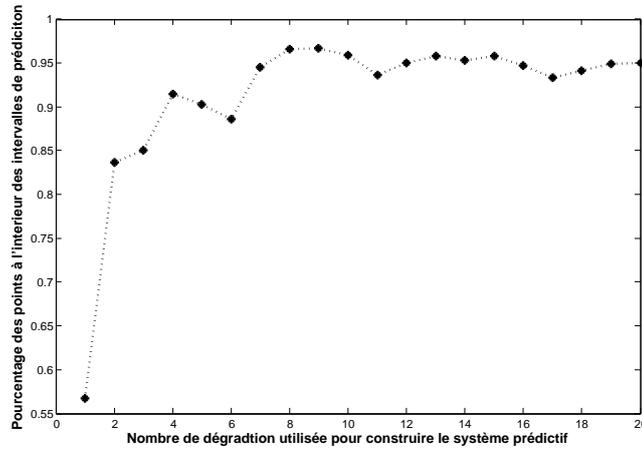


FIG. IV.10 – Pourcentage des points à l'intérieur de l'intervalle prédiction pour les 20 dégradations de test

#### IV.4.3 Estimation du $RUL$ en intégrant la confiance

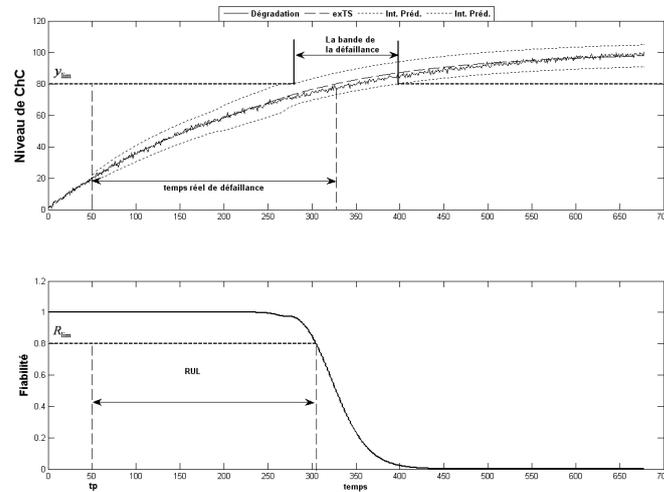
Dans cette section, on a choisi une base de données de 10 dégradations, et comme test une série de dégradation. L'objectif est de montrer l'intervalle de prédiction déterminé par la méthode proposée, et de modéliser la fiabilité prévisionnelle afin de déduire le  $RUL$ . Le tableau IV.1 présente les conditions de simulation.

Nombre d'entrées	2 : $[y(t-1), y(t)]$
Horizon de prédiction	$h=1, (\hat{y}(t+1))$
Base d'apprentissage	10 dégradations
Erreur d'apprentissage	Moyenne : 0.00062
	Écart type : 1.07325
Arrêt l'apprentissage	50
Type de prédiction	Multi-Step ahead
Niveau de confiance	0.95
$y_{lim}$	80
$R_{lim}$	0.8

TAB. IV.1 – Conditions de simulation

A partir de l'échantillon 50, on arrête d'adapter la structure et les paramètres de l'exTS, et on commence l'étape de prédiction en multi-step-ahead.

La partie supérieure de la figure IV.11 montre la prédiction de l'indice de dégradation (niveau de  $ChC$ ) par l'exTS à partir de l'instant actuel  $tp = 50$ , ainsi que l'intervalle de prédiction pour une confiance de 95%, cet intervalle de confiance a été construit par la méthode proposé dans la section précédente. Ceci permet de donner une première

FIG. IV.11 – Modélisation de la fiabilité en ligne et  $RUL$ 

approximation du  $RUL$  ; par comparaison des courbes de prédiction extrêmes avec le seuil de dégradation limite avant défaillance (80% du niveau de  $ChC$  sur la figure IV.11).

La partie inférieure de la figure IV.11 illustre le calcul de la fiabilité prévisionnelle. En précisant un seuil  $R_{lim}$ , il est ainsi possible d'estimer le  $RUL$  de manière plus déterminée. Dans cet exemple, le  $RUL$  estimé est égal à 310 unités de temps pour un  $R_{lim} = 0.8$ . Formulé autrement, il y a 80% de chance que le système ne soit pas défaillant avant 310 unités de temps. Ce résultat se confirme en regardant la valeur du  $RUL$  : 342 unités. L'erreur réalisée de 32 unités de temps est inférieure à 10% de la durée de vie résiduelle réelle et semble tout à fait acceptable. L'approche proposée permet donc de fiabiliser l'information nécessaire pour dimensionner les politiques de maintenance.

## IV.5 Conclusion

L'activité de prédiction est indispensable dans un processus de pronostic. Nous avons consacré les chapitres II et III de cette thèse afin d'abord de définir un système prédictif pour le pronostic à partir de données, et ensuite, de proposer une méthode de mise en oeuvre de ce système. Ceci étant, la prédiction est toujours entachée d'une incertitude. Nous nous sommes ainsi attachés à quantifier cette incertitude afin de maîtriser le processus de pronostic. Le système prédictif choisi (exTS) ne donne pas l'incertitude de prédiction, nous avons proposé dans ce chapitre une méthode pour estimer l'incertitude de ce système. Cette méthode est basée sur l'intégration d'outils de statistiques au système prédictif exTS, et vise d'abord à calculer l'erreur de prédiction durant la phase d'apprentissage, et en ensuite à la propager dans le futur. Cette

contribution permet de déterminer une bande de temps où le *RUL* se trouve et par suite d'estimer le *RUL* en modélisant la fiabilité.

La dernière partie de ce chapitre a été dédiée à la validation de notre proposition. Nous avons utilisé la dégradation réelle d'un équipement (circuit imprimé). Plusieurs simulations ont été faites pour construire une base des données (apprentissage, test). Le résultat est très encourageant : le système prédictif a pu prédire en ligne l'évolution de la dégradation et l'estimation de l'incertitude de prédiction permet de construire un intervalle de prédiction et de déterminer le temps résiduelle avant la défaillance (*RUL*).



# Conclusion et perspectives

## Conclusion générale

Dans cette thèse, nous avons qualifié le pronostic comme étant un processus indispensable dans une stratégie de maintenance prévisionnelle visant à assurer la sûreté de fonctionnement des systèmes industriels de plus en plus complexes. L'objectif du pronostic est d'appréhender, de suivre, et d'anticiper le comportement des équipements afin d'être capable de réagir intelligemment tout en réduisant les coûts de maintenance superflus (juste à temps). Cette activité de pronostic est relativement récente et n'est pas simple à mettre en œuvre. Cette thèse vise ainsi à contribuer au développement d'outils de pronostic industriel.

Nous avons d'abord positionné le pronostic au sein de la maintenance prévisionnelle. Récemment, plusieurs architectures informatisées de maintenance (OSA/CBM, Open System Architecture for Condition Based Maintenance) ont été proposées et intègrent le processus de pronostic. Le pronostic a pour objectif de prédire l'état futur d'un équipement, et s'appuie sur les informations issues d'autres modules (détection, diagnostic). Parmi les nombreuses définitions du pronostic que l'on trouve dans la littérature, nous avons finalement retenue que le pronostic vise à estimer le temps résiduel avant la défaillance d'un bien (*RUL*, Remaining Useful Life). Pour évaluer la performance d'un processus de pronostic, plusieurs métriques ont été proposées dans la littérature (*RUL*, exactitude, précision, date au plus tôt, date au plus tard, etc.). Nous pouvons conclure que le pronostic est un processus incertain. Récemment, de nombreux outils et méthodes de pronostic de défaillance ont été suggérés dans la littérature. [LT01] distingue trois approches de pronostic : les approches basées sur un modèle, les approches guidées par les données, et les approches basées sur l'expérience. Nous avons présenté les principes de fonctionnement, les avantages et inconvénients de chaque approche, ainsi que les techniques et outils associés à chacune d'elles.

Pour synthétiser, le pronostic est nécessaire dans une stratégie de maintenance. Ce processus vise à estimer le temps avant la défaillance d'un équipement (*RUL*). Cette estimation doit être accompagnée d'une mesure de confiance afin de mieux dimension-

ner les politiques de maintenance. Il n'existe pas d'approche universelle et le choix d'une technique convenable est lié aux conditions d'applicabilité (disponibilité des données/connaissances, systèmes réels complexes/dynamiques, capteurs, etc.). Aussi, nous avons restreint notre cadre de travail comme suit :

- d'abord, nous ne nous intéressons qu'aux composants jugés critiques : **ap-proche «locale»** du pronostic,
- ensuite, les défaillances considérées résultent d'un processus de **dégradation** pour lequel **aucun modèle *a priori*** n'est disponible. Le pronostic consiste ainsi à déterminer le temps résiduel avant que l'état de dégradation du bien ne permette plus de satisfaire une certaine exigence de performance,
- enfin, l'état de santé de l'équipement critique peut être décrit par un ou plusieurs descripteurs de dégradation construits sur la base de données capteurs. L'approche de pronostic développée est donc **guidée par les données**.

Sur cette base, nous avons orienté nos travaux vers la définition d'un système de pronostic composé de deux sous-activités : (1) la *prédiction* de l'évolution future de la dégradation, (2) l'*évaluation* de l'état prédit en fixant un seuil de défaillance. La phase de *prédiction* est à notre sens la plus critique. Elle constitue ainsi le centre de gravité de cette thèse.

La prédiction est le processus d'estimation de situations inconnues dans le futur. Deux familles de méthodes existent pour réaliser la tâche de prédiction :

1. qualitative : ce type de technique utilise l'expérience et le jugement pour établir les comportements futurs,
2. quantitative : ce type de technique utilise des données historiques pour établir des relations et tendances pouvant être projetées dans l'avenir.

Conformément à notre cadre de travail, nous avons écarté les approches qualitatives et les techniques quantitatives basées sur un modèle (absence de connaissance *a priori*). Nous avons ainsi mené une étude pour sélectionner une méthode quantitative basée sur des séries temporelles selon nos critères de choix (contraintes industrielles et performance d'un système prédictif). Les systèmes d'intelligence artificielle apparaissent comme adéquats pour supporter la phase de prédiction du pronostic, et plus précisément, notre choix s'est porté le modèle neuro-flou du type Takagi-Sugeno. Ce modèle combine la capacité d'apprentissage des réseaux de neurones avec la formalisation de règles floues tel que dans le raisonnement humain. Pour identifier ce modèle, nous avons proposé d'utiliser l'algorithme évolutif proposé par Angelov [AZ06]. Cet algorithme ne nécessite aucune connaissance *a priori* pour définir la structure floue du modèle prédictif et peut adapter sa structure et ajuster ses paramètres en ligne. Un tel système prédictif (exTS, evolving eXtend Takagi-Sugeno) correspond à nos critères de choix (contraintes industrielles, performances souhaitables). Par ailleurs, au delà de sa faculté à approximer une fonction de transfert inconnue, ce système est évolutif et est donc à même de s'enrichir de manière incrémentale à mesure que de nouvelles données sont disponibles.

Ceci étant, le fait de savoir qu'une technique de prédiction peut être intéressante ne signifie pas pour autant que la déployer soit facile. Nous nous sommes ainsi attachés à montrer comment utiliser le système exTS dans des applications de prédiction de séries temporelles, sans connaissance *a priori*. Plus précisément, nous avons proposé une procédure de génération automatique du système prédictif.

La proposition est fondée sur le constat suivant, performance de prédiction et complexité du système prédictif sont corrélées. Cependant, il existe un stade au delà duquel, le fait de construire un système prédictif plus complexe ne permet d'améliorer les prédictions que de façon marginale. Plus encore, cela peut amener à des situations dans lesquelles le système prédictif perd toute capacité de généralisation. Il convient donc davantage de rechercher un compromis «performance-complexité». Pour ce faire, nous avons analysé le processus d'identification du système d'inférence flou de l'exTS afin, d'une part, d'identifier quelles étapes impactent à la fois les performances de prédiction et la complexité du système, et d'autre part, afin de déterminer à quel niveau l'utilisateur peut avoir une influence critique. Il apparaît que l'intervention humaine ne se fait qu'au moment du choix des entrées du système prédictif (choix des régresseurs). Nous avons automatisé ce choix. La démarche est basée sur la construction d'une mesure de parcimonie permettant d'agrèger les mesures de performance et de complexité en un seul critère. Ce critère peut alors être utilisé afin de rechercher une structure optimale en terme de compromis «performance-complexité». Au final, la procédure permet de générer un système prédictif directement à partir des données, en s'affranchissant de l'intervention de l'utilisateur.

Si nous disposons d'un bon outil prédictif et d'une manière de le déployer, il nous est encore nécessaire d'intégrer la confiance à l'activité de prédiction afin de pouvoir, non seulement prédire une dégradation, mais également apprécier la qualité de cette prédiction afin d'estimer le *RUL*. Pour ce faire, nous avons développé une méthode d'estimation de l'incertitude de prédiction. Nous avons quantifié l'incertitude de prédiction dans la zone d'apprentissage à partir des entrées et de la variance des paramètres du système prédictif. Nous avons ensuite propagé cette incertitude sur une prédiction à plusieurs pas en avant (multi-step-ahead). Ceci nous permet d'obtenir l'incertitude à tout horizon de prédiction, et ainsi de construire la bande où se trouve le *RUL*. Enfin, nous avons réalisé des simulations numériques et des tests pour valider notre contribution.

## Perspectives

Dans cette thèse, nous avons contribué au pronostic industriel en développant un système prédictif neuro-flou évolutif. Plusieurs perspectives liées à ces travaux sont actuellement en phase d'amélioration :

- construire un système prédictif multi-variables (la surveillance des systèmes complexes ne peut se baser sur le suivi d'un unique critère). De ce point

- de vue, l'architecture exTS est *a priori* adaptée mais des développements supplémentaires sont nécessaires et des essais doivent être envisagés,
- maîtriser l'erreur d'un système prédictif reste toujours un défi. L'étude est actuellement poursuivie afin de considérer la maîtrise de l'erreur de prédiction comme un objectif explicite lors de la phase d'apprentissage des paramètres du réseau neuro-flou. L'idée sous-jacente est de chercher à trouver un compromis entre généralisation et approximation, en cohérence avec les exigences de précision de l'utilisateur (un système dont l'erreur de prédiction est constante mais connue est préférable à un système dont l'erreur est généralement faible mais parfois catastrophique...). Ceci nécessite le développement d'un nouvel algorithme d'apprentissage,
  - valider nos travaux sur des équipements réels. Un banc de test sur des roulements a été réalisé au sein de l'équipe COSMI du département AS2M de l'institut Femto-st. La première campagne d'expériences est en cours. Nous l'utiliserons pour mettre à l'épreuve nos développements.

## Annexe

### A Éléments de logique floue

#### Théorie de la logique floue

##### A- Ensemble flou

La plupart des problèmes rencontrés sont modélisables mathématiquement. Mais, ces modèles prennent appui sur des hypothèses parfois trop restrictives, rendant délicate l'application au monde réel. Les problèmes du monde réel doivent tenir compte d'informations imprécises, incertaines.

Dans la théorie des ensembles, un élément appartient ou n'appartient pas à une classe. La notion d'ensemble est à l'origine de nombreuses théories mathématiques. Cette notion essentielle ne permet cependant pas de rendre compte de situations pourtant simples et rencontrées fréquemment. Parmi des fruits, il est facile de définir l'ensemble des pommes. Par contre, il sera plus difficile de définir l'ensemble des pommes mûres. On conçoit bien que la pomme mûrit progressivement... la notion de pomme mûre est donc graduelle. C'est pour prendre en compte de telles situations qu'a été créée la notion d'ensemble flou. La théorie des ensembles flous repose sur la notion d'appartenance partielle : chaque élément appartient partiellement ou graduellement aux ensembles flous qui ont été définis. Les contours de chaque ensemble flou (figure A1) ne sont pas « nets », mais « flous » ou « graduels ».

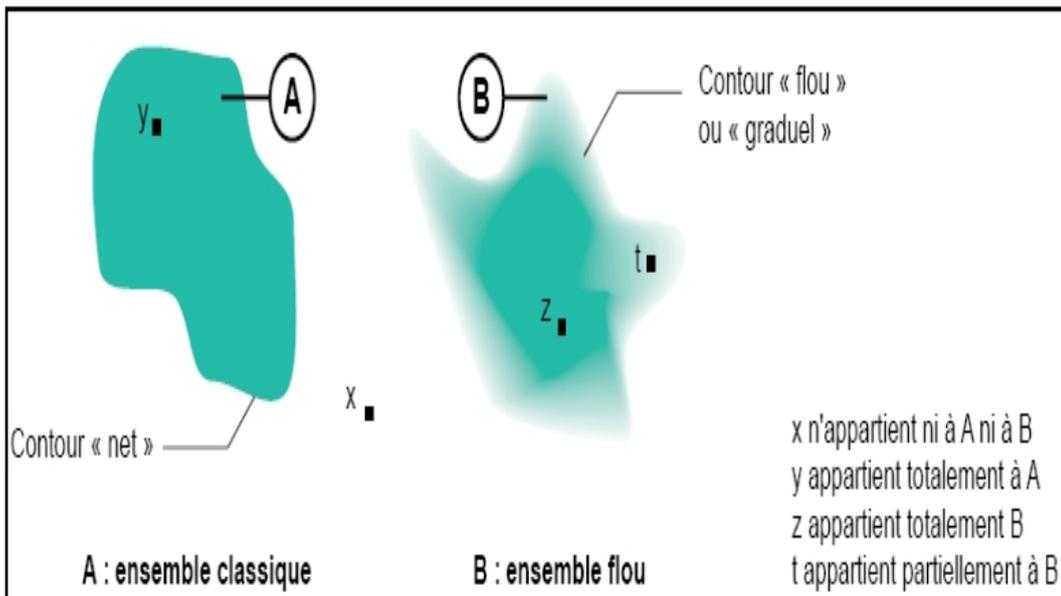


FIG. A1 – Comparaison d'un ensemble classique et d'un ensemble flou

### B- Fonction d'appartenance

Un ensemble flou est défini par sa « fonction d'appartenance », qui correspond à la notion de « fonction caractéristique » en logique classique. Supposons que nous voulions définir l'ensemble des personnes de « taille moyenne ». En logique classique, nous conviendrons par exemple que les personnes de taille moyenne sont celles dont la taille est comprise entre 1,60 m et 1,80 m. La fonction caractéristique de l'ensemble (figure A2, a) donne « 0 » pour les tailles hors de l'intervalle [1,60 m ; 1,80 m] et « 1 » dans cet intervalle. L'ensemble flou des personnes de « taille moyenne » sera défini par une « fonction d'appartenance » qui diffère d'une fonction caractéristique par le fait qu'elle peut prendre n'importe quelle valeur dans l'intervalle [0, 1]. A chaque taille possible correspondra un « degré d'appartenance » à l'ensemble flou des « tailles moyennes » (figure A2, b), compris entre 0 et 1. Donc, un sous-ensemble flou  $A$  d'un référentiel  $R$  est caractérisé par une fonction d'appartenance  $\mu$  :

Si  $\mu_A$  est la fonction d'appartenance de l'ensemble flou  $A$  :

$$\forall x \in R, \quad \mu \in [0, 1]$$

L'ensemble  $A$  est définie par :  $A = \{(x, \mu_A(x)), x \in X\}$

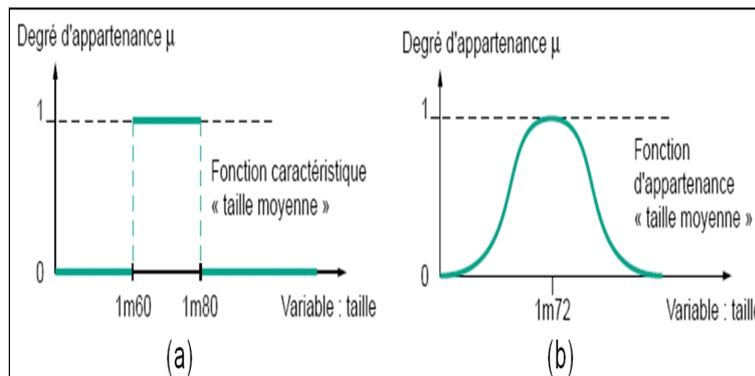


FIG. A2 – (a) fonction caractéristique, (b) fonction d'appartenance

De plus, plusieurs ensembles flous peuvent être définis sur la même variable, par exemple les ensembles « taille petite », « taille moyenne » et « taille grande », notions explicitées chacune par une fonction d'appartenance (figure A3). Cet exemple montre la gradualité que permet d'introduire la logique floue. Une personne de 1,80 m appartient à l'ensemble «taille grande» avec un degré 0,3 et à l'ensemble «taille moyenne» avec un degré de 0,7. En logique classique, le passage de moyen à grand serait brusque. Une personne de 1,80 m serait par exemple de taille moyenne alors qu'une personne de 1,81 m serait grande, ce qui choque l'intuition. La variable (par exemple : taille) ainsi que les termes (par exemple : moyenne, grande) définis par les fonctions d'appartenance portent respectivement les noms de variable linguistique et de termes linguistiques.

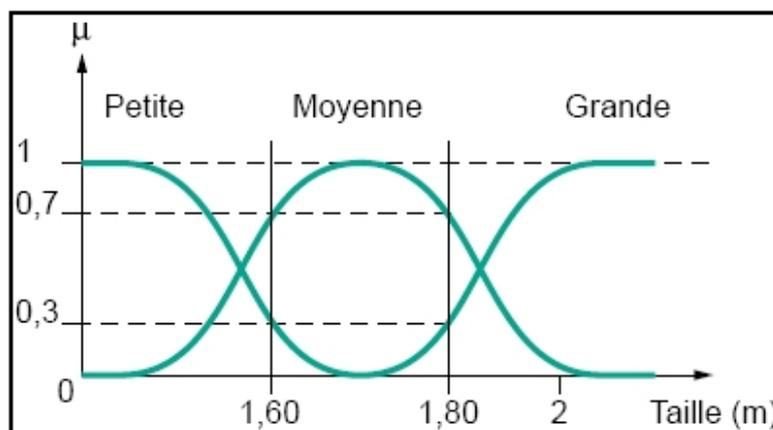


FIG. A3 – Fonction d'appartenance, variable et terme linguistique

Les fonctions d'appartenance peuvent théoriquement prendre n'importe quelle forme. La figure A4 montre un aperçu des fonctions les plus usuelles.

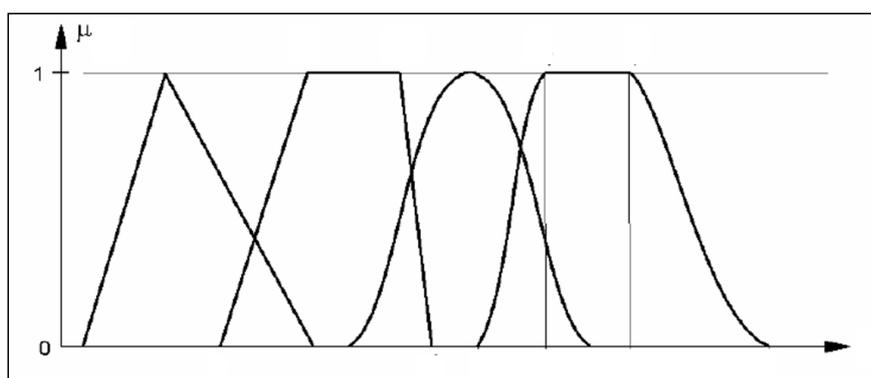


FIG. A4 – Formes typiques représentatives des fonctions d'appartenance

### C- Opérateurs entre ensemble flous

Ces opérateurs permettent d'écrire des combinaisons logiques entre notions floues, c'est-à-dire de faire des calculs sur des degrés de vérité. Comme pour la logique classique, on peut définir des opérateurs ET, OU, négation. Exemple : *Appartement Intéressant : Loyer Raisonnable ET Surface Suffisante*. Par suite, pour choisir un opérateur, il existe de nombreuses variantes dans ces opérateurs. La figure A5) résume les principaux.

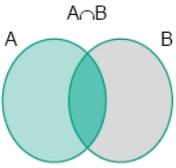
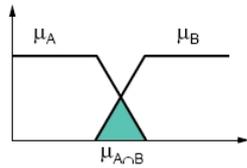
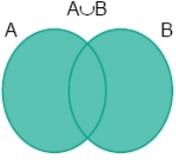
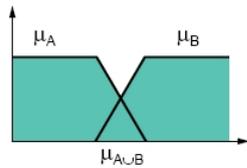
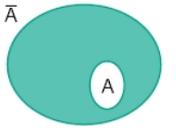
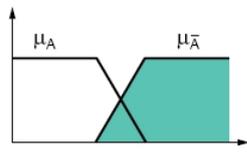
		Opérateur de ZADEH	Opération logique	
Intersection		$\mu_{A \cap B} = \text{MIN}(\mu_A, \mu_B)$	ET	
Union		$\mu_{A \cup B} = \text{MAX}(\mu_A, \mu_B)$	OU	
Négation		$\mu_{\bar{A}} = 1 - \mu_A$	NON	

FIG. A5 – Opérateurs entre ensemble flous

## Modèle flou

Les modèles flous peuvent être considérés comme des modèles logiques qui utilisent des règles du type « *Si Alors* » pour établir des relations qualitatives entre les variables du modèle. Ils reposent sur une dualité linguistique/numérique dans laquelle les ensembles flous servent d'interfaces entre les variables qualitatives (linguistiques) impliquées dans les règles et les valeurs numériques présentes dans les données entrées/sorties du modèle. La nature des modèles flous (basés sur des règles) permet l'utilisation d'information sous la forme d'expressions du langage naturel, ce qui facilite la formalisation de la connaissance des experts ainsi que la transparence et l'interprétabilité du modèle. De plus, les modèles flous ont une structure mathématique flexible capable d'approximer un grand nombre de systèmes non linéaires complexes avec une bonne précision [ZS95] [Wan94].

### A- Structure générale : règle floue

En général les systèmes flous s'appuient sur une représentation de la connaissance sous forme de règles «*Si-Alors*» qui permettent de représenter les relations entre les variables d'entrée et de sortie dont l'expression générique est de la forme :

***Si** antécédent **Alors** conséquent*

Dans un premier temps et afin de faciliter l'interprétation, on peut considérer l'*antécédent* (*prémisse*) comme une description linguistique qui indique les conditions de validité du phénomène représenté. Pour sa part, le *conséquent* (*conclusion*) représente le comportement associé aux conditions de validité décrites par l'*antécédent*. Considérons à titre illustratif la règle suivante :

*Si concentration de polluant est élevée Alors temps de dégradation est long*

Les règles floues établissent des relations logiques entre les variables du système en associant la valeurs qualitative d'une variable (la concentration de polluant est élevée) avec celle d'une autre variable (le temps de dégradation est long). Les valeurs qualitatives ont typiquement une interprétation linguistique, elles sont nommées termes linguistiques (étiquettes). La signification des termes linguistiques par rapport aux variables d'entrée/sortie numériques (concentration de polluant, temps de dégradation) est définie par des ensembles flous appropriés. Dans ce sens, les ensembles flous, ou plus précisément leurs fonctions d'appartenance, fournissent une interface entre les variables numériques d'entrée/sortie et les valeurs linguistiques qualitatives dans les règles. Dans un cadre plus formel, la représentation d'un modèle flou demande souvent l'utilisation de plusieurs règles et comporte diverses opérations mathématiques pour le traitement d'informations symboliques.

### C- Structure interne d'un modèle flou

De manière classique, le fonctionnement interne des systèmes d'inférence flous repose sur une structure, représentée en figure A6 [BR98] [Gal01], qui inclut :

- la *fuzzification* des variables d'entrée, avec éventuellement un prétraitement de l'information,
- l'*inférence* à partir d'une base de connaissance,
- la *défuzzification*, avec éventuellement un post-traitement d'information.

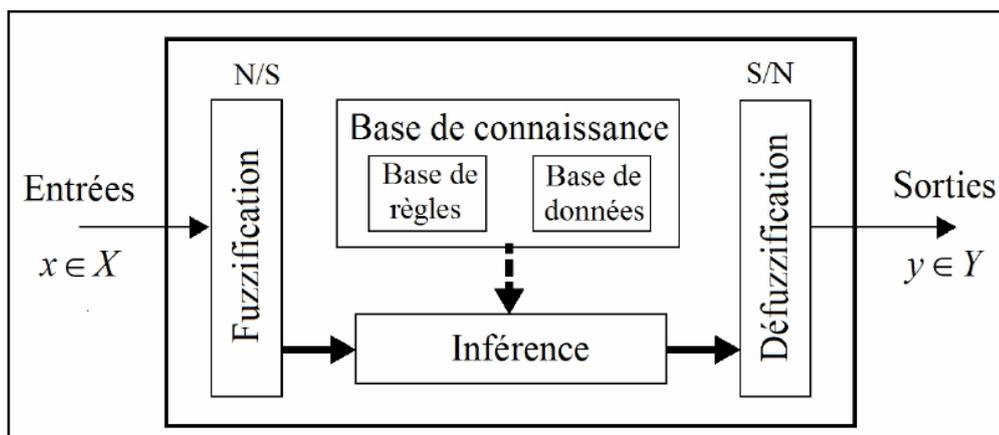


FIG. A6 – Représentation interne d'un modèle flou

L'étape de *fuzzification* consiste à transformer les entrées numériques disponibles en parties floues. Celles-ci alimentent alors le mécanisme d'*inférence* qui à partir d'une valeur d'entrée et selon la connaissance fournie par la *base de connaissance*, détermine la valeur correspondante de la sortie. Cette base de connaissance est composée par la *base de règles* et par la *base de données*, qui stocke les fonctions d'appartenance associées aux termes linguistiques employés dans le modèle flou. Cela constitue le fondement du *raisonnement approché* du système, car la combinaison des entrées avec les règles floues permet de tirer des conclusions. Enfin, la *défuzzification* est l'opération inverse de la *fuzzification*, en convertissant les parties floues relatives aux sorties du mécanisme d'inférence en sorties numériques.

## B Réseaux de Neurones

### Historique

L'idée de modéliser mathématiquement un cerveau humain remonte à 1890 : W. James introduisit le concept de mémoire associative, et proposa ce qui deviendra une loi de fonctionnement pour l'apprentissage sur les réseaux de neurones connue plus tard sous le nom de loi de Hebb. En 1943, J. Mc Culloch et W. Pitts proposent une modélisation du neurone biologique (un neurone au comportement binaire). Ce furent les premiers à montrer que des réseaux de neurones formels simples peuvent réaliser des fonctions logiques, arithmétiques et symboliques complexes (tout au moins au niveau théorique). En 1949, D. Hebb expliqua le conditionnement chez l'animal par les propriétés des neurones eux-mêmes. Ainsi, un conditionnement de type pavlovien tel que, nourrir tous les jours à la même heure un chien, entraîne chez cet animal la sécrétion de salive à cette heure précise même en l'absence de nourriture. La loi de modification des propriétés des connexions entre neurones qu'il proposa explique en partie ce type de résultats expérimentaux.

Mais, il faut attendre 1957, pour que F. Rosenblatt, développe le modèle du Perceptron. Il construisit le premier neuro-ordinateur basé sur ce modèle et l'appliqua au domaine de la reconnaissance de formes. Notons qu'à cet époque les moyens à sa disposition étaient limités et ce fut une prouesse technologique que de réussir à faire fonctionner correctement cette machine plus de quelques minutes. Puis, en 1960 B. Widrow, un automaticien, développa le modèle Adaline (Adaptative Linear Element). Dans sa structure, le modèle ressemble au Perceptron, cependant la loi d'apprentissage est différente. Celle-ci est à l'origine de l'algorithme de rétropropagation de gradient très utilisé aujourd'hui avec les Perceptrons multicouches. Les réseaux de type Adaline restent utilisés de nos jours pour certaines applications particulières. Par contre, un ouvrage a été publié dans l'année 1969 par M. Minsky et S. Papert qui met en exergue les limitations théoriques du perceptron. Limitations alors connues, notamment concernant l'impossibilité de traiter par ce modèle des problèmes non linéaires. Ils étendirent implicitement ces limitations à tous modèles de réseaux de neurones artificiels ce qui conduisit à l'abandon financier des recherches dans le domaine (surtout aux U.S.A.).

Quelques années d'ombre se succédèrent ensuite de 1967 à 1982. Le renouveau de cette discipline reprit en 1982 grâce à J. J. Hopfield, un physicien reconnu. Au travers d'un article court, clair et bien écrit, il présenta une théorie du fonctionnement et des possibilités des réseaux de neurones. Alors que les auteurs s'acharnaient jusqu'alors à proposer une structure et une loi d'apprentissage, puis à étudier les propriétés émergentes, J. J. Hopfield fixa préalablement le comportement à atteindre par son modèle et construisit, à partir de là la structure et la loi d'apprentissage fournissant le résultat escompté. Ce modèle est aujourd'hui encore très utilisé pour des problèmes d'optimi-

sation. On peut citer encore la Machine de Boltzmann en 1983 qui fut le premier modèle connu, apte à traiter de manière satisfaisante les limitations recensées dans le cas du Perceptron. Mais l'utilisation pratique s'avère difficile, la convergence de l'algorithme étant extrêmement longue (les temps de calcul sont considérables). Ce n'est qu'en 1985 que l'algorithme de rétro-propagation de gradient apparut. Cet algorithme d'apprentissage est adapté au Perceptron-Multi-Couches et sa découverte permit de réaliser une fonction non linéaire d'entrée/sortie sur un réseau, en décomposant cette fonction en une suite d'étapes linéairement séparables, [ZEM03], [DMS<sup>+</sup>02].

## Éléments de base

L'inspiration à l'origine de la technique des « Réseaux de Neurones (RNs) formels », communément appelé « réseau de neurones » vient du fait que le cerveau humain est un système apprenant qui n'est pas basé sur les principes de la logique formelle mais sur une structure, le cerveau humain, contenant environ 100 milliards de neurones reliés entre eux par 10 000 contacts synaptiques soit environ un million de milliards de synapses. Les réseaux de neurones formels sont une tentative pour imiter le mécanisme d'apprentissage qui se produit dans le cerveau.

### A- Neurone réel

Le neurone réel est une cellule vivante spécialisée dans le traitement des signaux électriques. Les neurones sont reliés entre eux par des liaisons appelées axones. Ces axones vont eux mêmes jouer un rôle important dans le comportement logique de l'ensemble. Ces axones conduisent les signaux électriques de la sortie d'un neurone vers l'entrée (synapse) d'un autre neurone. Les neurones font une sommation des signaux reçus en entrée et en fonction du résultat obtenu vont fournir un courant en sortie.

La structure d'un neurone se compose de trois parties (figure B1) :

- la soma : ou cellule d'activité nerveuse, au centre du neurone,
- l'axone : attaché au soma qui est électriquement actif, ce dernier conduit l'impulsion conduite par le neurone,
- les dendrites : électriquement passives, elles reçoivent les impulsions d'autres neurones.

### B- Neurone formel (Artificiel)

La figure B2 montre la structure d'un neurone artificiel. Chaque neurone artificiel est un processeur élémentaire. Il reçoit un nombre variable d'entrées en provenance de neurones amonts. À chacune de ces entrées est associée un poids  $w$  abréviation de weight (poids en anglais) représentatif de la force de la connexion. Chaque processeur élémentaire est doté d'une sortie unique, qui se ramifie ensuite pour alimenter un nombre variable de neurones avals. À chaque connexion est associée un poids.

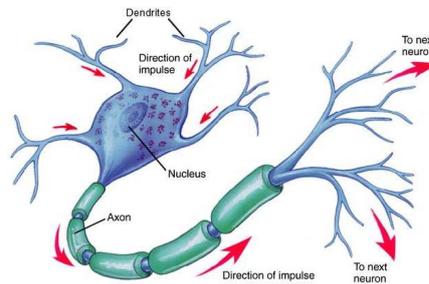


FIG. B1 – Neurone biologique

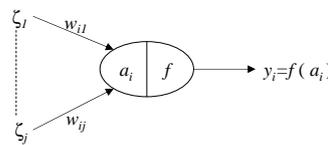


FIG. B2 – Neurone formel (artificiel)

Par analogie avec le neurone réel, le comportement du neurone artificiel se compose de deux phases. La première phase, appelée activation, représente le calcul de la somme pondérée des entrées selon l'expression suivante :

$$a_i = \sum_j \omega_{ij} \zeta_j \quad (\text{B1})$$

A partir de cette valeur, une fonction de transfert calcule la valeur de l'état du neurone. Cette valeur sera transmise aux neurones avals. Il existe de nombreuses formes possibles pour la fonction de transfert. Les plus courantes sont présentées sur la figure B3. On remarquera qu'à la différence des neurones biologiques dont l'état est binaire, la plupart des fonctions de transfert sont continues, offrant une infinité de valeurs possibles comprises dans l'intervalle  $(0, +1)$  ou  $(-1, 1)$ .

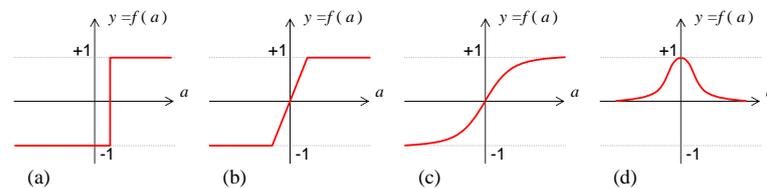


FIG. B3 – Différents types de fonctions de transfert pour le neurone artificiel : a) fonction à seuil du neurone de Mc Culloch et W. Pitts (1949), b) linéaire par morceaux du modèle Adaline de Widrow et Hoff (1960), c) sigmoïde d'un réseau Perceptron Multi Couches de Rosenblatt (1962), d) gaussienne du réseau RFR de Moody et Darken (1989) , [ZEM03]

## Différentes architectures de RNs

Les connexions entre les neurones qui composent le réseau décrivent la topologie du modèle. Elle peut être quelconque, mais le plus souvent il est possible de distinguer une certaine régularité.

### A- Réseau monocouche

La structure d'un réseau monocouche est telle que des neurones organisés en entrée soient entièrement connectés à d'autres neurones organisés en sortie par une couche modifiable de poids (figure B4).

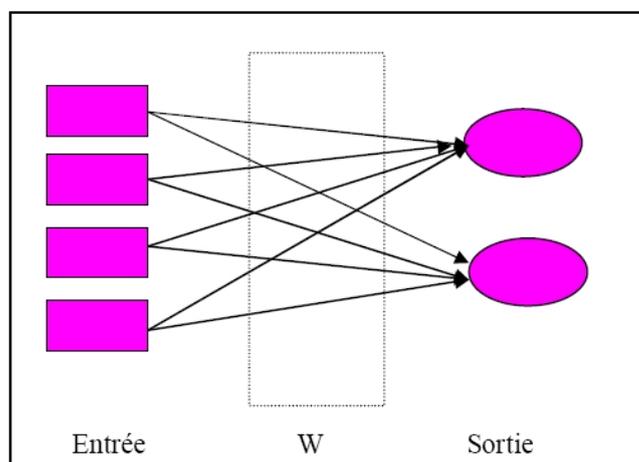


FIG. B4 – Réseau monocouche

### B- Réseau multicouches

Les neurones sont arrangés par couche. Il n'y a pas de connexion entre neurones d'une même couche, et les connexions ne se font qu'avec les neurones de couches avales. Habituellement, chaque neurone d'une couche est connecté à tous les neurones de la couche suivante et celle-ci seulement. Ceci nous permet d'introduire la notion de sens de parcours de l'information (de l'activation) au sein d'un réseau et donc définir les concepts de neurone d'entrée, neurone de sortie. Par extension, on appelle couche d'entrée l'ensemble des neurones d'entrée et couche de sortie l'ensemble des neurones de sortie. Les couches intermédiaires n'ayant aucun contact avec l'extérieur sont appelées couches cachées (figure B5).

### C- Réseau à connexion complète

C'est la structure d'interconnexion la plus générale. Chaque neurone est connecté à tous les neurones du réseau (et à lui-même) (figure B6).

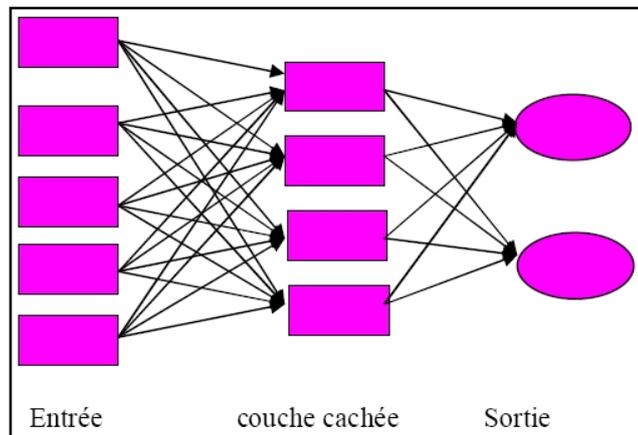


FIG. B5 – Réseau Multicouches

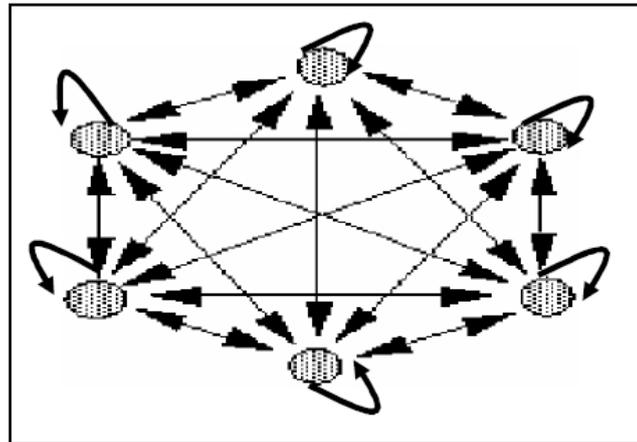


FIG. B6 – Réseau à connexion complète

Nous avons introduit dans cette section, différentes architectures, nous avons notamment distinguées deux types :

- les RNs non-bouclés, statiques, qui réalisent des fonctions non-linéaires,
- les RNs bouclés, dynamiques, qui réalisent des équations aux différences non-linéaires.

Plusieurs propositions de modèles de réseaux de neurones se trouvent dans la littérature (Modèle de Hofield, Kohonen, perceptrons multicouche, Elman, etc). Les sorties ( $y_i$ ) de ces modèles sont non-linéaires. Un réseau de neurones émule entre les entrées ( $x_i$ ) et les paramètres du réseau (poids des couches,  $w$ ) :  $y_i = f(x_i, w)$ . Par suite, un étape d'apprentissage nécessaire. Donc, nous allons introduire la notion d'apprentissage dans la section suivante.

## Apprentissage des RNs

On appelle «Apprentissage» des RNs la procédure qui consiste à estimer les paramètres des neurones du réseau, afin que celui-ci remplisse au mieux la tâche qui lui est affectée.

L'apprentissage est vraisemblablement la propriété la plus intéressante des réseaux neuronaux. Elle ne concerne cependant pas tous les modèles, mais les plus utilisés. L'apprentissage est une phase du développement d'un réseau de neurones durant laquelle le comportement du réseau est modifié jusqu'à l'obtention du comportement désiré. L'apprentissage neuronal fait appel à des exemples de comportement.

Durant cette phase de fonctionnement, le réseau adapte sa structure (le plus souvent, les poids des connexions) afin de fournir sur ses neurones de sortie les valeurs désirées. Cet apprentissage nécessite des exemples désignés aussi sous l'appellation d'échantillon d'apprentissage ainsi qu'un algorithme d'apprentissage. Après initialisation des poids du réseau (en général des valeurs aléatoires), il y a présentation des exemples au réseau et calcul des sorties correspondantes. Une valeur d'erreur ou de correction est calculée et une correction des poids est appliquée.

Au niveau des algorithmes d'apprentissage, il a été défini deux grandes classes selon que l'apprentissage est dit supervisé ou non supervisé. Cette distinction repose sur la forme des exemples d'apprentissages. Dans le cas de l'apprentissage supervisé, les exemples sont des couples (Entrée, Sortie associée) alors que l'on ne dispose que des valeurs (Entrée) pour l'apprentissage non supervisé. Remarquons cependant que les modèles à apprentissage non supervisé nécessitent avant la phase d'utilisation une étape de labélisation effectuée par l'opérateur, qui n'est pas autre chose qu'une part de supervision.

### *A- Apprentissage supervisé*

L'apprentissage est dit supervisé lorsque les exemples sont constitués de couples de valeurs du type : (valeurs d'entrées  $x_i$ , valeurs de sorties désirées,  $y_i$ ,  $i = 1, \dots, N$ ). Tout le problème de l'apprentissage supervisé consiste, étant donné un ensemble d'apprentissage de  $N$  couples (entrées - sorties désirées), à déterminer le vecteur des poids  $w$  du réseau.

### *B- Apprentissage non supervisé*

L'apprentissage est qualifié de non supervisé lorsque seules les valeurs d'entrée sont disponibles. Ainsi, un réseau de neurones peut également être utilisé dans un but de visualisation ou d'analyse de données : on dispose d'un ensemble de données, représentées par des vecteurs de grande dimension, et l'on cherche à les regrouper, selon des critères de ressemblance qui sont inconnus *a priori*. Ce type de tâche est connu en

statistique sous le nom de méthodes «d'agrégation» ou classification automatique (en anglais *clustering*).

### *C- Algorithmes d'apprentissages*

Plusieurs algorithmes d'apprentissage existent dans la littérature. La sélection d'un algorithme se fait selon la tâche à réaliser. Une liste non exhaustive d'algorithmes d'apprentissage employés pour adapter les paramètres des réseaux neurones est la suivante :

- retropagation du gradient,
- méthodes d'optimisation de second ordre (Newton, Quasi newton, moindres carrés non-linéaire, etc),
- méthodes de régularisation,
- algorithme de Kohonen,

Pour plus de détails voir [ZEM03], [DMS+02].

## C Algorithmes des Moindres Carrés

Supposons qu'il existe une séquence de  $S$  échantillons d'apprentissage entrées/sorties  $Z^k = \{X^k, y^k\}$  où  $X \in \mathfrak{R}^n$ , avec  $n$  entrées,  $y \in \mathfrak{R}$  est la seule sortie, et  $k = 1, \dots, S$ . Les  $S$  sorties sont regroupées dans le vecteur  $Y$ . Sur cette base, l'équation II.5, le vecteur  $Y$  peut être reformulée comme suit.

$$\underbrace{\begin{bmatrix} y^1 \\ \vdots \\ y^S \end{bmatrix}}_Y = \underbrace{\begin{bmatrix} \lambda_1^1 & \lambda_1^1 x_1^1 & \cdots & \lambda_1^1 x_n^1 & \cdots & \lambda_R^1 & \lambda_R^1 x_1^1 & \cdots & \lambda_R^1 x_n^1 \\ \vdots & \vdots \\ \lambda_1^S & \lambda_1^S x_1^S & \cdots & \lambda_1^S x_n^S & \cdots & \lambda_R^S & \lambda_R^S x_1^S & \cdots & \lambda_R^S x_n^S \end{bmatrix}}_W \underbrace{\begin{bmatrix} a_{10} \\ a_{11} \\ \vdots \\ a_{1n} \\ \vdots \\ a_{R0} \\ a_{R1} \\ \vdots \\ a_{Rn} \end{bmatrix}}_\theta \quad (\text{C1})$$

Avec  $W$  la matrice des entrées pondérées par les degrés d'activations (II.4),  $\theta$  le vecteur des paramètres conséquents (paramètres linéaires). D'après l'équation C1,  $Y$  est linéaire par rapport au  $\theta$ . La solution au problème d'ajustement des paramètres de  $\theta$  est ainsi la minimisation d'un critère linéaire des moindres carrés, de la façon suivante :

$$\theta = \arg \min_{\theta} \|Y - W\theta\|_2 = (W^T W)^{-1} Y^T W \quad (\text{C2})$$

Où  $T$  désigne la transposée d'une matrice.

## D Algorithme de Rétro-Propagation du gradient (RP)

L'algorithme de RP vise le calcul du gradient de l'erreur totale  $E$  (éq. II.6) afin de corriger les paramètres non-linéaires de l'ANFIS. Si  $k$  désigne l'itération de calcul en cours, nous avons :

$$\alpha_k - \alpha_{k-1} = \Delta\alpha = -\eta \times \nabla E = -\eta \times \frac{\partial E}{\partial \alpha} \quad (\text{D1})$$

Où  $\eta$  désigne le pas d'apprentissage,  $\alpha$  l'un des paramètres non-linéaires ( $x_l^{j*}, \sigma_l^j$ ) à ajuster,  $\frac{\partial E}{\partial \alpha}$  la composante du gradient de l'erreur de prédiction inhérente au paramètre  $\alpha$ .

La fonction de coût classique est la fonction d'erreur quadratique :

$$E^k = (y^k - \sum_{i=1}^R (\lambda_i^k x_e^{Tk} \pi_i))^2 \quad (\text{D2})$$

Par suite, on calcule le gradient de l'erreur pour le nœud de sortie II.6 :

$$\frac{\partial E}{\partial S n_{1,5}} = -2 \times (y^k - S n_{5,1}) \quad (\text{D3})$$

Pour chacun des nœuds des couches 1 à 4, nous obtenons le gradient de l'erreur par récursivité :

$$\frac{\partial E}{\partial S n_{u,v}} = \sum_{(v+1,b) \in \text{Succ}(u,v)} \left( \frac{\partial E^k}{\partial S n_{b,v+1}} \times \frac{\partial S n_{b,v+1}}{\partial S n_{u,v+1}} \right) \quad (\text{D4})$$

Où  $\text{Succ}(u, v)$  désigne l'ensemble des nœuds successeurs du nœud  $(u, v)$ .

A ce stade, l'apprentissage porte sur la minimisation du gradient de l'erreur par rapport aux paramètres à modifier. Ceci implique, pour chaque nœud et pour l'ensemble des paramètres  $\alpha$ , le calcul du gradient partiel suivant :

$$\frac{\partial E^k}{\partial \alpha} = \frac{\partial E^k}{\partial S n_{u,v}} \times \frac{\partial S n_{u,v}}{\partial \alpha} \quad (\text{D5})$$

Le principe précédent peut ensuite être étendu à l'erreur totale (nécessaire pour l'équation D1). Cette erreur totale est obtenue en considérant l'ensemble des données d'apprentissage :

$$E = \sum_{k=1}^S E^k \quad (\text{D6})$$

et chaque composante  $(\frac{\partial E}{\partial \alpha})$  du gradient total  $(\nabla E)$  peut être ainsi déterminé :

$$\frac{\partial E}{\partial \alpha} = \sum_{k=1}^S \left( \frac{\partial E^k}{\partial \alpha} \right) \quad (\text{D7})$$

En conséquent, cet algorithme est capable d'ajuster les paramètres prémisses.

## E Méthode de «Subtractive Clustering» (SC)

Dans la base de données (entrées/sortie,  $Z^k = \{X^k, y^k\}, k = 1, \dots, S$ ) l'algorithme décèle les points autour desquels il y a concentration de données. A chaque observation  $Z^k$  un potentiel  $P^k$  en fonction de sa distance par rapport aux autres observations peut être déterminé :

$$P^k = \frac{1}{S} \sum_{g=1}^S \exp^{-\frac{4}{r_a^2} \|Z^k - Z^g\|^2}; k = 1, \dots, S \quad (\text{E1})$$

où :

- $\|\cdot\|$  est la distance euclidienne,
- $r_a$  est une constante positive appelée rayon du groupe.

La valeur du potentiel d'un point est d'autant plus élevée qu'il y a de données dans son voisinage. Désignant par  $P_1^*$  le potentiel le plus élevée correspondant au premier centre  $c_1 = Z^{k^*}$ , les potentiels de tous les autres points sont réévalués en excluant l'influence de  $c_1$  :

$$P_2^k = P_1^k - P_1^* \exp^{-\frac{4}{r_b^2} \|c_1 - Z^k\|^2}; k = 1, \dots, S \quad (\text{E2})$$

Où le  $r_b$  est une constante positive qui définit le voisinage (distance minimale entre deux groupes) :  $r_b = Jr_a$ ,  $J$  une constante positive appelée «squach factor». On détermine ensuite le point de plus grand potentiel  $P_2^*$  parmi les  $P^k$  recalculés par l'expression E2. Ce point est accepté comme centre ( $c_2$ ) si l'une des conditions suivantes est vérifiée :

$$P_2^* > \varepsilon_{\text{sup}} P_1^* \quad (\text{E3})$$

$$\frac{d_{\text{min}}}{r_a} + \frac{P_2^*}{P_1^*} > 1 \quad (\text{E4})$$

Où  $\varepsilon_{\text{sup}}$  est une constante positive appelée «accept ratio» et  $d_{\text{min}}$  est la distance minimale entre le centre  $c_2$  et tous les autres centres trouvés (à cette étape,  $c_1$  seul). Les autres centres sont obtenus par itération de l'algorithme. A l'itération  $g$ , les potentiels des points sont réévalués par l'expression :

$$P_g^k = P_{g-1}^k - P_{g-1}^* \exp^{-\frac{4}{r_b^2} \|c_{g-1} - Z^k\|^2}; k = 1, \dots, S \quad (\text{E5})$$

Si le point de potentiel maximal  $P_g^*$  ne vérifie aucune des conditions (E3, E4),  $P_g^*$  est fixé à 0 et le point de plus grand potentiel est sélectionné parmi les points restants.

Ces étapes sont itérées jusqu'à ce que la condition suivante soit vérifiée :

$$P_m^* \geq \varepsilon_{\text{inf}} P_1^* \quad (\text{E6})$$

Où  $\varepsilon_{\text{inf}}$  est une constante positive appelée «reject ratio».

---

**Algorithm 3:** Subtractive Clustering
 

---

**Initialisation :**  $r_a, J, \varepsilon_{\text{sup}}, \varepsilon_{\text{inf}}$ 
**Pour**  $g = 1$  à  $S$  **faire**

 Initialiser le potentiel  $P^k$  de  $Z^k$  par l'équation :

$$P^k = \frac{1}{S} \sum_{g=1}^S \exp^{-\frac{4}{r_a^2} \|Z^k - Z^g\|^2}$$

 Accepter  $Z_1^*$  comme centre tel que  $P_1^* = \max_g(P_1^*)$ 
 $l=1$  // compteur de centre de groupes

 $P_m^* = P_1^*$ 
**Tant que**  $P_m^* \geq \varepsilon_{\text{inf}} P_1^*$  **faire**

 Incrémenter  $l$ 
**Pour**  $k = 1$  à  $S$  **faire**

 Mettre à jour le potentiel  $P_k$  de  $Z^k$  en excluant l'influence du point de potentiel le plus élevé ( $P_{l-1}^*$ )

$$P_k = P_{k-1} - P_{l-1}^* \exp^{-\frac{4}{r_b^2} \|Z_{l-1}^* - Z^k\|^2}$$

 Poser  $P_m^* = \max_k(P_k)$ 

 Tester si le point  $Z^h$  de potentiel  $P_m^*$  est un centre : calculer la plus petite des distances entre  $Z^h$  et tous les autres centres trouvés précédemment :

$$d_{\text{min}} = \min_{b=1, \dots, l-1} \|Z^h - Z_b^*\|$$

**Si**  $P_m^* > \varepsilon_{\text{sup}} P_1^*$  **ou**  $\frac{d_{\text{min}}}{r_a} + \frac{P_m^*}{P_1^*}$  **alors**

 Accepter  $Z^h$  comme centre :  $Z_l^* = Z^h, P_l^* = P_m^*$ 
**Sinon**

 Rejeter  $Z^h$  :  $P^h = 0, P_l^* = P_{l-1}^*$ 


---



# Bibliographie

- [AC92] J. S. ARMSTRONG et F. COLLOPY : Error measures for generalizing about forecasting methods : Empirical comparisons. *International Journal of Forecasting*, 8:69–80, 1992. 68
- [AF03] P. ANGELOV et D. FILEV : On-line design of takagi-sugeno models. In *Lecture Notes in Computer Science 2715 : Proc. of the 10th Intern. Fuzzy Syst. Asso. World Congress : ISFA*, 2003. 49, 52
- [AF04] P. ANGELOV et D.P. FILEV : An approach to online identification of takagi-sugeno fuzzy models. *IEEE Trans. on Syst. Man ad Cybern. - Part B : Cybernetics*, 34:484–498, 2004. 41
- [Aka74] H. AKAIKE : A new look at the statistical model identification. *IEEE Transaction Automatic Control*, 19:716–723, 1974. 64
- [Ald07] R. P. ALDACO : *A model based framework for fault diagnosis and prognosis of dynamical systems with an application to helicopter transmissions*. Thèse de doctorat, Georgia Institute of Technology, 2007. 13
- [Ang02] P. P. ANGELOV : *Evolving Rule-Based Models, A tool for Design of Flexible Adaptive Systems*. Physica-Verlag, A Springer- Verlag Company, 2002. 46, 48, 49, 50
- [ATP02] M. AZAM, F. TU et K. R. PATTIPATI : Condition based prédictive maintenance of industrial power systems. In *Conférence on Fault Diagnosis, Prognosis and System Health Management, Orlando*, 2002. 25
- [AZ06] P. ANGELOV et X.W. ZHOU : Evolving fuzzy systems from data streams in real-time. In *Proceedings of the Int. Symposium on Evolving Fuzzy Systems, UK*, pages 26–32. IEEE Press, 2006. 48, 52, 56, 102
- [Ben04] M. BENGTTSSON : *Condition based maintenance Systems an investigation of technical constituents and organization aspects*. Thèse de doctorat, Department of Innovation, Design, and Product Development Mälardalen University, 2004. 8, 9
- [Bez81] J. BEZDEK : Pattern recognition with fuzzy objective function algorithms. In *In Plenum Press, USA*, 1981. 46

- [BR98] R. BABUSKA et A.J. ROUBOSVERBRUGGEN : Identification of mimo systems by input-output ts models. *IEEE International Conference on Fuzzy Systems, Anchorage, USA*, 1:657–662, 1998. 109
- [BRKG02] C. BYINGTON, M. ROEMER, G. KACPRZYNSKI et T. GALIE : Prognostic enchainement to diagnostic systems for improved condition based-maintenance. *In IEEE Aerospace conference, Big Sky, USA*, 2002. 15
- [BT03] P. BORTOLET et A. TITLI : *Modélisation floue : approche structurale, Commande floue 2 de l'approximation à l'apprentissage*. Série Systèmes Automatisés - Traité IC2, Hermès Science Publications, 2003. 39
- [CA82] R. CARBONE et J. S. ARMSTRONG : Evaluation of extrapolative forecasting methods : Results of a survey of academicians and practitioners. *Journal of Forecasting*, 1:215–217, 1982. 68
- [CB04] R. B. CHINNAM et P. BARUAH : A neuro-fuzzy approach for estimating mean residual life in condition-based maintenance systems. *International Journal of Materials and Product Technology*, 20, 2004. 13
- [CC03] D. CHELIDZE et J. P. CUSUMANO : A dynamical systems approach to failure prognosis. *Journal of Vibration and Acoustics*, 126:2–8, 2003. 23
- [Chi94] S.L. CHIU : Fuzzy model identification based on cluster estimation. *Intell. Fuzzy Sets*, 2:267278, 1994. 46
- [CLOP04] C. CLAROTTI, A. LANNOY, S. ODIN et H. PROCACCIA : Detection of equipment aging and détermination of the efficiency of a corrective measure. *Reliability Engineering and System Safety*, 84:57–64, 2004. 27
- [DaRS98] D. DUBOIS et H. Prade abd R. SABBADIN : Qualitative decision theory with sugeno integrals. *In 14eme Conf. Uncertainty in Artificial Intelligence (UAI'98), Madison, Morgan Kaufmann*, 1998. 41
- [DGZ08] O. E. DRAGOMIR, R. GOURIVEAU et N. ZERHOUNI : Adaptive neuro-fuzzy inference system for mid term prognostic error stabilization. *International Journal of Computers, Communications and Control*, 3:271–276, 2008. 16
- [DLN03] D. DJURDJANOVIC, J. LEE et J. Ni : Watchdog agent, an infotronics-based prognostics approach for product performance degradation assessment and prediction. *Engineering Informatics*, 17(3-4):109–125, 2003. 13
- [DMS<sup>+</sup>02] G. DREYFUS, J.M. MARTINEZ, M. SAMUELIDES, M. B. GORDON, F. BADRAN, S. THIRIA et L. HÉRAULT : *Réseaux de neurones (Méthodologie et application)*. 2002. 112, 117
- [EUR01] UNION EUROPPIENNES : Recommandation de la commission du 30 mai 2001 concernant la prise en considération des aspects environnementaux dans les comptes et rapports annuels des sociétés : inscription comptable, évaluation et publication d'informations. *Journal officiel des Communautés européennes*, 2001. 7
- [EVW05] J. ESPINOSA, J. VANDEWALLE et V. WERTZ : *Fuzzy Logic, Identification and Predictive Control*. British Library Cataloguing, 2005. 46

- [Fre01] D.C. FRECHTLING : *Forecasting Tourism Demand (methods and strategies)*. Butterworth Heinemann, British Library Cataloguing In Publication Data, 2001. 34
- [Gal01] S. GALICHTET : Contrôle flou : de l'interpolation numérique au codage de l'expertise. *In Habilitation à Diriger des Recherches, Laboratoire LAMII, Université de Savoie, Annecy, France*, 2001. 109
- [GB05] K GOEBEL et P. BONISSONE : Prognostics information fusion for constant load systems. *In In : Proc 7th annual Conference on Fusion, vol. 2, pp. 1247-1255.*, 2005. 18
- [GH06] J. G. GOOIJER et Rob J. HYNDMAN : 25 years of time series forecasting. *International Journal of Forecasting (Elsevier)*, 443 473:22, 2006. 69
- [GK79] D. GUSTAFSON et W. KESSEL : Fuzzy clustering with a fuzzy covariance matrix. *In In Proceedings of IEEE CDC, San Diego, CA, USA*, 1979. 46
- [GKZ07] R. GOURIVEAU, M. E. KOUJOK et N. ZERHOUNI : Spécification d'un système neuro-flou de prédiction de défaillances à moyen terme. *In In. : LFA, Nîmes, France*, 2007. 38
- [GM95] C. GOURIÉROUX et A. MONFORT : *Séries temporelles et modèles dynamiques*. Économie et statistiques avancées., 1995. 89
- [Gol89] D.E. GOLDBERG : Genetic algorithms in search, optimization and machine learning. *In Addison Wesley, USA*, 1989. 46
- [GP02] F. GREITZER et A. PAWLOWSKI : Embedded prognostics health monitoring. *In Instrumentations, Systems, and Automation Society International Instrumentation Symposium, San Diego, USA.*, 2002. 25
- [Hai09] ftp://ftp.esat.kuleuven.ac.be/sista/data/mechanical. 2009. 74
- [HK06] R. J. HYNDMAN et A. B. KOEHLER : Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22:679–688, 2006. 68
- [HM09] A. HENG et S. Zhang A. Tan J. MATWEW : Rotating machinery prognostic : State of the art, challenges and opportunities. *Mechanical Systems and Signal Processing*, 23:724–739, 2009. 20
- [HPS01] H.S. HIPPERT, C.E. PEDREIRA et R.C. SOUZA : Neural network for short term load forecasting : A review and evaluation. *IEEE Transaction on Power Systems*, 16:44–55, 2001. 39
- [HS03] P.L. HALL et J. E. STRUTT : Probabilistic physics-of-failure models for component reliabilities using monte carlo simulation and weibull analysis : a parametric study. *Reliability Engineering and System Safety*, 80:233–242, 2003. 23
- [ISO04] ISO : *Norme ISO 13381-1 : Surveillance et diagnostic des machines :Prognostic*. 2004. 16
- [JB04] A. JARDINE et D. BANJEVIC : Interprétation of inspection data emanating from equipment condition monitoring tools : Method and software. *In*

- Fourth International Conférence on Mathematical Methods in Reliability Methodology and Practice. Santa Fe, USA, 2004.* 27
- [JLA<sup>+</sup>03] W.F.C. JAMES, D.A. LINKENS, M.F. ABBOD, M. CHEN, J.L. BURTON and K. FEELEY et F.C. HAMDY : Artificial intelligence in predicting bladder cancer outcome : A comparison of neuro-fuzzy and artificial neural networks. *Clinical Cancer Research*, 9:4172–4177, 2003. 70
- [JLB06] A.K.S. JARDINE, D. LIN et D. BANJEVIC : A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mech. Syst. and Sign. Proc.*, 20:1483–1510, 2006. 15, 19
- [JS95] J.S.R. JANG et C.T. SUNL : Neuro-fuzzy modeling and contro. *IEEE Proceedings*, 83:378–406, 1995. 44, 70
- [KGZ08a] M. E. KOUJOK, R. GOURIVEAU et N. ZERHOUNI : Development of a prognostic tool to perform reliability analysis. *In European Safety and Reliability and Risk Analysis Conference, ESREL'08', 17th SRA-EUROPE, Valence, Espagne, 2008.* 70
- [KGZ08b] M. E. KOUJOK, R. GOURIVEAU et N. ZERHOUNI : From monitoring data to remaining useful life : an evolving approach including uncertainty. *In 34th ESReDA European Safety Reliability Data Association Seminar and 2nd Joint ESReDA/ESRA Seminar on Supporting Technologies for Advanced Maintenance Information Management, Saint-Sebastian, Espagne, 2008.* 88
- [KGZ08c] M. E. KOUJOK, R. GOURIVEAU et N. ZERHOUNI : Towards a neuro-fuzzy system for time series forecasting in maintenance applications. *In 17th IFAC World Congress, seoul Korée, 2008.* 70
- [KGZ09] M. E. KOUJOK, R. GOURIVEAU et N. ZERHOUNI : Error estimation of a neuro-fuzzy predictor for prognostic purpose. *In 7th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes SAFE-PROCESS '09', Barcelone, Espagne, 2009.* 83
- [KGZ10a] M. E. KOUJOK, R. GOURIVEAU et N. ZERHOUNI : A neuro-fuzzy self built system for prognostics : a way to ensure good prediction accuracy by balancing complexity and generalization. *In IEEE Prognostics and System Health Management Conference (PHM), Macau, Chine, 2010.* 62
- [KGZ10b] M. E. KOUJOK, R. GOURIVEAU et N. ZERHOUNI : Reducing arbitrary choices in model building for prognostics : an approach by applying parsimony principle on an evolving neuro-fuzzy system. *Microelectronics Reliability Journal, Available online 12 october 2010, DOI 10.1016/j.microrel.2010.09.014, 2010.* 66
- [KMCZ09] M. H. KARRAY, B. MORELLO-CHEBEL et N. ZERHOUNI : Towards a maintenance semantic architecture. *In The Fourth World Congress on Engineering Asset Management (WCEAM 2009) Athens, 2009.* 9

- [KPM02] G.J. KACPRZYNSKI, M. J. Roemer G. A. Modgil A. PALLADINO et K. MAYNARD : Enhancement of physicsof- failure prognostic models with system level features. *In IEEE Aerospace Conference, Big Sky, USA.*, 2002. 23
- [LBZ<sup>+</sup>99] Y. LI, S. BILLINGTON, C. ZHANG, T. KURFESS, S. DANYLUK et S. LIANG : Adaptive prognostics for rolling element bearing condition. *Mechanical Systems and Signal Processing*, 13:103–113, 1999. 23
- [LKL00] Y. LI, T. R. KURFESS et S. Y. LIANG : Stochastic prognostics for rolling element bearing. *Mechanical Systems and Signal Processing*, 14:747–762, 2000. 23
- [LM03] D. LIN et V. MAKIS : Recursive lters for a partially observable system subject to random failure. *Advances in Applied Probability*, 207-227:35, 2003. 15
- [LNP<sup>+</sup>] J. LUO, M. NAMBURU, K. PATTIPATI, L. QIAO, M. KAWAMOTO et S. CHIGUSA : Model-based prognostic techniques. AUTOTESTCON 2003, California, USA. 23
- [LPQC03] J. LUO, K. R. PATTIPATI, L. QIAO et S. CHIGUSA : Model-based prognostic techniques applied to a suspension system. *IEEE Transactions on Systems, Man, and Cybernetics, Part A*, 38(5):1156–1168, 2003. 24
- [LRB03] M. LEBOLD, K. REICHARD et D. BOYLAN : Utilizing dcom in an open system architecture framework for machinery monitoring and diagnostics. *In Aerospace Conference Proceedings*, 2003. 14
- [LT01] M. LEBOLD et M. THURSTON : Open standards for condition-based maintenance and prognostic systems. *In 5th Annual Maintenance and Reliability Conference (MARCON 2001), Gatlinburg, USA*, 2001. 13, 14, 19, 20, 101
- [LW01] G. LEE et J. S. WANG : Efficient neuro-fuzzy control systems for autonomous. Rapport technique, 2001. 40
- [MCP<sup>+</sup>01] A. MATHUR, K. CAVANAUGH, K. PATTIPATI, P. WILLET et T. GALIE : Reasoning and modeling systems in diagnosis and prognosis. *In SPIE Aerosense Conference, Orlando, USA.*, 2001. 15
- [ME98] W.Q MEEKER et L.A ESCOBAR : Statistical methods for reliability data. wiley series in probability and statistics. *Wiley series in probability and statistics, John Wiley & sons*, 1998. 23, 30
- [MF06] C. MAHABIR et F. Hicks F.R. FAYEK : Neuro-fuzzy river ice breakup forecasting system. *Cold regions science and technology*, 46:100–112, 2006. 40, 70
- [Mij03] V. MIJAILOVIC : Probabilistic method for planning of maintenance activities of substation components. *Electric Power Systems Research*, 64:53–58, 2003. 27

- [ML95] W.Q. MEEKER et M.J. LUVALLE : An accelerated life test model based on reliability kinetics. *Technometrics*, 37:2, 1995. 94
- [MSI03] A. MULLER, M. C. SUHNER et B. IUNG : Développement dun processus de pronostic par combinaison d'approches probabilistes et événementielles. *In Journées Doctorales d'Automatique (JDA'03), Valenciennes, France, 2003.* 15
- [MZ09] K. MEDJAHER et R. Gouriveau N. ZERHOUNI : A procedure for failure prognostic in dynamic systems. *In 13th IFAC Symposium on Information Control Problems in Manufacturing, INCOM'09, 2009.* 12
- [NFE01] NFEN : *Norme X60-319/NF EN 13306 Terminologie de la maintenance.* 2001. 6, 9, 10, 11
- [NK97] D. NAUCK et R. KRUSE : *What are Neuro-Fuzzy Classifiers ?* Thèse de doctorat, University of Madenburg, 1997. 40
- [NK99] D. NAUCK et R. KRUSE : Neuro-fuzzy systems for function approximation. *Fuzzy Sets and Systems*, 101:261–271, 1999. 68
- [NK04] J.M. Van NOORTWIJK et H. E. KLATTER : The use of lifetime distributions in bridge maintenance and replacement modelling. *Computers and Structures*, 82:1091–1099, 2004. 27
- [Orc07] M. E. ORCHARD : *A Particule Filtering-Based Framework For On-Line Fault Diagnosis And Failure Prognosis.* Thèse de doctorat, Georgia Institute of Technology, 2007. 13
- [PLR95] W. PEDRYCZ, P. LAM et A. F. ROCHA : Distributed fuzzy modelling. *IEEE Trans. on Systems, Man and Cybernetics-B*, 5:769–780, 1995. 40
- [PP05] A. K. PALIT et D. POPOVIC : *Computational Intelligence in Time Series Forecasting, Theory and Engineering Applications.* Springer, 2005. 36, 37
- [Rac06] D. RACOCEANU : *Contribution à la surveillance des Systèmes de Production en utilisant les Techniques de l'Intelligence Artificielle.* Thèse de doctorat, Habilitation à Diriger des Recherches, Université de Franche Comté, Besançon, 2006. 40
- [Ram04] G. RAMOS : Mathematics modeling of the behavior in operation of induced draft fans for 350-mw fossil power units to predict its optimum maintenance time. *Electric Power Systems Research*, 70:109–113, 2004. 27
- [Ras06] I. RASOVSKA : *Contribution à une méthodologie de capitalisation des connaissances basée sur le raisonnement à partir de cas : Application au diagnostic dans une plateforme de-maintenance.* Thèse de doctorat, Laboratoire d'Automatique de Besançon (LAB-CNRS), Université de Franche-Comté, juillet 2006. 9
- [Ray99] A. RAY : Stochastic modeling of fatigue crack damage for risk analysis and remaining life prediction. *Journal of Dynamic Systems, Measurement, and Control (ASME)*, 121:386–393, 1999. 23

- [RBKV05] M. ROEMER, C. BYINGTON, J. KACPRZYNSKI et G. VACHTSEVANOS : An overview of selected prognostic technologies with reference to an integrated phm architecture. *In Proc the IEEE Int Conf Aerospace*, 2005. 21, 27
- [Rey03] E. REYNAUD : Développement durable et entreprise : vers une solution symbiotique? *In Journée AIMS, Atelier Développement durable, Angers*, 2003. 7, 8
- [RG94] D.H. RAOA et M.M. GUPTA : Neuro-fuzzy controller for control and robotics applications. *Engineering Applications of Artificial Intelligence*, 7:479–491, 1994. 40
- [Rib09] P. RIBOT : *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, 2009. 29
- [Rid05] T. RIDHA : A propos de l'utilisation de l'intelligence artificielle en finance : Aperçu de quelques techniques. *In Les Fondements structurels et fonctionnels dun SNIE*, 2005. 37
- [SSR03] A. SCHÖMIG, O. ROSE SCHÖMIG et O. ROSE : On the suitability of the weibull distribution for the approximation of machine failures. *In Proceedings of the 2003 Industrial Engineering Research Conference, Portland OR*, 2003. 26
- [Tar05] V. TARARYKINE : *Modélisation des Flux d'Information dans un Système de E-maintenance*. Thèse de doctorat, Laboratoire d'Automatique de Besançon (LAB-CNRS) Université de Franche-Comté, Novembre 2005. 8
- [Vil88] A. VILLEMEUR : *Sûreté de fonction des systèmes industriels (Fiabilité-Facterus humains informatisation)*. 1988. 83
- [VLR<sup>+</sup>06] G. VACHTSEVANOS, F. L. LEWIS, M. ROEN, A. HESS et R. WU : Intelligent fault diagnosis and prognosis for engineering system. *In Wileyand Sons Inc, Hoboken, New Jersey USA*, 2006. 16, 17
- [VSU98] D.S.J. VEAUX, J. SCHWEINSBERG et J. UNGAR : Prediction intervals for neural networks via nonlinear regression. *Technometrics*, 40:273–282, 1998. 25
- [VW01] G. VACHTSEVANOS et P. WANG : Fault prognosis using dynamic wavelet neural networks. *In In proceedings from the IEEE System Readiness Technology Conference, Autotestcon Proceedings, Valley Forge, PA, USA*, 2001. 13
- [Wan94] L.X. WANG : Adaptive fuzzy systems and control. *In Analysis. Prentice Hall, New Jersey*, 1994. 108
- [WGI03] W. WANG, F. GOLNARAGHI et F. ISMAIL : A robust prognostic system for real-time industrial applications. *In International Conférence on Industrial Automation, Montréal, Canada.*, 2003. 25

- [WGI04] W.Q. WANG, M.F. GOLDNARAGHI et F. ISMAIL : Prognosis of machine health condition using neuro-fuzzy systems. *Mechanical Systems and Signal Processing*, 18:813–831, 2004. 26, 40, 70
- [WV99] P. WANG et G. VACHTSEVANOS : Fault prognosis using dynamic wavelet neural networks. *In Maintenance And Reliability Conference (MARCON 99), Gatlinburg, USA, 1999.* 15, 26
- [WYKL02] X. WANG, G. YU, M. KOÇ et J. LEE : Wavelet neural network for machining performance assessment and its implications to machinery prognostics. *In Managing Innovative Manufacturing "e-Manufacturing and e-Business Intégration"(MIM'2002), Milwaukee, USA, 2002.* 25
- [YLK02] T. YAN, T. LEE et M. KOÇ : Prédicative algorithm for machine dégradation détection using logistic régression. *In Managing Innovative Manufacturing "e-Manufacturing and e-Business Intégration"(MIM'2002), Milwaukee, USA, 2002.* 25
- [YTTL01] R.C.M. YAM, P.W. TSE, L. LI et P. TU : Intelligent predictive decision support system for condition-based maintenance. *International Journal of Advanced Manufacturing Technology*, 17:383–391, 2001. 38, 39
- [Zad65] L. ZADEH : Fuzzy sets. *Inf. Control*, 8:338–353, 1965. 39
- [Zad73] L. ZADEH : Outline of a new approach to the analysis of complex systems and decision processes. *IEEE Trans. on Systems, Man, and Cybernetics*, 1:28–44, 1973. 39
- [ZEM03] M. ZEMOURI : *Contribution à la surveillance des systèmes de production à laide des réseaux de neurones dynamiques : Application à la e-maintenance.* Thèse de doctorat, Laboratoire d'Automatique de Besançon (LAB-CNRS), Université de Franche-Comté, 2003. 112, 113, 117
- [ZPH98] G. ZHANG, B.E. PATUWO et M.Y. HU : Forecasting with artificial neural networks : the state of the art. *International Journal of Forecasting*, 14:35–62, 1998. 38
- [ZRZ06] R. ZEMOURI, D. RACOCEANU et N. ZERHOUNI : Recurrent radial basis function network for time-series prediction, engineering applications of artificial intelligence. *The International Journal of Intelligent Real-Time Automation, journal IFAC - the, International Federation of Automatic Control, Ed. Elsevier Science*, 16:453–463, 2006. 25
- [ZS95] X. ZENG et M. SINGH : Approximation theory of fuzzy systems mimo case. *IEEE Trans. on Fuzzy Systems*, 3:219–23, 1995. 108
- [Zwi99] G. ZWINGELSTEIN : Sûreté de fonctionnement des systèmes industriels complexes. Rapport technique, Techniques de l'Ingénieur, traité Informatique industrielle, S8250, 1999. 30



## Résumé

Le pronostic industriel est aujourd'hui reconnu comme un processus clef pour renforcer la sûreté de fonctionnement des matériels tout en réduisant les coûts de maintenance. Cependant, il est difficile de construire un outil de pronostic efficace, prenant en compte l'incertitude inhérente aux processus de défaillance mal appréhendés. L'objet de cette thèse est de proposer un système de pronostic qui, partant des données capteurs, permette de générer les indicateurs utiles à l'optimisation des stratégies de maintenance. Le travail vise en outre à pallier certains problèmes inhérents au manque de connaissance sur les phénomènes de dégradation (quantité de données, expertise dans la construction d'un modèle).

Les développements sont fondés sur l'utilisation du système neuro-flou évolutif exTS comme outil permettant de prédire la dégradation d'un bien. Une procédure de sélection automatique des entrées du système prédictif est proposée. L'approche est basée sur le principe de parcimonie. Elle permet de déterminer la structure du réseau neuro-flou en regard d'exigences de performance de prédiction. Une méthode d'estimation *a priori* de la distribution des erreurs de prédiction du système neuro-flou, ainsi que de propagation de cette erreur pour tout horizon est ensuite proposée et illustrée. Cette contribution permet d'intégrer la confiance au processus de pronostic. Enfin, les mécanismes d'évaluation de la fiabilité d'un bien sont adaptés au cas prédictif afin de générer les métriques de pronostic permettant d'optimiser les stratégies de maintenance, notamment le temps résiduel avant défaillance (Remaining Useful Life - *RUL*).

**Mots-clés :** maintenance prévisionnelle, pronostic, système neuro-flou évolutif, erreur de prédiction, intervalle de confiance.

## Abstract

Industrial prognostic is nowadays recognized as a key feature to reinforce the dependability of equipments while reducing maintenance costs. However, it can be difficult to implement an efficient prognostic tool since the lack of knowledge on the behaviour of an equipment can impede the development of classical dependability analysis. In this context, the general purpose of the work is to propose a prognostic system that starts from monitoring data and goes through useful indicators to optimize maintenance strategies. The work also aims at mitigating some problems that follow from the lack of knowledge on the degradation phenomena (amount of data, expertise in building a model).

Developments are based on the use of the neuro-fuzzy system exTS as a tool to predict the state of degradation of an equipment. Its structure is partially determined, on one side, thanks to its evolving capability, and on the other side, thanks to parsimony principle : a procedure to automatically generate an accurate exTS prediction system that reaches a compromise between complexity and generalization capability is proposed. Following that, a method to firstly, *a priori* estimate the probability density function (pdf) of the error of prediction of the neuro-fuzzy system, and secondly propagate it to any prediction step, is also proposed and illustrated. This contribution enables to provide a confidence measure on predictions and thereby to integrate uncertainty to the prognostic process. Finally, mechanisms of reliability evaluation are adapted to the predictive case in order to generate the prognostic metrics that allows optimizing maintenance strategies, notably the Remaining Useful Life (*RUL*).

**Keywords :** predictive maintenance, prognostic, evolving neuro-fuzzy system, error of prediction, interval of prediction.