



HAL
open science

Spécification d'un système neuro-flou de prédiction de défaillances à moyen terme.

Rafaël Gouriveau, Mohamed El Koujok, Nouredine Zerhouni

► To cite this version:

Rafaël 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., Nov 2007, Nîmes, France. pp.65-72. hal-00192060

HAL Id: hal-00192060

<https://hal.science/hal-00192060>

Submitted on 26 Nov 2007

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

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

Spécification d'un système neuro-flou de prédiction de défaillances à moyen terme

Specification of a neuro-fuzzy system for a mid-term failure prediction

GOURIVEAU Rafael EL-KOUJOK Mohamed ZERHOUNI Nouredine
Ecole Nationale Supérieure de Mécanique et des Microtechniques de Besançon
Laboratoire d'Automatique de Besançon

ENSMM - LAB, 24 rue Alain Savary, 25000 Besançon, {rgourive, mohamed.elkoujok, zerhouni}@ens2m.fr

Résumé :

Le travail rapporté ici vise la définition d'un outil de pronostic de défaillances capable d'approximer et de prédire la dégradation d'un équipement. Nous proposons pour cela l'utilisation d'un système neuro-flou basé sur le modèle ANFIS ; le modèle classique ANFIS est modifié afin de réaliser des prédictions temporelles qui soient, d'une part, précises à court terme, et d'autre part, relativement fiables à moyen terme.

Mots-clés :

Maintenance, pronostic, prédiction, série temporelle, système neuro-flou, ANFIS, sélection d'entrées.

Abstract:

The work reported here aims at defining a failure prognostic tool that is able to approximate and predict the degradation of an equipment. In this way, a neuro-fuzzy system for failure prediction based on the ANFIS model is proposed; the classical ANFIS model is modified in order to perform short term accurate and mid-term reliable predictions.

Keywords:

Maintenance, prognostic, forecasting, time series, neuro-fuzzy system, ANFIS, input selection.

1 Introduction

Le maintien en condition opérationnelle des systèmes industriels à moindre coût est devenu un facteur critique quant à la performance des entreprises. Les concepts traditionnels de maintenance préventive et corrective sont peu à peu supplantés par une prise en compte plus réactive et proactive des défaillances [7], [14]. Aussi, le pronostic se révèle être une activité tout à fait prometteuse pour ne pas engager de frais de maintenance inopportuns.

Ceci étant, relativement à la spécification d'un outil de pronostic, un problème central peut être soulevé : l'utilité d'un tel système est intimement liée à sa faculté à approximer et à prédire la dégradation d'un équipement. En d'autres termes, un outil de pronostic doit être à même de projeter dans le temps une situation courante. De ce point de vue, beaucoup de développements visant la proposition d'outils de prévision existent dans la littérature [4]. Cependant, dans la pratique, le choix d'une technique est fortement contraint : connaissance disponible (modèle, expériences passées...), dynamique de l'équipement (linéarité, périodicité...), critères décisionnels (précision, raisonnement...), implémentation réelle (flexibilité, complexité, temps de calcul...).

Ainsi, l'objet de ce papier est de dégager un type d'outil intéressant pour supporter l'activité de pronostic, et d'en étudier l'applicabilité. Pour cela, nous posons globalement le cadre de nos travaux : maintenance, pronostic et outils supports (section 2). Nous décrivons ensuite l'évolution de l'utilisation des techniques de prévisions basées sur l'intelligence artificielle (section 3). Une classe d'outils émerge de cette analyse : les systèmes neuro-flous. Nous étudions ainsi plus particulièrement le système ANFIS (section 4) et nous proposons de modifier ce modèle afin d'assurer des prévisions précises à moyen terme. Nous illustrons l'ensemble sur un exemple académique.

2 Du processus de pronostic au choix d'un outil de prédiction

2.1 Emergence du pronostic dans les stratégies de maintenance

L'activité de maintenance fait 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). Ceci étant, 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. C'est ce qui peut être entendu sous l'étiquette "pronostic de défaillances". Aussi, cette thématique devient un cadre de travaux de recherche de premier plan [3], [10] et le "pronostic" est aujourd'hui considéré comme un processus clef dans les stratégies de maintenance. Cependant, le concept n'est pas tout à fait stabilisé...

2.2 Pronostic et prédiction

Dans la littérature, le "pronostic" désigne selon les cas un processus visant à déterminer la durée de vie restante d'un système [10] ou la probabilité pour que le système fonctionne durant un certain temps [12]. Ainsi, même s'il n'existe pas d'acceptation du terme "pronostic" totalement consensuelle, un trait marquant peut être identifié : il est souvent assimilé à un processus de prédiction (une situation future doit être appréhendée).

Le comité ISO définit le pronostic comme "l'estimation de la durée de fonctionnement avant défaillance d'un système et du risque d'existence ou d'apparition ultérieure d'un ou de plusieurs modes de défaillances" [6]. Plus généralement, les définitions du terme "pronostic" sont fondées sur les concepts de défaillance et de dégradation, ce qui laisse transparaître la notion d'acceptabilité. Aussi, le pronostic devrait être basé sur des critères d'évaluation dont les bornes dépendent du

système surveillé et d'objectifs de performance. Considérons la figure 1 : la situation "prédite" à " $t+dt$ " ne peut être considérée comme critique que par l'existence d'une limite de dégradation. Sans ce seuil, il est impossible de conclure quant à la gravité de la situation et donc, impossible de mettre en place une maintenance appropriée.

Finalement, nous décomposons le pronostic en deux sous-activité : une première visant à prédire l'évolution d'une situation dans le temps, et une seconde permettant d'évaluer la situation prédite relativement à un référentiel.

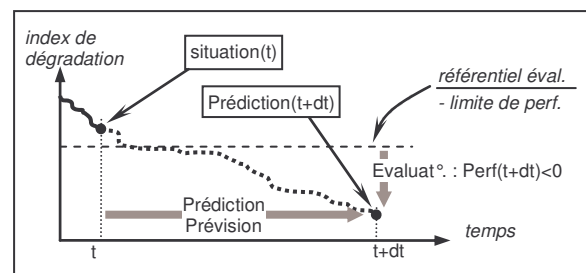


Figure 1 – Pronostic : prédiction et évaluation

Dans la pratique, tout ceci doit être supporté par des outils opérationnels. Ici, le caractère "évaluation" du pronostic n'est pas considéré et les développements ci-après portent sur l'activité de prédiction.

2.3 Outils de prédiction

Les auteurs parlent parfois d'outils de pronostic (cf. § 2.2). Les techniques présentées ci-après se réfèrent cependant à ce qui, dans ce papier, est libellé comme étant la "prédiction". Différentes techniques de "pronostic" ont été développées. Ces méthodes peuvent être associées à l'une des deux classes suivantes : les approches basées sur les modèles et les approches basées sur les données [1], [2].

Approches basées sur les modèles. Ce type de méthodes suppose la définition d'une relation mathématique permettant de prédire une situation à venir. Par exemple, les modèles physiques de fatigue sont largement employés pour représenter la naissance et la propagation d'anomalies structurelles dans les systèmes.

Le principal avantage des approches basées sur les modèles est leur capacité à intégrer des connaissances physiques de l'équipement. En revanche, elles présentent vite des limites si il est difficile voire impossible de saisir le comportement du système (non-linéarité...).

Approches basées sur les données. Ces approches 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. Dans la littérature, les techniques statistiques et les techniques de l'intelligence artificielle (IA) sont distinguées.

La force de ce type de méthode réside dans leur aptitude à apprendre (par les exemples) et à capturer les relations subtiles entre données, même si ces relations sont inconnues ou difficile à décrire.

Choix d'un outil de prédiction. Les systèmes réels sont complexes et de comportement généralement non-stationnaire et non-linéaire ce qui rend difficile une étape de modélisation. Pourtant, l'implémentation d'un outil de prédiction doit s'accommoder de cela et, conformément aux remarques précédentes, 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 de méthodes "conventionnelles" [16], [17] [18]. Dans l'ensemble, les réseaux adaptatifs sont particulièrement appropriés. La section suivante leur est consacrée.

3 Réseaux adaptatifs – vers un système neuro-flou de prédiction

3.1 Réseaux de neurones – une technique de prédiction éprouvée et adaptée

Les réseaux de neurones (RN) constituent un cas particuliers de réseaux adaptatifs. Ils ont eu un succès fort de part 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. Les RN présentent deux types d'architecture : les réseaux non bouclés et les réseaux bouclés ou récurrents. Ces deux types de RN ont été utilisés pour la prédiction temporelle mais il n'existe cependant pas de manière unique pour construire un RN adapté à cette problématique.

3.2 Des réseaux de neurones aux systèmes neuro-flous pour la prédiction

L'idée d'utiliser les RN 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 et nous en retraçons ci-après l'évolution (figure 2).

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 [18]. Par suite, les RN non bouclés associés à l'algorithme de rétro-propagation (introduit à cette époque) se montrèrent plus performants que les modèles classiques d'autorégression pour la prédiction de séries temporelles non linéaires [17].

Phase 2 : amélioration de l'apprentissage et du paramétrage des RN. Beaucoup de facteurs influent sur la performance des RN (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 des RN tout en diminuant la complexité des modèles et le temps de calcul. Ces travaux visent la recherche de "guides" pour l'optimisation des architectures des RN et des algorithmes d'apprentissage [5].

Phase 3 : les réseaux récurrents. Afin de prendre en compte de manière explicite le temps, les architectures de réseaux récurrents ont été développées et comparés aux autres techniques de prédiction de séries temporelles non linéaires. Les résultats montrent que ces RN présentent de meilleures performances que celles des méthodes classiques et plus encore, que celles des réseaux non bouclés [17].

Phase 4 : vers les systèmes neuro-flous. Les RN ont été utilisés avec succès pour supporter l'activité de prédiction. Cependant, certains auteurs restent sceptiques : 1) l'optimisation d'un RN est plus un art qu'une science, 2) les RN sont des boîtes noires et il n'est pas possible d'explicitement et d'analyser les relations entre entrées et sorties. Ainsi, afin de pallier cette faiblesse des RN (tout en préservant leur capacité d'apprentissage, voire en réduisant la complexité des modèles), des travaux insistent sur l'intérêt de systèmes combinant l'aspect connexionniste des RN à des techniques de raisonnement. Dans cet objectif, les systèmes neuro-flous sont particulièrement indiqués...

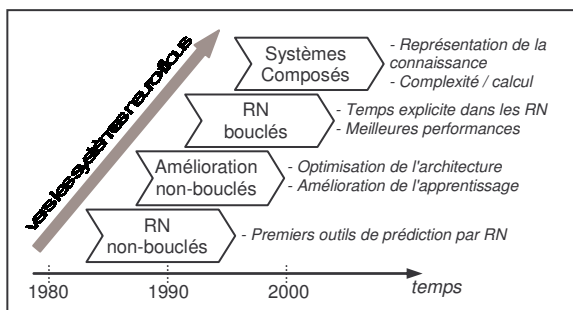


Figure 2 – Des RN pour la prédiction aux systèmes neuro-flous

3.3 Systèmes neuro-flous de prédiction

L'intérêt de construire des systèmes de prédiction intégrant les réseaux de neurones et les systèmes d'inférence floue (SIF) réside dans leurs caractéristiques complémentaires. Les SIF exploitent des règles linguistiques du type SI-ALORS traduisant une connaissance sur la dynamique d'un système. Etant donné une situation caractérisée à la date "t" (entrée), ils permettent ainsi d'en prédire l'évolution à

"t+r" (sortie). Cependant, un SIF n'est pas à même d'apprendre : les règles doivent être formulées ce qui est parfois difficile... Ainsi, une solution consiste à utiliser les propriétés des RN afin "d'apprendre" la structure floue et d'en adapter les paramètres en conséquence.

Des développements actuels sur de problèmes de prédiction de séries temporelles non linéaires montrent que les performances des NF dépassent celles d'autres méthodes aussi bien en terme de précision des résultats que d'efficacité d'apprentissage [16]. De plus, les règles d'un système NF sont transparentes, ce qui permet la validation et la manipulation par un expert [8]. Enfin, les systèmes NF sont très prometteurs dans les cas où les données disponibles sont limitées [13].

Enfin, les systèmes NF sont des outils adaptés pour supporter l'activité de prédiction du processus de pronostic. La section suivante est consacrée au système ANFIS (Adaptive Neuro Fuzzy Inference System).

4 ANFIS : vers un système de prédiction précis à moyen terme

4.1 Le système ANFIS : Adaptive Neuro Fuzzy Inference System

Principe. Considérons la figure 3 pour décrire le système ANFIS et brièvement expliquer les processus d'apprentissage et d'inférence. [9] et [17] en proposent une vision plus détaillée.

Le système ANFIS est une classe de réseau adaptatif introduit par [9]. Il peut être vu comme un réseau de neurones non bouclé pour lequel chaque couche est un composant d'un système neuro-flou. Le réseau ANFIS est composé de 5 couches, exception faite de la couche d'entrée. Si deux ensembles flous sont associés à chaque variable d'entrée (comme en figure 3), alors le système présente 16 règles d'inférence R_j (2^4). Ces inférences sont du type Sugeno du premier ordre :

$$R_j : \text{si } (x_1 \text{ est } A_1^j) \text{ et } (x_2 \text{ est } A_2^j) \\ \text{et } (x_3 \text{ est } A_3^j) \text{ et } (x_4 \text{ est } A_4^j) \\ \text{alors } y_j = c_1^j x_1 + c_2^j x_2 + c_3^j x_3 + c_4^j x_4 + c_5^j \quad (1)$$




Figure 3 – Système ANFIS à 4 entrées et 2 fonctions d'appartenance par entrée

Dans la couche 1 (de fuzzification), chaque nœud se comporte comme une fonction d'appartenance (gaussienne, sigmoïde...). Par exemple, des fonctions gaussiennes :

$$\mu_{A_l^j}(x) = \exp(-[x - m_l^j]/b_l^j]^2) \quad (2)$$

avec $l=\{1, \dots, 4\}$ le numéro de l'entrée et $\{m_l^j, b_l^j\}$ l'ensemble des paramètres des gaussiennes. Dans la couche 2, chaque nœud réalise une T-norme floue. L'opérateur produit est généralement utilisé.

$$\mu_j = \mu_{A_1^j}(x_1) \mu_{A_2^j}(x_2) \mu_{A_3^j}(x_3) \mu_{A_4^j}(x_4) \quad (3)$$

Dans la couche 3, les sorties des T-normes sont normalisées. Après combinaison linéaire des variables d'entrée dans la couche 4, la sortie "prédite" est obtenue dans la couche 5 par une moyenne pondérée des sorties des différentes règles :

$$y = \frac{\sum_{j=1}^{16} \mu_j (c_1^j x_1 + c_2^j x_2 + c_3^j x_3 + c_4^j x_4 + c_5^j)}{\sum_{j=1}^{16} \mu_j} \quad (4)$$

Le système neuro-flou décrit ci-avant comporte 96 paramètres devant être optimisés (16 inhérents aux fonctions gaussiennes et 80 à la linéarisation des sorties de règles) et c'est l'objet de la phase d'apprentissage. En général, des algorithmes hybrides sont utilisés. Plus particulièrement, des travaux montrent que la

combinaison de l'algorithme de descente du gradient et de l'algorithme LSE (Least Square Estimate) permet de réduire la complexité de l'apprentissage et d'en améliorer l'efficacité [9], [11], [16].

Performances et limites. Différents travaux montrent (cf. § 3.3) que le système neuro-flou ANFIS est à même de "capturer" le comportement d'un système rapidement et précisément, et cela, mieux encore que d'autres méthodes, réseaux de neurones inclus. Aussi, contrairement aux RN, il présente l'avantage de pouvoir être interprété par un expert.

Ceci étant, dans la pratique, la construction d'un système ANFIS se heurte à des problèmes similaires à ceux rencontrés pour les RN. L'exactitude des prédictions réalisées dépend de beaucoup de facteurs : choix des entrées, nombre et type des fonctions d'appartenance, algorithme d'apprentissage. A titre d'exemple, le système proposé en figure 3 avec 3 fonctions d'appartenance pour chaque entrée (au lieu de 2) comporterait 431 paramètres devant être optimisés (au lieu de 96). Ce serait bien évidemment très coûteux en temps de calcul et cela rendrait inexploitable l'ensemble des règles par un expert. Cependant, de meilleurs résultats peuvent être obtenus sans augmenter la complexité du modèle. C'est ce qui fait l'objet de la section suivante.

4.2 Sélection des entrées

Entrées traditionnelles. Dans les applications de prédiction, les entrées d'un système ANFIS sont directement extraites de la série de données. Par exemple, [16] se base sur 4 entrées $x_{t-3}, x_{t-2}, x_{t-1}, x_t$ pour prédire la sortie $y=x_{t+1}$. Cependant, ce type de sélection d'entrées n'exploite pas complètement les spécificités de l'inférence d'ANFIS...

Sélection des entrées. Le système ANFIS réalise une approximation linéaire de la variable de sortie en décomposant l'espace des entrées en différents espaces flous (équations 1 et 4). Il est possible de tirer partie de cette caractéristique. Considérons la figure 4.




Figure 4 – Approximation linéaire pour la prédiction via le système ANFIS

A l'instant "t", la grandeur " x_{t+r} " peut être estimée comme suit (approximation linéaire) :

$$x_{t+r} = x_{t-3} + (x_{t-2} - x_{t-3}) + (x_{t-1} - x_{t-2}) + (x_t - x_{t-1}) + A_r \quad (5)$$

Sur cette base, et compte tenu des capacités d'apprentissage du système ANFIS, la sortie prédite peut être bien estimée en modifiant le partitionnement classique des variables d'entrées et en retenant l'ensemble des entrées suivant : $\{x_{t-3}, x_{t-2} - x_{t-3}, x_{t-1} - x_{t-2}, x_t - x_{t-1}\}$.

Ce prétraitement permet de prendre en compte la dynamique du signal, et "d'apprendre" cette évolution plutôt que la série de données (la sortie "prédite" tient compte de cette évolution).

Données de tests. Nous avons utilisé la série temporelle de Mackey-Glass pour valider l'effet de la sélection d'entrées proposée. Cette série de données est un benchmark largement utilisé. La série de Mackey-Glass est chaotique, donc non périodique et non convergente. Aussi, être à même de réaliser des prédictions sur un tel signal est de bonne augure en regard de notre objectif applicatif final (le pronostic de défaillances) : les systèmes réels sont complexes et de comportement généralement non-stationnaire et non-linéaire ce qui rend difficile une étape de modélisation. Travailler avec cette série de données constitue donc un premier pas vers la spécification d'un système de pronostic capable de prendre en compte la dynamique des équipements réels.

Simulation. Les conditions de simulation sont résumées dans le tableau 1. Les mêmes

données d'apprentissage et de test ont été utilisées sur les deux modèles (avec ou sans sélection des entrées) : d'un modèle à l'autre, le système ANFIS et son exploitation sont inchangés mais un prétraitement permet de réaliser la "sélection des d'entrées". Les prédictions ont été réalisées à " $t+1$ ", à " $t+10$ " et à " $t+50$ " afin d'évaluer la stabilité des résultats en fonction de l'horizon de prédiction (tableau 2). Les mesures de performances utilisées sont l'erreur quadratique moyenne (EQM) et l'erreur moyenne absolue en pourcentage (EMAP).

Tableau 1 – conditions de test

Système d'inférence	
nombre d'entrées	4
fonct° d'appart.	Gaussienne, 2 par entrée
T-norme	produit
type d'inférence	linéaire – Sugeno
Apprentissage	
nombre total de données	1000
apprentissage/test	500/500 et 250/750
algorithmes	LSE + Desc. Grad.

4.3 Discussion

Prédictions à court terme. A court terme ($t+1$), le modèle ANFIS à sélection d'entrées (ANFIS2) ne donne pas de résultats meilleurs de manière significative (EQM et EMAP sont très similaires d'un modèle à l'autre). Cependant, la précision des résultats est légèrement améliorée.

Prédictions à moyen terme. A moyen terme ($t+10$ et $t+50$), l'intérêt de réaliser une sélection des entrées devient beaucoup plus évident : le deuxième ANFIS réalise des prédictions beaucoup plus sûres. EQM et EMAP sont divisés par deux.

Dispersion de l'erreur. Le maximum de l'erreur moyenne en pourcentage est systématiquement plus faible avec le deuxième modèle. Ceci est d'autant plus significatif à moyen terme (jusqu'à 2 fois plus petit).

Revenant à la problématique de maintenance, cet aspect est très important : le système ANFIS2 laisse présager d'un outil de prédiction dont la distribution de l'erreur est réduite. La confiance dans ces prédictions n'en est que meilleure.

Tableau 2 – résultats de simulation

N=500		Entrées classiques	Sélection d'entrées
t+1	EQM	0,0012	0,0010
	Erreur - min	0	0
	EMAP	0,09%	0,09%
	Erreur - max	8,34%	7,26%
t+10	EQM	0,0512	0,0277
	Erreur - min	0	0
	EMAP	4,57%	2,27%
	Erreur - max	37,62%	12,52%
t+50	EQM	0,1024	0,0529
	Erreur - min	0	0
	EMAP	9,79%	5,8%
	Erreur - max	57,62%	30,88%
N=250		Entrées classiques	Sélection d'entrées
t+1	EQM	0,0013	0,0012
	Erreur - min	0	0
	EMAP	0,11%	0,10%
	Erreur - max	8,15%	7,63%
t+10	EQM	0,0549	0,0339
	Erreur - min	0	0
	EMAP	5,04%	2,96%
	Erreur - max	27,23%	13,90%
t+50	EQM	0,1084	0,0581
	Erreur - min	0	0
	EMAP	10,26%	5,05%
	Erreur - max	59,19%	32,31%

Base d'apprentissage. Le modèle ANFIS à sélection d'entrées exercé sur une base d'apprentissage de 250 données a des performances supérieures au modèle classique (ANFIS1) optimisé avec 500 données : les prédictions de ANFIS2 à "t+50" avec 250 données d'apprentissage sont beaucoup plus précises et de dispersion de l'erreur plus faible que celles de l'ANFIS1 avec 500 données d'apprentissage, et très proches de celles de

l'ANFIS1 à "t+10" avec N=500. Ce résultat est très encourageant : normalement, la base d'apprentissage d'un système ANFIS doit être de taille 5 fois supérieure au nombre de paramètres à optimiser, élément souvent rédhibitoire dans les applications réelles. Pourtant nous avons ici 96 paramètres dans chacun des modèles.

En un mot, la modification des entrées proposée est un moyen efficace pour améliorer la qualité des prédictions du système ANFIS, notamment à moyen terme. Ceci laisse ainsi espérer qu'il sera possible de construire un système de pronostic dont l'erreur de prédiction pourra être maîtrisée. Les décisions de maintenance conséquentes n'en seront que meilleures.

Rappelons également que cette amélioration n'est pas due à une complexité accrue du modèle, non plus à l'utilisation d'un algorithme d'apprentissage différent. Aussi, les bases d'apprentissage sont rigoureusement les mêmes.

5 Conclusion et travaux en cours

L'activité de pronostic devient un élément clef dans la recherche de stratégies de maintenance industrielle. Il existe cependant encore peu de systèmes réels permettant de supporter ce processus. Dans ce cadre, le travail rapporté ici vise la spécification d'un système de pronostic capable de prendre en compte la dynamique des équipements réels.

Nous avons dans un premier temps positionné le concept de pronostic dans le cadre général de la maintenance. Il en ressort qu'il est nécessaire de pouvoir suivre et prévoir l'évolution de la dégradation d'un équipement. Aussi, nous avons étudié les différentes approches de prédiction existantes afin de dégager une technique intéressante pour notre application. Conformément aux spécifications pouvant être attendues d'un outil de prédiction (précis, données non-linéaires, représentation de la connaissance, flexibilité, temps de calcul...) nous avons alors centré l'analyse sur le modèle adaptatif neuro-flou ANFIS.

Nous avons montré comment cet outil peut être modifié pour réaliser des prédictions précises et de dispersion de l'erreur relativement faible à moyen terme, sans pour autant augmenter la complexité et la base d'apprentissage nécessaire.

Les travaux sont actuellement étendus suivant quatre axes complémentaires. D'abord, nous tâchons de conforter les fondements théoriques de notre proposition de modification des entrées du système ANFIS. Nous étudions également de manière plus accentuée les passerelles pouvant être exploitées entre les réseaux de neurones récurrents et les systèmes neuro-flou du type ANFIS. Ensuite, nous tâchons de construire un système prédictif multi-variables (la surveillance des systèmes complexes ne peut se baser sur le suivi d'un unique critère). Enfin, nous tentons d'intégrer les sollicitations futures mais connues du système dans notre modèle prédictif.

D'un point de vue applicatif, ces travaux sont menés dans la perspective d'être intégrés à une plateforme de e-maintenance en cours de développement au sein de l'entreprise DCNS (la plateforme Nemosys®). Les premiers développements semblent effectivement s'accorder avec les principales préoccupations technologiques de cet industriel (système temps réel, complexe et de comportement non linéaire, recherche de la génération de connaissances pour un meilleur retour d'expériences...).

Références

- [1] C. Byington, M. Roemer, G. Kacprzyński, T. Galie. Prognostic Enhancements to diagnostic Systems for Improved Condition- based maintenance. *IEEE Aerospace Conference, Big Sky, USA, 2002*.
- [2] L.H. Chiang, E. Russel, R. Braatz. *Fault detection and diagnosis in industrial systems*. Springer-Verlag, London, 2001.
- [3] F.E. Ciarapica, G. Giachetta. Managing the condition-based maintenance of a combined-cycle power plant: an approach using soft computing techniques. *Journal of Loss Prevention in the Process Industries*, 19:316-325, 2006.
- [4] J.G. De Gooijer, R.J. Hyndman. 25 years of time series forecasting. *International Journal of Forecasting*, 22:443-473, 2006.
- [5] H.S. Hippert, C.E. Pedreira, R.C. Souza. Neural Network for short term load forecasting: A review and evaluation. *IEEE Transaction on Power Systems*, 16:44-55, 2001.
- [6] ISO 13381-1. *Condition monitoring and diagnostics of machines – prognostics – Part 1: General guidelines*. International Standard, ISO, 2004.
- [7] B. Iung, G. Morel, J.B. Leger. Proactive maintenance strategy for harbour crane operation improvement. *Robotica*, 21:313-324, 2003.
- [8] W.F.C. James, D.A. Linkens, M.F. Abbod, M. Chen, J.L. Burton, K. Feeley, 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.
- [9] J.S.R. Jang, C.T. Sun. Neuro-Fuzzy modeling and control. *IEEE Proceedings*, 83:378-406, 1995.
- [10] A.K.S. Jardine, D. Lin, D. Banjevic. A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing*, 20:1483-1510, 2006.
- [11] C. Li, K.H. Cheng. Recurrent neuro-fuzzy hybrid-learning approach to accurate system modeling. *Fuzzy Sets and Systems*, 158:194-212, 2007.
- [12] D. Lin, V. Makis. Recursive filters for a partially observable system subject to random failure. *Advances in Applied Probability*, 35:207-227, 2003.
- [13] C. Mahabir, F. Hicks, F.R. Fayek. Neuro-Fuzzy river ice breakup forecasting system. *Cold regions science and technology*, 46:100-112, 2006.
- [14] A. Muller, M.C. Suhner, B. Iung. Formalisation of a new prognosis model for supporting proactive maintenance implementation on industrial system. *Reliability Engineering and System Safety*, in Press, 2007.
- [15] N.A. Sisman-Yilmaz, F.N. Alpaslan, L. Jain. ANFIS unfolded in time for multivariate time series forecasting. *Neurocomputing*, 61:139-168, 2004.
- [16] W.Q. Wang, M.F. Goldnaraghi, F. Ismail. Prognosis of machine health condition using neuro-fuzzy systems. *Mechanical Systems and Signal Processing*, 18:813-831, 2004.
- [17] R.C.M. Yam, P.W. Tse, L. Li, P. Tu. Intelligent predictive decision support system for condition-based maintenance. *International Journal of Advanced Manufacturing Technology*, 17:383-391, 2001.
- [18] G. Zhang, B.E. Patuwo, M.Y. Hu. Forecasting with artificial neural networks: the state of the art. *International Journal of Forecasting*, 14:35-62, 1998.