

الجمهورية الجزائرية الديمقراطية الشعبية

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

وزارة التعليم العالي و البحث العلمي

MINISTERE DE L'ENSEIGNEMENT SUPPERIEUR  
ET DE LA RECHERCHE SCIENTIFIQUE

جامعة فرحات عباس- سطيف-1

UNIVERSITE FERHAT ABBAS - SETIF 1  
UFAS (ALGERIE)

## THESE

Présentée à la Faculté de Technologie  
Département d'électrotechnique  
Pour l'obtention du Diplôme de

## DOCTORAT EN SCIENCES

Option : Automatique

Par

**M. Lakhdar Aggoune**

## THEME

**Détection de défauts dans les procédés industriels par l'utilisation  
des méthodes d'identification paramétrique**

Soutenu le : **03/12/2015**

devant un Jury composé de :

M. Mohamed Naguib Harmas	Prof à l'université de Sétif 1	Président
M. Hammoud Radjeai	Prof à l'université de Sétif 1	Rapporteur
M. Yahya Chetouani	M.C à l'université de Rouen (France)	Co-rapporteur
M. Tarek Raïssi	Prof au CNAM de Paris (France)	Co-rapporteur
Mme. Leila Hayet Mouss	Prof à l'université de Batna	Examinatrice
M. Djamel Boukhetala	Prof à l'ENP Alger	Examinateur

## ملخص :

تتكون منشآت الصناعة من أنظمة معقدة ذات حجم كبير والتي تتطلب تصميم أنظمة فعالة لكشف الأعطاب وذلك لضمان جودة المنتوجات وثبات وأمن هذه المنشآت. العمل المنجز في هذه الرسالة يخص دراسة كشف الأعطاب في عمود التقطير وذلك بإستعمال طريقة تعتمد على التنسيق بين النمذجة من نوع العلبة السوداء والإختبارات التسلسلية للفرضيات. في مرحلة أولى تم تطوير عدة نماذج خطية وغيرخطية من أجل تقريب تغير درجة الحرارة في أعلى عمود التقطير. من أجل إختيار أحسن نموذج تم إستخدام ثلاث معايير إحصائية. النتائج المحصل عليها بينت أن النموذج NARMAX يقدم أحسن تقريب لدرجة الحرارة في أعلى العمود. في مرحلة ثانية تم إستخدام إختبارات الفرضيات لكشف الأعطاب عمود التقطير. لهذا الغرض تم إقتراح أربع إختبارات تسلسلية لكشف إنحراف معدل راسب النموذج NARMAX. لغرض إختبار فعالية طريقة كشف الأعطاب المقترحة تم إستخدام أعطاب حقيقية لعمود التقطير. النتائج التجريبية المحصل عليها أثبتت فعالية الطريقة.

كلمات رئيسية : النمذجة؛ تعريف الأنظمة؛ إختبارات الفرضيات؛ كشف الأعطاب؛ الأنظمة الصناعية؛ عمود التقطير.

## Résumé :

Les installations industrielles sont des systèmes complexes de grandes échelles qui nécessitent la conception de systèmes robustes de détection de défauts pour assurer une bonne qualité des produits, la fiabilité et la sécurité dans les différentes conditions de fonctionnement. Le travail réalisé dans cette thèse concerne l'étude de la détection de défauts dans une colonne à distiller en utilisant une approche issue de la combinaison de la modélisation de type boîte noire et des tests séquentiels d'hypothèses. Dans un premier temps, plusieurs modèles linéaires et non-linéaires sont développés afin de prédire l'évolution de la température en tête de la colonne à distiller. Afin de sélectionner le modèle optimal du processus, trois critères statistiques sont utilisés. Les résultats obtenus montrent que le modèle NARMAX offre la meilleure prédiction de la température en tête de colonne. Dans un deuxième temps, les tests statistiques sont employés afin de détecter les anomalies. Ainsi, quatre tests séquentiels sont proposés pour détecter des déviations dans la moyenne du résidu généré par le modèle NARMAX. Les méthodes de détection de défauts proposées sont implémentées et validées expérimentalement en utilisant des défauts réalistes de la colonne à distiller. Les résultats expérimentaux montrent que les méthodes proposées sont efficaces.

**Mots clés : Modélisation; Identification des systèmes; Tests d'hypothèses; Détection de défauts, Processus industriels; Colonne de distillation.**

## Abstract :

Industrial plants are complex large-scale systems which need designing robust fault detection schemes to ensure high product quality, reliability and safety under different operating conditions. This thesis concerns the study of fault detection in a distillation column process using an approach based on the combination of black-box modelling method and sequential hypothesis testing. Firstly, several linear and nonlinear models are developed to predict the evolution of the overhead temperature in distillation column. In order to select an optimal model for the process, three statistical criteria are used. The obtained results show that NARMAX model gives a better prediction of the overhead temperature. Secondly, the statistical tests are used to detect anomalies. Indeed, four sequential tests are proposed to detect deviations in the mean of the residual generated by NARMAX model. The proposed fault detection methods are implemented and validated experimentally using realistic faults of the distillation column. The experimental results demonstrate that the proposed methods are accurate.

**Keywords: Modelling; System identification; Hypothesis testing; Faults detection; Industrial processes; Distillation column.**

## Remerciements

A l'issue de ces années de thèse, et avant que ce manuscrit ne suive son propre chemin, je tiens à remercier tous ceux qui ont contribué de près ou de loin à la bonne conduite de ma thèse.

Je souhaite exprimer ma plus sincère reconnaissance à Monsieur Yahya Chetouani, Maître de conférences à l'université de Rouen pour m'avoir accueilli au sein du laboratoire de génie chimique et ainsi m'avoir fait confiance et confié ce sujet de thèse. Je vous remercie, Yahya, pour votre suivi, votre disponibilité, votre aide, et votre implication dans mon travail.

Je tiens bien sûr à remercier l'IUT de Rouen (Département génie chimique) pour m'avoir permis de réaliser le travail expérimental de la thèse.

Je tiens à faire part de toute ma gratitude à Monsieur Tarek Raïssi, Professeur au CNAM de Paris pour m'avoir très bien accueilli et intégré dans son équipe de recherche (Cedric-laetitia-Cnam) lors de mon stage de finalisation de thèse. Je le remercie particulièrement pour l'encadrement, la disponibilité et la correction du manuscrit.

Un grand merci à mon directeur de thèse Monsieur Hammoud Radjeai qui m'a accordé autant de confiance et de liberté.

Mes remerciements vont également à Madame Leila Hayet Mouss et Monsieur Djamel Boukhatela qui m'ont fait l'honneur d'examiner mon travail. Qu'ils soient assurés de ma profonde reconnaissance. Je remercie également Monsieur Mohamed Naguib Harmas d'avoir accepté le double rôle d'examineur et de président du jury de cette thèse.

La présente thèse a pu être terminée grâce à une bourse algérienne, qui m'a été allouée par le programme PNE, auquel j'adresse ma profonde reconnaissance. Pendant les 18 mois de bourse, j'ai beaucoup apprécié l'ambiance amicale qui règne au département EASY (CNAM de Paris), je tiens à remercier tous ses membres et plus particulièrement ceux de la chaire d'Automatisme Industriel.

Merci à tous ceux qui comptent, famille et amis, pour leur soutien sans faille. Je pense aujourd'hui avec beaucoup de tendresse à mes parents et ma tante, à la confiance qu'ils m'accordent. Je veux les remercier de tout mon cœur, ainsi que mes sœurs, mes frères et mes cousins. Sans votre soutien, tout ceci n'aura jamais pu aboutir et je vous serai éternellement reconnaissant d'avoir su me donner les moyens d'arriver jusqu'ici. Aucun mot ne saurait décrire ma pensée.

Je salue par ailleurs le lecteur de ces lignes et j'espère qu'il trouvera ce qu'il est venu chercher dans les pages qui suivent.

## Table des matières

Remerciement.....	ii
Table des matières.....	iii
Notations.....	v
Liste des figures.....	vi
Liste des tableaux.....	ix
Publication de L'auteur.....	x
Introduction générale.....	11
Chapitre 1 : Notions sur les processus industriels de distillation	
1.1 Introduction.....	19
1.2 Principe de la distillation.....	19
1.2.1 Equilibre Liquide-Vapeur.....	20
1.2.2 Lois fondamentales.....	21
1.2.3 Distillation de mélanges binaires.....	23
1.2.4 Distillation continue.....	24
1.2.5 Distillation discontinue (distillation batch).....	25
1.2.6 Appareillage.....	25
1.2.6.1 Colonnes à garnissage.....	25
1.2.6.2 Colonnes à plateaux.....	26
1.3 Description du système de distillation étudié.....	27
1.3.1 Le bouilleur.....	29
1.3.2 Le condenseur.....	29
1.3.3 La préchauffe.....	31
1.3.4 Système de supervision.....	31
1.4 Conclusion.....	32
Chapitre 2 : Méthodes de diagnostic des processus industriels	
2.1 Introduction.....	33
2.2 Concept du diagnostic de défauts.....	34
2.2.1 Terminologie et définitions.....	34
2.2.2 Types de défauts.....	36
2.2.3 Procédure de diagnostic.....	37
2.3 Méthodes de détection et de localisation de défauts.....	39
2.3.1 Méthodes sans modèle.....	39
2.3.2 Méthodes à base de modèle.....	45
2.3.3 Méthodologies d'analyse des risques.....	52
2.4 Analyse des résidus.....	55
2.4.1 L'analyse fréquentielle.....	55
2.4.2 Tests non statistiques de logique à seuil.....	56

2.4.3 Tests statistiques.....	56
2.5 Conclusion.....	57
Chapitre 3 : Identification paramétrique d'un processus industriel de distillation	
3.1 Introduction.....	58
3.2 Modèles paramétriques.....	60
3.2.1 Modèles ARX et NARX.....	62
3.2.2 Modèles ARMAX et NARMAX.....	65
3.2.3 Modèle de Hammerstein.....	68
3.3 Choix des variables entrées/sorties et élaboration de la base de données.....	71
3.4 Recherche du modèle de référence.....	72
3.4.1 Identification des modèles linéaires ARX et ARMAX.....	74
3.4.2 Identification des modèles non-linéaires NARX, NARMAX et HARMAX.....	83
3.5 Validation du meilleur modèle.....	90
3.6 Conclusion.....	92
Chapitre 4 : Tests statistiques pour la détection de défauts application à un processus industriel de distillation	
4.1 Introduction.....	93
4.2 Principe des Méthodes statistiques de décision.....	95
4.2.1 Tests non paramétriques.....	95
4.2.2 Tests paramétriques.....	96
4.2.3 Quelques généralités sur les tests d'hypothèses.....	96
4.2.4 Tests d'hypothèses pour la détection de changement.....	100
4.2.4.1 Test de Neyman Pearson.....	103
4.2.4.2 Test du CUSUM.....	104
4.2.4.3 Distances statistiques.....	106
4.2.4.3.1 La distance de Kullback-Leibler.....	107
4.2.4.3.2 La distance de Hellinger.....	107
4.3 Détection d'anomalie pour un système de distillation.....	108
4.4 Conclusion.....	116
Conclusion Générale.....	117
Bibliographie.....	121

## Notations

### Mathématiques

$u$	Vecteur d'entrée
$y$	Sortie du système
$\hat{y}$	Sortie du modèle
$\varphi$	Vecteur de régression
$\varepsilon$	Erreur de prédiction (résidu)
$\phi_{\varepsilon\varepsilon}$	Fonction d'autocorrélation
$\phi_{u\varepsilon}$	Fonction d'intercorrélation
$\varepsilon_1, \dots, \varepsilon_N$	Vecteur de N observations
$N(\mu, \sigma^2)$	Distribution gaussienne de moyenne $\mu$ et de variance $\sigma^2$
$P_\theta$	Distribution/loi de probabilité paramétrée par $\theta$
$H$	Hypothèse dans un test statistique
$t$	Temps discret
$t_d$	Temps de défaut, point de rupture
$t_a$	Temps d'alarme (signalé par un détecteur)
$t_r$	Temps de retard à la détection

### Acronymes

AIC	Critère d'Information d'Akaike (Akaike information criterion)
ARX	AutoRégressif à entrée eXogène (AutoRegressive with eXogenous input)
ARMAX	AutoRégressif à Moyenne Ajustable et à entrée eXogène (AutoRegressive Moving Average with eXogenous input)
HARMAX	Hammerstein ARMAX
MISO	Entrée multiple sortie simple (Multiple Input Single Output)
MCR	Moindres carrés récursifs (Recursive Least Squares)
MCE	Moindres carrés étendus (Recursive Extended Least Squares)
ESMPE	Erreur de sortie avec modèle de prédiction étendu

	(Output Error with Extended Prediction Model)
NARX	Non linéaire AutoRégressif à entrée eXogène (Nonlinear AutoRegressive with eXogenous input)
NARMAX	Non linéaire AutoRégressif à Moyenne Ajustable et à entrée eXogène (Nonlinear AutoRegressive Moving Average with eXogenous input)
NSE	Critère de Nash-Sutcliffe
RMSE	Racine carrée de l'erreur quadratique moyenne (Root Mean Squared Error)



## Liste des figures

1.1 Diagramme de phases isobare pour un mélange binaire (la fraction molaire se rapporte au constituant le plus volatil) ;.....	21
1.2 Schéma d'une colonne de distillation binaire.....	24
1.3 Vue générale de l'unité de distillation.....	28
1.4 Bouilleur de l'unité de distillation.....	30
1.5 Condenseur de l'unité de distillation.....	30
1.6 La partie de préchauffe.....	31
2.1 Principe des méthodes de surveillance.....	35
2.2 Évolution temporelle des différents types de défauts.....	37
2.3 Les différentes étapes du diagnostic.....	37
2.4 Composants d'un système expert.....	41
2.5 Diagnostic à base de modèles.....	46
2.6 Principe de la génération de résidus par estimation paramétrique.....	48
2.7 Principe de la génération de résidus par un reconstituteur d'état.....	49
2.8 Organigramme de la procédure de l'examen HAZOP.....	54
3.1 Procédure d'identification d'un système.....	61
3.2 Principe de l'identification.....	61
3.3 Structure d'un modèle HARMAX MISO.....	69
3.4 Schéma fonctionnel du modèle boîte noire de la colonne.....	71
3.5 Représentation des données d'estimation et de validation.....	72
3.6- (a) Évolution de $Q_b$ et $R_t$ (b) Évolution de $Q_f$ et $\Delta P$ .....	72
3.7 Comparaison entre la sortie du système et celle du modèle ARX identifié par l'algorithme MCR.....	78
3.8 Évolution de l'erreur de prédiction du modèle ARX pour les données de validation.....	79
3.9 Comparaison entre la sortie du système et celle du modèle ARMAX identifié par l'algorithme MCE.....	79
3.10 Évolution de l'erreur de prédiction du modèle ARMAX identifié par l'algorithme MCE pour les données de validation. ....	80
3.11 Comparaison entre la sortie du système et celle du modèle ARMAX identifié par l'algorithme ESMPE.....	80
3.12 Évolution de l'erreur de prédiction du modèle ARMAX identifié par l'algorithme ESMPE pour les données de validation.....	81
3.13 Comparaison entre la sortie du système et celle du modèle NARX.....	86
3.14 Évolution de l'erreur de prédiction du modèle NARX.....	87
3.15 Comparaison entre la sortie du système et celle du modèle NARMAX.....	87
3.16 Évolution de l'erreur de prédiction du modèle NARMAX.....	88

3.17 Comparaison entre la sortie du système et celle du modèle HARMAX.....	88
3.18 Évolution de l'erreur de prédiction du modèle HARMAX.....	89
3.19 Résultats de validation du modèle NARMAX.....	92
4.1 Région de rejet pour un test bilatéral avec $\alpha = 5\%$ .....	100
4.2 Région de rejet pour un test unilatéral à gauche avec $\alpha = 5\%$ .....	100
4.3 Test binaire à partir d'une observation.....	102
4.4 Graphes des différents tests pour le défaut D1.....	110
4.5 Graphes des différents tests pour le défaut D2.....	111
4.6 Graphes des différents tests pour le défaut D3.....	112
4.7 Graphes des différents tests pour le défaut D4.....	113
4.4 Graphes des différents tests pour le défaut D5.....	114

## Liste des tableaux

3.1 Comparaison entre différentes structures du modèle ARX identifiées pas l'algorithme MCR.....	75
3.2 Comparaison entre différentes structures du modèle ARMAX identifiées pas l'algorithme MCE.....	76
3.3 Comparaison entre différentes structures du modèle ARMAX identifiées pas l'algorithme ESMPE.....	77
3.4 Paramètres du modèle ARMAX identifiées pas l'algorithme ESMPE.....	82
3.5 Paramètres du modèle NARX retenu.....	84
3.6 Paramètres du modèle NARMAX retenu.....	85
3.7 Paramètres du modèle HARMAX retenu.....	86
3.8 Comparaison des performances de meilleures structures identifiées.....	89
4.1 Défauts considérées de la colonne.....	109
4.2 Retard à la détection des méthodes proposées.....	115

## **Publications de l'auteur**

### **Reuves internationales avec comité de lecture**

1. Aggoune, L., Chetouani, Y., Radjeai, H. Change detection in a distillation column using non-linear auto-regressive moving average with exogenous input model and Hellinger distance. *IET Science, Measurement & Technology*, 8 pp. DOI: 10.1049/iet-smt.2015.0045, Available online: 04 November 2015
2. Aggoune, L., Chetouani, Y., Radjeai, H., 2014. Recursive Identification of the Dynamic Behavior in a Distillation Column by Means of Autoregressive Models. *Journal of Dynamic Systems, Measurement, and Control*. 136, 044506-5.

### **Conférences internationales**

3. Aggoune, L., Chetouani, Y., Radjeai, H., 2012. Using ARX Model for Prediction Overhead Temperature of a Distillation Column. *International Conference on Electrical Engineering and Automatic Control (ICEEAC'13)*, November 24-26, Sétif, Algérie.
4. Aggoune, L., Chetouani, Y., Radjeai, H., 2012. Identification of Distillation Column Using ARMAX Structure and Recursive Extended Least Square Algorithm. *International Conference on Complex Systems (ICCS'12)*, November 05-06, Agadir, Morocco.

# **Introduction générale**

## **Introduction générale**

De nos jours, les processus industriels sont devenus de plus en plus complexes et de grandes dimensions, qu'il s'agisse d'unités de production (raffineries de pétrole, centrales nucléaires), de moyens de transport (avions, trains), ou autres... Ils résultent fréquemment de l'interconnexion de plusieurs sous-systèmes. L'étude de ces processus a connu un regain d'intérêt de la part de la communauté scientifique lors de ces dernières années, notamment en ce qui concerne le développement de stratégies de diagnostic, et ceci pour plusieurs raisons : tout d'abord, la compétitivité industrielle induite par les exigences du marché économique incite la réduction des coûts de production. Ensuite, les exigences de fiabilité, de disponibilité des systèmes sont devenues indispensables pour augmenter la productivité d'un processus industriel. Enfin, la commande tolérante aux défauts (FTC for Fault Tolerant Control) a été particulièrement développée ces dernières années, produisant des résultats applicables à la régulation des systèmes.

Dans ce contexte de diagnostic, les industriels doivent satisfaire des cahiers de charges contraignants : satisfaction des contraintes de qualité et de sécurité et respect de normes environnementales (bruit, pollution...). Pour respecter ces spécifications, il est primordial d'assurer que les processus industriels fonctionnent de manière sûre vis-à-vis de son environnement humain et matériel. Il est également important d'optimiser la production afin de réduire les coûts. Cependant, des défauts peuvent apparaître sur ces systèmes, que ce soit sur l'instrumentation (les capteurs et les actionneurs) ou dans le système lui-même. Cela peut provoquer une dégradation des performances du système (qualité du produit, stabilité, disponibilité etc.), ce qui pourrait faire échouer la mission du système en question. Ce problème a un impact direct sur les objectifs énoncés ci-dessus. En effet, la détermination des conditions de fonctionnement à chaque instant est nécessaire et ce, afin de connaître l'instant où le système dévie de son comportement normal et de prendre les mesures nécessaires pour qu'il n'y ait pas d'interruption de service. Ceci est le but du diagnostic des systèmes qui fournit un dispositif de détection de défauts. Cette préoccupation doit être assurée tout au long de la durée de vie d'un processus.

D'une façon générale, les processus industriels sont destinés à produire des objets, à synthétiser des composants, ou à réaliser des services, ce qui permet d'obtenir en grande quantité des produits qui autrement seraient relativement difficiles ou coûteux à obtenir. Ils aident à faire face à d'importants défis sociaux tels que le changement climatique, les pénuries d'énergie, les questions sécuritaires et la santé. L'incertitude, l'imprédictibilité, la dynamique des phénomènes et le nombre important de données à traiter rendent les décisions difficiles. De plus, les défaillances des processus industriels sont devenues difficilement prévisibles. Pour faire face à ces difficultés, il est indispensable d'assurer à ces processus plus de sûreté de fonctionnement et de fiabilité.

L'industrie chimique est un acteur majeur de l'économie dans beaucoup de pays. Ce secteur fournit des produits essentiels (médicaments, engrais, plastique,...). Malgré sa contribution à la progression du niveau de vie, elle doit faire face à une image d'industrie dangereuse et polluante en raison des systèmes et matières premières qu'elle utilise. Ainsi, la moindre anomalie dans un système chimique peut se propager dans toute l'installation et provoque ainsi de lourdes conséquences. Depuis la seconde guerre mondiale, la croissance et l'expansion rapides de l'industrie chimique ont engendré de graves accidents, pour l'environnement naturel et industriel. Dans la nuit du 3 décembre 1984, à Bhopal (centre de l'Inde) (Stellman et Dufresne, 2000), l'explosion d'une usine d'une filiale de la firme américaine Union Carbide produisant des pesticides, a dégagé 40 tonnes d'isocyanate de méthyle dans l'atmosphère de la ville. Cet accident a provoqué la mort de 2500 personnes et a fait 200 000 blessés. La cause de l'accident est une réaction chimique du produit avec de l'eau restée dans une cuve après un nettoyage. Bhopal est probablement la pire catastrophe chimique industrielle de tous les temps. Le 21 septembre 2001 (Souriau et al., 2002), une explosion a détruit en grande partie le complexe chimique toulousain AZF (Azote Fertilisants) appartenant à la société Grande Paroisse (groupe Total), premier fabricant français d'engrais. Trente personnes furent tuées et 2500 blessées ainsi que 27 000 logements endommagés. L'explosion s'est produite dans un stock d'environ 300 tonnes de granulés de nitrate d'ammonium, creusant un cratère de forme ovale de 70 mètres de long et 40 mètres de largeur, et de 5 à 6 mètres de profondeur. La détonation

a été entendue à plus de 80 km de Toulouse. Un séisme de magnitude 3,4 a été enregistré. La cause la plus probable de cette catastrophe est le mélange de produits incompatibles dans le hangar, qui contenait des déchets de fabrication et où une benne venait d'être vidée trente minutes avant l'explosion, où s'est produite l'explosion.

En Algérie, plusieurs catastrophes aux conséquences dramatiques restent en mémoire. Le 19 janvier 2004 à Skikda (Achour et Hached, 2004), survient la plus grande catastrophe industrielle algérienne dans la zone pétrochimique. Une explosion s'est produite au niveau du complexe de production de gaz naturel liquéfié (GNL) suivie d'un incendie. Trois unités de liquéfaction sur les six que comporte le complexe ont été fortement endommagées et soumises à un feu intense. L'explosion aura provoqué la mort de 27 personnes et fait 74 blessés, touchés directement par le souffle de l'explosion ou indirectement par des objets portés par ce souffle (projection et effondrements de structures). La catastrophe est à l'origine de l'explosion d'une chaudière à haute pression fabriquant de la vapeur. L'estimation des dégâts matériels est d'environ 800 million de dollars.

Au vu de ces catastrophes et de bien d'autres, il s'avère indispensable de garantir un fonctionnement normal des installations industrielles. En effet, la détection d'un dysfonctionnement au début de son apparition peut éviter de graves conséquences. Les premiers travaux sur la détection de défauts des systèmes datent du début des années 1970 (Willsky, 1976; Mehra et Peshon, 1971) et a été depuis largement abordée dans la littérature (Lyonnet et al., 2012; Ding, 2008; Samantaray et Ould-Bouamama, 2008). Les approches développées peuvent être classées en deux grandes catégories : les approches avec modèles qui se basent sur l'existence d'un modèle du système à surveiller et les approches sans modèles qui se basent sur l'analyse des variables de surveillance et sur l'expertise humaine. Cette dernière catégorie nécessite la plupart du temps la connaissance a priori de tous les modes de fonctionnement (normal et défaillant) du système surveillé. Or, l'obtention d'une telle connaissance est loin d'être aisée en raison notamment de la nature complexe des systèmes physiques. C'est pourquoi les techniques à base de modèle semblent intéressantes pour la détection de défauts en ligne.



Les méthodes de détection de défauts à base de modèle nécessitent la connaissance de l'état de fonctionnement du système étudié par le biais d'une estimation de ses variables de sortie. Ensuite, les défauts sont détectés en comparant le comportement observé à celui donné par le modèle. Plus précisément, la phase de détection de défauts est liée à la génération des symptômes de dysfonctionnement du système à partir d'une vérification de la cohérence entre des signaux extraits du système qui renseignent sur son comportement réel et des signaux estimés qui traduisent le comportement attendu. Tout écart non permis entre ces signaux révèle la présence d'une anomalie. Les performances de ces méthodes dépendent fortement de la qualité du modèle utilisé.

D'une façon générale, il existe différentes approches pour construire un modèle d'un système donné (Billings, 2013; Isermann et Münchhof, 2011; Landau et al., 2011; Giri et bai, 2010). Deux grandes familles de modèles sont recensées selon la procédure mise à profit pour obtenir la représentation du système étudié. La première, connue sous l'appellation de modèles de connaissance (modélisation de type boîte blanche), est basée entièrement sur les lois physiques régissant le système. La seconde, connue sous l'appellation de modèles de représentation (modélisation de type boîte noire), fait intervenir des données d'entrée et de sortie extraites du système. De plus, La combinaison de ces deux types de modélisation peut conduire à l'élaboration de modèles mixtes (modélisation de type boîte grise).

L'élaboration d'un modèle de type boîte blanche requiert une connaissance profonde de la dynamique des processus. Cependant, le recours à ces techniques peut présenter certaines limites dans des situations pratiques. En effet, la complexité des systèmes physiques actuels rend particulièrement difficile la définition de la totalité des lois physiques régissant le système étudié, ce qui peut compromettre la réussite d'une telle démarche de modélisation. Néanmoins, les approches permettant la modélisation en s'appuyant sur des données d'entrée et de sortie peuvent jouer un rôle important pour la détection de défauts. Ainsi, les modèles de type boîte noire ont été à l'origine de nombreuses techniques exploitées pour la détection d'anomalies, telles que : les réseaux de neurones artificiels (Chetouani, 2014), l'identification ensembliste

(Chai et Qiao, 2014), les méthodes des sous-espaces (Akhenak et al., 2013) ou les modèles polynomiaux (Shashoa et al., 2013; Peng et al., 2011). Dans ce travail de thèse, cette dernière catégorie de modèles est retenue principalement pour sa capacité à approcher le comportement dynamique, aussi complexe soit-il, d'une large gamme de systèmes (Billings, 2013).

Une fois le modèle du système surveillé est défini, les symptômes de dysfonctionnement (résidus) peuvent être déduits. L'étape suivante consiste alors à analyser ces résidus afin de détecter la présence ou non de défauts. Un résidu est, en théorie, nul dans des conditions normales de fonctionnement et significativement différent de zéro dans le cas contraire. Souvent, cette condition n'est pas tout à fait satisfaite à cause des bruits de mesure et des erreurs de modélisation qui ne doivent pas être confondues avec les défauts. Il est alors nécessaire d'introduire des méthodes d'analyse afin d'éviter des fausses alarmes. Cette tâche est souvent confiée à un module de décision. Il exploite toute information livrée par les entrées de commande envoyées aux actionneurs et les mesures des sorties provenant des capteurs et par le comportement attendu du système fourni par un modèle en vue de détecter tout comportement anormal du système et permettant également d'estimer un instant d'apparition du défaut. Parmi les méthodes utilisées, on peut citer les tests statistiques d'hypothèses (Ding, 2008; Basseville et Nikiforov, 1993)

L'application principale de ce travail de thèse concerne la surveillance d'une colonne de distillation. Un tel système consiste en la séparation des constituants d'un mélange liquide. Les systèmes de distillation sont de nos jours utilisés à grande échelle, notamment dans l'industrie chimique. De par leur présence grandissante dans des domaines applicatifs toujours plus diversifiés, les problèmes liés à la sécurité de ce type de système prennent une plus large part dans les contraintes d'exploitation. La moindre défaillance sur l'unité de distillation peut limiter les performances des produits et avoir de graves conséquences si elle n'est pas détectée rapidement. Il s'avère particulièrement pertinent de pouvoir surveiller ces systèmes en temps réel de manière à garantir la sécurité des biens et des personnes en relation directe ou indirecte avec l'application, tout en atteignant les objectifs d'exploitation fixés.

L'objectif de cette thèse est alors de mettre au point des méthodes de détection d'anomalie issues de la combinaison de la modélisation de type boîte noire et les tests statistiques d'hypothèses. Ces méthodes consistent à construire des procédures automatiques d'alarmes qui ont pour rôle d'alerter les opérateurs de l'occurrence d'un défaut. Cinq types d'anomalies pouvant survenir aux entrées de l'unité de distillation ont été étudiés. Les défauts d'entrées sont parmi les plus répandus (Chetouani, 2014, Namdari et Jazayeri-Rad, 2014; Zhu et al., 2014; Wang et al., 2012). Dans ce contexte, le choix du modèle de la colonne est primordial. Ce modèle doit être capable de reproduire le comportement du système dans une large plage de fonctionnement, afin de prendre en compte les changements dans les modes de fonctionnement du système.

Cette thèse se divise en quatre chapitres, dont le contenu est organisé de la manière suivante :

Le premier chapitre présente des généralités sur la distillation des mélanges liquides. Les concepts généraux ainsi que la procédure de séparation des constituants et plus particulièrement de mélanges binaires sont introduits. Ce premier chapitre se termine par une présentation de l'unité de distillation sur laquelle porte ce travail de thèse. Cette dernière appartient au département génie chimique et se trouve à l'université de Rouen (France).

Le deuxième chapitre introduit les différents termes et définitions relatifs au diagnostic. L'accent sera mis, à travers ce chapitre, sur les méthodes de surveillance des processus, que ce soit des méthodes à base de modèle ou sans modèle a priori.

Le troisième chapitre est consacré à la modélisation de la colonne de distillation en vue de la détection de défauts. Il fait principalement référence aux modèles paramétriques de type boîte noire (identification paramétrique). Afin de prouver l'importance du choix de modélisation, les concepts de l'identification paramétrique sont introduits. Deux catégories de modèles paramétriques sont ensuite proposées pour décrire le comportement dynamique du système. Dans la première, des modèles autorégressifs linéaires et non-linéaires sont mis à profit pour l'identification du système de distillation. Parmi ces modèles, ceux qui présentent le plus d'intérêt pour la

description des systèmes dynamiques sont les modèles linéaires ARX et ARMAX et non-linéaires NARX et NARMAX. La seconde catégorie s'appuie sur l'utilisation de modèles à base de blocs structurés de type Hammerstein. Ce modèle est composé d'un élément statique non-linéaire suivi d'un bloc dynamique linéaire. L'intérêt suscité par les modèles utilisés a largement été démontré dans la littérature. Leurs capacités à approximer les comportements dynamiques d'une large gamme de systèmes réels expliquent la popularité de ces modèles. L'estimation des différents paramètres des modèles utilisés est basée sur des algorithmes de moindres carrés. Le but étant de trouver un modèle de référence de l'unité de distillation. Toutefois, le choix approprié de ce modèle doit garantir un compromis satisfaisant entre des objectifs contradictoires qui sont la précision de prédiction (meilleure approximation) et la simplicité (moindre complexité). Afin de surmonter cette difficulté, les critères statistiques AIC, NSE et RMSE ont été utilisés. Cela a permis de choisir le modèle de référence de l'unité de distillation. Ce modèle sera par la suite utilisé pour la mise au point des algorithmes de détection de défauts.

Le quatrième et dernier chapitre est dédié à la détection en ligne de défauts d'entrées de la colonne de distillation en s'appuyant sur le modèle de référence identifié dans le chapitre précédent. L'étape de détection est la première phase de la procédure de diagnostic. La stratégie proposée est basée sur les méthodes statistiques de détection dont l'objectif est de signaler le plus tôt possible un changement dans les données observées. D'abord, les méthodes séquentielles à base de tests d'hypothèses et leurs propriétés sont présentées. Lors de l'occurrence d'un défaut, l'évolution de l'erreur de prédiction (résidu) du modèle de référence est modifiée entraînant un changement des caractéristiques statistiques. Les tests de Neyman Pearson (Neyman et Pearson 1933), de CUSUM (Page, 1954), et les distances statistiques de Hellinger et de Kullback-Leibler (Gibbs et 2002; Kullback et Leibler, 1951) ont été proposés afin d'exploiter ces changements pour indiquer la présence d'un défaut. Enfin, Les résultats obtenus sur des données réelles avec défauts sont présentés, ainsi qu'une évaluation des performances de détection.

Le manuscrit s'achève par une conclusion générale et quelques directions futures de recherche.

# **Chapitre 1**

## **Notions sur les processus industriels de distillation**

## **1.1 Introduction**

Un grand nombre de secteurs industriels ont pour objectif de séparer un ou plusieurs constituants d'un mélange plus ou moins complexe. C'est le cas en pétrochimie, pharmacie, agroalimentaire... Cette séparation peut être réalisée de façon continue ou discontinue. L'appareil principal permettant de réaliser cette opération est le plus souvent une colonne à distiller. Il existait en 1998 aux États-Unis environ 40000 colonnes à distiller qui utilisaient 7% de l'énergie totale consommée dans le pays (Sticklmair et Fair, 1998). Cependant, malgré ses atouts indéniables, la mise en œuvre d'un système de distillation à l'échelle industrielle n'est envisageable que si une étude de sécurité poussée a été préalablement réalisée.

Ce premier chapitre a pour objectif d'introduire différents concepts liés à la distillation. En premier lieu, l'accent sera mis sur certaines notions théoriques de la procédure de séparation, les différents modes opératoires, les configurations possibles et les procédés de distillation. Ensuite, une description du procédé employé dans ce travail et ces différents composants sera présentée.

## **1.2 Principe de la distillation**

La distillation est une des méthodes de séparation les plus utilisées industriellement. Cette opération permet la séparation et la purification des mélanges de constituants dont les températures d'ébullition sont différentes, en mettant à profit la différence de volatilité (capacité à s'évaporer selon la température) des constituants puis en réalisant une succession de condensations et de vaporisations pour terminer par la récupération d'un des constituants. Cette procédure de séparation est connue depuis plus de 2000 ans.

La distillation consiste à chauffer jusqu'à l'ébullition un mélange liquide le constituant le plus volatile s'évapore le premier. Par condensation de la phase vapeur, on récupère un liquide nommé distillat ou extrait (dit aussi produit de tête) avec une concentration élevée du composé le plus volatil. La phase liquide non évaporée constitue le résidu ou le raffinat (appelée également produit de pied ou de fond).

Le distillat n'est pas un produit pur, il est enrichi en constituant léger de température d'ébullition moins élevée, tandis que le produit de pied est formé par le constituant lourd dont la température d'ébullition est plus élevée. Pour obtenir un distillat à un degré de pureté élevée, en particulier lorsque les constituants du mélange ont des températures d'ébullitions voisines, on a souvent recours à la rectification.

La rectification est une technique qui utilise une distillation répétée de manière à provoquer des échanges entre les phases vapeur montant et liquide refluant dans une colonne destinée à la mise en contact des deux phases.

### **1.2.1 Equilibre Liquide-Vapeur**

La séparation des constituants d'un mélange liquide nécessite la connaissance des lois des équilibres liquide-vapeur. Les mélanges liquides peuvent être classés en fonction du nombre de leurs constituants, en mélanges binaires, ternaires... Dans ce qui suit, les mélanges binaires seront seuls considérés.

Considérons un mélange liquide binaire introduit dans un récipient fermé. Il est d'usage, en distillation, de caractériser la composition du mélange par sa composition molaire du constituant ayant la température d'ébullition la plus faible. Si on chauffe le récipient à pression fixée, trois domaines caractéristiques sont observables :

- en deçà d'une température où apparaît la première bulle de vapeur; le mélange est entièrement liquide; il est sous-refroidi. Cette température est appelée la température de bulle du mélange.
- en continuant le chauffage, la fraction de vapeur croît jusqu'à une température où la dernière goutte de liquide disparaît. Cette température de rosée du mélange marque la fin du domaine biphasique.
- au-delà de la température de rosée, seule la phase vapeur subsiste.

En faisant varier la composition du mélange binaire considéré, les températures de bulle et de rosée évoluent comme montre la Figure 1.1 (Koller, 2013). Il est possible de constater que ces courbes partagent le diagramme en trois parties sous la courbe de bulle, tout mélange est entièrement liquide; au-dessus de la courbe de rosée, il est



totalemment gazeux. La partie entre les deux courbes correspond aux conditions biphasiques (mélange liquide-vapeur). Toute charge, telle que celle représentée par le point F, se décompose en une phase gazeuse V, de composition  $y_V$  et une phase liquide L, de composition  $x_L$ . Pour une même température, les abscisses  $x_L$  et  $y_V$  représentent les compositions des phases liquide et vapeur à l'équilibre.

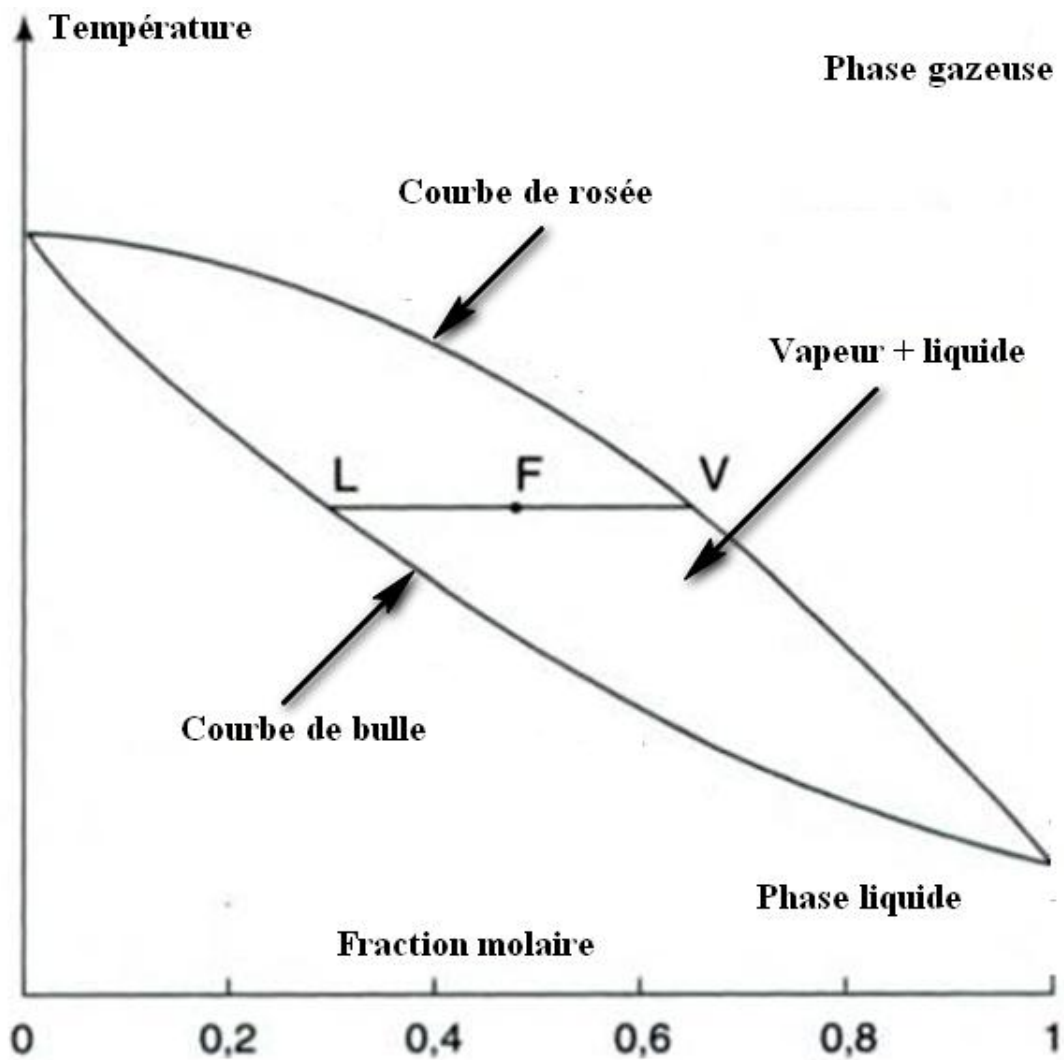


Figure 1.1- Diagramme de phases isobare pour un mélange binaire (la fraction molaire se rapporte au constituant le plus volatil)

### 1.2.2 Lois fondamentales

#### ▪ Fractions molaires et pressions

Soit un mélange liquide constitué de  $n_A$  molécules du corps A et  $n_B$  molécules du corps B; les fractions molaires sont :

$$X_A = \frac{n_A}{n_A + n_B} \quad \text{et} \quad X_B = \frac{n_B}{n_A + n_B} = 1 - X_A \quad (1.1)$$

Pour une température donnée, la vapeur en équilibre au-dessus de ce liquide est un mélange des deux corps A et B aux fractions molaires  $Y_A$  et  $Y_B$  et la pression totale est, suivant la loi de Dalton relative aux vapeurs parfaites :

$$P = p_A + p_B \quad (1.2)$$

avec  $p_A$  et  $p_B$ , les pressions partielles des constituants A et B, et

$$Y_A = p_A / P \quad \text{et} \quad Y_B = p_B / P \quad (1.3)$$

La pression partielle du constituant A dans la vapeur en équilibre avec le liquide ayant la fraction molaire  $X_A$ , à température constante, est donnée par la loi de Raoult :

$$p_A = X_A / p_{vA} \quad \text{et} \quad p_B = X_B / p_{vB} \quad (1.4)$$

avec  $p_{vA}$  et  $p_{vB}$  les tensions de vapeur saturante des constituants A (pur) et B à la température d'ébullition du mélange. En combinant les lois de Dalton et Raoult, on obtient :

$$Y_A = X_A (p_{vA} / P) \quad \text{et} \quad Y_B = X_B (p_{vB} / P) \quad (1.5)$$

Un mélange qui vérifie cette loi est dit mélange idéal.

#### ▪ Volatilité relative

La volatilité relative d'un corps A par rapport à un corps B est définie par le rapport :

$$\alpha = \frac{Y_A / X_A}{Y_B / X_B} = \frac{k_A}{k_B}$$

(1.6)

où :

$$k_A = p_{vA} / P \quad \text{et} \quad k_B = p_{vB} / P \quad (1.7)$$

sont appelés coefficients d'équilibre; en remplaçant  $k_A$  et  $k_B$  dans (1.5), on obtient :

$$\alpha = p_{vA} / p_{vB} \quad (1.8)$$

Le paramètre  $\alpha$  est choisi par rapport au constituant le plus volatil, de manière à avoir toujours  $\alpha \geq 1$ . Lorsque le mélange binaire considéré est idéal, il est possible d'écrire :

$$Y_A = \frac{\alpha X_A}{X_A(\alpha - 1) + 1} \quad (1.9)$$

La volatilité relative exprime le pouvoir de séparation d'un mélange; plus  $\alpha$  est grand, plus les courbes de rosée et de bulle du diagramme température – concentration sont écartées.

En pratique cependant, on ne peut assimiler le liquide à une solution idéale. En effet, on conserve alors la forme des expressions précédentes et l'on fait intervenir des termes correctifs, dits coefficients d'activité  $\gamma$ , qui sont déterminés généralement par l'intermédiaire d'informations expérimentales. Il en résulte alors :

$$k_A = \gamma_A p_{vA} / P \text{ et } \alpha = (\gamma_A / \gamma_B)(p_{vA} / p_{vB}) \quad (1.10)$$

### **1.2.3 Distillation de mélanges binaires**

La distillation peut s'effectuer en continu ou en discontinu. Elle se déroule dans un appareil de séparation de phases dit colonne de distillation. Cet appareil est composé d'une enveloppe cylindrique verticale qui renferme les dispositifs (plateaux ou garnissages) permettant d'augmenter la surface de contact entre la phase liquide et la phase gazeuse, améliorant ainsi les échanges entre les phases pour un volume de colonne donné. En plus de la colonne et de ces plateaux ou garnissages, deux échangeurs de chaleur permettent d'apporter/retirer l'énergie nécessaire pour la séparation : un bouilleur situé en bas de colonne et le condenseur en tête de colonne qui permet de liquéfier les vapeurs afin de récupérer le produit purifié sous forme liquide. Une partie des condensats est souvent réinjectée dans la colonne pour augmenter la pureté du produit désiré, il s'agit du reflux (Figure 1.2).

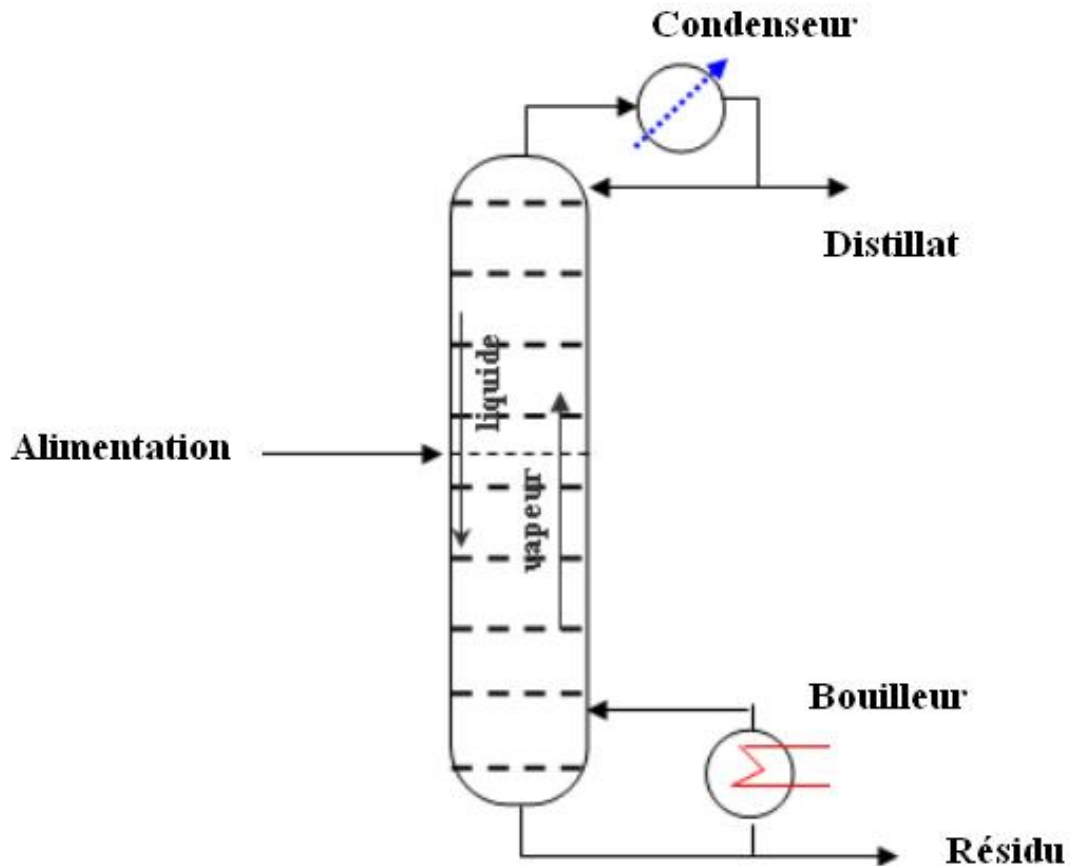


Figure 1.2- Schéma d'une colonne de distillation binaire

Le mélange liquide à séparer (alimentation) est introduit dans la colonne. Ce liquide est ensuite porté à ébullition par le bouilleur. La vapeur s'échappant du bouilleur est condensée dans le condenseur. Le liquide non évaporé est extrait en fond de colonne et constitue le résidu. La vapeur produite est toujours plus riche en constituant le plus volatil, de façon que la composition du condensat est en tous temps supérieure à celui du mélange initial. Une partie de la vapeur condensée est renvoyée en tête de colonne et constitue la phase liquide dans la partie supérieure de la colonne, c'est le reflux. En effet, le liquide se déplace dans la colonne par gravité de haut en bas et la vapeur se déplace de bas en haut. Le reste de la vapeur est soutiré et constitue le distillat.

#### 1.2.4 Distillation continue

En distillation continue, la colonne est alimentée de façon permanente, tandis qu'on soutire, à débits et compositions fixes. La séparation des constituants du

mélange s'opère en continu et l'ensemble des paramètres reste constant (concentrations du distillat et du résidu, températures, débits de résidu et de distillat). Les séparations en mode continu sont les plus couramment utilisées par l'industrie, surtout dans les domaines de la chimie et de la pétrochimie.

### **1.2.5 Distillation discontinue (distillation batch)**

Il s'agit maintenant d'une opération évoluant dans le temps. Le mélange à séparer est chargé une fois dans l'installation où il est chauffé; sa composition varie ainsi que celle du distillat. La distillation discontinue est fréquemment employée pour les produits à forte valeur ajoutée dans les industries pharmaceutique et agroalimentaire. L'opération discontinue présente l'avantage de pouvoir séparer un mélange de plusieurs constituants avec un appareillage relativement simple mais a l'inconvénient d'être grosse consommatrice en temps et en énergie.

### **1.2.6 Appareillage**

Les procédés de séparations ont tous pour but de réaliser le meilleur échange entre les phases liquide et vapeur. Les appareils de séparation industriels sont constitués d'un grand cylindre d'acier vertical à l'intérieur duquel sont disposés les dispositifs qui assurent le contact entre la vapeur montante et le liquide descendant. Il existe plusieurs types de colonnes mais elles se classent essentiellement selon leurs internes en deux catégories (Cicile, 2001) :

- colonne à garnissage.
- colonnes à plateaux.

#### **1.2.6.1 Colonnes à garnissage**

Dans une colonne garnie, les transferts de matière entre liquide et vapeur ont lieu de façon continue sur toute la hauteur de la colonne. L'échange des constituants entre les phases se fait d'autant mieux que la surface de contact est importante. C'est la raison pour laquelle on emplit la colonne d'éléments solides (le garnissage, encore appelé remplissage ou packing).

Les colonnes à garnissage ont une faible retenue de liquide et une faible perte de charge, mais, en revanche, elles sont peu souples, c'est-à-dire qu'on ne doit pas trop s'écarter des conditions opératoires pour lesquels elles ont été choisies et dimensionnées afin de ne pas voir baisser leurs performances. Les types de garnissage apparaissent dans l'industrie sous plusieurs formes, les plus rencontrées étant :

- **garnissage en vrac** : ce sont les premiers garnissages qui ont été utilisés. Il s'agit de construire un volume rempli de petits éléments adaptés aux conditions de distillation. Ces éléments peuvent avoir plusieurs formes. Il est possible de distinguer parmi les plus fréquemment employées, les anneaux rasching, les anneaux pall, les selles de berl et les selles intalox. Quant aux matériaux utilisés, ils peuvent être l'acier, la céramique ou la porcelaine.
- **Garnissage structuré** : ce type de garnissage est composé d'un assemblage de plaques ondulées montées verticalement dos à dos. L'inclinaison des ondulations avec la verticale peut être de 30° ou de 45°. Ils sont généralement fabriqués à partir des métaux avec des formes géométriques différentes.

#### **1.2.6.2 Colonnes à plateaux**

Le fonctionnement et l'intérieur des colonnes à plateaux diffèrent nettement à ceux des colonnes à garnissage. Un tel appareil est formé par une succession de plateaux disposés à intervalles réguliers dans la colonne. Un plateau a pour fonction de mettre en contact les phases afin de provoquer des transferts de matière. Le passage de la vapeur se fait de plateau en plateau par des orifices dont la taille et la forme peuvent être très variables. Le liquide descend de plateau en plateau par des déversoirs situés le long de la paroi de la colonne. Ainsi, le mouvement des phases peut se faire selon deux façons différentes. Deux types de plateaux sont utilisés dans l'industrie selon le mouvement des phases, d'une part les plateaux dites à courants croisés avec trop plein, où la phase gazeuse traverse le liquide qui se déplace horizontalement sur un plateau avant de déboucher par le trop plein sur un plateau inférieur; et d'autre part les plateaux à contre-courant sans trop-plein, qui ne comportent ni barrage de sortie ni trop plein, le liquide et la vapeur s'écoulent par les mêmes orifices.

Un plateau à courant croisé se compose d'une plaque métallique plane sur laquelle sont fixés les éléments de barbotage dont la disposition peut être rectangulaire, triangulaire ou en losange, des barrages et des trop-pleins. Le plateau à contre-courant est une simple plaque métallique perforée de trous.

Il convient toutefois de souligner que certains mélanges ne peuvent pas être séparés sous pression atmosphérique car :

- soit ils se décomposent à une température inférieure à leur température d'ébullition sous pression normale, ou ils s'oxydent à l'air à cette température;
- soit leur température d'ébullition est très élevée.

Afin de surmonter ces difficultés, une réduction de la pression dans le procédé de séparation permettant de baisser la température d'ébullition du mélange considéré est souvent utilisée dans l'industrie. La procédure ainsi obtenue est dite de distillation sous pression réduite. Parmi les dispositifs qui permettent de travailler sous une pression inférieure à la pression atmosphérique, il existe les différentes pompes à vide et les trompes à eau.

### **1.3 Description du système de distillation étudié**

L'installation étudiée dans le cadre de cette thèse dont la vue générale est présentée sur Figure 1.3, représente le fonctionnement à échelle réduite d'une unité de distillation. Les principaux appareils constituant l'installation sont la colonne, le bouilleur, le garnissage ainsi que le condenseur en tête de colonne. Il convient d'ajouter un organe de circulation (la pompe), pour une distillation fonctionnant en continu. Le réservoir d'alimentation est situé en dessous de la colonne. Ce réservoir contient le mélange à séparer (toluène-méthylcyclohexane) dont on a défini la composition massique à 23 % en méthylcyclohexane. Ce mélange est introduit en un certain point de la colonne appelé plateau d'alimentation, de telle sorte qu'une partie est volatilisée (méthylcyclohexane), tandis que l'autre redescend avec le reflux dans le bouilleur.




Figure 1.3- Vue générale de l'unité de distillation

Le garnissage de la colonne est très important puisqu'il permet de favoriser le transfert de matière entre la phase vapeur et la phase liquide. Le type du garnissage est MULTIKNIT inox 316L, ce sont des mailles tressées. De plus la colonne est divisée en trois parties de 330 mm reliées par des plateaux. Suivant le type d'alimentation choisi, on peut différencier une alimentation basse d'une alimentation haute.

Le timer est constitué d'un clapet électromagnétique et permet ainsi de réguler le taux de reflux. De plus, il est régulé par TIC2 (température en tête de colonne). Lorsque la température de consigne de TIC2 est atteinte, le timer s'ouvre. Dans le cas



contraire il reste fermé (mode automatique). L'unité de distillation possède onze capteurs permettant la mesure en continu de la température dans toute la colonne.

La pompe doseuse est une pompe volumétrique. La configuration du montage de la pompe est un montage en aspiration. Un clapet anti-retour empêche le réservoir de la préchauffe de se vider. La pompe volumétrique est constituée d'une membrane permettant dans un premier temps l'aspiration du mélange à distiller puis son refoulement vers le réservoir de préchauffe. D'après les données constructrices la pompe d'alimentation peut délivrer un débit de 4.32 L/h.

### **1.3.1 Le bouilleur**

Les bouilleurs sont des échangeurs de chaleur dont le but est de permettre au liquide de s'appauvrir en constituant volatil et à la vapeur de s'en enrichir. La quantité vaporisée s'appelle le taux de rebouillage. Il existe plusieurs types de bouilleurs, les bouilleurs à faisceaux tubulaires et les bouilleurs à résistances plongeantes.

Les bouilleurs du premier type ont pour principe de fonctionnement de chauffer le mélange à séparer grâce à un fluide caloporteur circulant dans la calandre de l'échangeur (bouilleur). En général le fluide le plus souvent utilisé est de la vapeur d'eau. Le principe de fonctionnement du deuxième type de bouilleur est d'envoyer une certaine intensité permettant ainsi de fournir une puissance adéquate pour porter le mélange à ébullition. Les caractéristiques du bouilleur de l'installation étudiée (Figure 1.4) sont les suivantes :

- le bouilleur a une capacité de 2 litres, et possède un capteur de niveau permettant l'arrêt automatique de la chauffe si le niveau est insuffisant;
- le thermoplongeur possède une puissance de chauffe de 3.3 Kw.

### **1.3.2 Le condenseur**

La fonction principale du condenseur est de transformer la vapeur montante en liquide sur une surface froide, ou via un échangeur thermique maintenu froid par la circulation d'un fluide réfrigérant. Cependant la température du liquide ne doit pas être inférieure

à la température d'ébullition du mélange à séparer, sans quoi le reflux serait trop froid et déséquilibrerait la colonne.

La Figure 1.5 illustre le condenseur utilisé pour la séparation du mélange toluène-méthylcyclohexane avec une surface d'échange totale de  $0.08 \text{ m}^2$ .



Figure 1.4- Bouilleur de l'unité de distillation



Figure 1.5- Condenseur de l'unité de distillation

### **1.3.3 La préchauffe**

La préchauffe est constituée de trois cartouches de résistances chauffantes d'une puissance de 250 W chacune. Elle possède en plus un capteur de niveau empêchant ainsi la mise en route si le niveau dans le corps de verre est trop bas (Figure 1.6).



Figure 1.6- La partie de préchauffe

### **1.3.4 Système de supervision**

Le système de supervision est constitué du logiciel ETP 200. Il permet de suivre l'évolution de grandeurs physiques telles que la pression différentielle ou les températures en un point donné de la colonne de distillation. Ce logiciel possède de multiples fonctionnalités permettant le contrôle automatisé de la colonne de distillation.

La première fonctionnalité est la modification de paramètres. Celle-ci permet la configuration des paramètres de régulation (PID). De plus, ce menu permet de régler

l'installation en mode manuel ou automatique ainsi que la consigne opératoire du procédé. La visualisation de la mesure de chaque appareil y est observée.

La deuxième fonctionnalité importante est la tendance de groupe. La tendance de groupe permet de suivre l'évolution des mesures de chaque appareil lié à la régulation. Cette évolution peut être visualisée en temps réel ou en historique.

Le troisième menu important est la tendance d'un appareil. Comme la fonctionnalité précédente, elle permet de suivre l'évolution de la mesure, de la consigne ainsi que la sortie.

Il existe un menu qui permet d'avoir un historique sur les alarmes ayant pu être déclenchées lors d'une manipulation. Ce logiciel possède aussi une visualisation synoptique.

## **1.4 Conclusion**

Ce chapitre introduit le principe de séparation des constituants d'un mélange liquide. Ce principe est rencontré dans plusieurs domaines de l'industrie. La description de la procédure de distillation, des différentes étapes qui la composent, des procédés de séparation ont été présentés. Un accent particulier sur la séparation des mélanges binaires a été mis en évidence. Une brève description de l'appareillage de distillation (séparation) utilisé dans les installations industrielles a ainsi été donnée et les modes de fonctionnement associés ont été présentés. Ce chapitre a également détaillé l'unité de séparation du mélange binaire toluène-méthylcyclohexane utilisée dans le cadre de ce travail. L'objectif visé est la mise au point de méthodes performantes pour assurer une surveillance efficace et prévenir d'éventuels pannes ou accidents dans la distillation continue. Le chapitre suivant présente les principaux concepts de détection de défauts, et les méthodes qui lui sont associées.

# **Chapitre 2**

## **Méthodes de diagnostic des processus industriels**

## **2.1 Introduction**

Actuellement la détection de défauts des installations industrielles est une des plus importantes tâches de la supervision. Les industries dans nombreux secteurs d'activité (automobile, sidérurgie, chimie,...) sont de plus en plus soumises à la concurrence du marché. Afin de répondre aux attentes du client en termes de quantité et qualité des produits, et de délais, outre les exigences de performances, les exigences de sécurité des individus, de l'environnement et des systèmes eux-mêmes doivent être également satisfaites. L'industrie chimique constitue un des domaines importants de l'économie mondiale. Néanmoins, il faut tenir compte du fait que la plupart des accidents industriels apparus à partir de la deuxième moitié du vingtième siècle ont démontré à quel point des incidents dans ce secteur d'activité pouvaient être dangereux et polluants. Pour ce faire, il est important que tous les composants d'un procédé chimique fonctionnent correctement. Dans le cas contraire, il convient de détecter le plus tôt possible toute anomalie du procédé de façon à pouvoir réagir de manière adéquate. La supervision des procédés est assurée aujourd'hui principalement par les opérateurs, seuls à pouvoir juger du bon fonctionnement du procédé supervisé. Les algorithmes de surveillance assurant la détection et la localisation de dysfonctionnements du système fournissent aux opérateurs les outils nécessaires à la prise de décision. Ces outils permettent aussi d'éviter la propagation d'un défaut conduisant à la dégradation du système ou, même pire, à des défaillances catastrophiques.

Le diagnostic a fait l'objet d'un nombre important de travaux ces dernières décennies afin de pouvoir répondre à la diversité des applications. Dans les industries à grand risque (nucléaire, aéronautique, industrie chimique...), les tâches de diagnostic sont souvent accomplies via la redondance matérielle (capteurs ou actionneurs multiples réalisant la même fonction). Le traitement de données issues des éléments redondants permet d'effectuer des comparaisons et distingue la partie défectueuse. Si un défaut est détecté, l'élément défaillant est mis hors service et un autre élément sain prend le relais. D'autre part, cette méthode est pénalisante en termes de coût, de puissance consommée et de volume des installations. Il est donc judicieux de faire

appel à d'autres approches. La littérature sur la détection de défauts est vaste, il existe un grand nombre de méthodes, s'étendant de la redondance analytique aux techniques à base de données. Ces méthodes se basent sur le principe de la redondance des sources d'information, c'est-à-dire la comparaison entre des grandeurs issues des capteurs et des données théoriques fournies par un modèle.

Selon la description du système, on distingue deux grandes familles de méthodes, à savoir les méthodes dites à base de modèle (modèle analytique) et les méthodes sans modèle. De nombreuses techniques ont été développées, un très bon état de l'art récent peut être obtenu en consultant les ouvrages de référence (Ding, 2008; Blank et al., 2006; Isermann, 2006; Toscano, 2004; Simani et al., 2002; Dubuisson, 2001 ; Zwingelstein, 1995).

On trouve également des méthodes d'analyse des risques réalisées hors ligne. Parmi les méthodes largement répandues dans la pratique industrielle, on peut citer l'analyse préliminaire des risques (APR), la méthode HAZOP (HAZard and OPerability) et AMDEC (Analyse des Modes de Défaillances, de leurs Effets et de leur Criticité).

Nous présentons dans ce chapitre le problème générale de la détection de défauts ainsi que les différents termes et définitions utilisés. L'accent sera mis sur les méthodes qui sont les plus largement utilisées pour les systèmes dynamiques. Le but ici n'est pas de présenter une synthèse exhaustive de l'existant, mais de montrer la richesse des possibilités qui s'offrent au concepteur de systèmes de diagnostic.

## **2.2 Concept du diagnostic de défauts**

### **2.2.1 Terminologie et définitions**

Nous présentons dans cette partie la définition des termes principaux utilisés dans le domaine de la surveillance. Les définitions employées ici ont été proposées initialement par le comité technique SAFEPROCESS de l'IFAC (International Federation of Automatic Control) et utilisées dans (Isermann, 1997).

#### **- Défaut (fault)**

Un défaut est une modification inattendue d'une propriété ou d'un paramètre caractéristique du système surveillé par rapport au fonctionnement acceptable ou habituel.

- **Défaillance (failure)**

Interruption permanente de la capacité d'un système à accomplir sa mission, compte tenu de ses conditions de fonctionnement nominales.

- **Détection de défauts (faults detection)**

La détection de défauts consiste à mettre en évidence la présence de défauts dans le système et leurs instants d'apparition.

- **Localisation de défauts (faults isolation)**

Elle consiste à déterminer le type, la localisation et l'instant d'occurrence d'un défaut.

- **L'identification (ou estimation) de défauts (faults identification)**

Elle vise à caractériser l'amplitude et le comportement temporel des défauts.

La procédure complète est désignée sous les acronymes FDI (Fault Detection and Isolation) ou FDD (Fault Detection and Diagnosis) pour la détection et le diagnostic de défauts (ce dernier incluant l'identification). Ces procédures nécessitent la vérification de la cohérence entre le comportement nominal et celui observé du système. La Figure 2.1 montre le principe général du diagnostic utilisé pour la détection de défauts.

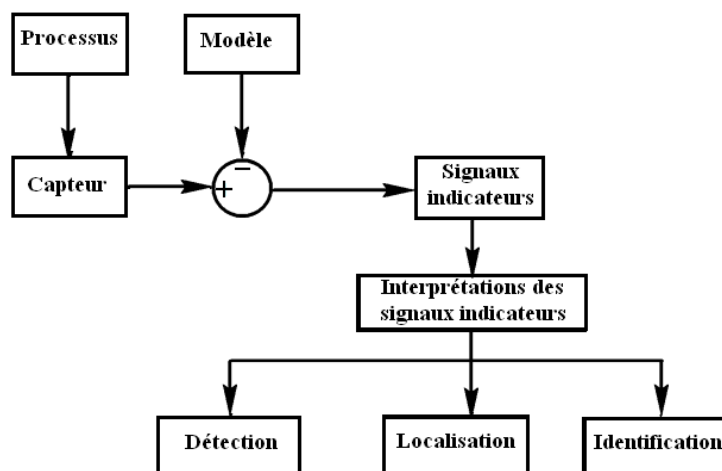


Figure 2.1 – Principe des méthodes de surveillance



En cas de défaut, il est indispensable de le compenser par une modification adéquate de la loi de commande du système. C'est pourquoi la commande tolérante aux défauts FTC (Fault Tolerant Control) a été introduite. Le lecteur peut se référer aux références (Zolghadri et al., 2014; Zhang et Jiang, 2008) pour plus de détails. La commande tolérante aux défauts est un domaine de recherche à part entière, qui ne sera pas abordé dans ce manuscrit.

### **2.2.2 Types de défauts**

Les défauts peuvent affecter un système de différentes manières. Trois principaux types de défauts sont distingués en fonction de l'élément du système qu'ils affectent.

#### **- Défauts de capteurs**

Un défaut capteur se traduit généralement par une variation anormale entre la mesure et sa valeur réelle, telle qu'un biais, une saturation, un défaut de calibrage, un bruit ou une dérive.

#### **- Défauts d'actionneurs**

Un défaut d'actionneur représente un dysfonctionnement de la partie opérative qui agit sur le système, par exemple le blocage d'une vanne.

#### **- Défauts systèmes**

Les défauts systèmes se caractérisent par des changements dans les paramètres internes du système qui entraînent une modification de sa dynamique dues à l'altération ou à la casse d'un ou de plusieurs composant(s), comme la détérioration d'un plateau de la colonne à distiller.

L'évolution temporelle des défauts est imprévisible : ils peuvent être de faible ou de forte amplitude, brusques ou graduels sous forme de dérives. On distingue dans la littérature les défauts suivants :

- ✓ défaut brusque (ou modélisé par un biais);
- ✓ défaut naissant (ou dérive);
- ✓ défaut intermittent (avec interruptions).

La Figure 2.2 représente l'évolution dans le temps des différents défauts.

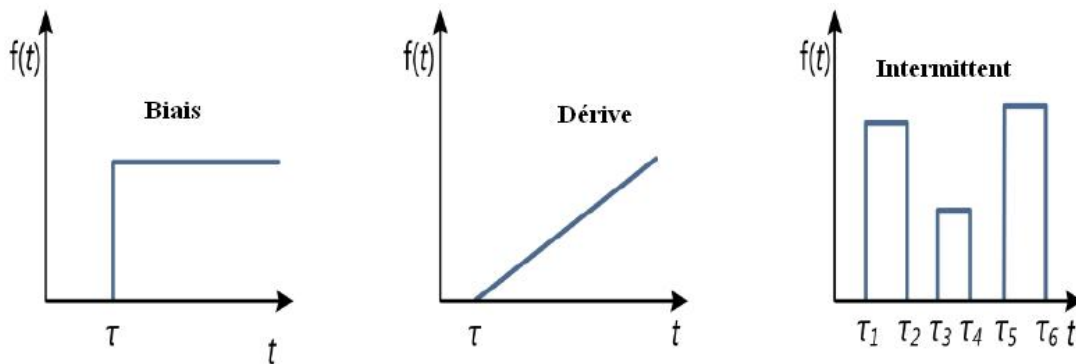


Figure 2.2- Évolution temporelle des différents types de défauts

### 2.2.3 Procédure de diagnostic

Le diagnostic de défauts nécessite un certain nombre d'étapes à suivre afin de fournir un ensemble de décisions booléennes sur la présence de défauts, comme illustré sur la Figure 2.3.

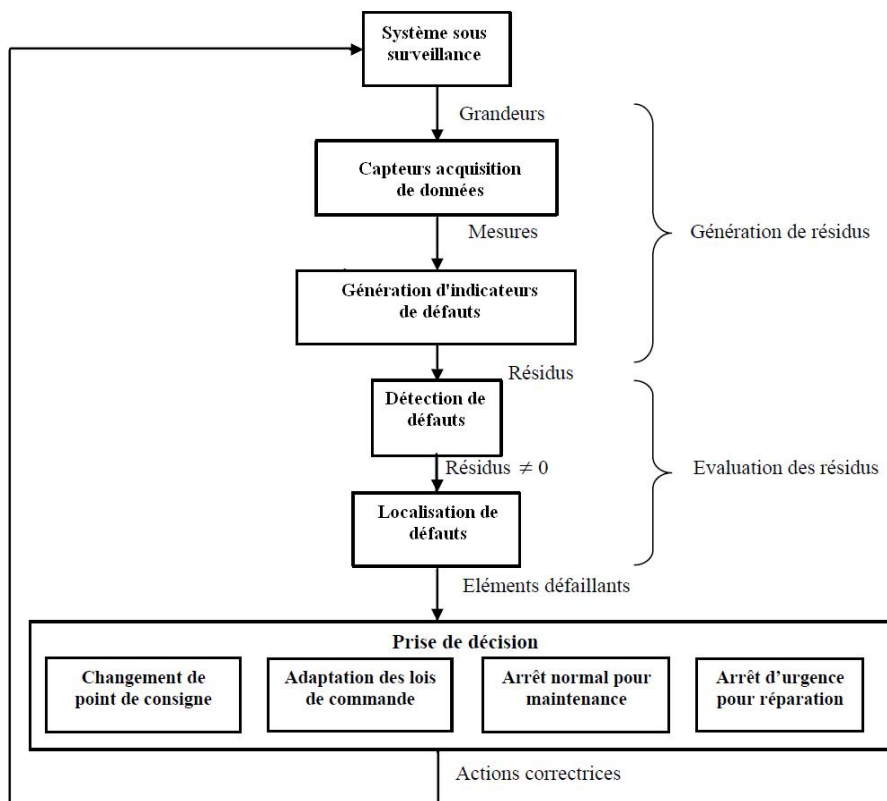


Figure 2.3- Les différentes étapes du diagnostic

La disposition d'informations sur le fonctionnement réel du système à surveiller est indispensable pour le diagnostic. La phase d'acquisition de données permet de recueillir ces informations et sa validation est ainsi assurée lors de cette étape. Pour réaliser cette tâche, il est nécessaire de disposer de capteurs qui permettent de mesurer les variables du processus. L'instrumentation du système à surveiller n'entraîne pas obligatoirement un coût supplémentaire dans la mesure où celle-ci est indispensable pour réaliser la supervision de processus.

L'étape d'élaboration des indicateurs de défauts couramment dénommés résidus utilise une représentation du système considéré. Elle consiste à utiliser les mesures des sorties provenant des capteurs pour prédire le comportement et le comparer au fonctionnement réel du système. L'objectif est de construire un ensemble d'indicateurs permettant de mettre en évidence les éventuels défauts pouvant affecter le procédé. L'étape d'élaboration d'indicateurs de défauts consiste finalement, quelle que soit l'approche utilisée, à comparer le comportement réel du système à un comportement de référence. Dans le cas idéal, cet écart est nul en l'absence de défaut et différent de zéro dans le cas contraire.

L'étape de détection consiste, quant à elle, à choisir entre deux hypothèses, la première correspond au fonctionnement sain, la deuxième correspond au fonctionnement en présence de défauts. Cette étape se base le plus souvent sur des tests statistiques. Le seuil est donc simplement défini par des lois de probabilité.

Une fois une anomalie est détectée, c'est-à-dire les résidus sont statistiquement non nuls, il est nécessaire de déterminer le ou les éléments défaillant(s). Toutefois, Il faut prendre en considération la possibilité d'avoir plusieurs défauts en même temps ce qui rend cette étape de localisation difficile.

Après la détection et la localisation d'un dysfonctionnement du système, il est important d'entreprendre des actions afin de conserver les performances souhaitées du système sous surveillance. En l'absence de module FTC cette étape de prise de décision est assurée par des opérateurs humains. Les actions correctrices à effectuer peuvent être : un changement de point de consigne afin de compenser l'effet d'un

défaut, l'adaptation paramétrique de la loi de commande dans le but de conserver les performances de l'installation, une procédure normale d'arrêt ou encore un arrêt d'urgence en cas de détection d'une anomalie sévère mettant en danger les personnes ou le matériel.

## **2.3 Méthodes de détection et de localisation de défauts**

Dans cette partie une classification des approches de diagnostic en ligne et hors ligne est présentée. Différentes méthodes peuvent être envisagées pour la détection des anomalies. Celles-ci peuvent être classées selon le type de représentation utilisée. En fonction de la représentation du système employée pour réaliser des tests de cohérence vérifiant l'adéquation des informations réelles fournies par les capteurs et le comportement de référence, on distingue deux familles d'approches : approches avec modèle et approches sans modèle.

### **2.3.1 Méthodes sans modèle**

Ces méthodes sont les plus adaptées aux cas où on ne dispose pas de modèle exploitable; elles ne présupposent pas l'existence d'un modèle analytique du système à surveiller, mais seulement la disponibilité d'observations acquises en temps réel et éventuellement des données historiques du fonctionnement. Il existe essentiellement deux stratégies pour traiter les données et de les utiliser comme connaissance a priori sur le système. La première est appelée classification : elle consiste à construire des classes de fonctionnement dans la base de données de manière supervisée (avec l'aide d'un expert) ou semi-supervisée (création automatique de classes en regroupant les éléments jugés proches, puis appel à l'expert pour identifier les classes). Il est donc nécessaire d'élaborer un classifieur permettant de distinguer ces classes et de placer un nouveau point dans une de celles-ci (typiquement, selon un mode de fonctionnement défaillant ou non défaillant). La deuxième façon est la régression, qui cherche à construire un modèle empirique à l'aide de la base de données pour prédire les valeurs des différentes variables. En d'autres termes, elle vise à reproduire la représentation de la connaissance dans le cerveau humain.

▪ **Systemes experts**

Dans le cas où l'obtention d'un modèle est difficile, le savoir des experts représente des informations utiles et peut être incorporé dans un dispositif, appelé système expert. L'idée est alors de construire des processus capables d'imiter les prises de décision d'un opérateur humain en se basant sur l'utilisation des concepts de la théorie de la logique floue et des systèmes d'inférence floue (SIF) (Dash et al., 2003). Ce type de représentation peut être exprimé à l'aide d'un ensemble de règles imitant le raisonnement humain, associant prémisses et conclusions. L'utilisation de cette approche s'avère intéressante dans le cas de la surveillance des grands systèmes. La structure de base d'un SIF est constituée d' :

- un univers de discours qui contient les fonctions d'appartenance des variables d'entrée et de sortie à des classes. Ces fonctions peuvent avoir différentes formes; les plus usuelles étant les formes triangulaires, trapézoïdales, et gaussiennes;
- une base de connaissance qui regroupe les règles liant les variables d'entrée et de sortie sous la forme « Si...Alors... »;
- un mécanisme de raisonnement basé sur la logique du modus ponens généralisé.

La nature complexe des systèmes industriels nécessite le développement de plusieurs méthodes assurant leur surveillance. L'utilisation des systèmes experts, paraît alors précieuse. Dans la plupart des cas, les connaissances utilisées pour le développement d'un système expert d'aide au diagnostic reposent sur l'apprentissage des relations entre les causes et les effets observées pour chaque défaut. Un système expert est composé de deux parties indépendantes (Figure 2.4) où les données (la base de connaissance) sont bien séparées du programme qui les manipule (moteur d'inférences) :

- **une base de connaissance** : composée d'une base de règles qui modélisent la connaissance du domaine considéré et d'une base de faits qui contient les informations concernant le cas traité;
- **un moteur d'inférence** : Il est capable de raisonner à partir des informations contenues dans la base de connaissance et de faire des déductions. Au fur et à

mesure, le moteur d'inférence utilise les données et les règles pour produire de nouvelles données.

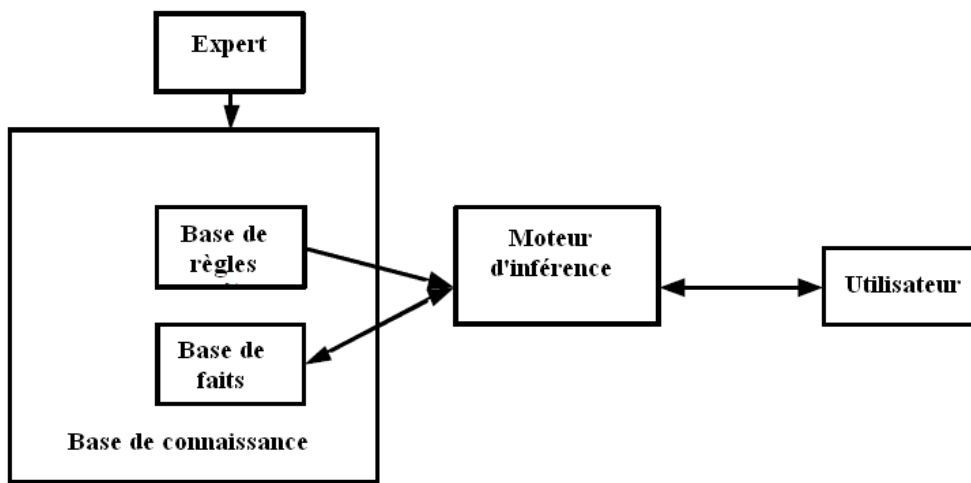


Figure 2.4- Composants d'un système expert

Les principaux avantages d'un système expert sont sa capacité à regrouper les connaissances de plusieurs experts et la possibilité d'ajouter, de modifier ou d'effacer certaines règles. Les principaux inconvénients de ces systèmes sont leur manque de généralité et la difficulté de prendre en compte des situations non prévues.

#### ▪ Diagnostic par reconnaissance de formes

L'utilisation des données historiques permet la détection des anomalies par reconnaissance de formes, qui regroupe l'ensemble des méthodes permettant la classification automatique d'objets, suivant leurs ressemblances par rapport à des objets de référence. L'objectif est de décider, après avoir observé un objet, à quelle forme celui-ci ressemble le plus. Une forme est définie à l'aide de  $p$  paramètres, appelés descripteurs, qui sont les composantes d'un vecteur forme que nous noterons par  $X$ . La résolution d'un problème de reconnaissance de formes nécessite (Bishop, 2006; Toscano, 2004; Dubuisson, 2001) :

- la définition précise des  $l$  classes entre lesquelles va s'opérer la décision. Cette étape est liée à la nature des objets à classer et est donc spécifique au problème posé;

- le choix d'un jeu de caractères pertinents pour la discrimination des vecteurs de formes. Malheureusement, il n'existe pas de méthodes systématiques permettant de choisir les paramètres les plus appropriés à la résolution d'un problème donné. Par conséquent, seule une bonne connaissance du problème à résoudre peut permettre un choix adéquat des paramètres de forme. Notons enfin que le nombre de caractères fixe la dimension de l'espace de représentation. Ceci peut représenter une contrainte sévère dans un contexte de traitement en temps réel des objets à classer;
- l'élaboration d'un classificateur permettant l'affectation d'une forme observée à l'une des classes. Le classificateur est généralement établi à l'aide d'un ensemble d'apprentissage constitué de formes pour lesquelles on connaît l'appartenance aux différentes classes.

On remarque que la qualité de réalisation de chaque étape du processus dépend souvent de celle des étapes précédentes (Duda et al. 2000). Deux opérations préalables doivent être réalisées hors ligne : les données d'apprentissage sont à regrouper par classes et une règle de décision est à définir. Chaque point de la base de données est affecté à l'une des classes. Dans le cas du diagnostic, les classes à considérer sont le mode de fonctionnement normal et tous les modes de dysfonctionnement à détecter. La détermination des grandeurs à observer est basée sur le savoir des experts, ou sur l'analyse fonctionnelle suivie d'une analyse dysfonctionnelle permettant de déterminer quelles sont les variables à surveiller pour une meilleure détection des défauts les plus critiques.

Le problème consiste alors à définir les frontières entre les classes qui permettent l'affectation d'une nouvelle observation à l'une d'entre elles, il s'agit de l'opération de classification. En d'autres termes, cette classification permettra de définir une règle de décision, qui sera utilisée par la suite pour classer automatiquement toute nouvelle observation.

L'application des méthodes de reconnaissance de forme au diagnostic ne pose pas de difficultés si toutes les classes sont connues. Cette hypothèse est souvent

vérifiée en reconnaissance de formes conventionnelle, mais pour les applications où seuls quelques modes de fonctionnement sont connus, elle n'est pas vérifiée. Il faut donc étendre les méthodes de la reconnaissance de forme au cas où toutes les classes qui représentent les modes de fonctionnement ne sont pas a priori connues. Ce problème peut être résolu à l'aide des techniques de décisions dites avec rejet (Dubuisson, 2001). Dans ce cas, les points rejetés sont mémorisés afin de construire des nouvelles classes si le nombre des points est suffisant. Cela devrait permettre d'inclure les nouvelles classes dans le système de surveillance en modifiant les règles de décisions; ce qui implique qu'un dispositif de diagnostic basé sur la reconnaissance de formes doit être un système évolutif, capable de prendre en compte tout nouveau phénomène normal ou anormal présent dans le processus surveillé.

▪ **Analyse en composantes principales (ACP)**

La complexité croissante des installations industrielles fait aussi croître le nombre de capteurs assurant la commande et la surveillance, ce qui rend l'analyse des informations fournies très difficile. L'ACP permet de réduire le nombre de variables à traiter par la projection orthogonale linéaire des observations de dimension  $m$  ( $m$  est le nombre de variables observées) dans un sous-espace de dimension inférieure ( $l < m$ ) en maximisant la variance des projections (Jolliffe, 2002). Le but de l'ACP est d'identifier la structure de dépendance entre des observations multivariées afin d'obtenir une représentation compacte de ces dernières. Selon les domaines d'application, l'ACP est aussi connue sous le nom de transformation de Karhunen-Loève, de transformation de Hotelling ou encore de décomposition orthogonale. Elle met en œuvre une décomposition en valeurs et vecteurs propres de la matrice de covariance des données ou encore une décomposition en valeurs singulières de la matrice des données. L'ACP a été largement appliquée pour la surveillance des processus industriels (Mnassri, 2012; Tharrault et al., 2008; Harkat et al., 2006).

Cette approche ne peut pas traiter le cas non-linéaire, car il s'agit d'une opération de projection linéaire; seules les dépendances linéaires entre les variables mesurées peuvent être révélées, ce qui n'est pas nécessairement réaliste. L'extension aux problèmes non-linéaires a été développée à l'aide des réseaux de neurones (Jia et



al., 1998), ou par l'utilisation d'autres techniques de décompositions comme l'analyse en composantes indépendantes (Li et al., 2000). À partir d'idées similaires, la méthode des moindres carrés partiels (MCP) peut être utilisée pour la détection des anomalies (Wang et al 2003).

▪ **Réseaux de neurones artificiels (RNA)**

Nés du rapprochement de la biologie et de l'informatique, les RNA constituent aujourd'hui une approche de traitement de données bien comprise et maîtrisée, ils sont connus sous des noms très différents tels que réseaux neuromimétique, modèles connexionnistes, réseaux de neurones formels, réseaux d'automates cellulaires, etc. Dans le cadre du diagnostic des défauts, les RNA visent à reproduire certaines des capacités de l'homme de façon artificielle, surtout la capacité de reconnaissance, celle de la classification et celle de la généralisation (extension des exemples appris à des cas non appris) (Monory et al., 2012; Manssouri et al., 2008).

Un RNA, par analogie avec les systèmes neuronaux biologiques, est un assemblage fortement connecté de neurones formels reliés entre eux par des liaisons synaptiques. Les RNA ont une propension naturelle pour stocker de la connaissance empirique et de la rendre disponible à l'usage. Ils fonctionnent essentiellement à base d'apprentissage qui consiste à estimer les paramètres des neurones du réseau, en ajustant les poids d'interconnexion entre les neurones afin que celui-ci remplisse au mieux la tâche qui lui est affectée. C'est grâce aux propriétés suivantes que les RNA ont pu fournir une solution intéressante pour des problématiques de surveillance des équipements industriels : potentialité à résoudre les problèmes de classification, grande capacité d'apprentissage et de généralisation et rapidité de traitement des données non-linéaires (Dreyfus et al., 2004).

Selon la nature des données en sortie du réseau, les RNA peuvent être exploités de deux manière différentes : comme outil principal de classification et de reconnaissance de de formes (classifieurs), ou comme outil permettant de reconstruire une quantité donnée (estimateur). En détection de défauts, les RNA sont utilisées comme outils de reconnaissance de formes. Ainsi le problème de diagnostic est

ramené à un problème de reconnaissance de formes, où ces dernières représentent l'ensemble des mesures du système et les classes correspondent aux différents modes de fonctionnement et de défaillance du système (Trigeassou, 2011).

Afin de réaliser un système de détection de défauts par les RNA, il est nécessaire de suivre les étapes suivantes :

- choix des indicateurs de défauts : pour une exploitation efficace des RNA, une analyse préalable, aussi soignée que possible des différentes variables du système à surveiller en fonctionnement normal et défaillant, doit être menée par des experts. Cette analyse permet de choisir les indicateurs les plus représentatifs des défauts. Ces derniers sont utilisés en tant qu'entrées du réseau;
- choix de la structure du réseau : un réseau de neurones est un ensemble de neurones connectés entre eux. Plusieurs architectures existent, selon le type de connexions. La structure MPL (Multi-Layer Perceptron) est la structure la plus utilisée dans le domaine de la classification (Rajakarunakaran et al., 2008). L'architecture d'un MPL est constituée d'une couche d'entrée, d'une ou plusieurs couches cachées et une couche de sortie. Le nombre des entrées correspond au nombre des indicateurs de défauts et le nombre de neurones de la couche de sortie correspond aux  $k$  classes (modes) choisies. Le nombre de neurones dans les couches cachées ne peut être fixé a priori,
- construction de la base d'apprentissage et de test : cette dernière étape consiste en une acquisition des données provenant d'un procédé ou d'un simulateur. Ces données sont ensuite traitées et classées dans la base de données. Cette dernière doit être assez représentative des différents modes de fonctionnement.
- apprentissage et test du réseau : une fois l'architecture d'un réseau de neurones choisie, il est nécessaire d'effectuer un apprentissage pour déterminer les valeurs des poids permettant à la sortie du réseau de neurones d'être aussi proche que possible de l'objectif fixé.

### **2.3.2 Méthodes à base de modèle**

- **Principe de la redondance analytique**

La majorité des méthodes de détection de défauts se base sur la redondance d'informations. Cette redondance est utilisée dans le but d'obtenir plusieurs informations pour une même variable d'un système. Dans les systèmes industriels à haut risque, telles que les centrales nucléaires ou l'industrie chimique, la redondance d'informations est assurée matériellement. La redondance matérielle a plusieurs avantages tels que la fiabilité et les bonnes performances. Il faut cependant noter les nombreuses contraintes de coût, de poids et d'encombrement.

La redondance analytique présente une alternative intéressante à la redondance matérielle. L'utilisation d'un modèle mathématique du système à la place du matériel additionnel permet d'assurer la redondance d'information.

La redondance analytique permet d'éviter les problèmes d'encombrement et de coût par rapport à la redondance matérielle. Elle a aussi l'avantage d'être simple et flexible. Néanmoins, afin d'assurer une meilleure efficacité, le modèle mathématique doit être précis. Le principe du diagnostic basé sur la redondance analytique consiste à comparer en temps réel le comportement attendu du système prédit par un modèle à celui observé par des capteurs.

La détection et la localisation de défauts basée sur l'utilisation de modèles se fait en plusieurs étapes (Figure 2.5) :




Figure 2.5- Diagnostic à base de modèles

- la génération de résidus : lors cette étape la détermination des grandeurs sensibles aux défauts, appelés résidus est nécessaire, en utilisant les signaux d'entrée et de sortie du système. Plusieurs méthodes peuvent être utilisées pour générer les

résidus à l'aide d'un modèle analytique. On distingue notamment les méthodes reposant soit sur une estimation d'état ou de paramètres;

- l'analyse des résidus : ces derniers sont évalués afin de décider si le système se trouve ou non dans un état de fonctionnement normal. Cette étape est souvent réalisée à l'aide d'un test basé sur un seuil;
- la localisation et l'identification du type de défaillance : la localisation consiste à retrouver l'origine du défaut et isoler la partie défectueuse. Alors qu'un seul résidu peut être suffisant pour détecter un défaut, la localisation nécessite souvent plusieurs résidus. L'identification de défauts est rarement mise en œuvre, et demande des efforts souvent considérés inutiles; les seules informations indiquant la présence et la localisation d'un défaut sont généralement suffisantes.

#### ▪ **Estimation paramétrique**

Cette approche est basée sur des modèles paramétriques d'un procédé. Quel que soit le modèle utilisé (modèle de connaissance ou de représentation) il fait intervenir un certain nombre de paramètres dont les valeurs numériques sont généralement inconnues. Les méthodes d'estimation paramétrique permettent l'obtention des paramètres à l'aide d'une structure du modèle et des mesures disponibles.

Cette technique considère que l'apparition d'une anomalie au sein du système entraîne une modification de son comportement d'où résulte une évolution significative de certains paramètres par rapport à leurs valeurs nominales. Le principe de cette approche consiste à estimer en temps réel les paramètres d'un procédé en utilisant les mesures entrée/sortie et en évaluant l'écart qui les sépare des valeurs de référence. La Figure 2.6 présente le principe de cette approche, où le vecteur  $\hat{\theta}$  contient les paramètres estimés en temps réel et  $\theta_n$  les valeurs nominales correspondantes. Si les valeurs nominales sont inconnues ou incertaines, les résidus peuvent être calculés comme étant l'écart entre l'estimée courante et sa valeur antérieure.

Si le but est uniquement la détection des anomalies, l'utilisation d'un modèle de représentation est suffisante. En revanche, si l'on souhaite localiser les défauts, l'utilisation d'un modèle de connaissance est préférée, puisque les paramètres d'un tel

modèle ont une signification physique directe, ce qui est un avantage pour l'interprétation et la localisation de défauts. Un certain nombre de méthodes utilisables pour ces fins sont décrites dans (Simani et al., 2002).

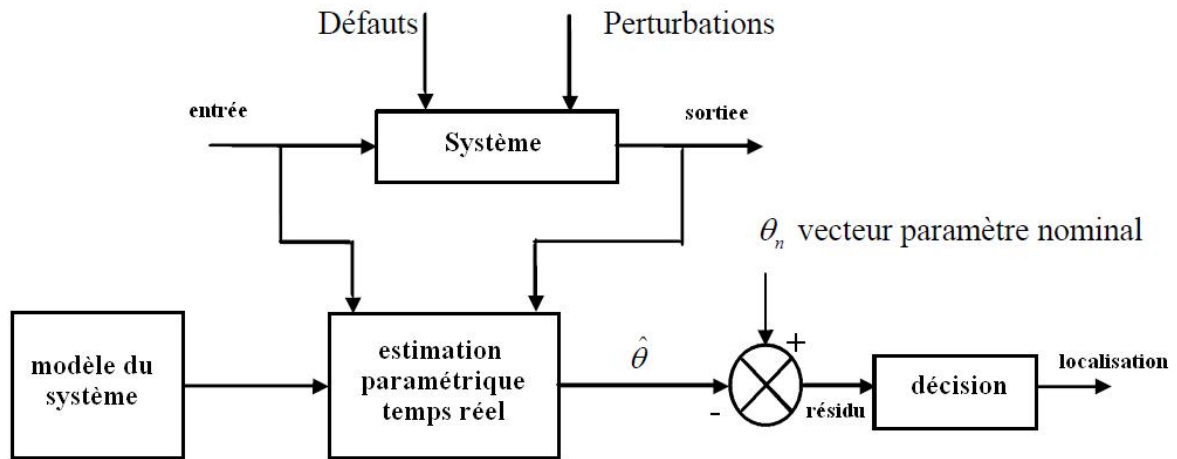


Figure 2.6- Principe de la génération de résidus par estimation paramétrique

Souvent, les méthodes d'identification paramétrique fournissent de bons résultats. Un problème à ne pas négliger lorsqu'il s'agit d'erreurs structurelles déterministes ou d'erreurs bornées est la convergence non garantie vers une solution optimale unique. Dans ce contexte, un ensemble des paramètres admissibles peut être déterminé (à base des méthodes ensemblistes), et le diagnostic peut s'effectuer en vérifiant que l'intersection entre l'ensemble des paramètres admissibles et l'ensemble des paramètres estimés est vide, ce qui signifie l'apparition d'un défaut (Videau et al., 2006).

#### ▪ Estimation d'état

Pour réaliser la commande ou la surveillance d'un système décrit par un modèle d'état, il est nécessaire de connaître, à chaque instant, l'état complet. Cette caractéristique est rarement réalisée en pratique. Il est donc nécessaire d'estimer les états du système. Les reconSTRUCTEURS d'état, qui sont des systèmes dynamiques ayant pour entrées, les entrées et les sorties du procédé, fournissent en sortie une estimation de l'état du système.

Estimer l'état du système permet de générer des résidus en comparant les signaux reconstruits avec leur valeur mesurée. L'obtention de cette estimation de l'état se fait généralement par observateurs dans le cas déterministe ou par filtre dans le cas stochastique. Les reconSTRUCTEURS d'état sont classés en fonction de la manière dont ils incorporent l'incertitude de mesure ou de modèle. La Figure 2.7 illustre le principe général de génération de résidu par cette approche.

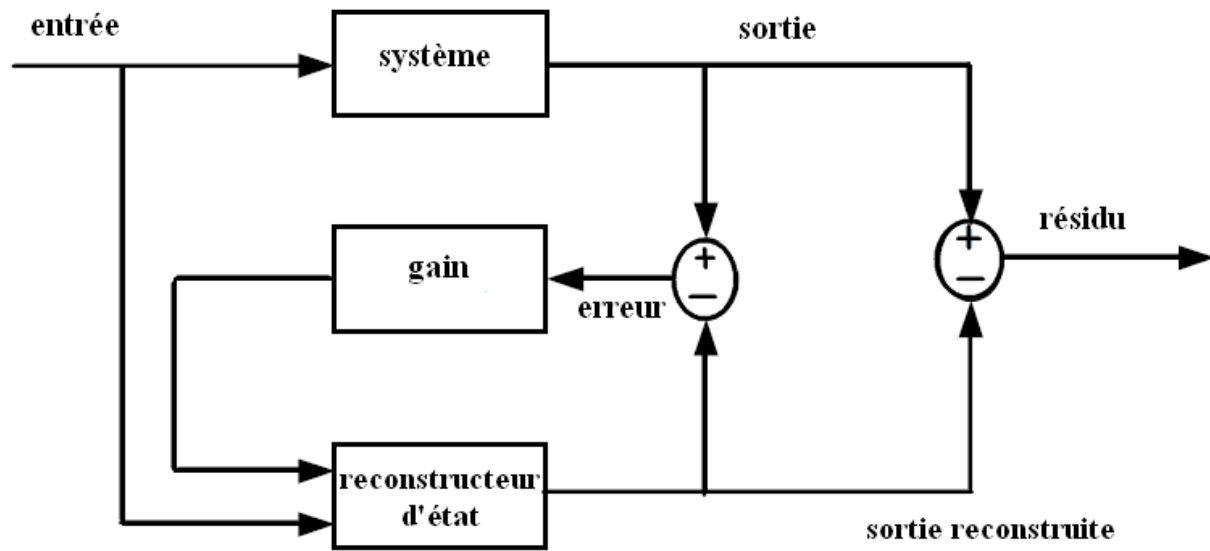


Figure 2.7- Principe de la génération de résidus par un reconSTRUCTEUR d'état

- **l'approche déterministe** : l'estimation d'état d'un système est d'une importance considérable. Le principe de base de la génération de résidus à l'aide d'observateurs est de réaliser une estimation des sorties du système à partir des grandeurs accessibles à la mesure. Les résidus sont calculés à l'aide de l'écart entre la sortie estimée et celle mesurée, c'est-à-dire à l'aide de l'erreur d'estimation sur la sortie. Par exemple, un observateur de Luenberger reconSTRUCTEUR les variables d'état dans un contexte déterministe. Un observateur excité par toutes les entrées et sorties du système est désigné sous le nom de Simplified Observer Scheme (SOS). Un tel observateur, permet la détection des défauts. Néanmoins, la localisation n'est généralement pas réalisable puisque les estimées des sorties réagissent à tout défaut agissant sur le système. On trouve dans la littérature essentiellement deux types de bancs d'observateurs pour générer des résidus qui ne soient sensibles qu'à un ensemble limité de défauts, à savoir le Dedicated Observer Scheme (DOS) et le

Generalized Observer Scheme (GOS). Un DOS est un banc d'observateurs excités par une seule mesure (ou une seule entrée) et donc sensible à un seul défaut capteur (ou actionneur). Dans le cas dual du GOS, les observateurs sont excités par toutes les sorties (ou entrées) sauf une, et donc sensibles à tous les défauts sauf un;

- **l'approche stochastique** : dans le cas où l'état et les mesures sont bruités, on se trouve dans un cadre stochastique et l'état du système peut être estimé à l'aide de filtres. Le filtre de Kalman permet d'estimer l'état à partir d'observations partielles et bruitées. Dans le cas linéaires, lorsque le filtre de Kalman est réglé correctement, son erreur de prédiction (innovation) est censée être un bruit blanc de moyenne nulle et de covariance connue. L'erreur de prédiction peut donc être utilisée comme résidu de détection de défaut; sa moyenne est nulle en l'absence de défauts (et de perturbations) et devient non nulle dans le cas contraire. Plusieurs travaux ont été réalisés dans la littérature pour développer des méthodes de détection de défauts, se basant sur l'erreur de prédiction (innovation) du filtre de Kalman (Chetouani, 2006; Bhagwat et al., 2003). Des méthodes d'estimation à base de modèles multiples (bancs de filtres) ont également été utilisés (Chetouani, 2008);
- **l'espace de parité** : l'approche par espace de parité se base sur un test de cohérence entre le modèle du système (représentation d'état) et les mesures. Elle consiste à réécrire les équations d'état et de mesure afin de ne garder que des variables connues (commandes et sorties). Le principe est d'exprimer une mesure en fonction des autres par une relation connue. La différence pondérée entre la mesure et sa valeur prédite par le modèle du processus à surveiller est appelée résidu. L'approche par espace de parité nécessite d'avoir un modèle d'état précis et complet du procédé. Il existe deux types de relation de redondance analytique (Toscano, 2004) : la redondance statique et la redondance dynamique. Cette méthode est plutôt adaptée pour des modèles linéaires ce qui n'est pas le cas des modèles des processus complexes. L'extension à certaines classes de systèmes non-linéaires a été examinée (Shumsky, 2007).

▪ **Méthodes basées sur les modèles graphiques**

Plusieurs travaux ont été réalisés dans la littérature pour développer des méthodes de diagnostic à base de modèles graphiques. La méthode la plus connue dans ce contexte est celle du bond graph. En effet, cet outil est basé principalement sur la notion de transfert de puissance entre les différentes parties ou composants du système et sur la transformation de l'énergie dans ces composants (dissipation, stockage, conversion du domaine énergétique) (Borutzky, 2010). Ces différents phénomènes, analogues dans tous les domaines physiques, sont codés graphiquement. Le caractère unifié du bond graph constitue un langage de communication universel entre les experts de différentes disciplines.

L'outil bond graph a été initialement utilisé pour la modélisation des systèmes physiques. Le modèle obtenu est un modèle de connaissance. Il a ensuite été utilisé pour la commande (Gawthrop, 2009) et la surveillance des processus (Samantaray et Ould-Bouamama, 2008).

On distingue principalement deux approches bond graph pour la surveillance des processus :

- l'approche qualitative : elle ne nécessite pas de modèle très précis. Les bond graphs qualitatifs ne décrivent explicitement que la localisation des composants du système et leurs interconnexions. Par exemple, la surveillance basée sur la modélisation par bond graph qualitatif pour un système de climatisation a été développée dans (Ghiaus, 1999). Ces modèles qualitatifs sont construits sans aucune considération des paramètres du système. Ils se basent sur des valeurs qualitatives (à la place des valeurs numériques) définies par l'ensemble  $\{[1] [+]$   $[0] [-]$   $[-1] [?]\}$  représentant la qualité de la déviation dans l'espace de mesures par rapport au fonctionnement normal;
- l'approche quantitative : contrairement à l'approche qualitative, elle se base sur des lois physiques et nécessite donc une connaissance profonde de la structure du système et des valeurs numériques des paramètres (modèle de connaissance ou modèle boîte blanche). Par sa structure graphique, l'outil bond graph permet une



analyse causale et structurelle directement sur le modèle. Ces propriétés fonctionnelles et causales permettent alors de générer les résidus à partir des équations de conservation énergétique issues des jonctions. On peut détecter tout type de défauts par cette approche. Depuis les années 1990 on utilise directement les modèles bond graph quantitatifs pour la conception des systèmes de surveillance. Des travaux récents basés sur le principe de Transformations Linéaires Fractionnelles LFT (Linear Fractional Transformations) appliquées au bond graph (Djeziri, 2009) ont permis de développer des algorithmes de génération de résidus robustes aux défauts actionneurs, en présence d'incertitudes paramétriques. L'utilisation de cette approche a permis d'utiliser un seul outil pour la modélisation, la génération des résidus et des seuils adaptatifs de fonctionnement normal et l'analyse de sensibilité. De plus, la compréhension des relations des résidus est simple puisqu'elles correspondent à des relations et des variables qui sont affichées par le modèle bond graph, image du processus physique.

### **2.3.3 Méthodologies d'analyse des risques**

L'analyse des risques d'un procédé industriel est un point capital lors de la mise au point d'un nouveau procédé, de la conception d'une nouvelle installation ou la modification d'une installation existante. Afin de prévenir les risques associés à un procédé, un certain nombre de méthodologies ont été développées pour procéder à une analyse systématique des risques et de leurs conséquences (Brown, 1999). Ces méthodologies servent à mettre en évidence toutes les sources de dangers, à identifier les risques posés par les éléments du système et leurs interactions, à anticiper des dérives et mettre en place des mesures de sécurité (ou barrières dans le cas d'accidents majeurs), pour d'une part éviter que ces déviations apparaissent et d'autre part en limiter les conséquences dans les cas où cette déviation ne pourrait être corrigée. L'application de méthodes d'analyse de risques permet donc de regrouper un certain nombre de données dans le but de maintenir à tout instant l'installation en sécurité que ce soit en fonctionnement normal ou dégradé.

Une comparaison de 62 méthodologies relatives au risque chimique et au transport de matières dangereuses est présentée dans (Tixier et al., 2002). Ces approches s'articulent toutes autour de trois phases :

- **une phase de définition du système et de son environnement** : cette phase préliminaire consiste à décrire le système à analyser en termes d'activités dangereuses, de matériaux dangereux et équipement;
- **une phase d'identification et d'évaluation des dangers** : après avoir choisi une technique d'analyse de dysfonctionnements, une évaluation peut-être réalisée de manière déterministe ou probabiliste pendant cette phase;
- **une phase de hiérarchisation** : cette phase consiste à ressortir les risques potentiels suite aux résultats des deux premières phases, afin de déterminer les barrières de sécurité à mettre en place.

Le choix d'une méthode d'analyse des risques est un problème important qui a des conséquences directes sur la qualité d'analyse. Une discussion à ce sujet peut être trouvée dans (Laurent, 2003). De nombreuses méthodes ont été développées, notamment, nous pouvons citer :

- l'analyse préliminaire des risques,
- la méthode HAZOP,
- la méthode par arbres des défaillances,
- la méthode par arbres d'événements,
- les listes de contrôle,
- l'analyse des modes de défaillances, de leurs effets et de leur criticité (AMDEC).

Le paragraphe suivant présente la méthode HAZOP qui est souvent utilisée.

#### ▪ **Méthode HAZOP**

HAZOP, acronyme des termes HAZard (danger) et OPerability (fonctionnement), est une méthode d'analyse des risques qui a été développée par la société Imperial Chemical Industries (ICI) au début des années 1970 (Dunjó et al., 2010). C'est une méthode typiquement exécutée par un groupe de travail permettant

d'identifier et d'analyser les dysfonctionnements et la mise en place de l'étude de leur prévention/protection. HAZOP est souvent utilisée dans l'industrie et, notamment lors de la conception d'une nouvelle installation, la modification ou la revue d'une installation existante. Cette approche est particulièrement intéressante dans le cas où le système examiné faisant intervenir des circulations de fluide, pour lesquels des paramètres comme le débit, la température, la pression, le niveau ou la concentration sont particulièrement importants pour la sécurité de l'installation. Elle requiert notamment l'examen de schémas et plans de circulation des fluides instrumentés ou schémas PID (Piping and Instrumentation Diagram). La Figure 2.8 présente le principe de l'examen HAZOP.

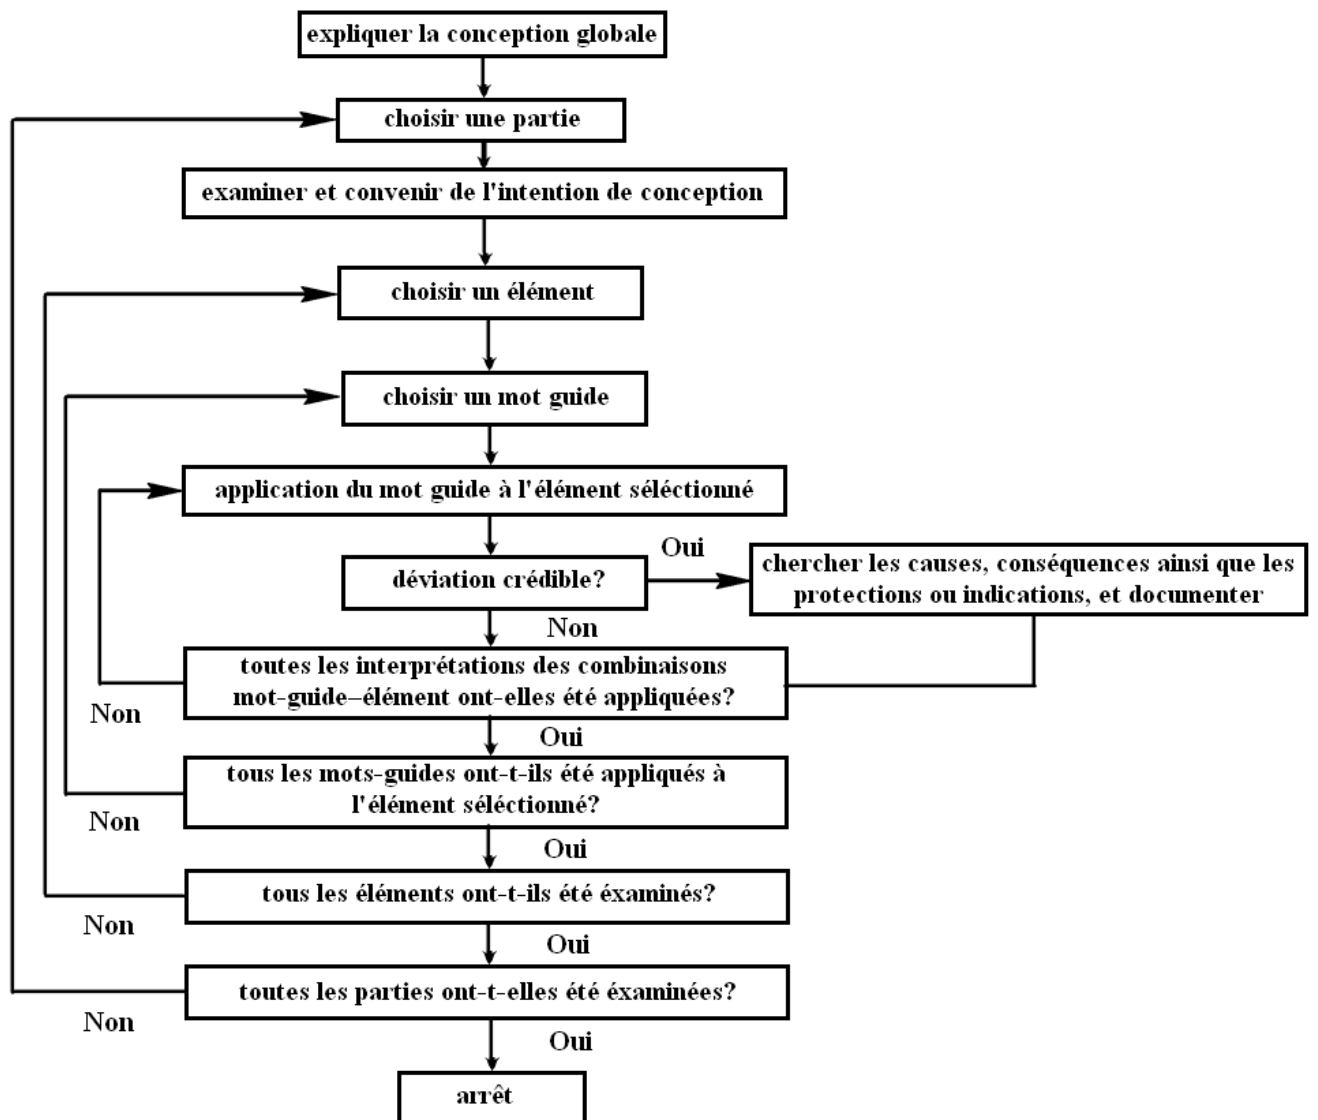


Figure 2.8- Organigramme de la procédure de l'examen HAZOP

L'analyse HAZOP se fait en s'intéressant à ce que l'on appelle points d'étude qui sont les dérives potentielles (ou déviations) des principaux paramètres liés à l'exploitation de l'installation. Pour chaque partie constitutive du système examiné, la génération des dérives est effectuée de manière systématique par l'application :

- de mots clés comme par exemple « Pas de »; « Plus de »; « Moins de »; « Trop de »;
- sur des paramètres associés au système étudié. Des paramètres couramment rencontrés concernent la température, la pression, le débit, la concentration mais également le temps ou des opérations à effectuer.

La qualité d'une analyse de risques par la méthode HAZOP dépend non seulement de la capacité des experts à appliquer la méthode, mais surtout à poser les bonnes questions afin de s'assurer que le groupe de travail identifie tous les risques inhérents au système étudié et non pas seulement les dangers les plus rencontrés. Cette compétence est principalement basée sur l'expérience des experts (méthodologie HAZOP, connaissance des procédés industriels et leur sécurité, de l'accidentologie, ...).

## **2.4 Analyse des résidus**

Dans la section précédente, on a présenté quelques méthodes de génération d'indicateurs de défauts. La particularité essentielle de ces indicateurs est leur sensibilité aux changements de comportement de système (ou des organes qui le composent comme les actionneurs et les capteurs). Les résidus générés doivent être analysés en temps réel afin de fournir une décision indiquant s'ils sont symptomatiques de l'apparition de défauts. Nous allons maintenant présenter quelques méthodes d'analyse de ces résidus afin de décider s'il y a ou non un défaut dans un système.

### **2.4.1 L'analyse fréquentielle**

Cette méthode s'appuie essentiellement sur des outils de traitement de signal. Elle est largement utilisée pour détecter les anomalies dans les machines électriques. L'exploitation du contenu spectral des signaux mesurés permet de détecter la présence de défauts tels que les ruptures de barres au rotor, la dégradation des roulements ou les courts-circuits dans les bobinages. Par ailleurs, beaucoup de travaux ont été consacrés à l'exploitation des approches de diagnostic basées sur l'analyse fréquentielle (Trajin, 2009; Antoni et Sidahmed, 2004). On peut citer, parmi les techniques couramment utilisées, l'analyse de Fourier, l'analyse d'enveloppe, la transformée en ondelettes et les paquets d'ondelettes.

#### **2.4.2 Tests non statistiques de logique à seuil**

Ces tests sont les plus simples à mettre en œuvre. La stratégie consiste à comparer les amplitudes des signaux avec des seuils préétablis. Les seuls paramètres de réglage sont les amplitudes des seuils qui sont réglées en fonction des différentes hypothèses de fonctionnement et de performances désirées. Le franchissement d'un seuil par l'un des signaux génère une alarme. On peut trouver deux types de seuil : seuil de pré-alarme qui permet d'entreprendre une action de maintenance préventive; et seuil d'alarme qui exige l'arrêt de la production et l'engagement d'une action de maintenance corrective. Les tests non statistiques de logique à seuil ont prouvé leur efficacité pour le diagnostic des systèmes physiques (Ballé et al., 1997; Gertler et al., 1995). Ces tests fournissent une détection très rapide de défauts soudains. En revanche, ils ne sont pas bien adaptés pour la détection de défauts de faible amplitude telle que l'apparition de petits biais ou de dérives.

#### **2.4.3 Tests statistiques**

La détection de points de changement dans un processus stochastique est une problématique importante et répandue dans plusieurs domaines. Il s'agit de l'utilisation de tests permettant la détection de changement des caractéristiques statistiques d'une variable aléatoire. L'hypothèse de base de cette catégorie de méthodes est que les propriétés statistiques des observations sont différentes avant et après l'instant du point de changement, ce qui se traduit par une modification dans la

moyenne et/ou la variance des données. Un des premiers tests, et qui reste encore aujourd'hui largement utilisé dans l'industrie, est le test des sommes cumulées CUSUM (Basseville et Nikiforov, 1993). Cette dernière approche d'analyse des résidus sera la seule considérée dans la suite de ce manuscrit, étant donné sa simplicité de mise en œuvre et sa faible complexité algorithmique.

## **2.5 Conclusion**

Après une brève introduction dans laquelle nous avons décrit la problématique abordée et le contexte général du travail, nous avons présenté quelques méthodes de diagnostic, souvent utilisées dans la littérature, permettant de détecter les défaillances survenant au sein d'un système dynamique. Une attention particulière est portée aux méthodes à base de modèles sans oublier une revue rapide des méthodes sans modèle et d'analyse des risques. Les techniques à base de modèles, nécessitent une connaissance des dynamiques mises en jeu. Le diagnostic se fait ensuite en utilisant un certain nombre de signaux significatifs (résidus) générés à l'aide d'un modèle représentant le système à surveiller. Selon la représentation utilisée, plusieurs stratégies peuvent être imaginées à cet effet. Néanmoins, le développement d'un modèle mathématique n'est pas toujours facile à cause de différents facteurs tels que la complexité et les non-linéarités présentes dans la dynamique des processus. Une étape de modélisation sera donc nécessaire afin de définir un modèle de référence assez proche de la réalité et d'assurer un diagnostic fiable et robuste.

Comme la phase de modélisation est primordiale pour la génération des résidus et le contrôle de cohérence, le prochain chapitre présentera les différentes méthodes envisagées pour déterminer un modèle mathématique assez précis de la colonne de distillation. Ce modèle sera testé à l'aide de mesures expérimentales.

# **Chapitre 3**

**Identification paramétrique d'un  
processus industriel de distillation**

### **3.1 Introduction**

La complexité croissante des processus industriels au cours des dernières années nous a montré l'importance de la modélisation, notamment pour la commande, la détection de défauts, l'analyse et la conception. La modélisation consiste à caractériser le comportement d'un système par le biais d'un modèle mathématique. Dans ce contexte, la nécessité d'un modèle aussi précis que possible dont la qualité est primordiale pour l'obtention des performances satisfaisantes est justifiée. D'une façon générale, deux types de modèles peuvent être employés pour décrire le comportement d'un système, à savoir : le modèle de connaissance (boîte blanche) et le modèle de représentation (boîte noire).

L'élaboration d'un modèle de connaissance nécessite la connaissance des lois physiques, chimiques, biologiques ou économiques régissant le comportement du système étudié. En effet, si on dispose d'une connaissance suffisante sur ces lois, l'obtention d'un tel modèle est envisageable. Dans la pratique, il est rare qu'une telle connaissance existe en raison d'une complexité importante du système et/ou d'une difficulté de décrire fidèlement les phénomènes présents dans le système. Par conséquent, le développement d'un modèle de connaissance est difficile, voire impossible dans ces conditions. Comme alternative, la modélisation expérimentale, donnant lieu à un modèle de représentation (type boîte noire), est très intéressante dans la mesure où elle permet d'obtenir une représentation du système à partir des données entrée/sortie. Dans ce cas, le problème de modélisation devient essentiellement un problème d'identification et l'objectif est de trouver la structure et les valeurs des paramètres d'un modèle capable de décrire le plus précisément possible le comportement externe du système sans aucune considération des phénomènes internes.

D'un point de vue pratique, l'identification est utilisée pour obtenir, à l'aide d'un modèle mathématique, une représentation du comportement d'un système inconnu. Le problème se pose généralement de la façon suivante : étant donné un ensemble de mesures entrée/sortie réalisées sur un processus de nature quelconque (physique, chimique, biologique, économique), on suppose qu'il existe une relation



déterministe entre les entrées et les sorties mesurées. Le problème est alors de rechercher une forme mathématique de cette relation, valable dans le domaine où les mesures ont été réalisées. En d'autres termes, il s'agit de construire un modèle entrées/sorties du processus étudié à partir des mesures disponibles (Toscano, 2004).

Il n'existe pas de méthode systématique permettant de choisir le modèle le plus approprié à la description d'un système donné. Néanmoins, un grand nombre de techniques ont été développées dans la littérature sur ce sujet. Pour plus de détails, le lecteur peut se référer aux références suivantes (Billings, 2013; Isermann et Münchhof, 2011; Landau et al., 2011; Söderström et Stoica, 1989). Plusieurs stratégies peuvent être utilisées pour définir un modèle linéaire ou non-linéaire d'un système (Giri et Bai, 2010; Nelles, 2001; Ljung, 1999;).

L'identification de la colonne de distillation a fait l'objet de nombreux travaux à cause de son comportement complexe. Un grand nombre de méthodes a été utilisé à cet effet telles que : le modèle ARX (Muddu et al., 2010), le modèle ARMAX (Waller et Boling, 2005), les modèles BJ et OE (Huyck et al., 2011), les Réseaux de neurones artificiels (Chetouani, 2009), les modèles à base de blocs structurés (Nugroho et al., 2004; Zhu, 1999). Cependant, dans le cadre de ce mémoire les modèles linéaires ARX et ARMAX et les modèles non-linéaires NARX, NARMAX et Hammerstein ARMAX (HARMAX) ont été employés pour approximer le comportement de la colonne de distillation, principalement pour leur simplicité et leur capacité de prédiction.

Dans ce chapitre, des modèles paramétriques linéaires et non-linéaires sont développés pour identifier le comportement dynamique de la température en tête de colonne représentant la sortie du procédé. Une comparaison est réalisée entre les modèles en termes de complexité et de précision pour différentes structures. Notre objectif est d'identifier un modèle de référence décrivant correctement le comportement de la dynamique du procédé. Ce modèle permet de prédire le plus précisément possible la sortie du processus dans différentes conditions de fonctionnement. Une validation du modèle identifié sera effectuée à travers des

comparaisons entre sa sortie (résultats de prédiction) et les observations expérimentales fournies par les capteurs.

### **3.2 Modèles paramétriques**

Le problème de l'identification paramétrique consiste à déterminer les valeurs numériques des paramètres d'un modèle du système considéré. Le choix des variables entrées/sorties d'un système est une phase préliminaire qui permet de faire apparaître les relations de cause à effet entre ces variables. L'identification est une approche expérimentale; elle sert à chercher un modèle mathématique. Ce modèle vise à prédire correctement le comportement dynamique du système réel. L'identification d'un système comporte quatre étapes essentielles (Landau, 2002; Ljung, 1999) :

- l'extraction des données, c'est-à-dire l'obtention des mesures entrées/sorties donnant le maximum d'information;
- la détermination de la structure, c'est-à-dire le choix des termes du modèle. Le choix de la structure dépend des hypothèses sur l'ordre du modèle et la nature du bruit;
- l'identification, c'est-à-dire la détermination des valeurs numériques des paramètres du modèle candidat à partir des mesures entrées/sorties;
- la validation, c'est-à-dire la réalisation de plusieurs tests appropriés. C'est la dernière étape de la procédure d'identification permettant de vérifier la bonne qualité du modèle vis-à-vis du système réel. Il est nécessaire pour cette étape d'utiliser des mesures différentes de celles utilisées lors de l'identification des paramètres.

L'identification d'un système est alors une procédure itérative qui comprend plusieurs étapes (Figure 3.1) où les choix doivent être remis en cause lors d'un échec de la validation du modèle identifié.

Une fois la structure de modèle choisie, l'étape suivante consiste à trouver les paramètres de ce modèle, c'est-à-dire la meilleure estimation possible des paramètres, à partir des mesures réalisées sur le système. On peut admettre que les bonnes valeurs

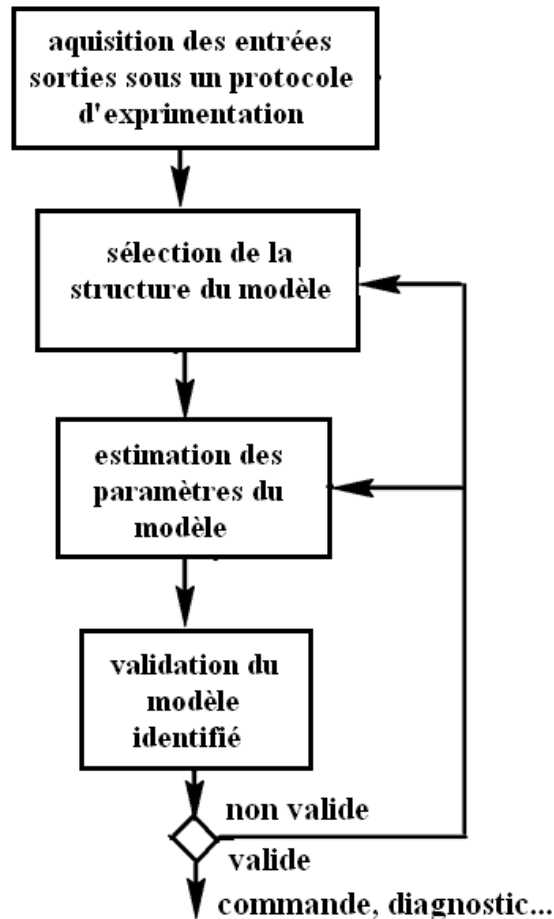


Figure 3.1- Procédure d'identification d'un système

des paramètres seront celles pour lesquelles les valeurs des sorties données par le modèle seront les plus proches possibles de celles effectivement fournies par les capteurs. L'objectif est de trouver les valeurs optimales des paramètres qui minimisent une fonction de coût qui, le plus souvent, est la fonction de coût des moindres carrés (Figure 3.2).

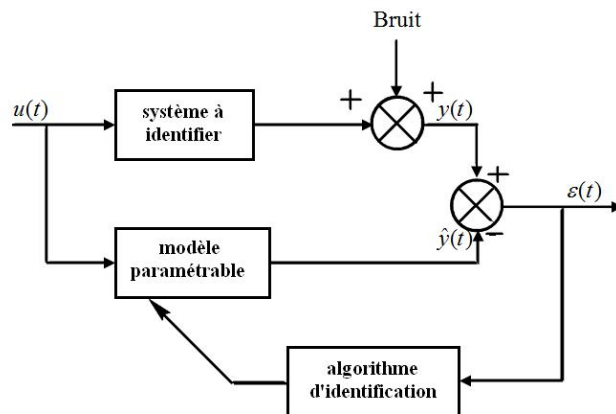


Figure 3.2- Principe de l'identification

Deux stratégies sont possibles pour estimer les paramètres. La première est l'estimation paramétrique non récursive, qui applique des algorithmes de minimisation de la fonction coût sur l'ensemble des données entrées/sorties simultanément. Les inconvénients majeurs de tels algorithmes sont l'impossibilité d'estimation des paramètres pendant l'acquisition des données (temps réel) ainsi que la complexité de calcul. La deuxième est l'estimation paramétrique récursive qui offre de nombreux avantages pour l'identification par rapport à la première. Les principaux avantages de l'estimation paramétrique récursive sont (Landau, 2002) :

- obtention d'une estimation des paramètres au fur et à mesure que le procédé évolue,
- compression importante des données;
- nécessite moins de puissance de calcul et de mémoire;
- mise en œuvre facile sur des calculateurs.

Différents algorithmes faisant appel à des techniques récursives, conduisant à une estimation des paramètres pour des structures spécifiques de modèles, ont été proposés dans la littérature (Billings, 2013; Landau et al., 2011; Giri et Bai, 2010; Ljung, 1999; Söderström et Stoica, 1989). Les algorithmes utilisés dans ce mémoire pour estimer les paramètres des différents modèles sont : MCR, MCE et ESMPE, principalement pour leur simplicité d'implantation et leurs bonnes performances (Aggoune et al., 2014). Néanmoins, d'autres algorithmes peuvent être utilisés.

### **3.2.1 Modèles ARX et NARX**

Le modèle paramétrique ARX permet de décrire le comportement d'un système en reliant sa sortie à un instant  $t$  notée  $y(t)$  aux valeurs de la sortie aux instants précédents  $t-1, t-2, \dots$  notée  $y(t-1), y(t-2), \dots$  et l'entrée  $u(t)$  aux instants précédents  $t-1, t-2, \dots$ , notée  $u(t-1), u(t-2), \dots$  (Landau et al., 2011; Ljung, 1999). Dans le cas des systèmes MISO, ce modèle est donné par l'équation aux différences suivante :

$$y(t) = - \sum_{i=1}^{i=n_a} a_i y(t-i) + \sum_{i=1}^{i=p} \sum_{j=0}^{j=n_{b_i}-1} b_{i,j} u_i(t-d_i-j) + e(t) \quad (3.1)$$

où  $a_i y(t-i)$  est la variable AR (AutoRegressive);  $b_{i,j} u_i(t-d_i-j)$  est la  $i^{\text{ème}}$  variable X (eXogenous);  $e(t)$  représente un bruit de modèle supposé blanc;  $p$  est la dimension du vecteur d'entrée;  $n_a, n_{b_i}, d_i$  représentent respectivement l'ordre de la variable AR (sortie du système), l'ordre de la  $i^{\text{ème}}$  variable X ( $i^{\text{ème}}$  entrée du système) et le retard entre la  $i^{\text{ème}}$  entrée et la sortie.  $a_1 \dots a_{n_a}, b_{1,0} \dots b_{p,n_{b_p}-1}$  sont les paramètres du modèle à estimer.

L'extension aux systèmes non-linéaires du modèle ARX est réalisée par le modèle NARX (Billings, 2013; Leontaritis et Billings, 1985), qui permet la modélisation des systèmes complexes. Pour les systèmes MISO, la structure NARX est décrite par :

$$y(t) = f(y(t-1), y(t-n_y), u_1(t-d_1), u_1(t-d_1-n_{u_1}+1), u_p(t-d_p), u_p(t-d_p-n_{u_p}+1)) + e(t) \quad (3.2)$$

où  $f$  est une fonction non-linéaire. Cette fonction est généralement inconnue. Il existe de nombreuses familles de fonctions de base (basis functions) telles que les fonctions polynomiales, les splines, les ondelettes et les fonctions radiales de base (Qi et Li, 2009; Sjöberg et al., 1995). Un choix judicieux des termes du modèle et la forme de la fonction non-linéaire permet d'approximer le comportement des systèmes complexes. Dans ce travail, la représentation polynomiale est choisie pour approximer  $f$  en raison de sa simplicité et de ses performances (Billings, 2013; Chen et Billings, 1989). L'équation d'une telle représentation est la suivante :

$$y(t) = \sum_{i_1=1}^n \beta_{i_1} x_{i_1}(t) + \sum_{i_1=1}^n \sum_{i_2=i_1}^n \beta_{i_1, i_2} x_{i_1}(t) x_{i_2}(t) + \dots + \sum_{i_1=1}^n \sum_{i_l=i_{l-1}}^n \beta_{i_1, \dots, i_l} x_{i_1}(t) \dots x_{i_l}(t) + e(t) \quad (3.3)$$

où  $n = n_y + n_{u_1} + \dots + n_{u_p}$ ,  $l$  est le degré du polynôme, les variables  $\beta$  représentent les paramètres du modèle et les variables  $x$  représentent la sortie et les entrées retardées (c'est-à-dire aux instants  $t-1, t-2, \dots$ ).

Nous allons maintenant présenter la technique de recherche des valeurs numériques des paramètres des modèles ARX et NARX. Notre choix s'est porté sur la méthode MCR (Landau et al., 2011). La sortie de chaque modèle, donnée par les équations (3.1) et (3.3), s'écrit également sous la forme équivalente suivante :

$$y(t) = \varphi^T(t)\theta + e(t) \quad (3.4)$$

où  $\varphi^T(t)$  est le vecteur de régression (ou vecteur des observations) dont les composantes sont constituées des mesures réalisées sur système, et  $\theta$  est le vecteur des paramètres à identifier. Dans le cas d'un modèle ARX, on peut écrire :

$$\varphi^T(t) = [-y(t-1), \dots, -y(t-n_a), u_1(t-d_1), \dots, u_p(t-d_p), \dots, u_p(t-n_{bp}-d_p+1)] \quad (3.5)$$

$$\theta = [a_1, \dots, a_{n_a}, b_{1,0}, \dots, b_{1,n_{b1}-1}, \dots, b_{p,0}, \dots, b_{p,n_{bp}-1}] \quad (3.6)$$

Pour un modèle NARX, le vecteur de régression  $\varphi^T(t)$  contient un certain nombre des sorties et entrées précédentes ainsi que de leurs combinaisons jusqu'au degré du polynôme  $l$ .

Le critère à optimiser (fonction de coût) que nous considérons dans ce travail est le critère des moindres carrés donné par :

$$J(\theta) = \frac{1}{N} \sum_{t=1}^N \lambda^{(N-t)} [y(t) - \varphi^T(t)\hat{\theta}(t)]^2 \quad (3.7)$$

où  $N$  représente le nombre de mesures disponibles, et le terme  $\varphi^T(t)\hat{\theta}(t)$  représente la prédiction de la sortie  $y(t)$ . L'estimation de  $\theta^*$  est définie comme la valeur  $\hat{\theta}$  qui minimise le critère (3.7). Le modèle décrit par l'équation (3.4) est linéaire par rapport aux paramètres, l'algorithme MCR peut être utilisé pour estimer le vecteur  $\theta$ . Cet algorithme est donné par le système d'équations suivant :

$$\begin{cases} \hat{\theta}(t) = \hat{\theta}(t-1) + P(t)\varphi(t)\varepsilon(t) \\ P(t) = \frac{1}{\lambda} (P(t-1) - \frac{P(t-1)\varphi(t)\varphi(t)^T P(t-1)}{\lambda + \varphi(t)^T P(t-1)\varphi(t)}) \\ \varepsilon(t) = y(t) - \varphi(t)^T \hat{\theta}(t) \end{cases} \quad (3.8)$$

où  $P$  est le gain d'adaptation,  $\lambda$  est un facteur d'oubli ( $0 < \lambda \leq 1$ ) et  $\varepsilon(t)$  est l'erreur de prédiction (résidu).

L'algorithme MCR doit être initialisé, c'est-à-dire que l'on doit fournir les valeurs initiales  $P(0)$  et  $\hat{\theta}(0)$ . Il existe deux façons d'initialiser l'algorithme :

- des valeurs initiales sont fixées, généralement  $\hat{\theta}(0)=0$  et  $P(0)=\alpha I$  où  $\alpha$  représente un très grand scalaire (par exemple  $\alpha = 1000$ ,  $\alpha = 10000$ ) et  $I$  est la matrice unité;
- l'algorithme commence à l'itération  $K + 1$  ( $KI = \text{MAX}(n_a, n_{b_i}, d_i) + 1$ ) avec :

$$\hat{\theta}(0) = (\Phi^T \Phi)^{-1} \Phi^T Y \text{ et } P(0) = (\Phi^T \Phi)^{-1} \quad (3.9)$$

$P(0)$  est obligatoirement inversible avec :

$$Y = \begin{bmatrix} y(KI) \\ \vdots \\ y(K) \end{bmatrix} \text{ et } \Phi = \begin{bmatrix} \varphi^T(KI) \\ \vdots \\ \varphi^T(K) \end{bmatrix} \quad (3.10)$$

### 3.2.2 Modèles ARMAX et NARMAX

Le modèle ARMAX décrit la sortie d'un système à un instant  $t$  non seulement à partir des entrées et des sorties mais également des bruits passés. Ce modèle est très utilisé pour la description des systèmes complexes (Hervé, 2012; Ríos-Moreno et al., 2007; Maddison, 2005). Le modèle ARMAX à plusieurs entrées et une seule sortie possède la structure suivante :

$$y(t) = - \sum_{i=1}^{i=n_a} a_i y(t-i) + \sum_{i=1}^{i=p} \sum_{j=0}^{j=n_{b_i}-1} b_{i,j} u_i(t-d_i-j) + \sum_{i=1}^{i=n_c} c_i e(t-i) + e(t) \quad (3.11)$$

où  $a_i y(t-i)$  est la variable AR (AutoRegressive);  $b_{i,j} u_i(t-d_i-j)$  est la  $i^{\text{ème}}$  variable X (eXogenous);  $c_i e(t-i)$  représente la variable MA (MovingAverage) du bruit de modèle supposé blanc;  $p$  est la dimension du vecteur d'entrée;  $n_a, n_{b_i}, n_c, d_i$  représentent respectivement les dimensions de la variable AR (sortie du système), de la  $i^{\text{ème}}$  variable X ( $i^{\text{ème}}$  entrée du système), de la variable MA et le retard entre la  $i^{\text{ème}}$  entrée et la sortie.  $a_1 \dots a_{n_a}, b_{1,0} \dots b_{p,n_{b_p}-1}, c_1 \dots c_{n_c}$  représentent les paramètres du modèle à estimer.

L'extension au cas non-linéaire du modèle (3.11) est introduite dans

(Leontaritis et Billings, 1985) où il a été montré que le modèle non-linéaire ARMAX (NARMAX) peut représenter une large classe de systèmes non-linéaires. Dans le cas d'un système MISO, ce modèle a pour équation :

$$y(t) = f(y(t-1), \dots, y(t-n_y), u_1(t-d_1), \dots, u_1(t-d_1-n_{u1}+1), \dots, u_p(t-d_p), \dots, u_p(t-d_p-n_{up}+1) + e(t-1), \dots, e(t-n_e)) + e(t) \quad (3.12)$$

Lorsque les termes  $e(t-1), \dots, e(t-n_e)$  ne sont pas considérés, le modèle (3.12) se ramène à un modèle NARX. Si on admet une représentation polynomiale de la fonction  $f$ , la structure générale d'une telle représentation est donnée par l'équation suivante :

$$y(t) = \sum_{i_1=1}^n \beta_{i_1} z_{i_1}(t) + \sum_{i_1=1}^n \sum_{i_2=i_1}^n \beta_{i_1, i_2} z_{i_1}(t) z_{i_2}(t) + \dots + \sum_{i_1=1}^n \sum_{i_l=i_{l-1}}^n \beta_{i_1, \dots, i_l} z_{i_1}(t) \dots z_{i_l}(t) + e(t) \quad (3.13)$$

Avec  $n = n_y + n_{u_1} + \dots + n_{u_p} + n_e$ ,  $l$  est le degré du polynôme, les variables  $\beta$  représentent les paramètres du modèle et les variables  $z$  représentent la sortie, les entrées le bruit retardés (c'est-à-dire aux instants  $t-1, t-2, \dots$ ).

Pour déterminer les paramètres des modèles ARMAX et NARMAX, les équations (3.11) et (3.13) sont exprimées comme suit :

$$y(t) = \varphi^T(t) \theta + e(t) \quad (3.14)$$

où

$$\varphi^T(t) = \left[ -y(t-1), \dots, -y(t-n_a), u_1(t-d_1), \dots, u_1(t-n_{b1}-d_1+1), \dots, u_p(t-d_p), \dots, u_p(t-n_{bp}-d_p+1), e(t-1), \dots, e(t-n_c) \right] \quad (3.15)$$

$$\theta = \left[ a_1, \dots, a_{n_a}, b_{1,0}, \dots, b_{1,n_{b1}-1}, \dots, b_{p,0}, \dots, b_{p,n_{bp}-1}, \dots, c_1, \dots, c_{n_c} \right] \quad (3.16)$$

dans le cas du modèle NARMAX le vecteur de régression  $\varphi^T(t)$  est composé d'un certain nombre des valeurs passées des entrées, de la sortie, du bruit ainsi que de leurs



combinaisons jusqu'au degré du polynôme  $l$ . Il faut rappeler que les termes  $e(t-1), \dots, e(t-n_c)$  ne sont pas mesurables, ce qui rend l'estimation des paramètres par la méthode MCR impossible. Cependant, on suppose que ces termes peuvent être estimés itérativement à partir de la différence entre la sortie mesurée et celle prédite par les modèles ARMAX et NARMAX. Par conséquent, le vecteur de paramètres  $\theta$  peut être estimé en utilisant MCE. La séquence du bruit  $e(t)$  peut être estimée itérativement par :

$$\varepsilon(t) = y(t) - \hat{y}(t) \approx e(t) \quad (3.17)$$

Le vecteur de régression  $\varphi^T(t)$  du modèle ARMAX devient alors :

$$\varphi^T(t) = \left[ -y(t-1), \dots, -y(t-n_a), u_1(t-d_1), \dots, u_1(t-n_{b1}-d_1+1), \dots, u_p(t-d_p), \dots, \right. \\ \left. u_p(t-n_{bp}-d_p+1), \varepsilon(t-1), \dots, \varepsilon(t-n_c) \right] \quad (3.18)$$

Il a été démontré dans (Ljung, 1999) que la convergence de l'algorithme MCE peut être assurée lorsque :

$$\frac{1}{1+c_1z^{-1}+\dots+c_{n_c}z^{-n_c}} - \frac{1}{2} > 0 \quad (3.19)$$

où  $z$  est une variable complexe.

La sortie estimée  $\hat{y}(t)$  est donnée par l'expression suivante :

$$\hat{y}(t) = \varphi^T(t-1)\hat{\theta} \quad (3.20)$$

Les valeurs initiales des termes  $\varepsilon(0), \dots, \varepsilon(-n_c)$  sont choisies nulles. Les paramètres estimés des modèles ARMAX et NARMAX sont obtenus par l'algorithme (3.8).

Il est aussi possible d'utiliser l'algorithme ESMPE pour estimer le vecteur de paramètres  $\theta$  des modèles ARMAX et NARMAX. Le lecteur peut se référer par exemple aux références suivantes pour plus de détails sur cet algorithme (Landau et al., 2011; Landau, 2002).

Considérons l'équation (3.14) à laquelle on ajoute le terme  $\pm(a_1\hat{y}(t-1)...a_{n_a}\hat{y}(t-n_a))$ . Les vecteurs de régression et de paramètres du modèle ARMAX sont maintenant définis par :

$$\varphi^T(t) = \left[ -\hat{y}(t-1), \dots, -\hat{y}(t-n_a), u_1(t-d_1), \dots, u_1(t-n_{b_1}-d_1+1), \dots, u_p(t-d_p), \dots, \right. \\ \left. u_p(t-n_{b_p}-d_p+1), \varepsilon(t-1), \dots, \varepsilon(t-n_c) \right] \quad (3.21)$$

$$\theta = \left[ a_1, \dots, a_{n_a}, b_{1,0}, \dots, b_{1,n_{b_1}-1}, \dots, b_{p,0}, \dots, b_{p,n_{b_p}-1}, \dots, h_1, \dots, h_{n_h} \right] \quad (3.22)$$

avec  $h_i = c_i - a_i$ ;  $i = 1, 2, \dots, \max(n_a, n_c)$ .

On remarque donc que la sortie mesurée  $y(t)$  est remplacée par son estimée  $\hat{y}(t)$  dans le vecteur de régression. L'estimation des paramètres des modèles ARMAX et NARMAX s'effectue par l'algorithme (3.8).

### 3.2.3 Modèle de Hammerstein

Une autre approche employée dans le domaine de l'identification des systèmes non-linéaires est l'utilisation de modèles à base de blocs structurés (Block-oriented models) (Giri et Bai, 2010). Ils peuvent être obtenus par la mise en série d'un bloc dynamique linéaire et d'un bloc statique non-linéaire. La combinaison de ces deux blocs peut donner un grand nombre de structures de modèles. Parmi eux, on peut citer les structures suivantes : Wiener, Hammerstein, Hammerstein-Wiener, Wiener-Hammerstein. Le plus répandu de ces modèles est celui dit de type Hammerstein. L'intérêt accordé à ce dernier s'explique, en partie, par sa capacité à modéliser différents systèmes physiques (Le et al., 2012; Karra et Karim, 2009; Nugroho et al., 2004). De nombreux travaux de recherche ont été dédiés à l'identification de ce modèle (Rejeb et al., 2011; Giri et al., 2008; Ding et Chen, 2005; Bai et Li, 2004). Le modèle de Hammerstein se compose d'un bloc statique non-linéaire suivi d'un bloc dynamique linéaire. Plusieurs structures peuvent être envisagées pour la représentation du bloc dynamique. Dans la suite, nous supposons que ce dernier est décrit par une structure ARMAX (Ding et Chen, 2005), on parle alors de modèle HARMAX

(Hammerstein ARMAX). Pour les systèmes MISO, la structure d'un tel modèle est donnée sur la Figure 3.3. Les blocs linéaires sont décrits par la structure ARMAX comme suit :

$$y(t) = \frac{B_1(q)}{A(q)} \bar{u}_1(t) + \dots + \frac{B_p(q)}{A(q)} \bar{u}_p + \frac{C(q)}{A(q)} e(t) \quad (3.23)$$

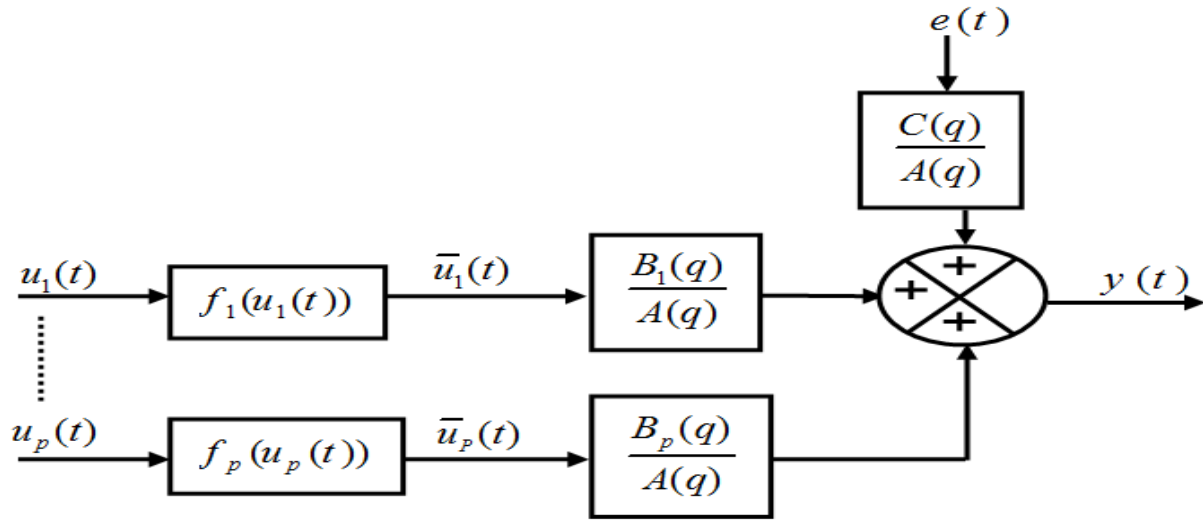


Figure 3.3- Structure d'un modèle HARMAX MISO

où  $A(q)$ ,  $B(q)$  et  $C(q)$  sont des polynômes en  $q^{-1}$  (l'opérateur de retard  $[q^{-1}y(t) = y(t-1)]$ ).

avec :

$$A(q) = 1 + a_1 q^{-1} + \dots + a_{n_a} q^{-n_a} \quad (3.24)$$

$$B_i(q) = b_{i,0} q^{-d_i} + b_{i,1} q^{-(d_i+1)} + \dots + b_{i,n_i} q^{-(d_i+n_i-1)} \quad (3.25)$$

$$C(q) = 1 + c_1 q^{-1} + \dots + c_{n_c} q^{-n_c} \quad (3.26)$$

$y(t)$  est la sortie du système;  $u_i(t)$  est la  $i^{\text{ème}}$  entrée;  $\bar{u}_i(t)$  est un signal intermédiaire qui n'est pas accessible à la mesure;  $e(t)$  est le bruit;  $p$  représente la dimension du vecteur d'entrée;  $n_a$ ,  $n_i$ ,  $n_c$  indiquent l'ordre respectif des polynômes  $A(q)$ ,  $B(q)$  et  $C(q)$ ;  $d_i$  est le

retard de la  $i^{\text{ème}}$  entrée.  $a_1 \dots a_{n_a}, b_{1,0} \dots b_{p,n_p-1}, c_1 \dots c_{n_c}$  sont les paramètres du bloc linéaire.  $n_a, n_i, n_c$  et  $d_i$  sont supposés connus. La fonction  $f_i$  est généralement décrite par une somme de fonctions de base (Qi et Li, 2009; Sjöberg et al., 1995) de la forme :

$$\bar{u}_i(t) = f_i(u_i(t)) = \alpha_{i,0} + \sum_{j=1}^{j=m_i} \alpha_{i,j} g_j(u_i(t)) \quad (3.27)$$

où  $g_j(u_i(t))$  ( $j = 1 \dots m_i$ ) sont des fonctions non-linéaires de base,  $\alpha_{i,0} \dots \alpha_{i,m_i}$  sont des paramètres inconnus et  $m_i$  supposé connu est le nombre de fonctions de base.

Le problème d'identification du modèle HARMAX consiste à retrouver les paramètres des blocs linéaires et non-linéaires à partir des mesures  $\{u_1(t) \dots u_p(t), y(t)\}$ . Pour ce faire, en multipliant (3.23) à gauche et à droite par  $A(q)$ , on obtient :

$$\begin{aligned} y(t) = & -a_1 y(t-1) + \dots + a_{n_a} y(t-n_a) + b_{1,0} \alpha_{1,0} + b_{1,0} \sum_{j=1}^{j=m_1} \alpha_{1,j} g_j(u_1(t)) + \\ & \vdots \\ & + b_{p,0} \alpha_{p,0} + b_{p,0} \sum_{j=1}^{j=m_p} \alpha_{p,j} g_j(u_p(t)) + c_1 e(t-1) + \dots + c_{n_c} e(t-n_c) + e(t) \end{aligned} \quad (3.28)$$

Comme les termes  $e(t-1), \dots, e(t-n_c)$  ne sont pas accessibles à la mesure, leurs estimées sont données par (3.17). En fin, la sortie  $y(t)$  s'exprime comme suit :

$$y(t) = \varphi^T(t) \theta + e(t) \quad (3.29)$$

avec :

$$\theta = \left[ a_1, \dots, a_{n_a}, \gamma_{1,01}, \dots, \gamma_{1,0m_1}, \dots, \gamma_{p,01}, \dots, \gamma_{p,(n_p-1)m_p}, \dots, c_1, \dots, c_{n_c}, \delta \right] \quad (3.30)$$

$$\begin{aligned} \varphi^T(t) = & \left[ -y(t-1), \dots, -y(t-n_a), g_1(t-d_1), \dots, g_{m_1}(t-d_1), \dots, g_p(t-d_p), \dots, \right. \\ & \left. g_{m_1}(t-n_p-d_p+1) + \varepsilon(t-1), \dots, \varepsilon(t-n_c), 1 \right] \end{aligned} \quad (3.31)$$

$$\text{où: } \gamma_{i,jh} = b_{i,j} \alpha_{i,h} \text{ et } \delta = \alpha_{i,0} \sum_{j=0}^{j=n_i-1} b_{i,j} \quad i = 1, \dots, P \quad j = 0, \dots, n_i - 1 \quad h = 1, \dots, m_i \quad (3.32)$$

Il est maintenant possible de retrouver le vecteur de paramètres  $\theta$  à l'aide de la méthode MCE et l'algorithme (3.8). La méthode ESMPE peut aussi être utilisée pour déterminer les paramètres du modèle HARMAX en remplaçant la sortie mesurée  $y(t)$  par son estimée  $\hat{y}(t)$  dans le vecteur de régression.

### 3.3 Choix des variables entrées/sorties et élaboration de la base de données

Avant de procéder à la collection des données expérimentales, une étape préliminaire permettant de définir les entrées et les sorties pertinentes est nécessaire. Les entrées/sorties utilisées pour l'identification d'un modèle de la colonne de distillation sont définies expérimentalement dans (Chetouani, 2009). La sortie représente la température en tête de colonne ( $T_d$ ); les entrées sont la puissance de chauffe ( $Q_b$ ), la puissance de préchauffe ( $Q_f$ ), le débit d'alimentation ( $F$ ), le taux de reflux ( $R_t$ ), la pression différentielle ( $\Delta P$ ) et la température de préchauffe ( $T_f$ ) comme montre la Figure 3.4. Il s'agit donc de considérer la colonne comme un système MISO.

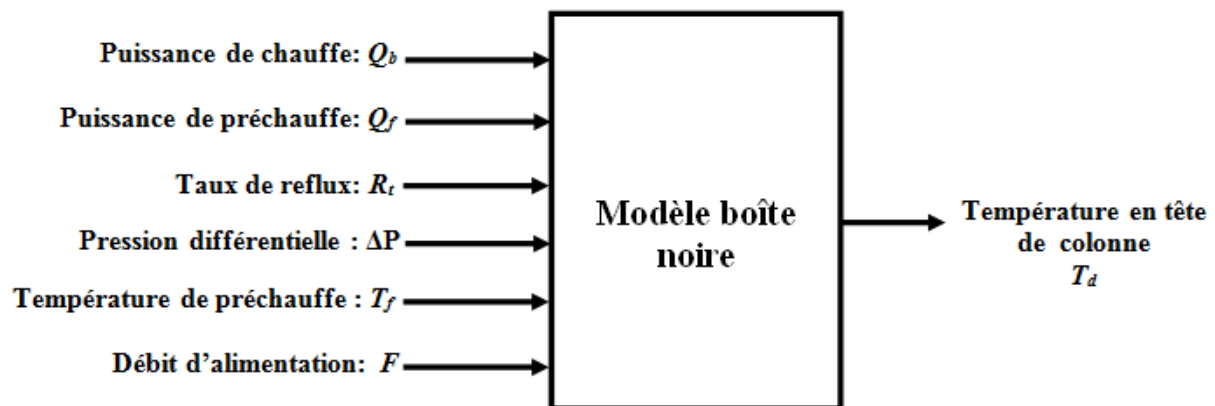


Figure 3.4- Schéma fonctionnel du modèle boîte noire de la colonne

Afin d'obtenir une base de données appropriée pour la prédiction du comportement de la température  $T_d$  sous les conditions normales de fonctionnement, nous avons mis la colonne en comportement normal mais en faisant varier la température  $T_d$  dans l'intervalle [101.5°C 103.5°C] et le débit d'alimentation a été varié dans l'intervalle [30% 60%] pendant une durée de 13h. La période d'échantillonnage est fixée à 11 secondes. L'intervalle de variation de la température  $T_d$  a été défini à partir du

diagramme isobare liquide vapeur du mélange toluène/méthylcyclohexane. Les mesures recueillies sur le procédé sont séparées en un sous ensemble d'estimation que nous utiliserons pour la recherche du vecteur de paramètres et un autre sous ensemble qui servira à valider le modèle identifié. Ces mesures sont illustrées sur les Figures 3.5 et 3.6. Cette dernière figure représente l'évolution de  $Q_b$ ,  $Q_f$ ,  $R_t$  et  $\Delta P$  entre 1540 seconds et 2365 secondes pour une meilleure lisibilité.




Figure 3.5- Représentation des données d'estimation et de validation

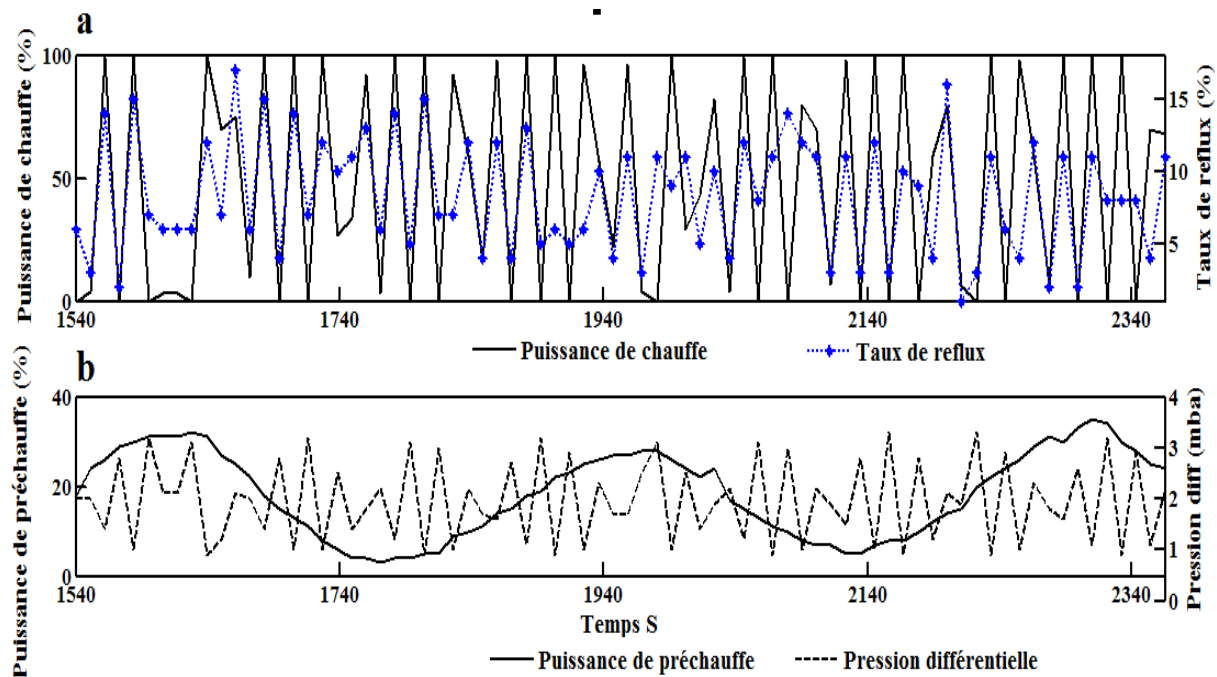


Figure 3.6- (a) Évolution de  $Q_b$  et  $R_t$  (b) Évolution de  $Q_f$  et  $\Delta P$

### 3.4 Recherche du modèle de référence

Après avoir introduit les notions de base concernant les modèles choisis, et la question du choix des variables d'entrées et de sorties, nous allons présenter dans cette partie les résultats permettant de choisir le meilleur modèle entrée/sortie parmi ceux utilisés. Le but est de trouver un modèle MISO permettant de décrire de manière fidèle l'évolution de la température  $T_d$  avec la meilleure prédiction possible, parmi les différentes représentations proposées. Cette qualité est assurée par un choix judicieux de la structure des modèles de type boîte noire. Toute la difficulté réside alors dans le choix du vecteur de régression nécessaire pour décrire le système. On cherche à obtenir un modèle qui soit, d'une part, aussi simple que possible contenant un minimum de paramètres, et d'autre part, précis en disposant d'une bonne capacité d'approximation.

Le choix de la structure consiste dans la détermination des ordres et des retards des modèles ARX, ARMAX, NARX, NARMAX et HARMAX, qui ainsi spécifient la complexité de la représentation la plus apte à caractériser le comportement dynamique de la colonne. La littérature propose un nombre important d'approches visant à sélectionner les termes des modèles mathématiques. Nous pouvons citer : le rapport de réduction d'erreur (error reduction ratio en anglais) (Billings, 2013), l'utilisation des algorithmes évolutionnaires (Cheng, 2011) ou les méthodes fondées sur l'utilisation de critères statistiques (Ljung, 1999).

Afin de sélectionner le meilleur modèle, des critères statistiques ont été construits en faisant varier le nombre de paramètres des différents modèles (Landau et al, 2011; Ljung, 1999) pour la prédiction de la température  $T_d$ . Dans le cadre de ce travail, nous utiliserons les critères statistiques suivants : AIC (Aikeke's Information Criterion), RMSE (Root Mean Square Error) et NSE (Nash-Sutcliffe Efficiency) (Akaike, 1974; Nash and Sutcliffe, 1970), donnés par :

$$AIC = \ln\left(\frac{N}{2}V\right) + \frac{2n}{N} \quad (3.33)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (\hat{y}(t) - y(t))^2}{N}} \quad (3.34)$$

$$NSE = \left( 1 - \frac{\text{var}(\varepsilon(t))}{\text{var}(y(t))} \right) \quad (3.35)$$

où  $N$  est le nombre de mesures,  $n$  représente le nombre de paramètres à estimer et  $V$  est la fonction de perte donnée par :

$$V = \frac{1}{N} \sum_{i=1}^N \varepsilon_i^2 \quad (3.36)$$

La structure permettant d'avoir le minimum des critères AIC, RMSE, et le maximum du critère NSE est sélectionné en tant que structure optimale. La sélection d'un modèle parmi un ensemble de candidats se fait en comparant les performances de chacune des représentations proposées dans la section précédente (ARX, ARMAX, NARX, NARMAX, HARMAX), après l'estimation des paramètres.

L'élaboration de l'ensemble des modèles candidats est réalisée par la combinaison des coefficients  $n_a$ ,  $n_b$ ,  $n_c$ ,  $d$ ,  $l$  et  $m_i$  qui peuvent prendre respectivement les valeurs suivantes :  $\max (n_a = 5, n_b = 5, n_c = 5, d = [5 \ 10 \ 5 \ 5 \ 10 \ 50], l = 4 \text{ et } m_i = 5)$ , et l'utilisation des équations (3.1), (3.3), (3.11), (3.13) et (3.23).

Dans un premier temps, nous allons étudier les modèles linéaires ARX et ARMAX et les algorithmes MCR, MCE et ESMPE pour l'estimation des paramètres. Ensuite, nous évaluerons les performances de prédiction du comportement dynamique de la température  $T_d$ . Dans un deuxième temps, nous allons étudier les modèles non-linéaires NARX, NARMAX et HARMAX. Enfin, nous évaluerons les performances des meilleures structures des différents modèles pour choisir un modèle de référence de la colonne à distiller.

### 3.4.1 Identification des modèles linéaires ARX et ARMAX

Afin de sélectionner les modèles ARX et ARMAX appropriés capables de



prédire le comportement dynamique de l'unité de distillation, plusieurs combinaisons des ordres et des retards (AR, MA, X et le retard  $d$ ) ont été examinées. Toutes les structures sont paramétrées dans le but d'obtenir des représentations comparables. En utilisant les critères statistiques, une comparaison de performances des différentes structures de modèles ARX et ARMAX est donnée dans les Tableaux 3.1, 3.2 et 3.3 (en ne présentant que les résultats significatifs). Les paramètres de ces modèles sont estimés à l'aide des données tracés sur les Figures 3.5 et 3.6.

Ordres [ $n_a, n_b$ ]	Retards $d$	AIC	NSE	RMSE
[2, 112111]	[2 4 3 1 6 8]	2.8736	0.6001	0.1185
[2, 112211]	[2 4 2 2 7 12]	2.9171	0.5826	0.1211
[2, 112121]	[2 4 2 3 7 16]	2.8746	0.6000	0.1185
[2, 112112]	[2 4 2 4 6 18]	2.8828	0.5967	0.1190
[2, 222111]	[2 4 2 1 5 20]	2.8501	0.6100	0.1170
[2, 122212]	[2 4 2 2 4 26]	2.8716	0.6015	0.1183
[2, 122211]	[1 2 2 2 4 26]	2.8999	0.5901	0.1200
[2, 112221]	[1 2 3 3 5 26]	2.9223	0.5808	0.1213
[2, 221211]	[1 3 1 2 6 30]	2.8569	0.6074	0.1174
[2, 122221]	[1 3 1 1 5 34]	2.8983	0.5911	0.1199
[3, 122221]	[1 3 2 1 4 36]	2.6128	0.6929	0.1039
[3, 122222]	[1 3 2 2 3 38]	1.9738	0.8380	0.0754
<b>[3, 122232]</b>	<b>[1 3 1 2 2 41]</b>	<b>1.9083</b>	<b>0.8484</b>	<b>0.0730</b>
[3, 1 2 2 3 2 2]	[1 4 2 1 6 44]	2.3795	0.7572	0.0924
[3, 123222]	[1 4 2 2 5 46]	2.2780	0.7806	0.0878
[3, 132222]	[2 5 2 1 5 48]	2.4328	0.7439	0.0949
[3, 222222]	[2 5 3 2 2 49]	2.3783	0.7575	0.0923
[4, 122232]	[2 5 1 2 2 50]	2.0612	0.8235	0.0787

Tableau 3.1- Comparaison entre différentes structures du modèle ARX identifiées par l'algorithme MCR

Ordres [ $n_a, n_b, n_c$ ]	Retards $d$	AIC	NSE	RMSE
[2, 222232, 2]	[1 4 2 1 5 8]	-0.2968	0.9833	0.0242
[2, 222322, 2]	[1 4 2 1 5 14]	-0.3091	0.9835	0.0241
[2, 223222, 2]	[1 4 1 1 5 17]	-0.3198	0.9837	0.0239
[2, 232222, 2]	[1 4 2 2 6 19]	-0.2497	0.9825	0.0248
[2, 322222, 2]	[1 4 1 1 5 20]	-0.3239	0.9837	0.0239
[2, 222222, 2]	[1 3 1 2 5 21]	-0.3207	0.9837	0.0239
[2, 222231, 2]	[2 3 2 2 4 30]	-0.2894	0.9832	0.0243
[3, 222231, 1]	[2 5 2 2 5 30]	-0.2628	0.9827	0.0246
[3, 222321, 1]	[2 5 1 2 6 33]	-0.3127	0.9836	0.0240
[3, 223221, 1]	[1 3 2 1 3 22]	-0.2871	0.9831	0.0243
[3, 233121, 1]	[1 3 2 1 4 25]	-0.2999	0.9834	0.0242
[3, 332121, 1]	[1 3 2 1 5 25]	-0.2766	0.9830	0.0245
[4, 223121, 1]	[1 3 2 1 5 30]	-0.3254	0.9838	0.0239
[4, 232121, 1]	[1 3 2 2 6 30]	-0.3099	0.9835	0.0241
<b>[5, 123121, 1]</b>	<b>[1 3 1 3 4 34]</b>	<b>-0.3376</b>	<b>0.9840</b>	<b>0.0237</b>
[5, 213121, 1]	[2 4 1 1 5 36]	-0.3071	0.9835	0.0241
[5, 122231, 1]	[2 4 1 1 6 38]	-0.3218	0.9837	0.0239
[5, 222121, 1]	[2 4 2 2 6 46]	-0.2846	0.9831	0.0244

Tableau 3.2- Comparaison entre différentes structures du modèle ARMAX identifiées par l'algorithme MCE

Ordres $[n_a, n_b, n_c]$	Retards $d$	AIC	NSE	RMSE
[2, 2 2 2 1 2 1, 2]	[1 5 1 2 6 8]	-0.3212	0.9837	0.0240
[2, 1 2 2 1 2 1, 2]	[1 4 1 1 5 20]	-0.3638	0.9843	0.0234
[2, 1 1 1 1 1 1, 2]	[1 4 2 1 5 30]	-0.2679	0.9827	0.0246
[2, 1 2 1 1 1 1, 2]	[1 4 2 1 5 40]	-0.2717	0.9828	0.0246
<b>[2, 1 2 2 2 2 1, 2]</b>	<b>[1 4 1 1 5 46]</b>	<b>-0.3687</b>	<b>0.9844</b>	<b>0.0234</b>
[2, 1 2 3 1 2 1, 2]	[1 3 1 2 4 46]	-0.3348	0.9839	0.0238
[2, 1 3 2 1 2 1, 2]	[1 5 2 2 5 46]	-0.2417	0.9823	0.0249
[2, 1 2 2 2 1 1, 2]	[1 3 1 2 5 46]	-0.3370	0.9839	0.0238
[2, 1 2 2 1 1 1, 2]	[1 3 1 1 3 46]	-0.3196	0.9836	0.0240
[2, 1 2 3 1 2 1, 2]	[1 3 2 1 4 46]	-0.2797	0.9830	0.0244
[2, 1 3 2 1 2 1, 2]	[1 4 1 2 5 46]	-0.3571	0.9843	0.0235
[2, 2 2 2 2 2 1, 2]	[1 5 1 1 5 46]	-0.3674	0.9844	0.0234
[2, 1 2 2 1 2 2, 2]	[1 5 2 1 5 46]	-0.2830	0.9830	0.0244
[2, 1 2 2 1 3 1, 2]	[1 5 1 2 5 46]	-0.3581	0.9843	0.0235
[2, 1 2 2 1 1 1, 2]	[1 3 1 1 3 46]	-0.3196	0.9836	0.0240
[2, 1 2 2 1 1 1, 2]	[1 4 2 1 5 50]	-0.2839	0.9830	0.0244
[3, 1 2 2 2 2 1, 3]	[2 4 1 2 6 46]	-0.3673	0.9844	0.0234
[3, 1 2 3 1 2 1, 3]	[2 4 1 1 5 46]	-0.3618	0.9844	0.0234

Tableau 3.3- Comparaison entre différentes structures du modèle ARMAX identifiées pas l'algorithme ESMPE

La meilleure structure du modèle ARX est obtenue avec  $n_a = 3$ ,  $n_b = [1 2 2 2 3 2]$ , et  $d = [1 3 1 2 2 41]$ . Les critères statistiques correspondants sont : AIC = 1.9083, NSE = 0.8484 et RMSE = 0.0730 (voir Tableau 3.1).

D'après les résultats du Tableau 3.2, les valeurs des critères statistiques de la structure optimale du modèle ARMAX identifié par l'algorithme MCE sont : AIC = -0.3376, NSE = 0.9840 et RMSE = 0.0237. Ces valeurs sont obtenues avec  $n_a = 5$ ,  $n_b = [1 2 3 1 2 1]$ ,  $n_c = 1$ , et  $d = [1 3 1 3 4 34]$ .

En se basant sur les résultats du Tableau 3.3, la meilleure structure du modèle ARMAX identifié par l'algorithme ESMPE est la suivante :  $n_a = 2$ ,  $n_b = [1 \ 2 \ 2 \ 2 \ 1]$ ,  $n_c = 2$ , et  $d = [1 \ 4 \ 1 \ 1 \ 5 \ 46]$ . Les valeurs des critères statistiques obtenues pour les données d'estimation sont :  $AIC = -0.3687$ ,  $NSE = 0.9844$  et  $RMSE = 0.0234$ .

La différence entre les trois structures choisies provient de la façon dont les ordres et les retards sont combinés. Nous allons maintenant examiner les comportements dynamiques des meilleures structures pour les données de validation. Les Figures 3.7-3.12 présentent des comparaisons entre la sortie mesurée du système et celle estimée par les modèles ARX et ARMAX ainsi que les erreurs de prédiction correspondantes.

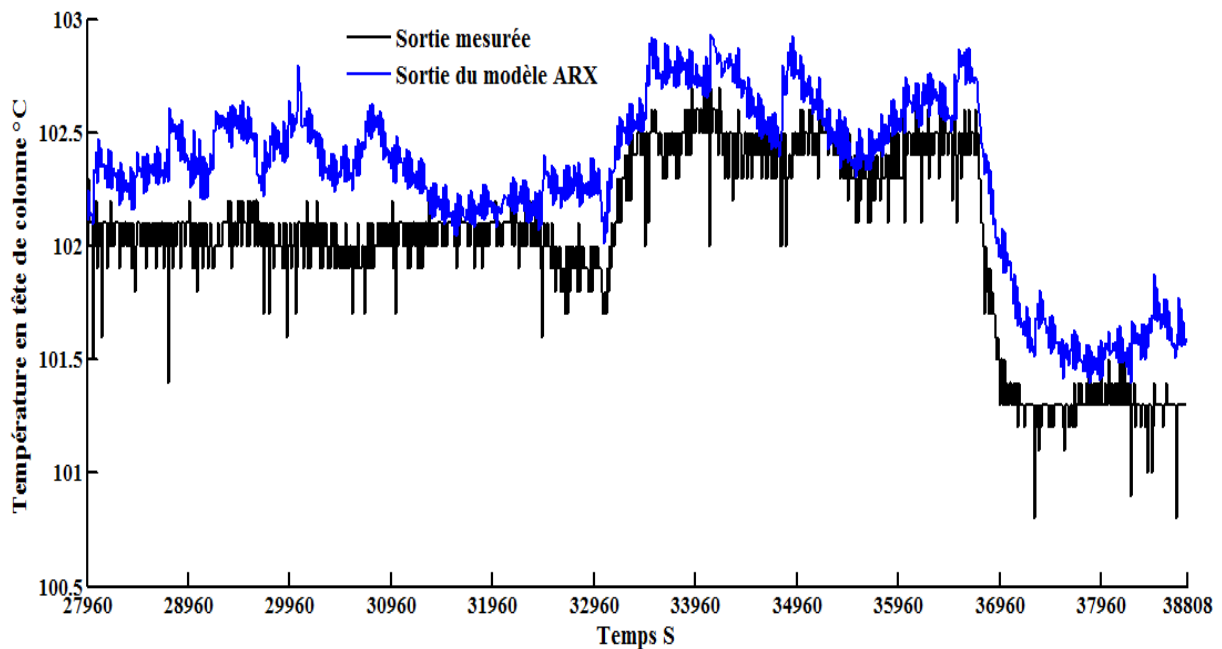


Figure 3.7- Comparaison entre la sortie du système et celle du modèle ARX identifié par l'algorithme MCR




Figure 3.8- Évolution de l'erreur de prédiction du modèle ARX pour les données de validation

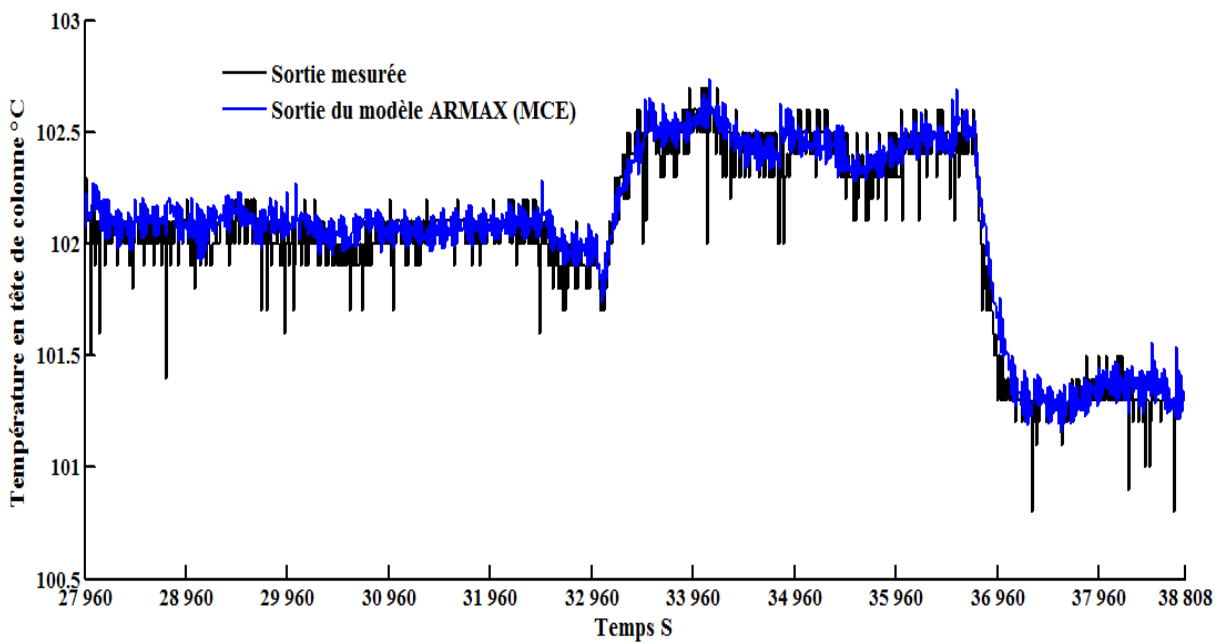


Figure 3.9- Comparaison entre la sortie du système et celle du modèle ARMAX identifié par l'algorithme MCE




Figure 3.10- Évolution de l'erreur de prédiction du modèle ARMAX identifié par l'algorithme MCE pour les données de validation

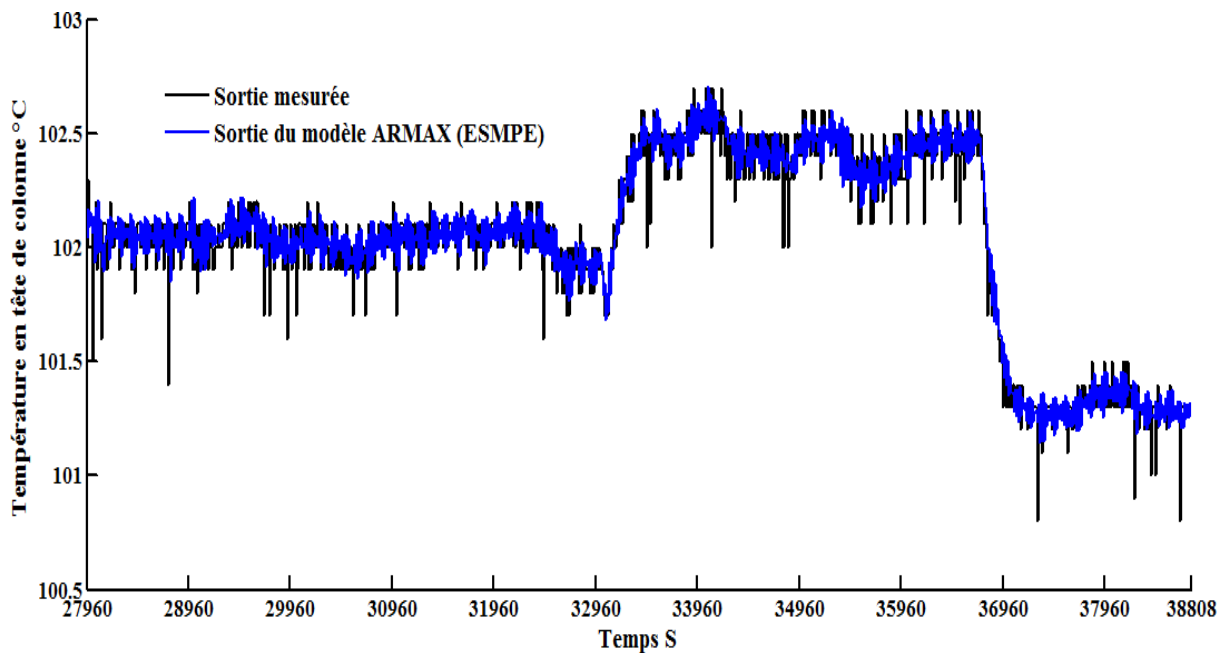


Figure 3.11- Comparaison entre la sortie du système et celle du modèle ARMAX identifié par l'algorithme ESMPE




Figure 3.12- Évolution de l'erreur de prédiction du modèle ARMAX identifié par l'algorithme ESMPE pour les données de validation

Les résultats d'identification des modèles linéaires choisis présentés ci-dessus permettent de visualiser les performances de prédiction des meilleures structures de chaque modèle. Ces résultats montrent que la prédiction de la température  $T_d$  obtenue avec le modèle ARMAX est meilleure que celle obtenue avec le modèle ARX, cela peut facilement être vérifié à travers les résultats de comparaisons entre la sortie mesurée et celle estimée par les meilleurs structures. De plus, les valeurs numériques des critères statistiques permettent de confirmer la qualité du modèle ARMAX. Cela permet de justifier le choix du type de structure linéaire utilisé dans le modèle de Hammerstein.

D'après les Figures 3.9 et 3.11, les deux modèles ARMAX identifiés parviennent à reproduire le comportement de la colonne à distiller. Afin de choisir la meilleure expression des modèles ARMAX (identifiés par les algorithmes MCE et ESMPE), des comparaisons entre les erreurs de prédiction des structures optimales ont été établies à l'aides d'un jeu de données différent de celui utilisé en estimation. Ces erreurs sont illustrées sur les Figures 3.10 et 3.12. Il est possible de constater que l'erreur de prédiction commise avec l'algorithme ESMPE est plus petite que celle de l'algorithme MCE avec un minimum de paramètres. De plus, la sélection entre les

deux structures peut être quantifiée au moyen de la norme deux donnée par la relation suivante :

$$\|\varepsilon\|_2 = \sqrt{|y(1) - \hat{y}(1)|^2 + \dots + |y(N) - \hat{y}(N)|^2} \quad (3.37)$$

La valeur obtenue pour la meilleure structure identifiée par l'algorithme MCE est : 2-norm = 3.84. La valeur obtenue pour la meilleure structure identifiée par l'algorithme ESMPE est : 2-norm=2.84. Ces résultats montrent que le modèle ARMAX identifié par l'algorithme ESMPE est plus parcimonieux et possède une meilleure capacité de prédiction. En effet, ce dernier modèle est choisi comme la meilleure représentation linéaire de l'évolution de la température en tête de colonne. Les paramètres de cette représentation sont donnés dans le Tableau 3.4.

Valeur du paramètre	Terme du modèle
-0.1530	$T_d(t-1)$
-0.8150	$T_d(t-2)$
0.0188	$Q_b(t-1)$
-0.0488	$Q_f(t-4)$
-0.0683	$Q_f(t-5)$
0.1154	$R_t(t-1)$
0.1178	$R_t(t-2)$
0.0249	$\Delta P(t-1)$
-0.0305	$\Delta P(t-2)$
-0.1117	$T_f(t-5)$
-0.0099	$T_f(t-6)$
0.0049	$F(t-46)$
0.3115	$e(t-1)$
0.4814	$e(t-2)$

Tableau 3.4- Paramètres du modèle ARMAX identifiés pas l'algorithme ESMPE



### **3.4.2 Identification des modèles non-linéaires NARX, NARMAX et HARMAX**

Cette sous-section est consacrée à l'identification des modèles NARX, NARMAX et HARMAX basés sur les résultats des représentations linéaires de la température en tête de colonne. Ces résultats sont considérés comme un point de départ pour la définition des meilleures structures de modèles non-linéaires. L'augmentation et la diminution des valeurs optimales des ordres et des retards des modèles ARX et ARMAX (identifiés par l'algorithme ESMPE) ainsi que les termes non-linéaires correspondants permettent de trouver les meilleures structures des modèles NARX, NARMAX et HARMAX par l'évaluation des critères statistiques. Il est ainsi nécessaire de tester les différentes structures avec toutes les données. La sélection d'une structure de modèle ne doit être faite que sur la base de données d'estimation puisque certaines structures peuvent avoir des critères de performances meilleurs que d'autres pour les données d'estimation, et disposer d'une capacité de prédiction médiocre pour les données de validation. La technique retenue pour l'estimation des paramètres des modèles NARMAX et HARMAX est basée sur l'algorithme ESMPE en raison de ses meilleures performances. De plus, l'entrée  $F$  (débit d'alimentation) n'est pas prise en compte dans la relation (3.11).

La meilleure structure du modèle NARX est obtenue avec  $AIC = 1.7579$ ,  $NSE = 0.8699$  et  $RMSE = 0.0676$ . Les valeurs des critères statistiques de la structure optimale du modèle NARMAX sont :  $AIC = -0.4126$ ,  $NSE = 0.9851$  et  $RMSE = 0.0229$ . Les critères de sélection obtenus lors de la définition de la meilleure structure du modèle HARMAX sont :  $AIC = -0.3733$ ,  $NSE = 0.9845$  et  $RMSE = 0.0233$ . Les paramètres et les termes des structures optimales identifiées sont donnés respectivement dans les Tableaux 3.5-3.7.

Les performances des modèles non-linéaires retenus sont évaluées à partir d'un nouveau ensemble de données non utilisées pour l'estimation des vecteurs de paramètres. Une comparaison entre la sortie mesurée et ses estimées ainsi que les erreurs de prédiction obtenues pour chaque modèles sont représentées sur les Figures

3.13-3.18. Il est possible de visualiser sur ces Figures que la prédiction de la température  $T_d$  obtenue avec les modèles NARMAX et HARMAX est meilleure que celle obtenue avec le modèle NARX. Toutefois, on constate que les valeurs des critères statistiques du modèle HARMAX sont proches de celles obtenues avec le modèle ARMAX identifié par l'algorithme ESMPE. La structure optimale du modèle NARMAX fournit les meilleures valeurs des critères statistiques (le minimum des critères AIC, RMSE, et le maximum du critère NSE) alors qu'un nombre supérieur de paramètres a été utilisé.

Valeur du paramètre	Terme du modèle
-0.2992	$T_d(t-1)$
-0.5782	$T_d(t-2)$
-0.0830	$T_d(t-3)$
0.0240	$Q_b(t-1)$
-0.0726	$Q_f(t-3)$
-0.0606	$Q_f(t-4)$
0.1096	$R_t(t-1)$
0.1673	$R_t(t-2)$
-0.0363	$\Delta P(t-2)$
0.0097	$\Delta P(t-3)$
0.0496	$T_f(t-2)$
-0.0910	$T_f(t-3)$
-0.0964	$T_f(t-4)$
0.0205	$F(t-41)$
-0.0152	$F(t-42)$
-0.0719	$Q_b(t-1)*R_t(t-2)$
0.0685	$Q_b(t-1)*R_t(t-3)$
-0.0457	$Q_b(t-5)*R_t(t-4)$

Tableau 3.5- Paramètres du modèle NARX retenu

Valeur du paramètre	Terme du modèle
-0.2601	$T_d(t-1)$
-0.6901	$T_d(t-2)$
0.0228	$Q_b(t-1)$
-0.0427	$Q_f(t-4)$
-0.0558	$Q_f(t-5)$
0.0685	$R_t(t-1)$
0.1053	$R_t(t-2)$
0.0165	$\Delta P(t-1)$
-0.0199	$\Delta P(t-2)$
-0.0971	$T_f(t-5)$
-0.0027	$T_f(t-6)$
0.3524	$e(t-2)$
0.4175	$e(t-1)$
0.2139	$T_d(t-2)*R_t(t-1)*\Delta P(t-5)$
0.1093	$R_t(t-6)*\Delta P(t-1)*\Delta P(t-6)$
-0.1050	$Q_b(t-1)*R_t(t-4)*\Delta P(t-1)$

Tableau 3.6- Paramètres du modèle NARMAX retenu

Lors de l'élaboration des modèles linéaires et non-linéaires, il a été constaté que le changement des ordres et des retards des modèles réalisé de manière à obtenir la meilleure prédiction possible de la sortie du système est d'une importance majeure. La prédiction de la température  $T_d$  est très sensible aux variations des valeurs des ordres et des retards des meilleures structures ARMAX et HARMAX. En effet, une petite déviation de l'ordre ou du retard d'une entrée peut donner une prédiction avec de performances très éloignées de celles des structures optimales. Par contre, le modèle NARMAX identifié n'est pas sensible (ou ne l'est que de manière légère) aux variations des valeurs des ordres et des retards. Ainsi, les performances de prédiction restent satisfaisantes.

Valeur du paramètre	Terme du modèle
-0.1807	$T_d(t-1)$
-0.7847	$T_d(t-2)$
0.0168	$Q_b(t-1)^2$
-0.2264	$1/(1+\exp(-Q_f(t-4)))$
-0.2874	$1/(1+\exp(-Q_f(t-5)))$
-0.1614	$\exp(-R_i(t-1))$
-0.1455	$\exp(-R_i(t-2))$
0.0124	$\exp(\Delta P(t-1))$
-0.0234	$\exp(\Delta P(t-2))$
0.5421	$1/(1+\exp(T_f(t-5)))$
0.0186	$1/(1+\exp(-F(t-46)))$
0.3049	$e(t-1)$
0.4493	$e(t-2)$

Tableau 3.7- Paramètres du modèle HARMAX retenu




Figure 3.13- Comparaison entre la sortie du système et celle du modèle NARX




Figure 3.14- Évolution de l'erreur de prédiction du modèle NARX

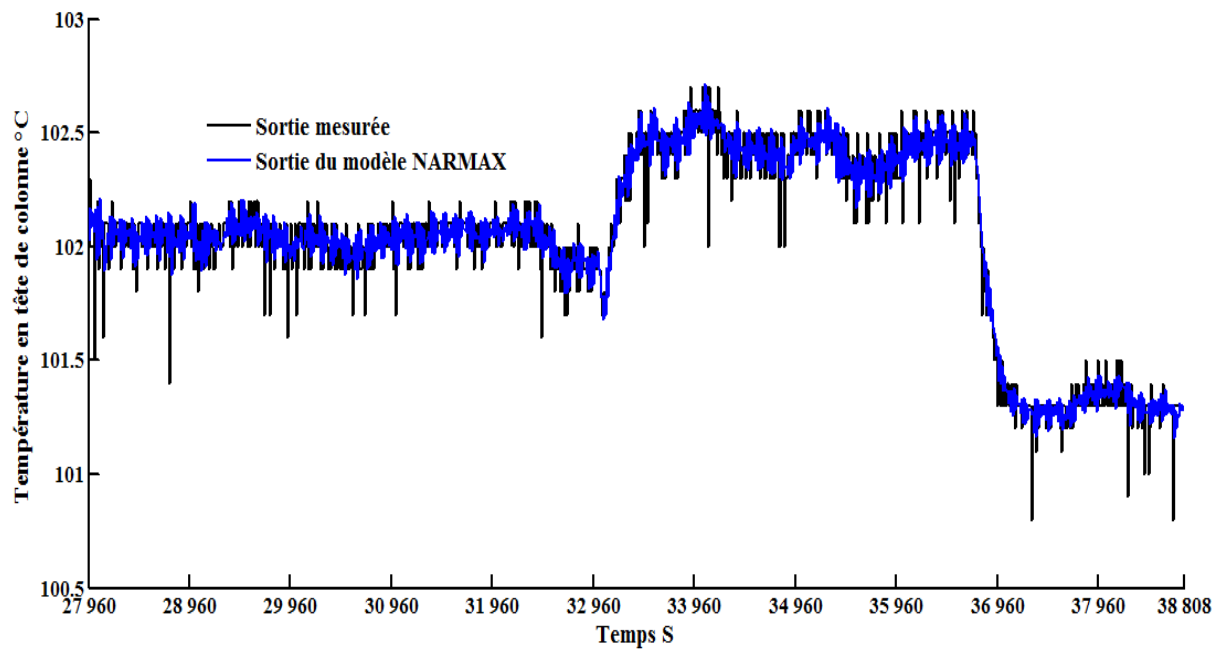


Figure 3.15- Comparaison entre la sortie du système et celle du modèle NARMAX




Figure 3.16- Évolution de l'erreur de prédiction du modèle NARMAX

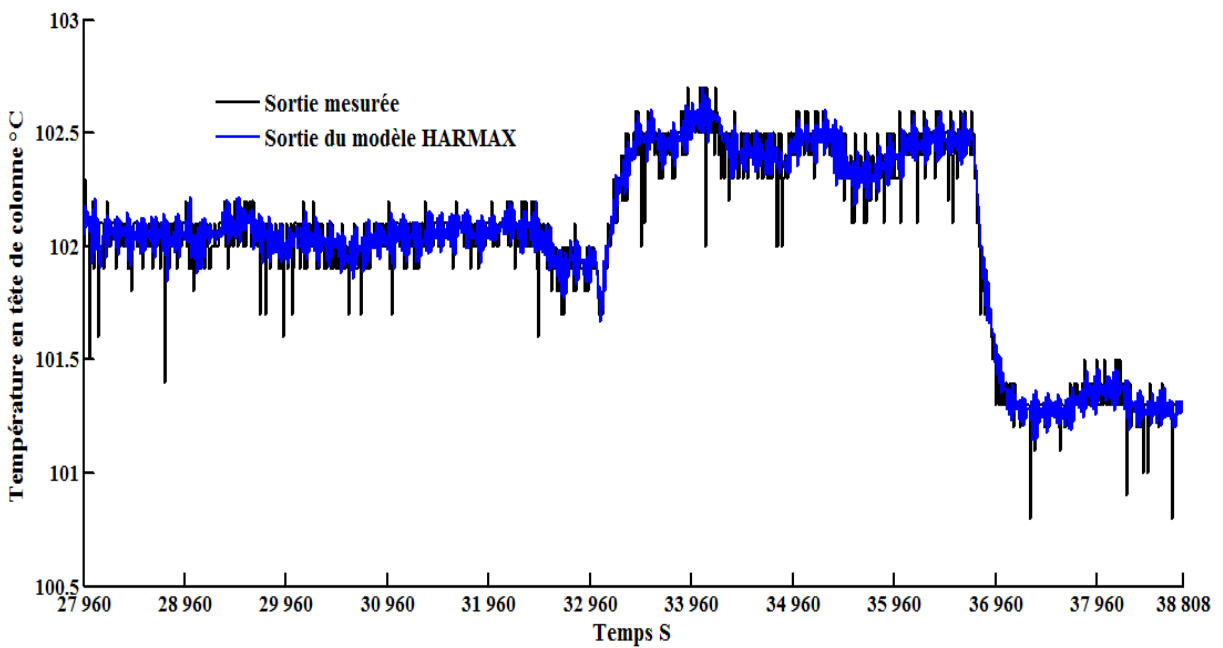


Figure 3.17- Comparaison entre la sortie du système et celle du modèle HARMAX




Figure 3.18- Évolution de l'erreur de prédiction du modèle HARMAX

Les résultats obtenus avec les meilleures structures linéaires et non-linéaires pour les données d'estimation et de validation sont présentés dans le Tableau 3.8.

Modèles	AIC	RMSE	NSE	Nombre de paramètres	Nombre d'entrées	2-norm (validation)
ARMAX (ESMPE)	-0.3687	0.9844	0.0234	14	6	2.84
NARMAX	-0.4126	0.9851	0.0229	17	5	2.79
HARMAX	-0.3733	0.9845	0.0233	14	6	2.83

Tableau 3.8- Comparaison des performances des meilleures structures identifiées

Sur la base des performances de prédiction obtenues avec les meilleurs modèles identifiés, le modèle NARMAX est le meilleur parmi les trois du point de vue précision, parce qu'il donne la plus petite erreur de prédiction sur les données de validation. De plus, ce modèle est robuste aux variations des ordres et des retards des entrées. Pour ces raisons, le modèle NARMAX est choisi comme le modèle de référence qui représente l'évolution de la température en tête de la colonne à distiller.

Il faut noter que le modèle identifié ne vérifie pas nécessairement les critères de validation expliqués dans la section suivante.

### 3.5 Validation du meilleur modèle

La dernière étape de la procédure d'identification est la validation du meilleur modèle obtenu compte tenu des données disponibles, de la structure de modèle proposée, du critère à optimiser et de l'algorithme d'estimation du vecteur de paramètres utilisé. Cette dernière étape permet de consolider les choix faits ou alors de remettre en cause certaines étapes de la procédure d'identification. Plusieurs aspects peuvent invalider le modèle identifié comme par exemple avoir des valeurs inadmissibles pour des paramètres physiques (résistance négative,...), le caractère prédictif (une séquence d'entrée différente appliquée au modèle ne permet pas d'approcher la sortie mesurée) ou la non robustesse (dépendance forte vis-à-vis des conditions initiales ou vis-à-vis de perturbations faibles sur les entrées). Il existe plusieurs approches permettant de valider le modèle identifié. Comme les méthodes d'estimation des paramètres employées sont basées sur le blanchissement de l'erreur de prédiction, on utilise alors le test de blancheur de l'erreur de prédiction pour la validation avec des nouvelles données non utilisées lors de l'identification du modèle (Landau et al, 2011). Il s'agit de vérifier que l'erreur de prédiction centrée (la valeur moyenne a été soustraite), obtenue comme différence entre la sortie réelle du système  $y(t)$  et la sortie du modèle identifié  $\hat{y}(t)$  (voir Figure 3.16), tendra asymptotiquement vers un bruit blanc dont la fonction d'autocorrélation  $\phi_{\varepsilon\varepsilon}(\tau)$  est une impulsion de Dirac. C'est-à-dire :  $\phi_{\varepsilon\varepsilon}(\tau) = 0$  pour  $\tau \neq 0$  et  $\phi_{\varepsilon\varepsilon}(\tau) = 1$ .  $\phi_{\varepsilon\varepsilon}(\tau)$  est donnée par la relation suivante :

$$\phi_{\varepsilon\varepsilon}(\tau) = E[\varepsilon(t-\tau)\varepsilon(t)] = \delta(\tau) \quad \forall \tau \quad (3.38)$$

où  $\varepsilon(t)$  est l'erreur de prédiction,  $E(X)$  est l'espérance mathématique de  $X$  et  $\tau$  est le décalage. En réalité, cette condition idéale est difficile à vérifier car le nombre de mesures disponible est souvent limité. D'autre part,  $\varepsilon(t)$  contient des erreurs résiduelles de structure (erreurs sur l'ordre, sur le retard, etc.). En conséquence on considère



comme critère pratique de validation l'intervalle de confiance avec 5% de risque d'erreur. La fonction d'autocorrélation  $\phi_{\varepsilon\varepsilon}(\tau)$  admet de ce fait des valeurs dans l'intervalle  $\pm 1.96/\sqrt{N}$ , où  $N$  est le nombre de données de validation. Ainsi, Billings et Voon (1986) ont proposé des tests d'intercorrélations entre l'erreur de prédiction et les entrées permettant de valider un modèle. La fonction d'inter corrélation  $\phi_{u\varepsilon}(\tau)$  est donnée par l'équation suivante :

$$\phi_{u\varepsilon}(\tau) = E[u(t-\tau)\varepsilon(t)] = 0 \quad \forall \tau. \quad (3.39)$$

Pour mettre en œuvre ces tests (équations (3.38) et (3.39)),  $u(t)$  et  $\varepsilon(t)$  doivent être centrées. La fonction d'intercorrélations entre les deux séquences  $u(t)$  et  $\varepsilon(t)$  est estimée par le biais de la relation suivante :

$$\phi_{u\varepsilon}(\tau) = \frac{\sum_{t=1}^{N-\tau} u(t)\varepsilon(t+\tau)}{\left[ \sum_{t=1}^N u^2(t) \sum_{t=1}^N \varepsilon^2(t) \right]^{1/2}} \quad (3.40)$$

Si les équations (3.38) et (3.39) sont satisfaites alors l'erreur de prédiction engendrée par le modèle identifié tend asymptotiquement vers un bruit blanc et indépendante des entrées du système. Le modèle identifié est donc valable pour représenter le comportement du système considéré.

La Figure 3.19 illustre les résultats des tests de validation obtenus par le modèle NARMAX. Les marges représentées sur cette figure correspondent à un intervalle de confiance à 95%.

Les tracés des fonctions d'intercorrélations montrent l'intervalle de confiance de 95%. Très peu de points sont à l'extérieur. De plus, nous constatons que ces fonctions sont petites, ce qui assure l'indépendance entre l'erreur de prédiction et les entrées du système. En ce qui concerne la fonction d'autocorrélation du modèle NARMAX, quatre points sont à l'extérieur de l'intervalle de confiance à 95%. Par conséquent, ce modèle est retenu pour représenter l'évolution de la température en tête de colonne.

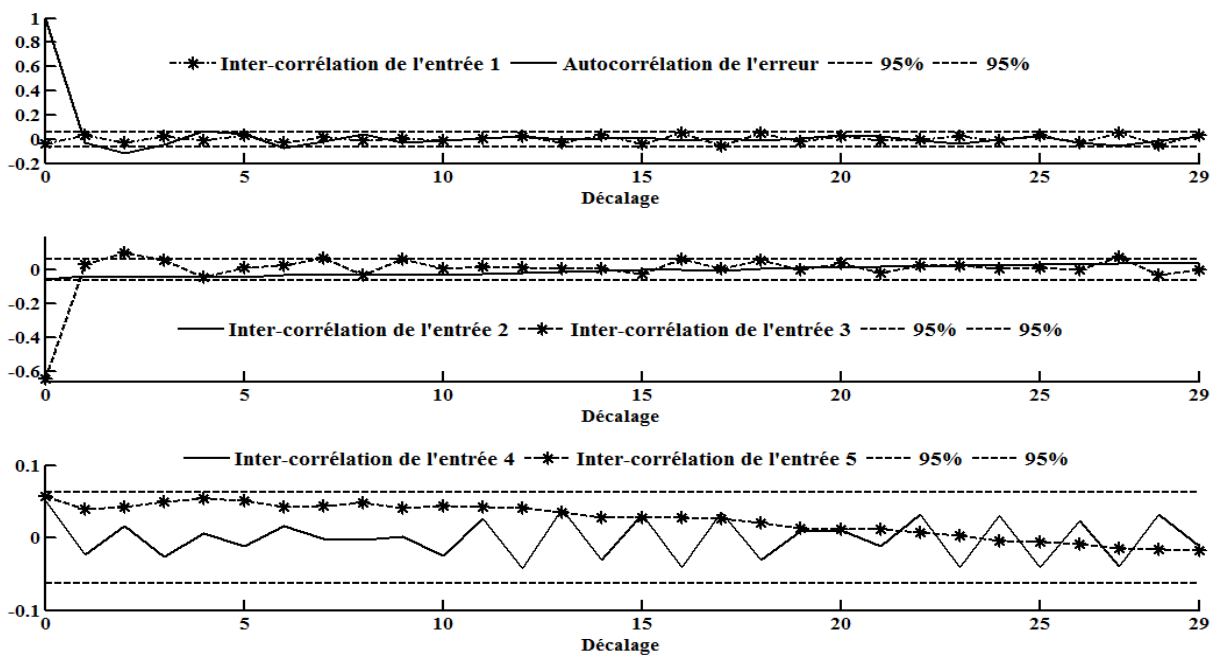


Figure 3.19- Résultats de validation du modèle NARMAX

### 3.6 Conclusion

Le problème d'identification d'une colonne de distillation, par des modèles paramétriques a été abordé. Nous avons commencé par présenter des notions sur l'identification des systèmes dynamiques nécessaire pour la compréhension de la suite du chapitre. Une brève description de la procédure d'élaboration des représentations entrée/sortie a été fournie. Ces représentations viennent répondre, par des techniques qui reposent essentiellement sur un ensemble d'observations expérimentales dont on dispose, aux difficultés dues à la complexité des modèles de connaissance.

Ensuite, nous avons exposé différents types de modèles paramétriques linéaires et non-linéaires pour identifier le comportement dynamique de la température en tête de colonne. Des algorithmes récursifs ont été utilisés pour l'estimation de paramètres des modèles choisis. Plusieurs combinaisons des ordres et des retards des modèles proposés ont été testées avec des données expérimentales. La sélection de la meilleure structure de chaque modèle a été réalisée à l'aide des critères statistiques AIC, NSE et RMSE. Ces critères permettent de choisir le nombre de termes linéaires et non-linéaires des modèles. Nous avons constaté que l'algorithme ESMPE fournit la

meilleure estimation de paramètres des modèles ARMAX, NARMAX et HARMAX. Une étude pour choisir le modèle permettant d'expliquer au mieux le comportement du système a été faite en comparant les valeurs numériques des critères statistiques et la norme deux de la structure optimale de chaque modèle. Nous avons pu mettre en évidence la pertinence du modèle NARMAX par rapport aux autres modèles.

Enfin, l'étape fondamentale de validation permettant de fournir des indices sur la qualité du modèle NARMAX a été réalisée. Les résultats de cette étape ont montré la capacité de ce modèle à approcher le comportement dynamique de la colonne à distiller.

A l'issue de ce chapitre, nous disposons d'un modèle de référence capable de prédire correctement le comportement dynamique de la colonne à distiller lorsqu'il fonctionne normalement. Nous allons maintenant mettre ce modèle au service de la détection de défauts aux entrées de l'unité de distillation dans le chapitre 4.

# **Chapitre 4**

**Tests statistiques pour la détection de  
défauts application à un processus  
industriel de distillation**

## **4.1 Introduction**

Dans le chapitre précédent nous avons proposé une procédure d'identification paramétrique, de type boîte noire, visant à caractériser le comportement dynamique de la colonne à distiller. Nous avons montré que le modèle NARMAX présente d'intéressantes propriétés pour réaliser la meilleure prédiction possible de la température en tête de la colonne. Nous allons montrer dans ce chapitre que le résidu du modèle NARMAX ( $\varepsilon(t) = y(t) - \hat{y}(t)$ ) permet de donner une indication sur l'état de fonctionnement de la colonne avec une certaine confiance. Cette indication peut servir d'entrée à un module de décision dont la fonction est potentiellement critique : il est donc primordial de suivre tout au long de la procédure de distillation l'évolution du résidu du modèle NARMAX. L'objectif de ce chapitre est de proposer une procédure de détection séquentielle (décision dès l'arrivée d'une nouvelle donnée) de défauts d'entrées de l'unité de distillation. La technique développée dans la suite du chapitre utilise des tests statistiques d'hypothèses, qui reposent sur le résidu du modèle NARMAX, pour résoudre le problème de détection d'anomalies.

Les méthodes statistiques sont apparues au début du 20<sup>ème</sup> siècle dans l'industrie pour vérifier la qualité des produits fabriqués. Après avoir connu un essor considérable dans différents domaines de l'industrie, ces méthodes ont été utilisées pour détecter des changements de régime de fonctionnement. En effet, les industriels cherchent continuellement à maîtriser le plus d'aspects possibles des processus dans le but de les rendre efficaces et sûrs. Nous commençons ce chapitre par un aperçu sur les méthodes statistiques pour la détection de changements. Nous présentons tout d'abord les bases statistiques des tests d'hypothèses (en général binaires). Les concepts d'hypothèses de fausse alarme et de non détection seront présentés avec quatre méthodes de détection de changement dans la moyenne du résidu du modèle NARMAX. Nous illustrons ensuite les résultats obtenus de ces quatre méthodes sur la problématique de la détection de défauts des entrées de la colonne à distiller. Ce chapitre permet donc d'évaluer les performances du modèle NARMAX pour la détection robuste de défauts. Nous confirmerons ce dernier point par des défauts expérimentaux. Il convient de

souligner que le résidu du modèle de référence est supposé suivre une distribution gaussienne.

## **4.2 Principe des Méthodes statistiques de décision**

Indépendamment de la manière de générer les indicateurs de défauts, la détection repose sur une prise de décision. En effet, il s'agit de déterminer si le système surveillé est en régime de fonctionnement normal ou en présence de défaut à partir des données collectées sur le système et le comportement de référence. L'idée consiste à essayer de déterminer le régime de fonctionnement du processus. On peut mentionner, parmi les différentes techniques couramment disponibles, les outils statistiques et plus particulièrement les travaux (Ding, 2008; Gentil, 2007; Blank et al., 2006; Gustafson, 2000; Basseville et Nikiforov, 1993). Parmi les tests statistiques de détection, on distingue les tests paramétriques et non paramétriques.

### **4.2.1 Tests non paramétriques**

Cette catégorie de tests est utilisée lorsque la nature de la loi de probabilité suivie par la variable testée n'est pas connue a priori. Les méthodes de détection doivent donc se baser uniquement sur les données disponibles. Brodsky et Darkhovsky (2000) proposent une large revue de ces méthodes pour des données indépendantes ou non, ou encore non stationnaires. Ce type de tests est particulièrement adapté à la finance et à l'économie, où il est généralement difficile, voire impossible, de disposer d'une modélisation du système étudié. On peut distinguer plusieurs tests non paramétriques, parmi lesquels :

- **Test de suites** : ce test analyse l'ordre ou la séquence des valeurs observées. Les observations sont rangées dans deux catégories selon une classification binaire. Tout groupe de résultats consécutifs faisant partie de la même catégorie constitue une suite ou une séquence;
- **Test des signes** : la démarche adoptée pour le test des signes est tout à fait similaire à celle du test de suites. Pour les  $n$  observations d'une variable  $Z_k$ , les signes des différences successives sont notés par  $Z_{k+1}-Z_k$ . Dans ce cas de figure, les groupes de signes consécutifs identiques constituent les suites.

### **4.2.2 Tests paramétriques**

Les tests paramétriques supposent que la variable testée suit une loi de distribution de probabilité connue (généralement une distribution normale). Cette condition doit être remplie pour pouvoir l'application de ces tests. Ces derniers sont utiles car ils permettent de détecter les changements dans les données (la moyenne et/ou la variance pour une distribution normale). La majorité des stratégies de détection d'anomalies est basée sur une quantité statistique connue sous le nom de rapport de vraisemblance. Les tests statistiques mis en place sont des tests séquentiels pour prendre en compte la dynamique du procédé. La manière la plus simple d'élaboration de ces tests est de supposer que les données sont toutes indépendantes et qu'elles suivent la même loi, le plus souvent une loi normale, avec un changement de moyenne et/ou de variance après l'apparition de pannes. C'est dans cette optique qu'ont été mises en œuvre les toutes premières règles de décision par Shewhart (1931) et surtout par Page avec la règle du CUSUM (Page, 1954).

### **4.2.3 Quelques généralités sur les tests d'hypothèses**

En pratique, les résidus générés à l'aide des méthodes à base de modèles sont différents de zéro y compris en mode sain et en l'absence de défauts. Ce phénomène s'explique par la présence de bruits de mesure, de perturbations et d'erreurs de modèles. Souvent, on suppose que le résidu présente un caractère aléatoire. Dans ce contexte, la décision de la présence d'une anomalie ou pas peut être effectuée à l'aide d'outils statistiques de décision et des tests d'hypothèses. Il s'agit, à partir de l'étude d'un ou de plusieurs échantillons, de prendre des décisions concernant l'ensemble des données. Un test d'hypothèse est une procédure dans laquelle un échantillon est utilisé afin de découvrir si l'on peut accepter l'hypothèse (supposée qu'elle est vraie) ou si l'on doit la rejeter (supposée qu'elle est fausse).

Dans la suite, nous allons d'abord définir dans les définitions 4.1 et 4.2 les concepts d'hypothèses et de tests d'hypothèses.

- **Définition 4.1 (Hypothèse statistique  $H$ )**

Pour tout entier  $k > 0$ , une hypothèse  $H_k = \{\theta \in \Theta_k\}$  est un sous-ensemble de  $\Theta$ . On dit que l'hypothèse  $H_k$  est simple lorsque l'ensemble  $\Theta_k$  contient un seul élément, sinon, l'hypothèse est dite composite. L'hypothèse  $H_k$  est vraie si  $\varepsilon \sim P_\theta$  où  $\{\theta \in \Theta_k\}$ .

- **Définition 4.2 (Test Hypothèse)**

On appelle un test statistique (règle de décision) de choix entre  $K$  hypothèses  $H_1, H_2, \dots, H_k$ , une application surjective de l'espace des échantillons sur l'ensemble des hypothèses envisagées  $\delta : \varepsilon \rightarrow \{H_1, H_2, \dots, H_k\}$ .

Les tests statistiques ont pour objectif de rationaliser, à partir de données expérimentale partielles, la prise de décision dans l'étape d'analyse de résidus. Cette prise de décision permet de contrôler les risques d'erreurs en les maintenant dans des limites fixées à l'avance. Leur exécution suppose principalement les cinq opérations suivantes :

- Définition de l'hypothèse  $H_0$  à contrôler, dite hypothèse nulle (l'hypothèse alternative  $H_1$  est définie comme la négation de  $H_0$ );
- Choix d'une loi statistique qui régit la variable aléatoire (variable de test) fonction des résultats expérimentaux dont la distribution de probabilité sous l'hypothèse  $H_0$ , est connue (analytiquement ou par estimation);
- Acceptation d'un risque d'erreur dans la décision étant donné que quelque soit le test mis en place, il va y avoir deux types d'erreurs qui seront détaillées dans la suite de cette section;
- Définition de la région de rejet (ou région critique) de l'hypothèse  $H_0$ ;
- Évaluation de la variable de test sur la base des échantillons observés. Si sa valeur est située dans la région de rejet, on rejette l'hypothèse  $H_0$ ; si elle est à l'extérieur de cette région, l'hypothèse  $H_0$  est acceptée relativement au risque d'erreur choisie.

La première étape de la procédure de décision consiste donc à définir l'hypothèse nulle  $H_0$  selon laquelle on fixe a priori un paramètre de la variable



aléatoire à une valeur particulière. N'importe quelle autre hypothèse qui diffère de  $H_0$  s'appelle hypothèse alternative (ou contre-hypothèse) et est notée  $H_1$ .  $H_0$  est soumise au test et la démarche du test s'effectue en considérant que cette hypothèse est vraie. Par exemple, on peut s'interroger sur l'égalité de la moyenne empirique d'un échantillon et la valeur  $\theta_0$  de la moyenne d'une distribution connue. Il s'agit en fait d'un test paramétrique. Typiquement, dans le cadre qui nous intéresse, on testera si la valeur moyenne du résidu peut être considérée comme acceptable. On peut également tester la supériorité ou l'infériorité de cette moyenne empirique par rapport à  $\theta_0$ . Les deux types d'hypothèses que nous venons d'évoquer ( $\theta = \theta_0$ ) et ( $\theta \geq \theta_0$ ) ou ( $\theta \leq \theta_0$ ) ont des structures mathématiques différentes, puisque l'une définit un point alors que les deux autres définissent une région. La première hypothèse est dite simple alors que les autres sont appelées hypothèses composites.

L'étape suivante de la procédure de décision nécessite la détermination de la fonction discriminante du test et de sa distribution de probabilité. De manière générale, la meilleure fonction discriminante est celle qui a la plus faible probabilité de rejeter  $H_0$  lorsque cette dernière est vraie et la plus grande probabilité de rejeter  $H_0$  lorsqu'elle est fausse.

Une fois les hypothèses  $H_0$  et  $H_1$  sont définies ainsi que la fonction discriminante, il faut encore le niveau de confiance  $\alpha$  et la taille de l'échantillon. L'élaboration de la décision s'effectue de la façon suivante. Nous commençons par établir des règles de décision qui vont conduire à l'acceptation ou au rejet de l'hypothèse  $H_0$ . Toutefois cette décision est fondée sur des valeurs estimées de la fonction discriminante; elle peut donc conduire à des erreurs. Il est donc statistiquement impossible de prendre la bonne décision à coup sûr. Par conséquent, on met en œuvre une démarche qui nous permettrait de rejeter à tort une hypothèse nulle vraie dans une faible proportion de cas. Cela revient à définir l'ensemble des valeurs qui seront si faibles que la probabilité de les observer, lorsque  $H_0$  est vraie, est très faible. En d'autres termes, on rejette  $H_0$  au bénéfice de  $H_1$  si la fonction discriminante a une valeur dont la probabilité d'occurrence sous l'hypothèse  $H_0$  est inférieure ou égale à  $\alpha$ . Cette probabilité  $\alpha$  est appelée niveau de confiance.

Une règle de décision peut conduire à deux types d'erreurs : la première, appelée erreur de type I, est le risque de rejeter l'hypothèse  $H_0$  alors qu'en réalité cette hypothèse est vraie. La seconde, appelée erreur de type II, est le risque d'accepter l'hypothèse  $H_0$  alors qu'en réalité cette hypothèse est fausse. La probabilité de commettre une erreur de type I est égale à  $\alpha$ ; celle de commettre une erreur de type II est égale à  $\beta$ . De manière idéale, il faudrait spécifier les valeurs de  $\alpha$  et  $\beta$  avant d'effectuer l'expérience. Toutefois, en pratique, on fixe plutôt la valeur de  $\alpha$  et l'on détermine ensuite  $\beta$ . Ce choix des risques  $\alpha$  et  $\beta$  est lié aux conséquences pratiques de la décision. Il faut noter que la diminution de  $\alpha$  entraîne une augmentation de  $\beta$ . Il est donc clair que lors d'un test statistique, les risques  $\alpha$  et  $\beta$  sont liés et varient en sens inverse. Il faut donc trouver un compromis pour optimiser le ratio entre les probabilités d'occurrence de ces erreurs afin de fournir une décision optimale. On définit donc la notion de puissance  $P$  d'un test comme étant la probabilité de rejeter  $H_0$  lorsque  $H_0$  est fausse, c'est à-dire :  $P = 1 - \beta$ .

Une fois on a choisi un niveau de confiance  $\alpha$ , l'ensemble des valeurs de la variable de test dont la probabilité de réalisation est en dessous du seuil  $\alpha$  s'appelle région de rejet (ou zone critique) du test. La position de la zone critique dépend de la nature de l'hypothèse  $H_1$ . En effet, selon la formulation de  $H_1$ , on applique soit un test bilatéral, soit un test unilatéral. Un test bilatéral s'applique quand on cherche une différence entre deux estimations, ou entre une estimation et une valeur donnée sans se préoccuper du signe ou du sens de la différence. Dans ce cas, la zone de rejet de l'hypothèse principale se fait de part et d'autre de la distribution de référence. La Figure 4.1 illustre cette situation.

Un test unilatéral s'applique quand on cherche à savoir si une estimation est supérieure (ou inférieure) à une autre ou à une valeur donnée. La zone de rejet de l'hypothèse principale est située d'un seul côté de la distribution de probabilité de référence (à droite ou à gauche), comme illustré en Figure 4.2.

Rappelons que dans les tests unilatéral et bilatéral, la taille de la zone critique des tests est identique. Dans un cas, elle est concentrée à une extrémité de la distribution, dans l'autre elle est répartie sur les deux extrémités.

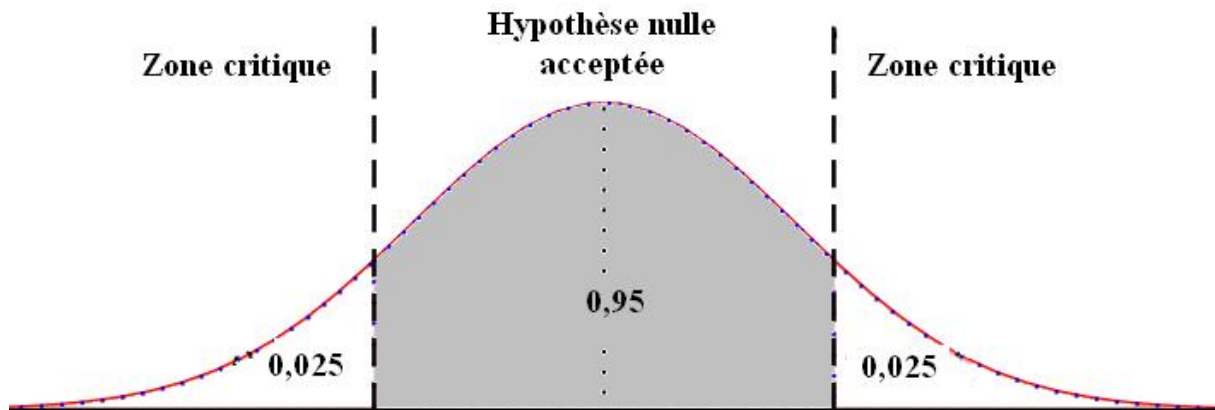


Figure 4.1- Région de rejet pour un test bilatéral avec  $\alpha = 5\%$

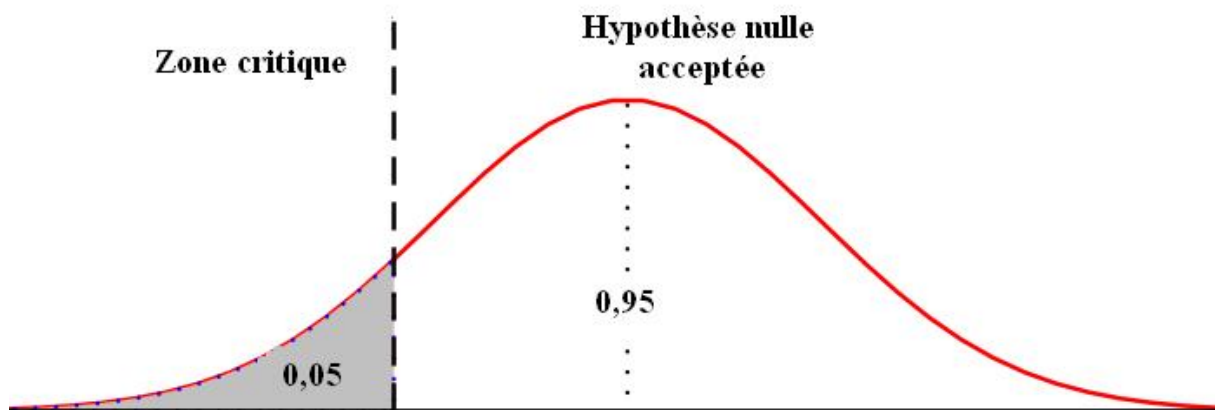


Figure 4.2- Région de rejet pour un test unilatéral à gauche avec  $\alpha = 5\%$

#### 4.2.4 Tests d'hypothèses pour la détection de changement

Les tests d'hypothèses, objet d'un développement continu depuis une trentaine d'années, se retrouvent dans plusieurs domaines allant de la théorie de la décision à la détection de signaux radar. Dans le domaine de la détection de défauts, on s'intéresse à une suite de données suivant une loi de probabilité dont les paramètres subissent des changements à un instant inconnu. Plus précisément, à partir des données  $\varepsilon_1, \dots, \varepsilon_t$ , on suppose que les observations  $\varepsilon_1, \dots, \varepsilon_{t_d-1}$  suivent la distribution  $P_{\theta_0}$  et que  $\varepsilon_{t_d}, \dots, \varepsilon_t$  suivent la distribution  $P_{\theta_1}$ . L'instant inconnu  $t_d$  représente le temps de changement (ou instant de défaut) au-delà duquel la distribution des données change de  $P_{\theta_0}$  à  $P_{\theta_1}$ .

L'objectif est alors de déterminer au plus tôt si un changement de fonctionnement a eu lieu. Cela revient à résoudre un problème de tests d'hypothèses binaires, où l'hypothèse  $H_0$  suppose que les paramètres statistiques de la suite observations  $\varepsilon_N$  sont les mêmes que dans le cas des conditions normales de fonctionnement, et l'hypothèse  $H_1$  est que les paramètres statistiques de la suite observations  $\varepsilon_N$  sont différents que ceux obtenus dans le cas du bon fonctionnement. Ainsi, on a :

$$\begin{cases} H_0 : \varepsilon_i \sim P_{\theta_0} \text{ (le système est en fonctionnement normal)} \\ H_1 : \varepsilon_i \sim P_{\theta_1} \text{ (le système est défectueux)} \end{cases} \quad (4.1)$$

Dans ce contexte de surveillance des systèmes, deux façons d'aborder le problème de détection de changement peuvent être distinguées :

- **La détection hors-ligne**

À partir d'une collection de données  $\varepsilon_1, \dots, \varepsilon_N$ , on cherche en effet à détecter s'il y a eu, un ou plusieurs changements de régime de fonctionnement entre les instants 1 et N. La mise en œuvre de cette technique de détection requiert l'acquisition de l'ensemble des mesures.

- **La détection en-ligne**

Les données arrivent en continu, et la taille de l'échantillon collecté n'est pas connue a priori. L'objectif est toujours la détection d'une anomalie le plus rapidement possible en s'appuyant sur l'ensemble des mesures disponibles. La variable de test est alors évaluée à chaque nouvelle donnée pour trancher entre les hypothèses  $H_0$  et  $H_1$ . Si l'hypothèse  $H_0$  est rejetée, une alarme sera déclenchée à l'instant  $t_a$ . Si l'hypothèse  $H_0$  est retenue, alors la surveillance continue.

Dans notre cas, nous avons choisi une approche de détection en-ligne afin de suivre l'évolution du système (prise de décision dès l'acquisition de nouvelles données). On suppose que les données sont indépendantes et identiquement distribuées (i.i.d.) avant et après changement selon une loi normale. De plus, on s'intéresse uniquement à des changements dans la moyenne du signal résidu.

La plupart des tests statistiques nécessitent la connaissance des densités de probabilités conditionnelles des observations relativement aux hypothèses  $H_0$  et  $H_1$ . Le plus souvent, on suppose que l'espace d'observation est divisé en deux sous-espaces disjoints  $Z_0$  et  $Z_1$ . Si l'observation courante appartient à  $Z_0$  l'hypothèse  $H_0$  est choisie, sinon l'hypothèse  $H_1$  est retenue. En réalité, quatre décisions  $D_{ij}$  peuvent être prises selon :

- $D_{00}$  : l'hypothèse  $H_0$  est vraie et  $H_0$  a été effectivement choisie,
- $D_{01}$  : l'hypothèse  $H_0$  est vraie mais  $H_1$  a été choisie,
- $D_{11}$  : l'hypothèse  $H_1$  est vraie et  $H_1$  a été choisie,
- $D_{10}$  : l'hypothèse  $H_1$  est vraie mais  $H_0$  a été choisie.

Il y a donc deux possibilités de mauvaise décision ( $D_{01}$  correspond à une erreur de type I et  $D_{10}$ , à une erreur de type II).

La situation  $D_{11}$  est relative à une bonne détection (avec une probabilité  $P_D = 1-\beta$ ), la situation  $D_{01}$  à une fausse alarme (avec une probabilité  $P_F = \alpha$ ) et  $D_{10}$  à un défaut non détecté (avec une probabilité  $P_{ND} = \beta$ ). Ce problème est illustré sur la Figure 4.3.




Figure 4.3- Test binaire à partir d'une observation

Les densités de probabilités conditionnelles des observations relativement aux deux hypothèses  $H_0$  et  $H_1$  étant connues, ces trois situations sont caractérisées par les probabilités :

$$P_D = 1 - \beta = P(H_1 \text{ choisie} | H_1 \text{ vraie}) = \int_{\gamma}^{\infty} p(Z | H_1) dZ \quad (4.2)$$

$$P_F = \alpha = P(H_1 \text{ choisie} | H_0 \text{ vraie}) = \int_{\gamma}^{\infty} p(Z | H_0) dZ \quad (4.3)$$

$$P_{ND} = \beta = P(H_0 \text{ choisie} | H_1 \text{ vraie}) = \int_{-\infty}^{\gamma} p(Z | H_1) dZ \quad (4.4)$$

Pour résoudre le problème de décision binaire, différents critères de choix ont été proposés et conduisent à des tests particuliers. Dans la suite de cette section les tests de Neyman Pearson, du CUSUM et deux distances statistiques seront présentés.

#### **4.2.4.1 Test de Neyman Pearson**

L'objectif d'un test statistique consiste toujours à maximiser la probabilité de détection et à minimiser la probabilité de fausse alarme. Un compromis entre ces deux exigences antagonistes doit être établi. Le test de Neyman Pearson, introduit dans (Neyman et Pearson 1933), permet d'accepter ou de rejeter l'hypothèse  $H_0$  en maximisant la puissance du test  $1 - \beta$  sachant que la probabilité de fausse alarme  $\alpha$  est fixée à un certain seuil (Ding, 2008; Barkat, 2005).

L'objectif principal est de détecter un changement dans la moyenne de la probabilité conditionnelle  $P_{\theta_0}(\varepsilon / H_0)$ , comme illustré dans l'équation 4.1, d'une valeur connue du paramètre  $\theta_0$  vers une autre valeur inconnue  $\theta_1$  qui se produit à l'instant de défaut. Le rapport de vraisemblance généralisé (en anglais GLR : Generalized Likelihood Ratio) remplace le paramètre inconnu  $\theta_1$  par son estimation au sens du maximum de vraisemblance. Le test de Neyman Pearson compare le GLR ( $\Lambda(\varepsilon)$ ) à un seuil pour chaque donnée comme suit :

$$\Lambda(\varepsilon) = \log \frac{\sup_{\theta_1} P_{\theta_1}(\varepsilon / H_1)}{P_{\theta_0}(\varepsilon / H_0)} \underset{H_0}{\underset{H_1}{\geq}} \log(\eta) \quad (4.5)$$

où  $(\varepsilon(t) = y(t) - \hat{y}(t))$  est le résidu du modèle NARMAX,  $P_{\theta_i}(\varepsilon / H_i)$  est la probabilité conditionnelle de la séquence  $\varepsilon_1, \dots, \varepsilon_N$  suivant l'hypothèse  $H_i$ ,  $i = 0, 1$  et  $\eta$  est le seuil du test qui doit être choisi de telle sorte que la contrainte  $P_{FA} = \alpha$  soit vérifiée. La densité de probabilité de  $\varepsilon$  sous l'hypothèse  $H_i$ ,  $i = \{0, 1\}$  est donné par la relation suivante :

$$P_{\theta_i}(\varepsilon) = \frac{1}{(2\pi\sigma^2)^{1/2}} \exp\left(-\frac{1}{2} \frac{(\varepsilon - \theta_i)^2}{\sigma^2}\right) \quad (4.6)$$

Dans ce cas, le GLR s'exprime sous la forme :

$$\Lambda(\varepsilon) = \log \frac{1/(2\pi\sigma^2)^{1/2} \exp(-(\varepsilon - \theta_1)^2 / 2\sigma^2)}{1/(2\pi\sigma^2)^{1/2} \exp(-(\varepsilon - \theta_0)^2 / 2\sigma^2)} = \frac{(\varepsilon - \theta)^2 - (\varepsilon - \theta_1)^2}{2\sigma^2} \underset{H_0}{\overset{H_1}{>}} \log(\eta) \quad (4.7)$$

où  $\theta_0$ ,  $\theta_1$  représentent les valeurs moyennes de  $\varepsilon$  sous l'hypothèse  $H_0$  et  $H_1$  respectivement et  $\sigma$  son écart-type. Si le rapport  $\Lambda(\varepsilon)$  est inférieur à  $\log(\eta)$ , on accepte l'hypothèse  $H_0$ ; dans le cas contraire, on accepte  $H_1$ . Comme  $\varepsilon$  suit une loi normale, la statistique  $\Lambda(\varepsilon)$  est distribuée selon une loi de  $\chi^2$  à 1 degré de liberté (Harrou et al., 2013). Par conséquent, le terme  $\log(\eta)$  garantit un taux  $\alpha$  de fausse alarme que l'on se fixe a priori et est déduit de la table de  $\chi^2$ . Dans ce travail, on a choisi  $\alpha = 10\%$ .

#### 4.2.4.2 Test du CUSUM

La règle du CUSUM (CUmulative SUM), introduite par Page (1954), permet de détecter une modification de la moyenne dans une suite d'observations indépendantes. Lorden (1971), Moustakides (1986) et Ritov (1990) ont démontré l'optimalité de cette règle de décision. Cette règle reste encore très utilisée sa forme originale, c'est à-dire sous l'hypothèse que les données suivent une distribution gaussienne. Il est ainsi possible d'utiliser le test du CUSUM avec des données dépendantes (Lai, 1998).

Afin de détecter un éventuel saut de moyenne à un instant inconnu  $t_d$ , la règle du CUSUM est fondée sur une stratégie de décision séquentielle entre les hypothèses

$H_0$  et  $H_1$  (équation 4.1) en utilisant le rapport de vraisemblance. On calcule alors, pour chaque observation de  $\varepsilon$ , la valeur de la somme cumulée  $S_r$  suivante :

$$\begin{aligned}
 S_r &= \log \frac{\prod_{t=1}^{td-1} P_{\theta_0}(\varepsilon_t / H_0) \prod_{t=td}^N P_{\theta_1}(\varepsilon_t / H_1)}{\prod_{t=1}^N P_{\theta_0}(\varepsilon_t / H_0)} \\
 &= \log \frac{\prod_{t=td}^N P_{\theta_1}(\varepsilon_t / H_1)}{\prod_{t=td}^N P_{\theta_0}(\varepsilon_t / H_0)} \\
 &= \sum_{t=td}^N \log \frac{P_{\theta_1}(\varepsilon_t / H_1)}{P_{\theta_0}(\varepsilon_t / H_0)}
 \end{aligned} \tag{4.8}$$

puis on la compare au seuil  $\log(\eta)$ . L'idée de base de ce test est que le rapport  $\log \frac{P_{\theta_1}(\varepsilon_t / H_1)}{P_{\theta_0}(\varepsilon_t / H_0)}$  de la somme cumulée  $S_r$  change de signe en moyenne après le changement du régime de fonctionnement du système surveillé.  $\theta_0, \theta_1$  représentent les paramètres des distributions avant et après la rupture. Lorsque  $S_r$  est supérieure au seuil, une anomalie est détectée et l'instant  $t_d$  correspondant à la somme la plus élevée.

L'application de la procédure du CUSUM nécessite la connaissance a priori des valeurs  $\theta_0, \theta_1$ . D'un point de vue pratique, cette condition s'avère à la fois restrictive et difficile à satisfaire. Pour surmonter ce problème, l'estimation de la moyenne  $\theta_0$  avant le défaut est réalisée à l'aide des premières valeurs des données disponibles. De plus, la valeur absolue minimale  $\delta = \theta_0 - \theta_1$  du saut de moyenne doit être choisie a priori. Comme le signe de  $\delta$  est inconnu a priori, il est recommandé d'effectuer deux tests en parallèle. Le premier permet de détecter une augmentation de moyenne et s'écrit sous la forme :

$$U_N = \sum_{t=1}^N \left( \varepsilon(t) - \theta_0 - \frac{\delta}{2} \right) \tag{4.9}$$

$$m_N = \min_{0 \leq t \leq N} (U_t), \quad U_0 = 0 \tag{4.10}$$



et l'augmentation de la moyenne est détectée lorsque :

$$U_N - m_N > \lambda \quad (4.11)$$

Le second test permet de détecter une diminution de la moyenne. On calcule maintenant :

$$T_N = \sum_{t=1}^N \left( \varepsilon(t) - \theta_0 + \frac{\delta}{2} \right) \quad (4.12)$$

$$M_N = \max_{0 \leq t \leq N} (T_t), \quad T_0 = 0 \quad (4.13)$$

et la diminution de moyenne est détectée lorsque :

$$M_N - T_N > \lambda \quad (4.14)$$

où  $\varepsilon(t)$  est le résidu à l'instant  $t$ ,  $\lambda$  est le seuil à ne pas dépasser,  $U_N$  et  $T_N$  représentent les deux sommes cumulées à l'instant  $t$ . L'instant estimé de l'anomalie est le dernier instant pour lequel le minimum de  $m_N$  (respectivement le maximum de  $M_N$ ) a été atteint avant le changement. Une fois un défaut est détecté, la procédure est réinitialisée. Le seuil de décision  $\lambda$  doit être fixé par apprentissage. Une valeur initiale du seuil peut être calculée par l'expression  $\lambda = 2 * h * \sigma / \delta$  avec, pour des distributions normales,  $h = 2$  (Ragot et al., 1990).

#### **4.2.4.3 Distances statistiques**

Les distances statistiques permettent de mesurer la similarité entre deux distributions de probabilité  $p_0(\varepsilon)$  (mode normal) et  $p_1(\varepsilon)$  (mode anormal) (Deza et Deza, 2009). Une mesure de similarité idéale est celle qui doit distinguer deux distributions de natures différentes. Plusieurs types de mesure de similarité peuvent être utilisés. Nous en utiliserons deux : la distance de Kullback-Leibler (Kullback et Leibler, 1951) et la distance de Hellinger (Gibbs et Su, 2002). On peut citer ici les travaux de Harmouche et al. (2013), et Ditzler et Polikar (2011) qui utilisent ces deux distances pour traiter le problème de détection de changements.

#### 4.2.4.3.1 La distance de Kullback-Leibler

La distance ou divergence de Kullback-Leibler, issue de la théorie de l'information, permet de mesurer la ressemblance de deux lois de probabilités. Son expression dans le cas discret est donnée par :

$$KL(p_1(\varepsilon) \parallel p_0(\varepsilon)) = \sum p_1(\varepsilon) \log \left( \frac{p_1(\varepsilon)}{p_0(\varepsilon)} \right) \quad (4.15)$$

Les distributions  $p_0(\varepsilon)$  et  $p_1(\varepsilon)$  sont considérées similaires si la distance entre elles est faible (proche de zéro). Sur un plan pratique, cela signifie que le système surveillé se trouve dans un état normal. Par ailleurs, une grande distance signifie que les deux distributions sont totalement différentes. Autrement dit, le mode anormal est détecté. La divergence de Kullback-Leibler entre les deux lois normales  $p_0(\varepsilon) \sim N(\mu_0, \sigma_0^2)$  et  $p_1(\varepsilon) \sim N(\mu_1, \sigma_1^2)$  est décrite par :

$$KL(p_1(\varepsilon) \parallel p_0(\varepsilon)) = \frac{1}{2} \left( \frac{\sigma_1^2}{\sigma_0^2} + \frac{(\mu_1 - \mu_0)^2}{\sigma_0^2} + \log \frac{\sigma_0^2}{\sigma_1^2} - 1 \right) \quad (4.16)$$

Lorsque  $\sigma_0 = \sigma_1$ . Alors, on peut écrire :

$$KL(p_1(\varepsilon) \parallel p_0(\varepsilon)) = \frac{1}{2} \left( \frac{(\mu_1 - \mu_0)^2}{\sigma_0^2} \right) \quad (4.17)$$

Considérons l'expression (4.17), les hypothèses  $H_0$  et  $H_1$  définies ci-dessus peuvent être formulées en termes de divergence de Kullback-Leibler comme suit :

$$\begin{cases} H_0 : KL(p_1(\varepsilon) \parallel p_0(\varepsilon)) \leq T_{DKL} \\ H_1 : KL(p_1(\varepsilon) \parallel p_0(\varepsilon)) > T_{DKL} \end{cases} \quad (4.18)$$

où  $T_{DKL}$  est le seuil de détection. La valeur de  $T_{DKL}$  est calculée par la règle dite des 3 sigmas (Georgoulas et al., 2013; Shi et al., 2005; Pukelsheim, 1994).

#### 4.2.4.3.2 La distance de Hellinger

La distance de Hellinger est issue du domaine des probabilités. Afin de mesurer la différence entre deux densités de probabilités discrètes, cette distance est définie par :

$$H^2(p_0(\varepsilon), p_1(\varepsilon)) = \frac{1}{2} \sum (\sqrt{p_0(\varepsilon)} - \sqrt{p_1(\varepsilon)})^2 \quad (4.19)$$

La distance de Hellinger est symétrique ( $H(p_0(\varepsilon), p_1(\varepsilon)) = H(p_1(\varepsilon), p_0(\varepsilon))$ ). Si les deux densités de probabilités sont égales, la distance tend vers zéro. Il est ainsi possible de conclure que le procédé surveillé se trouve dans le mode de fonctionnement normal. La détection de changement de mode de fonctionnement est obtenue par comparaison de la distance de Hellinger à un seuil établi lors d'une campagne de mesure faite pendant le fonctionnement du système en l'absence d'anomalie.

Dans le cas où  $p_0(\varepsilon)$  et  $p_1(\varepsilon)$  correspondent à des densités normales, la distance Hellinger se réécrit de la manière suivante :

$$H^2(p_0(\varepsilon), p_1(\varepsilon)) = 1 - \sqrt{\frac{2\sigma_0\sigma_1}{\sigma_0^2 + \sigma_1^2}} \exp\left(-\frac{1}{4} \frac{(\mu_0 - \mu_1)^2}{\sigma_0^2 + \sigma_1^2}\right) \quad (4.20)$$

Pour ( $\sigma_0 = \sigma_1$ ), on obtient :

$$H^2(p_0(\varepsilon), p_1(\varepsilon)) = 1 - \exp\left(-\frac{1}{8} \frac{(\mu_0 - \mu_1)^2}{\sigma_0^2}\right) \quad (4.21)$$

Considérons l'équation (4.21), les hypothèses  $H_0$  et  $H_1$  peuvent en être exprimées en termes de distance de Hellinger de la manière suivante :

$$\begin{cases} H_0 : H^2(p_0(\varepsilon), p_1(\varepsilon)) \leq T_{DH} \\ H_1 : H^2(p_0(\varepsilon), p_1(\varepsilon)) > T_{DH} \end{cases} \quad (4.22)$$

où  $T_{DH}$  est le seuil de décision calculé par la règle des 3 sigmas.

### 4.3 Détection d'anomalies pour un système de distillation

Dans cette partie, nous allons mettre en œuvre les outils mis au point dans la section précédente sur un système réel, à savoir une colonne de distillation. De nombreuses pannes peuvent avoir lieu sur ce type de procédé : variation de la puissance de chauffe ou de préchauffe, problème de capteur... Il est donc nécessaire de

pouvoir détecter ces anomalies qui peuvent parfois conduire à des conséquences graves comme l'arrêt du système. Cinq scénarios ont été conçus afin d'examiner le comportement du résidu généré par le modèle NARMAX en présence de différents défauts sur les entrées de la colonne. Ces défauts ont été réalisés après avoir établi le régime stationnaire de la colonne. Le Tableau 4.1 présente une description des anomalies considérées. On a réalisé deux sortes de pannes : la première où l'on a modifié la valeur de l'une des entrées par une valeur élevée voire maximale, et la deuxième par une valeur minimale voire nulle.

<b>Défauts</b>	<b>Description</b>
Cas sans défaut	Les valeurs des variables d'entrée/sortie, établies à partir de conditions normales sont : $T_d = 101.5\text{ °C}$ , $T_f = 80\text{ °C}$ , $Q_b = 80\%$ , $Q_f = 18\%$ , $R_t = 10\%$ , $F = 50\%$ , $\Delta P = 900\text{ mBar}$
D1	Augmentation de la puissance de chauffe à 100%
D2	Diminution de la puissance de chauffe à 0%
D3	La puissance de préchauffe est égale à 90%
D4	La puissance de préchauffe est égale à 10%
D5	Variation du taux de reflux de 10% à 100%

Tableau 4.1- Défauts considérées de la colonne

Il convient de souligner que tous les dysfonctionnements se sont produits à l'instant 10835 seconds. Afin de visualiser graphiquement les résultats de détection pour chacune des fautes, les Figures 4.4-4.8 représentent l'évolution des différents tests, où les termes  $t_d$  et  $t_a$  désignent respectivement l'instant de défaut et l'instant d'alarme.

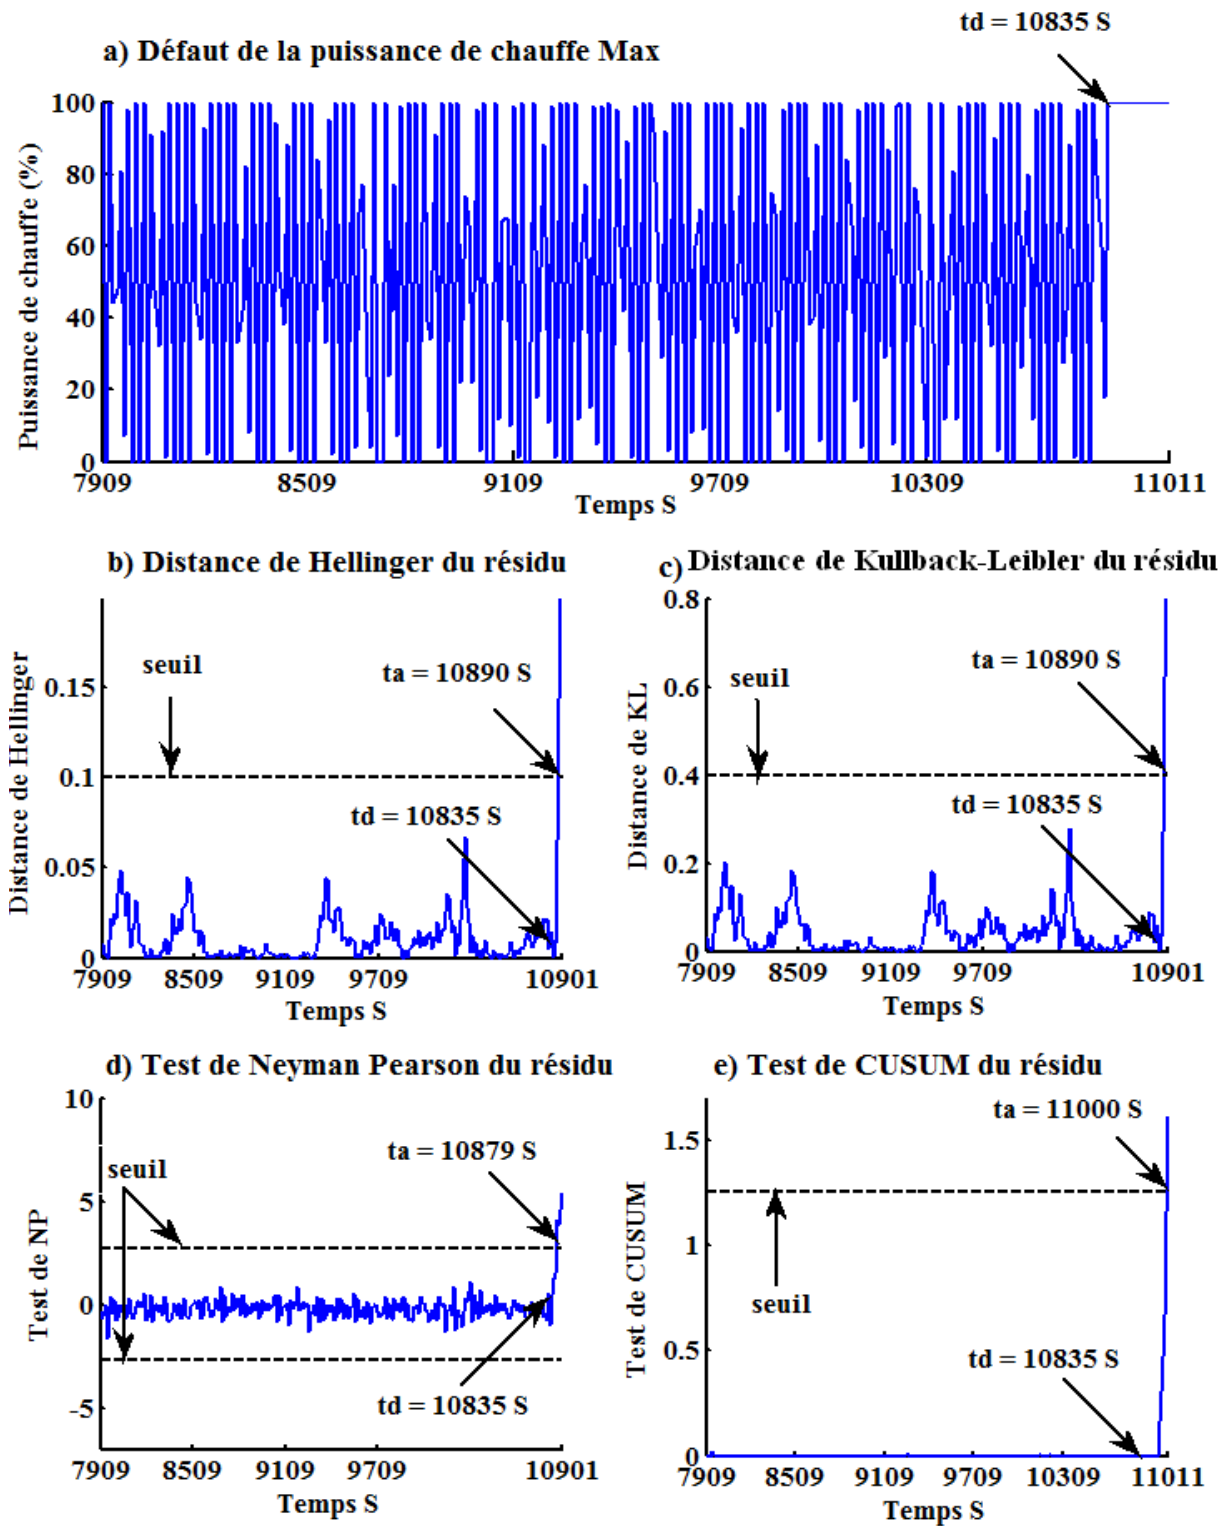


Figure 4.4- Graphes des différents tests pour le défaut D1

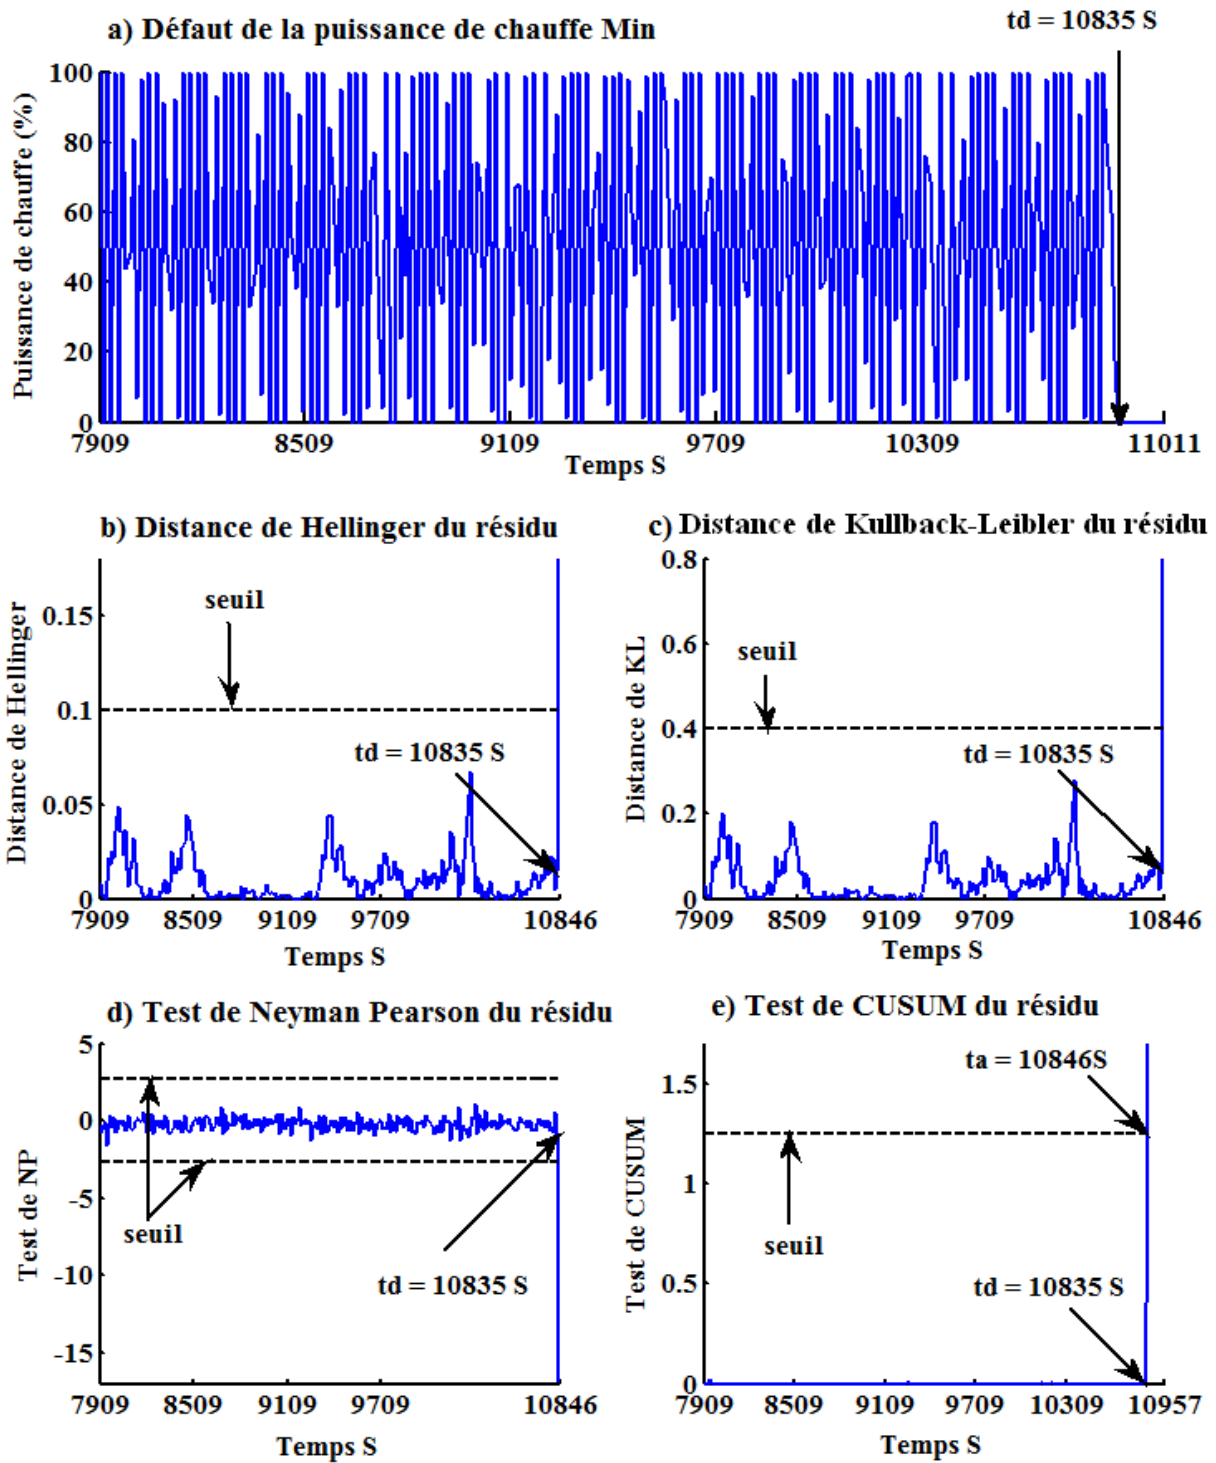


Figure 4.5- Graphes des différents tests pour le défaut D2

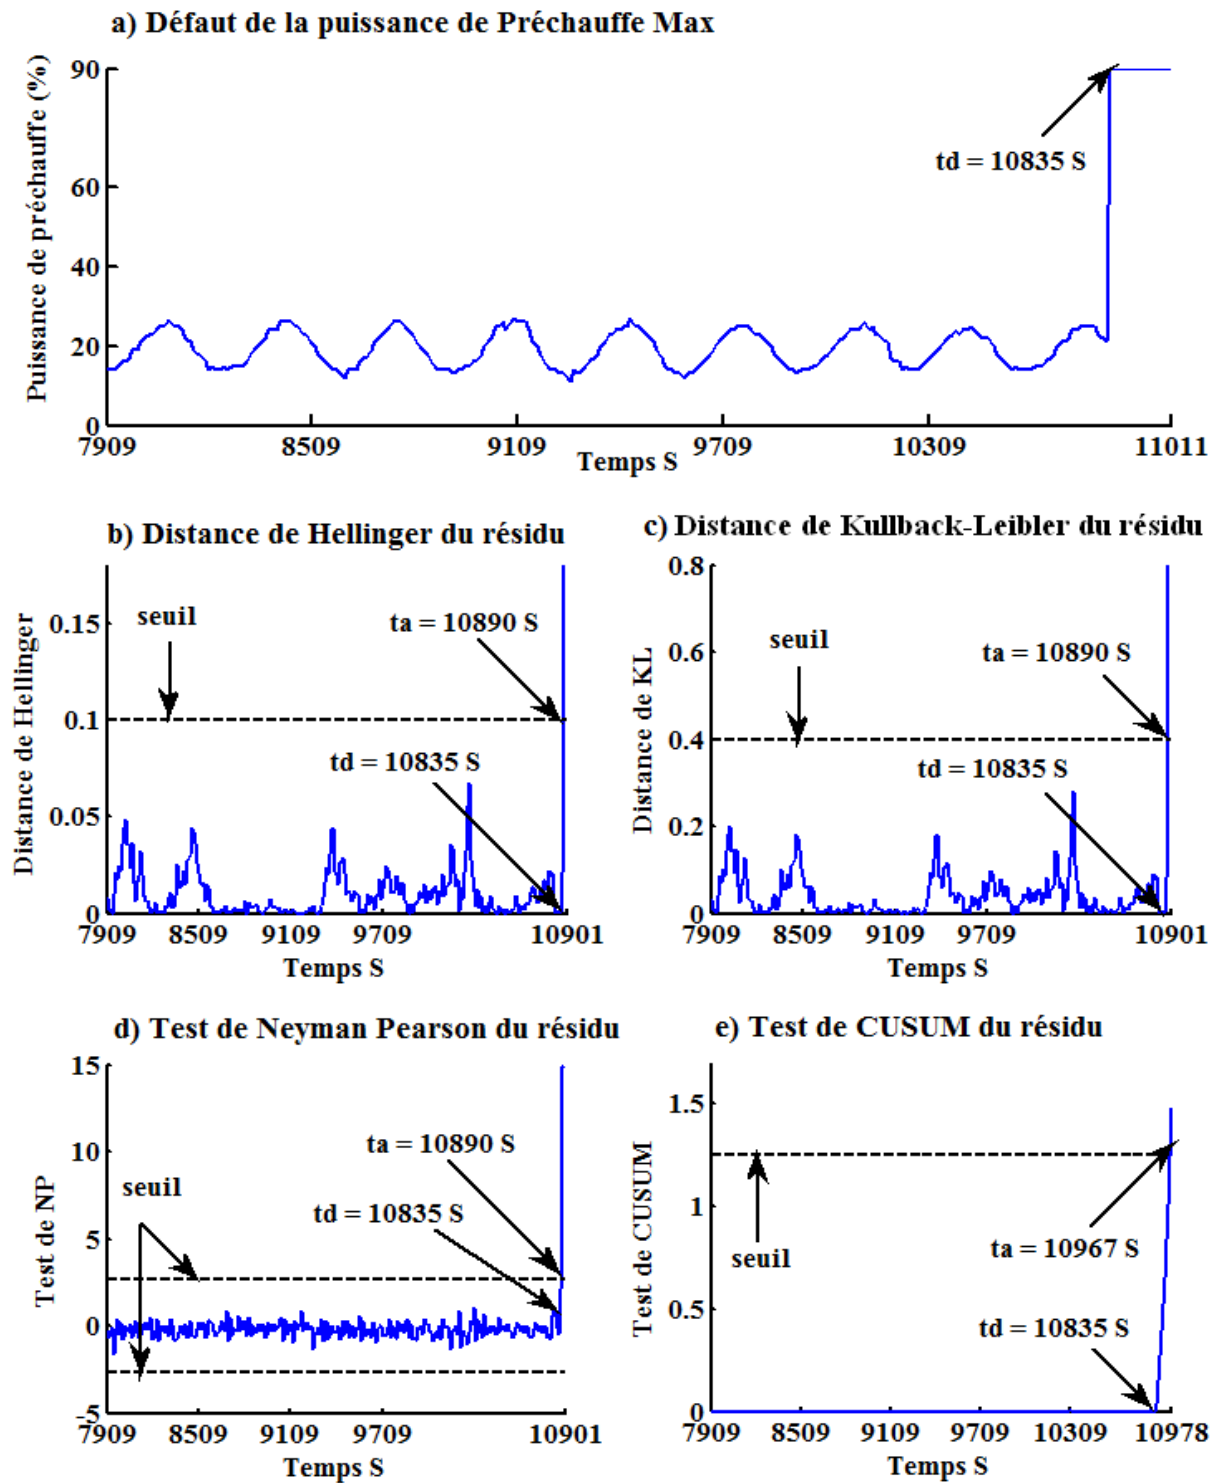


Figure 4.6- Graphes des différents tests pour le défaut D3

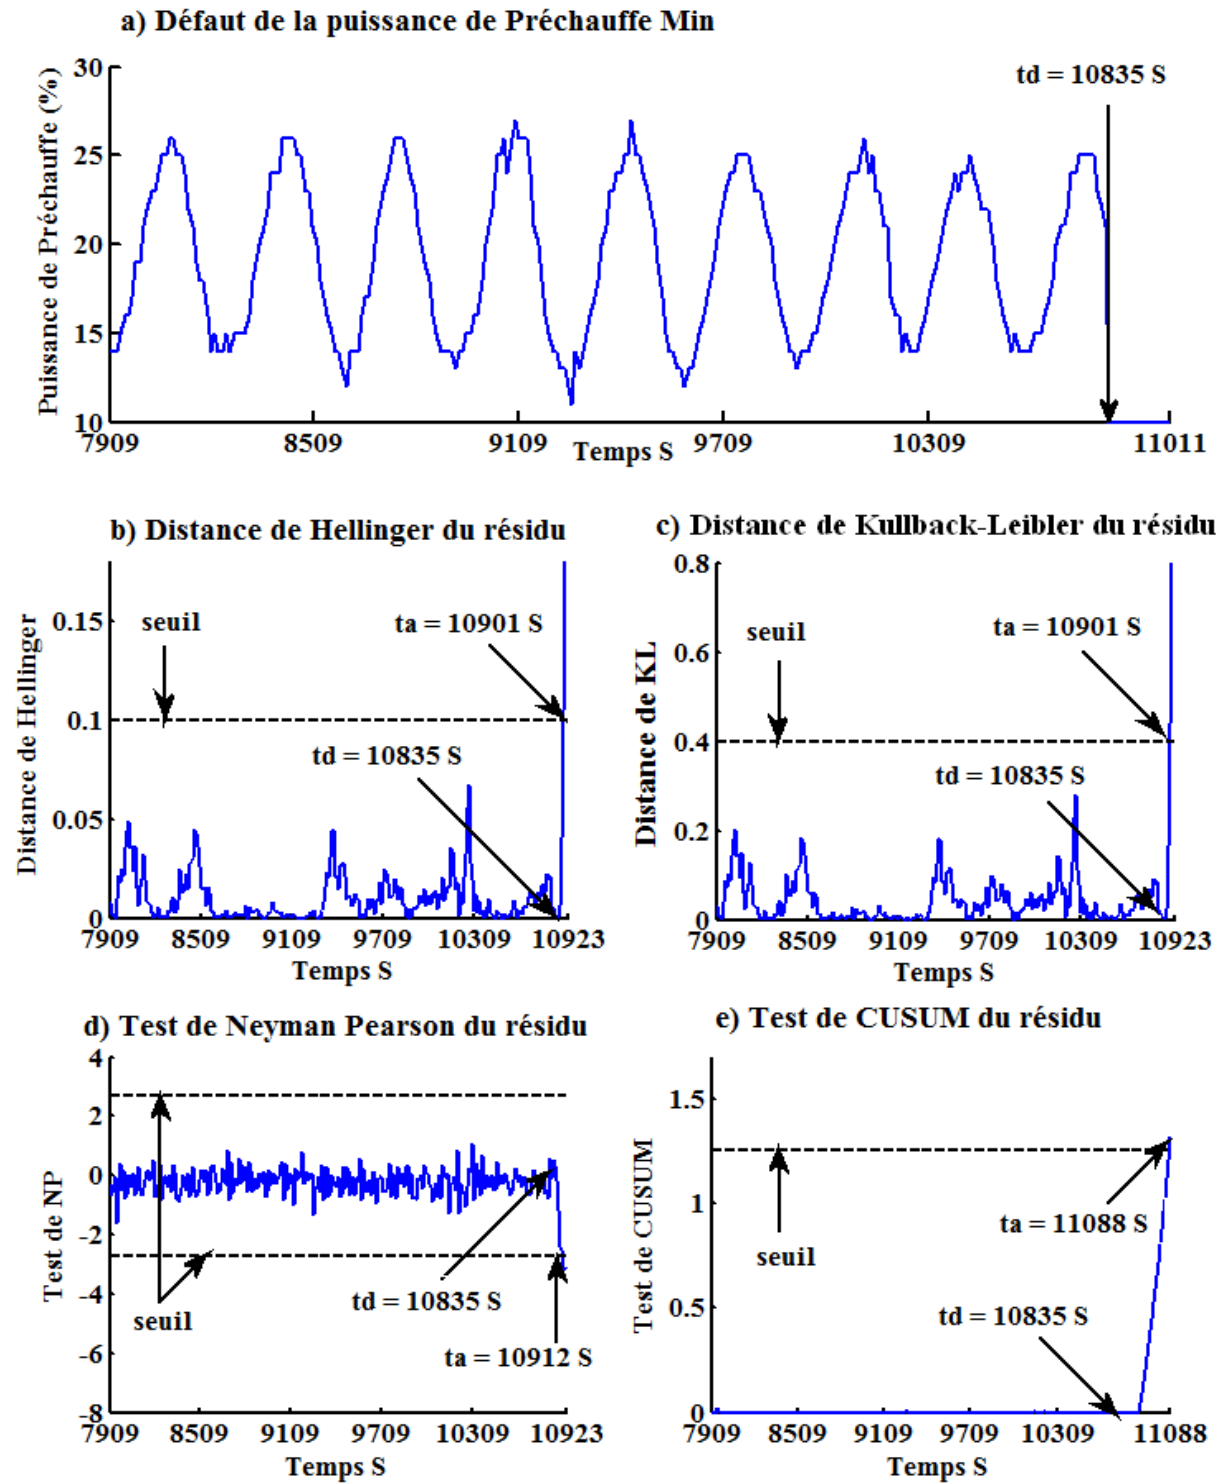


Figure 4.7- Graphes des différents tests pour le défaut D4



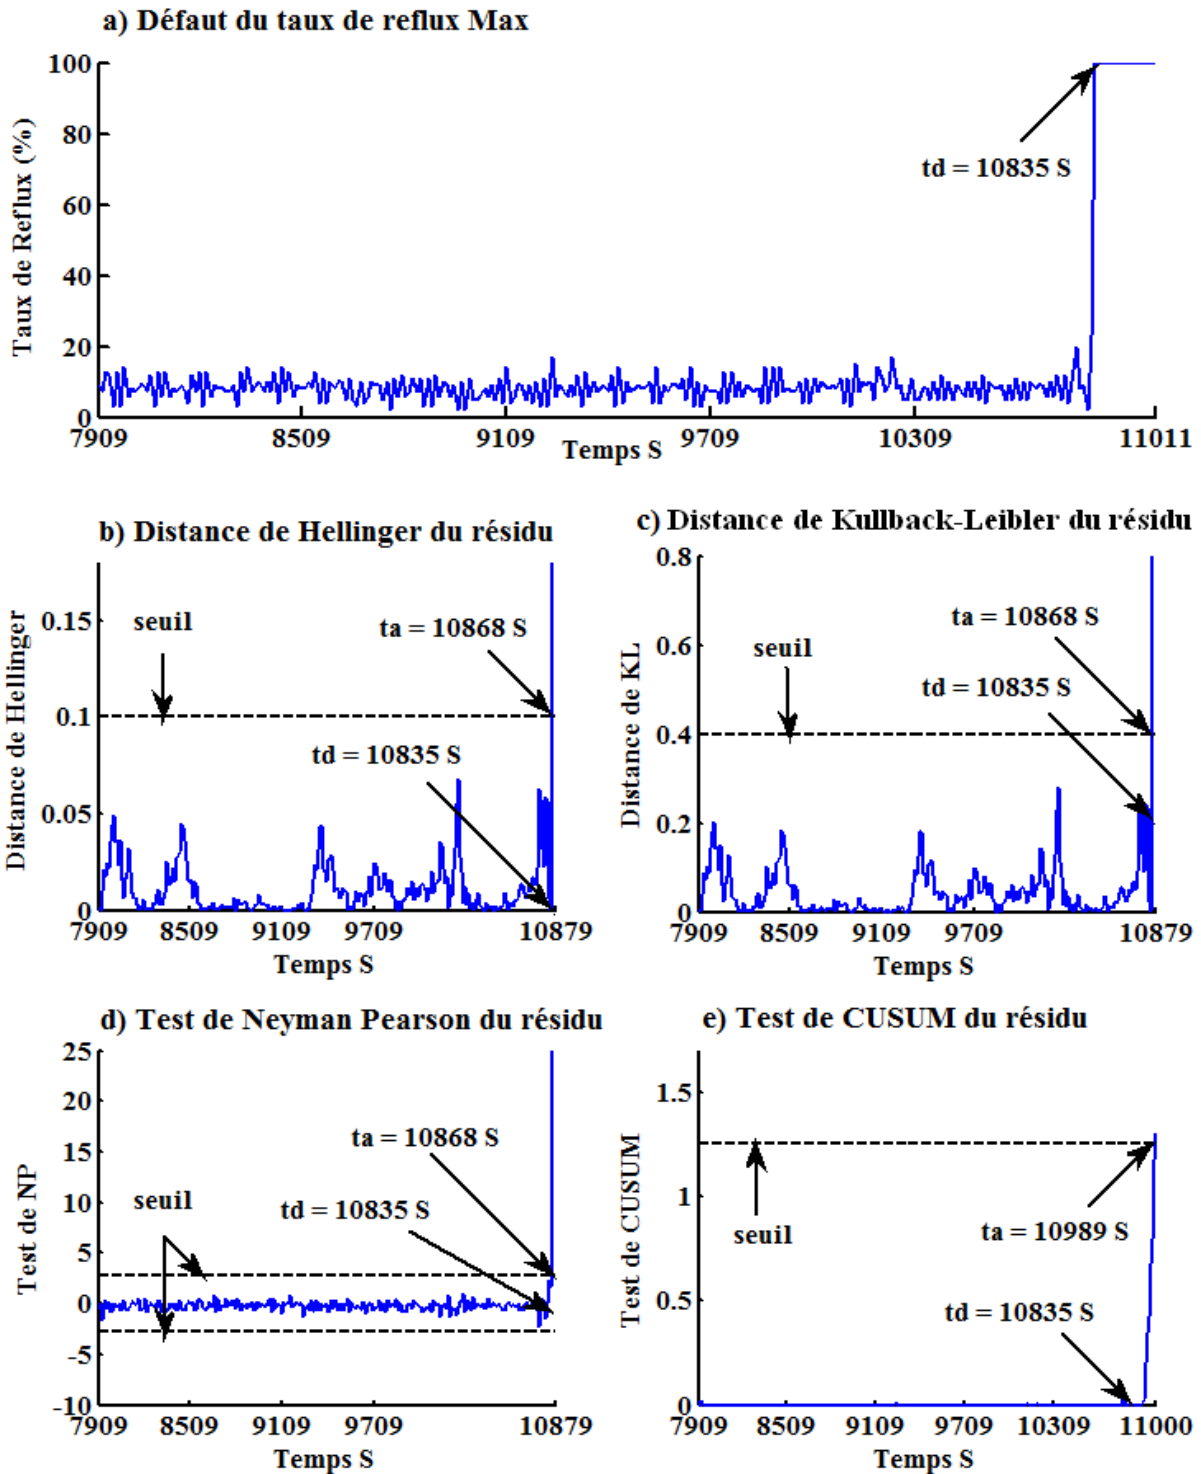


Figure 4.8- Graphes des différents tests pour le défaut D5

Une première analyse de ces graphes montre que tous les tests proposés sont sensibles à tous les défauts des entrées considérées. Chacun des quatre tests utilise une fonction de décision prenant la valeur faux (ou 0) si la moyenne du résidu reste statistiquement proche de la moyenne initiale  $\theta_0$ , et la valeur vrai (ou 1) si le résidu est loin de  $\theta_0$ .

La comparaison des résultats de détection obtenus pour toutes les anomalies permet de se rendre compte de l'intérêt de l'utilisation des quatre tests. Les indicateurs de performance des tests séquentiels sont généralement liés aux mesures du retard à la détection  $t_r = t_a - t_d$ . En effet, pour le défaut D1, le test de Neyman Pearson est plus rapide que les deux distances statistiques et le test du CUSUM. Par contre, pour le défaut D2, tous les algorithmes détectent au même instant le changement du régime de fonctionnement, et cela est dû au saut important d'amplitude. En ce qui concerne la détection du défaut D3 l'algorithme du CUSUM est moins rapide que les autres algorithmes. Le défaut D4 est rapidement détecté via les deux distances statistiques, tandis que les autres tests réagissent avec un retard plus important. La détection du défaut D5 est réalisée de la même manière qu'au scénario D3. Les résultats obtenus en termes du retard à la détection sont répertoriés dans le Tableau 4.2.

Méthode	Retard à la détection				
	D1 :	D2 :	D3 :	D4 :	D5 :
Distance de Hellinger	$t_r = 55$ s	$t_r = 11$ s	$t_r = 55$ s	$t_r = 66$ s	$t_r = 33$ s
Distance de Kullback-Leibler	$t_r = 55$ s	$t_r = 11$ s	$t_r = 55$ s	$t_r = 66$ s	$t_r = 33$ s
Test de Neyman Pearson	$t_r = 44$ s	$t_r = 11$ s	$t_r = 55$ s	$t_r = 77$ s	$t_r = 33$ s
Test de CUSUM	$t_r = 165$ s	$t_r = 11$ s	$t_r = 132$ s	$t_r = 253$ s	$t_r = 154$ s

Tableau 4.2- Retard à la détection des méthodes proposées

Cependant, il convient de souligner que la période d'échantillonnage est égale à 11 seconds. Par exemple, si  $t_r = 55$  seconds, cela correspond à 5 pas de temps, autrement dit, une alarme est déclenchée 5 pas de temps après le changement de l'état de fonctionnement du système.

A l'exception des retards à la détection du défaut D2, les résultats de détection montrent, que le test de Neyman Pearson et les deux distances statistiques sont plus adaptées à ce type d'anomalies. Les performances obtenues pour le test du CUSUM sont moins satisfaisantes.

## **4.4 Conclusion**

Ce chapitre a permis d'illustrer l'approche de surveillance des processus avec modèle de comportement. Pour cela, nous avons choisi un procédé, souvent utilisé dans l'industrie chimique. Nous avons montré dans quelle mesure les outils de modélisation, proposés dans le chapitre précédent, peuvent répondre aux besoins de la surveillance des systèmes. La stratégie de génération de résidus proposée est basée sur le modèle NARMAX de la colonne à distiller.

La problématique de détection de changement du régime de fonctionnement dans le cadre de la théorie des tests d'hypothèses a été abordée. Dans un premier temps, le principe des tests d'hypothèses est détaillé. Ensuite, quatre méthodes statistiques ont été proposées dont le but est de détecter la dégradation des indicateurs de défauts (saut de moyenne). L'exploitation de ces méthodes statistiques dans un contexte de surveillance des défauts des entrées de l'unité de distillation, a été illustrée. La moyenne et la variance nominales du résidu sont estimées sur les 100 premières données.

Les algorithmes ainsi construits ont été validés expérimentalement. La détection de changement est formulée sous la forme de tests séquentiels d'hypothèses qui s'appuient sur l'estimation de la moyenne courante du résidu. Des résultats en termes de détection ont été obtenus sur des jeux de données réelles avec dysfonctionnement. Les modes de défaillance choisis correspondent à des défauts interprétables et réalistes sur les systèmes de distillation. Les quatre méthodes proposées ont été évaluées en termes du retard à la détection et le test de Neyman Pearson et les deux distances statistiques ont surpassé le test du CUSUM.

# **Conclusion générale**

## **Conclusion générale**

Le travail de recherche effectué dans cette thèse traite le développement et mise en œuvre de procédures de détection de défauts dans un système industriel. L'application de ces méthodes à une unité de distillation a été l'une des motivations de cette thèse. L'objectif de la détection d'anomalies sur l'unité de distillation est de diminuer le nombre d'arrêts non planifiés, d'augmenter la disponibilité du procédé, d'éviter les détériorations de l'équipement et d'assurer la qualité de la production industrielle. Pour réaliser cet objectif, les méthodes de détection de défauts doivent satisfaire les contraintes industrielles très strictes concernant la robustesse aux imprécisions de modélisation et les bruits de mesure afin de déterminer, de manière automatique et en temps réel, un indicateur de l'état de fonctionnement du système de distillation pouvant être exploité par les opérateurs.

En raison du contexte d'utilisation de l'unité de distillation dans divers secteurs industriels connexes au génie chimique et des propriétés du défaut à détecter, des contraintes fortes en termes de rapidité, de robustesse, de sensibilité et de temps de calcul sont imposées dans la conception des outils contribuant à la détection d'anomalies. Compte tenu de ces contraintes, la méthode de détection de défauts proposée est basée sur la combinaison des modèles paramétriques de type boîte noire et les tests statistiques. Le choix de cette solution est motivé par de nombreux avantages :

- la disponibilité de calculateurs possédant des puissances de calcul conduisant à l'analyse, à l'interprétation et au traitement des mesures de manière efficace et garantissant un diagnostic rapide et fiable;
- la possibilité de modéliser les phénomènes physiques régissant le comportement du système de distillation ;
- la simplicité de réglage des paramètres de la méthode de détection proposée par des ingénieurs et des opérateurs non spécialistes.

Le choix du modèle de l'unité de distillation constitue un point de départ fondamental car il peut grandement conditionner les performances en termes de bonne détection et de retard à la détection du test statistique qui y sera associé. Le modèle recherché doit, dans tous les cas, être suffisamment général de façon à représenter avec la meilleure précision possible un large domaine de fonctionnement du système et non plus seulement au voisinage d'un point de fonctionnement déterminé avec un nombre réduit de paramètres.

L'étude proposée dans ce travail s'est déroulée en plusieurs phases. Dans un premier temps, l'accent a été mis au cours du premier chapitre sur les problèmes de séparation des mélanges liquides et l'application pratique à l'origine de la thèse. Ce qui a dégagé le rôle clé tenu par la colonne de distillation et a montré la nécessité de sa surveillance. Le second chapitre a exposé une revue des principales méthodes de diagnostic existantes.

Une contribution importante de ce travail de thèse apparaît au cours du troisième chapitre, portant sur la détermination d'un modèle de référence de la colonne de distillation. L'approche proposée est basée sur l'identification paramétrique de type boîte noire. Cinq modèles entrées-sorties du système ont été développés à cet effet : ARX, ARMAX, NARX, NARMAX et Hammerstein. Toute la difficulté réside alors dans le choix de la meilleure représentation du système qui a des conséquences directes sur la qualité d'approximation. Pour cette raison, trois critères de sélection des modèles (AIC, NSE, RMSE) ont été utilisés et comparés pour une évaluation de leurs performances vis-à-vis de différentes structures des cinq modèles proposés. En effet, la structure du modèle qui correspond au minimum des critères AIC et RMSE et au maximum du critère NSE a été choisie comme la meilleure structure de chacun des modèles considérés. La comparaison des valeurs de tous les critères de sélection pour chacun des modèles proposée a permis de conclure que seules les structures optimales des modèles ARMAX, Hammerstein et NARMAX possèdent de bonnes capacités à représenter le comportement dynamique du système de distillation. Un problème crucial a consisté à déterminer un modèle de référence du procédé. Une analyse des performances de prédiction des trois modèles a été présentée. Le choix du modèle de

référence tient compte du compromis entre la précision de prédiction vis-à-vis du nombre de paramètres. La motivation principale était d'identifier un modèle avec une bonne robustesse aux imprécisions de modélisation (ordres et retards des entrées) ou de mesure, tout en retrouvant un minimum de paramètres. Ceci a conduit à choisir le modèle NARMAX comme la représentation la plus pertinente de l'unité de distillation. L'étape fondamentale de validation de ce modèle a également été effectuée à l'aide de tests de corrélation de l'erreur de prédiction.

Enfin, le dernier chapitre, a été consacré au développement d'une stratégie de détection d'anomalies sur les entrées du système de distillation. Grâce au modèle obtenu dans le chapitre précédent, quatre techniques séquentielles à base de tests d'hypothèses ont été proposées dans le but de détecter la présence d'un dysfonctionnement. Ces tests sont basés sur l'acquisition de nouvelles données pour déterminer l'état de fonctionnement du système et prévenir les situations critiques. Le résidu du modèle NARMAX a donc été analysé à chaque instant pour en réaliser un suivi du mode de fonctionnement. Le principe de détection d'anomalies proposé est fondé sur l'estimation des paramètres statistiques du résidu, suivie par un test de décision basé sur un seuil de détection, préalablement déterminé. A chaque instant d'analyse, le système peut être signalé hors de contrôle dès lors qu'un changement significatif apparaît dans la distribution du résidu. Souvent, la détection en ligne de pannes est un problème compliqué puisqu'on doit prendre une décision en ayant le moins d'observations possibles sous l'hypothèse alternative  $H_1$ , pour avoir un faible retard à la détection. Les quatre techniques proposées ont été évaluées en terme de retard à la détection, en utilisant un jeu de données réelles. Les résultats obtenus ont montré que toutes les techniques proposées garantissent une détection correcte dans le cas d'un défaut de variation de la puissance de chauffe à une valeur nulle, tandis que les autres défauts détectables sont signalés rapidement, uniquement par le test de Neyman Pearson et les distances statistiques de Hellinger et de Kullback-Leibler. Entre autre, le test de CUSUM ne peut garantir une détection rapide de ces défauts.

Les résultats obtenus dans ce manuscrit offrent des perspectives intéressantes de développement. En particulier, les points suivants pourront faire l'objet de travaux ultérieurs :

- lors de cette thèse, le modèle NARMAX a été retenu pour prédire le comportement de la colonne de distillation. Pour la représentation des systèmes dynamiques, il est prouvé que tout système non-linéaire à temps invariant peut être représenté par le modèle NARMAX (Billings, 2013). Cependant, ce modèle contient des termes passés de l'erreur de prédiction (résidu). En effet, si un défaut introduit un faible changement au niveau de la sortie du système alors les termes d'erreur de prédiction pourraient conduire à la non détection de défauts. Afin de s'affranchir de cette problématique, il semble particulièrement intéressant de continuer à travailler sur l'identification de modèles sans termes de l'erreur de prédiction (modèles NARX, NOE...);
- le problème étudié dans le cadre de cette thèse porte essentiellement sur l'étape de détection de défauts d'entrées dans un système chimique. Néanmoins, la localisation de ces défauts à partir de l'évolution du résidu du modèle identifié reste un problème. Comme solution à ce problème, Il serait envisageable d'étudier l'utilisation des techniques d'intelligence artificielle telles que les Machines à Vecteurs Supports (Gins et al., 2015) dont le potentiel en terme de localisation a déjà été mis en évidence.



# **Bibliographie**

## **Bibliographie**

- Achour, B., Hached, A., 2004. The incident at the Skikda plant: description and preliminary conclusion. LNG14, Session 1, DOHA, Qatar, 21 March.
- Aggoune, L., Chetouani, Y., Radjeai, H. Change detection in a distillation column using non-linear auto-regressive moving average with exogenous input model and Hellinger distance. IET Science, Measurement & Technology, 8 pp. DOI: 10.1049/iet-smt.2015.0045, Available online: 04 November 2015
- Aggoune, L., Chetouani, Y., Radjeai, H., 2014. Recursive Identification of the Dynamic Behavior in a Distillation Column by Means of Autoregressive Models. Journal of Dynamic Systems, Measurement, and Control. 136, 044506-5.
- Aggoune, L., Chetouani, Y., Radjeai, H., 2012. Using ARX Model for Prediction Overhead Temperature of a Distillation Column. ICEEAC'13, November 24-26, Sétif, Algérie.
- Aggoune, L., Chetouani, Y., Radjeai, H., 2012. Identification of Distillation Column Using ARMAX Structure and Recursive Extended Least Square Algorithm. ICCS'12, November 05-06, Agadir, Morocco.
- Akaike, H., 1974. A new look at the statistical model identification. IEEE Transaction on Automatic Control. 19, 716-723.
- Akhenak, A., Duviella, E., Bako, B., Lecoeuche, S., 2013. Online fault diagnosis using recursive subspace identification: Application to a dam-gallery open channel system. Control Engineering Practice. 21, 797-806.
- Antoni, J., Sidahmed, M., 2004. Contrôle et diagnostic à partir des signaux acoustiques et vibratoires. Conférence sur les Méthodes de Surveillance et Techniques de Diagnostic Acoustiques et Vibratoire.
- Bai, E.W., Li, D., 2004. Convergence of the iterative Hammerstein system identification algorithm. IEEE Transactions on Automatic Control. 49, 1929-1940.

- Ballé, P., Juricic, D., Rakar, A., Ernst, S., 1997. Identification of Nonlinear Processes and Model Based Fault Isolation Using Linear Local Models. Proceedings of the American Control Conference, Albuquerque, New Mexico, USA. 1, 47-51.
- Barkat, M. 2005. Signal detection and estimation. Artech house, Boston.
- Basseville, M., Nikiforov, I.V., 1993. Detection of Abrupt Changes : Theory and Application. Prentice Hall Englewood Cliffs, New Jersey.
- Bhagwat, A., Srinivasan, R., Krishnaswamy, P.R., 2003. Fault detection during process transitions : a model-based approach. Chemical Engineering Science. 58, 309-325.
- Billing, S.A., 2013. Nonlinear System Identification : NARMAX Methods in the Time, Frequency, and Spatio-Temporal Domains. Wiley, New York.
- Billing, S.A., Voon, W.S.F., 1986. Correlation based model validity tests for nonlinear models. International Journal of Control. 44, 235-244.
- Blanke, M., Kinnaert, M., Lunze, J., Staroswiecki, M., 2006. Diagnosis and Fault-Tolerant Control. 2nd edition. Springer, Berlin.
- Bishop, C.M., 2006. Pattern recognition and machine learning. Springer, New York.
- Borutzky, W., 2010. Bond Graph Modelling of Engineering Systems. Springer, London.
- Brodsky, E., Darkhovsky, B.S., 2000. Non-parametric statistical diagnosis : problems and methods. Kluwer, Dordrecht.
- Brown, A.E., 1999. Risk analysis : An investment in engineering. Process Safety Progress.18, 121-125.
- Cicile, J.C., 2001. Distillation. Absorption. Etude pratique. Techniques de l'ingénieur. Génie des procédés. J2621-20.
- Chai, W., Qiao, J., 2014. Passive robust fault detection using RBF neural modeling based on set membership identification. Engineering Applications of Artificial Intelligence. 28, 1-12.

- Chen, S., Billings, S.A., 1989. Representations of non-linear systems : the NARMAX model. *International Journal of Control*. 49, 1013-1032.
- Cheng, Y., Wang, L., Hu, J., 2011. A two-step scheme for polynomial NARX model identification based on MOEA with prescreening process. *IEEJ Transactions on Electrical and Electronic Engineering*. 6, 253-259.
- Chetouani, Y., 2014. Model selection and fault detection approach based on Bayes decision theory : Application to changes detection problem in a distillation column. *Process Safety and Environment Protection*. 92, 215-223.
- Chetouani, Y., 2009. Model-order reduction based on artificial neural networks for accurate prediction of the product quality in a distillation column. *International Journal of Automation and Control*. 3, 332-351.
- Chetouani, Y., 2008. Design of a multi-model observer-based estimator for Fault Detection and Isolation (FDI) strategy : application to a chemical reactor. *Brazilian Journal of Chemical Engineering*. 25, 777-788.
- Chetouani, Y., 2006. Application of the generalized likelihood ratio test for detecting changes in a chemical reactor. *Process Safety and Environmental Protection*. 84, 371-377.
- Dash, S., Rengaswamy, R., Venkatasubramanian, V., 2003. Fuzzy-logic based trend classification for fault diagnosis of chemical processes. *Computers and Chemical Engineering*. 27, 347-362.
- Deza, M.M., Deza, E., 2009. *Encyclopedia of distances*. Springer, Berlin.
- Ding, F., Chen, T., 2005. Identification of Hammerstein nonlinear ARMAX systems. *Automatica*. 41, 1479-1489.
- Ding, S.X., 2008. *Model-based Fault Diagnosis Techniques : Design Schemes, Algorithms, and Tools*. Springer, Berlin.
- Ditzler, G., Polikar, R., 2011. Hellinger Distance Based Drift Detection for Nonstationary Environments. In *IEEE Symposium on Computational Intelligence in Dynamic and Uncertain Environments (CIDUE)*, Paris. 41-48.

- Djeziri, M.A., Merzouki, R., Oueld-Bouamama, B., 2009. Robust monitoring of an electric vehicle with structured and unstructured uncertainties. *IEEE Transactions on Vehicular Technology*. 58, 4710-4719.
- Dreyfus, G., Martinez, J.M., Samuelides, M., Gordon, M.B., Badran, F., Thiria, S., Hérault, L., 2004. Réseaux de neurones : Méthodologie et applications. Editions Eyrolles.
- Dubuisson, B., 2001. Diagnostic, intelligence artificielle et reconnaissance des formes. Hermès, Paris.
- Duda, R.O., Hart, P.E., Stork, D.G., 2000. Pattern classification. 2nd edition, Wiley, New York.
- Dunjó, J., Fthenakis, V., Vílchez, J.A., Arnaldos, J., 2010. Hazard and operability (HAZOP) analysis. A literature review. *Journal of hazardous materials*. 173, 19-32.
- Gawthrop, P.J., Wagg, D.J., Neild, S.A., 2009. Bond graph based control and substructuring. *Simulation Modelling Practice and Theory*. 17, 211-227.
- Gentil, S., 2007. Supervision des Procédés Complexes. Hermes, Paris.
- Gertler J., Costin, M., Fang, X., Kowalczyk, M., Kunwer, M., Monajemy, R., 1995. Model Based Diagnosis for Automotive Engines-Algorithm Development and Testing on a Production Vehicle. *IEEE Transactions on Control Systems Technology*. 3, 61-69.
- Ghiaus, C., 1999. Fault diagnosis of air conditioning systems based on qualitative bond graph. *Energy and buildings*. 30, 221-232.
- Gibbs, A.L., Su, F.E., 2002. On choosing and bounding probability metrics. *International Statistical Review*. 70, 419-435.
- Gins, G., Van den Kerkhof, P., Vanlaer, J., Van Impe, J.F.M., 2015. Improving classification-based diagnosis of batch processes through data selection and appropriate pretreatment. *Journal of Process Control*. 26, 90-101.

- Giri, F., Bai, E.W., 2010. Block-oriented nonlinear system identification. Springer, Berlin.
- Giri, F., Rochdi, Y., Chaoui, F.Z., Brouri, A., 2008. Identification of Hammerstein systems in presence of hysteresis-backlash and hysteresis-relay nonlinearities. *Automatica*. 44, 767-775.
- Georgoulas, G., Mustafa, M.O., Tsoumas, I.P., Antonino-Daviud, J.A., Climente-Alarcond, V., Stylios, C.D., Nikolakopoulos, G., 2013. Principal Component Analysis of the start-up transient and Hidden Markov Modeling for broken rotor bar fault diagnosis in asynchronous Machines. *Expert Systems with Applications*. 40, 7024-7033.
- Gustafsson, F., 2000. Adaptive filtering and change detection. Wiley, New York.
- Harkat, M.F., Mourot, G., Ragot, J., 2006. An improved PCA scheme for sensor FDI : Application to an air quality monitoring network. *Journal of Process Control*. 16, 625-634.
- Harmouche, J., Delpha, C., Diallo, D., 2014. Incipient fault detection and diagnosis based on Kullback–Leibler divergence using Principal Component Analysis : Part I. *Signal Process*. 94, 278-287.
- Harrou, F., Nounou, M.N., Nounou, H.N., Madakyaru, M., 2013. Statistical fault detection using PCA-based GLR hypothesis testing. *Journal of Loss Prevention in the Process Industries*. 26, 129-139.
- Hervé, A., Sipp, D., Schmid, P.J., Samuelides, M., 2012. A physics-based approach to flow control using system identification. *Journal of Fluid Mechanics*. 702, 26-58.
- Huyck, B., De Brabanter, K., Logist, F., De Brabanter, J., Van Impe, J., De Moor, B., 2011. Identification of a Pilot Scale Distillation Column : A Kernel Based approach. 18th IFAC congress Milano, August 28- September 2.
- Isermann, R., Münchhof, M., 2011. Identification of Dynamic Systems : An Introduction with Applications. Springer, Berlin.

- Isermann, R., 2006. Fault diagnosis systems. Springer, Berlin.
- Isermann, R., 1997. Trends in the application of model-based fault detection and diagnosis of technical processes. *Control Engineering Practice*. 5, 709-719.
- Jolliffe, I.T., 2002. Principal Component Analysis. 2nd edition, Springer, New York.
- Jia, F., Martin, E.B., Morris, A.J., 1998. Non-linear Principal Components Analysis for Process Fault Detection. *Computers and Chemical Engineering*. 22, S851-S854.
- Karra, S., Karim, M.N., 2009. Comprehensive methodology for detection and diagnosis of oscillatory control loops. *Control Engineering Practice*. 17, 939-956.
- Koller, E., 2013. Aide-mémoire de génie chimique. 4<sup>e</sup> édition, Dunod, Paris.
- Kullback, S., Leibler, R., 1951. On information and sufficiency. *Annals of Mathematical Statistics*. 22,86-79 .
- Lai, T.L., 1998. Information bounds and quick detection of parameter changes in stochastic systems. *IEEE Transactions on Information Theory*. 44, 2917-2929.
- Landau, I.D., Lozano, R., M'Saad, M., Karimi, A., 2011. Adaptive Control : Algorithms, Analysis and Applications. Springer, London.
- Landau, I.D., 2002. Commande des systems : Conception, Identification et Mise œuvre. Hermes, Paris.
- Laurent, A., 2003. Sécurité Des Procédés Chimiques, Connaissance de Base et Méthodes D'analyse de Risques. TecDoc, Lavoisier, Paris.
- Le, F., Markovsky, I., Freeman, C.T., Rogers, E., 2012. Recursive identification of hammerstein systems with application to electrically stimulated muscle. *Control Engineering Practice*. 20, 386-396.
- Leontaritis, I.J., Billings, S.A., 1985. Input-output parametric models for nonlinear systems. *International Journal of Control*. 4, 303-344.
- Li, W., Yue, H., Valle-Cervantes, S., Qin, S.J., 2000. Recursive PCA for adaptive process monitoring. *Journal of process control*. 10, 471-486.

- Ljung, L., 1999. System Identification, Theory for the User. Prentice Hall, Englewood Cliffs, New Jersey.
- Lorden, G., 1971. Procedures for Reacting to a Change in Distribution. The Annals of Mathematical Statistics. 42, 1897-1908.
- Luenberger, D.G., 1964. Observing the state of a linear system. IEEE Transactions on Military Electronics. 8, 74-80.
- Lyonnet, P., Thomas, M., Toscano, R., 2012. Fiabilité, diagnostic et maintenance prédictive des systèmes. Lavoisier Tec et doc, Paris.
- Maddison, D., 2005. Air pollution and hospital admissions : an ARMAX modelling approach. Journal of Environmental Economics and Management. 49, 116-131.
- Manssouri, I., Chetouani, Y., El Kihel, B., 2008. Using neural networks for fault detection in a distillation column. International Journal of Computer Applications in Technology. 32, 181-186.
- Namdari, M., Jazayeri-Rad, H., 2014. Incipient fault diagnosis using support vector machines based on monitoring continuous decision functions. Engineering Applications of Artificial Intelligence. 28, 22-35.
- Mehra R.K., Peshon, I., 1971. An innovation approach to fault detection and diagnosis systems. Automatica. 7, 637-640.
- Mnassri, B., 2012. Analyse de données multivariées et surveillance des processus industriels par analyse en composantes principales. Thèse de Doctorat, Université d'Aix-Marseille.
- Monroy, I., Benitez, R., Escudero, G., Graells, M., 2012. Enhanced plant fault diagnosis based on the characterization of transient stages. Computers and Chemical Engineering. 37, 200-213.
- Moustakides, G.V., 1986. Optimal Stopping Times for Detecting Changes in Distributions. The Annals of Statistics. 14, 1379-1387.



- Muddu, M., Naraga, A., Patwardhan, S.C., 2010. Reparametrized ARX Models for Predictive Control of Staged and Packed Bed Distillation Columns. *Control Engineering Practice*. 18, 114–130.
- Nash, J.E., Sutcliffe, J.V., 1970. River flow forecasting through conceptual models. *Journal of Hydrol.* 10, 282–290.
- Nelles, O., 2001. *Nonlinear system identification : from classical approaches to neural networks and fuzzy models*. Springer, Berlin.
- Neyman, J., Pearson, E.S., 1933. On the problem of the most efficient tests of statistical hypotheses. *Philosophical Transactions of the Royal Society of London. Series A*. 231, 289–337.
- Nugroho, S., Nazaruddin, Y.Y., Tjokronegoro, H. A., 2004. Non-linear Identification of Aqueous Ammonia Binary Distillation Column Based on Simple Hammerstein Model. *Proceeding of 5th Asian Control Conference, Melbourne, Australia, July 20–23*, 118–123.
- Page, E. S., 1954. Continuous inspection schemes. *Biometrika*. 41, 100-115.
- Peng, Z.K., Lang, Z.Q., Wolters, C., Billings, S.A., Worden, K., 2011. Feasibility study of structural damage detection using NARMAX modelling and Nonlinear Output Frequency Response Function based analysis. *Mechanical Systems and Signal Processing*. 25, 1045-1061.
- Pukelsheim, F., 1994. The Three Sigma Rule. *American Statistician*. 48, 88-91.
- Qi, C., Li, H.X., 2009. A time/space separation-based Hammerstein modeling approach for nonlinear distributed parameter processes. *Computers & Chemical Engineering*. 33, 1247-1260.
- Ragot, J., Darouach, M., Maquin, D., Bloch, G., 1990. *Validation de données et diagnostic. Traité des nouvelles technologies, série diagnostic et maintenance*. Hermès, Paris.

- Rajakarunakaran, S., Venkumar, P., Devaraj, D., Rao, K., 2008. Artificial neural network approach for fault detection in rotary system. *Applied Soft Computing*. 8, 740-748.
- Rejeb, S., Raoudha, B.H.A., Fayçel, B.H., Abdelkader, C., Hassani, M., 2011. Recursive identification of Hammerstein ARMAX model with general discontinuous nonlinearity. *Scientific Research and Essays*. 6, 4925-4935.
- Ríos-Moreno, G. J., Trejo-Perea, M., Castañeda-Miranda, R., Hernández-Guzmán, V. M., Herrera-Ruiz, G., 2007. Modelling temperature in intelligent buildings by means of autoregressive models. *Automation in Construction*. 16, 713-722.
- Ritov, Y., 1990. Decision theoretic optimality of the CUSUM procedure. *Annals of Statistics*. 18, 1464-1469.
- Samantaray, A.K., Ould-Bouamama, B., 2008. *Model-based process supervision*. Springer, London.
- Shashoa N.A.A., Kvaščev, G., Marjanović, A., Worden, K., 2013. Sensor fault detection and isolation in a thermal power plant steam separator. *Control Engineering Practice*. 21, 908-916.
- Shewhart, W.A., 1931. *Economic Control of Quality Manufactured Product*. D. Van Nostrand, Princeton, New Jersey.
- Shumsky, A., 2007. Redundancy relations for fault diagnosis in nonlinear uncertain systems. *International Journal of Applied Mathematics and Computer Science*. 17, 477-489.
- Shi, Z., Gu, F., Lennox, B., Ball, A.D., 2005. The development of an adaptive threshold for model-based fault detection of a nonlinear electro-hydraulic system. *Control Engineering Practice*. 13, 1357-1367.
- Simani, S., Fantuzzi, C., Patton, R.J., 2002. *Model-based Fault Diagnosis in Dynamic Systems Using Identification Techniques*. Springer, London.

- Sjöberg, J., Zhang, Q., Ljung, L., Benveniste, A., Delyon, B., Glorennec, P., et al., 1995. Nonlinear black-box modeling in system identification : A unified approach. *Automatica*. 31, 1691-1724.
- Söderström, T., Stoica, P., 1989. *System Identification*. Prentice-Hall, Englewood Cliffs, New Jersey.
- Souriau, A., Sylvander, M., Maupin, V., Fels, J.F., Rigo, A., 2002. Enregistrements sismologiques de l'explosion sur le site de l'usine AZF (Toulouse, France). *Comptes Rendus Geoscience*. 334, 155-161.
- Stellman, J.M., Dufresne, 2000. *Encyclopédie de sécurité et de santé au travail*, chapitre 39. Volume 2, Bureau International du travail, Genève.
- Sticklmair, J.G., Fair, J.R., 1998. *Distillation. Principles and practice*. Wiley, New York.
- Stoumbos, Z.G., Reynolds, M.R., Ryan T.P., Woodall, W.H., 2000. The state of statistical process control as we proceed into the 21st century. *Journal of the American Statistical Association*. 95, 992-998.
- Trajin, B., 2009. *Analyse et traitement de grandeurs électriques pour la détection et le diagnostic de défauts mécaniques dans les entraînements asynchrones. Application à la surveillance des roulements à billes*. Thèse de Doctorat, Institut National Polytechnique de Toulouse (INPT).
- Tharrault, Y., Mourot, G., Ragot, J., Maquin, D., 2008. Fault detection and isolation with robust principal component analysis. *International Journal of Applied Mathematics and Computer Science*. 18, 429-442.
- Tixier, J., Dusserre, G., Salvi, O., Gaston, D., 2002. Review of 62 risk analysis methodologies of industrial plants. *Journal of Loss Prevention in the process industries*. 15, 291-303.
- Trigeassou, J.C., 2011. *Diagnostic des machines électriques*. Lavoisier, Paris.
- Toscano, R., 2004. *Commande et diagnostic des systèmes dynamiques : modélisation, analyse, commande par PID et par retour d'état, diagnostic*. Ellipses, Paris.

- Videau, G., Raïssi, T., Zolghadri, A., 2006. Détection de défauts par analyse par intervalles. Journées Identification et Modélisation Expérimentale. Poitiers, 16-17 novembre.
- Waller, J.B., Böling, J.M., 2005. Multi-variable nonlinear MPC of an ill-conditioned distillation column. *Journal of process control*. 15, 23-29.
- Wang, X., Kruger, U., Lennox, B., 2003. Recursive partial least squares algorithms for monitoring complex industrial processes. *Control Engineering Practice*. 11, 613-632.
- Wang, Z., Zhao, J., Shang, H., 2012. A hybrid fault diagnosis strategy for chemical process startups. *Journal of Process Control*. 22, 1287-1297.
- Wauquier, J.P., 1998. *Le raffinage du pétrole : Procédés de séparation*. Technip, Paris.
- Willsky, A.S., 1976. A survey of design methods for failure detection in dynamic systems. *Automatica*. 12, 601-611.
- Zhang, Y., Jiang, J., 2008. Bibliographical review on reconfigurable fault-tolerant control systems. *Annual Reviews in Control*. 32, 229–252.
- Zhu, J., Shu, Y., Zhao, J., Yang, F., 2014. A dynamic alarm management strategy for chemical process transitions. *Journal of Loss Prevention in the Process industries*. 30, 207-218.
- Zhu, Y., 1999. Distillation Column Identification for Control using Wiener Model. *Proceedings of the American Control Conference*. San Diego, California, 23-29 (June 1999).
- Zolghadri, A., Henry, D., Cieslak, J., Efimov, D., Goupil, P., 2014. *Fault Diagnosis and Fault-Tolerant Control and Guidance for Aerospace Vehicles : From Theory to Application*. Springer, London.
- Zwingelstein, G., 1995. *Diagnostic des défaillances : Théorie et pratique pour les systèmes industriels*. Hermès, Paris.

