



**République Algérienne Démocratique et Populaire**  
**Ministère de l'Enseignement Supérieur et de la Recherche Scientifique**

**UNIVERSITÉ DE BATNA 2**  
Institut d'Hygiène et de Sécurité  
Laboratoire de Recherche en Prévention Industrielle (LRPI)

## **THÈSE**

Présentée pour l'obtention du grade de

**DOCTEUR EN SCIENCES**

En

Hygiène et Sécurité Industrielle

*Option* : Gestion des Risques

Par

**CHEBIRA Samia**

---

**Diagnostic et évaluation du risque incendie par  
la démarche RNA - Analyse statistique:  
cas de l'industrie Algérienne**

---

Soutenue publiquement le / /2021 devant le jury composé de :

Mr Rachid Naït-Saïd	Professeur à l'Université de Batna 2	<b>Président</b>
Mr Noureddine Bourmada	Professeur à l'Université de Batna 2	<b>Rapporteur</b>
Mr Belkacem Adouane	Professeur l'Université de Batna 1	<b>Examineur</b>
Mr Abderrahmane Dib	Professeur à l'Université Oum El Bouaghi	<b>Examineur</b>
M <sup>me</sup> Nouara Ouazraoui	Maître de Conférences A à l'Université de Batna 2	<b>Membre Invité</b>

**2020-2021**

# Dédicace

---

*À la mémoire de mon père,  
À ma mère,  
À mon mari,  
À ma fille Rahma,  
À ma sœur et mes frères,  
À tous ceux qui me sont chers*

*Je dédie cette thèse*

# Remerciements

---

*En premier lieu, je remercie le bon dieu de m'avoir donné la force et la patience pour achever ce travail de thèse.*

J'exprime mes profonds remerciements à mon directeur de thèse, le professeur Boumada Nourddine, qui a su m'encourager tout au long de ces années. Ces remarques très pertinentes ont permis d'améliorer la qualité du manuscrit final. Pour sa patience, je tiens à lui exprimer mes profonds remerciements.

Je tiens aussi à exprimer mes vifs remerciements et ma profonde gratitude à Monsieur Djebabra mebarek, Professeur à l'université de Batna 2 et directeur du laboratoire LRPI, pour l'aide considérable qu'il m'a apporté, pour ses encouragements et sa disponibilité. Je suis sincèrement reconnaissante pour ses précieux conseils.

Qu'il me soit permis ici de présenter mes vifs remerciements et mon profond respect à Monsieur Nait Said Rachid Professeur à l'université de Batna 2, pour l'honneur qu'il me fait en acceptant de présider le jury de cette thèse.

Je tiens à témoigner toute ma reconnaissance à M. Belkacem Adouane Professeur à l'Université de Batna 1, M. Abderrahmane Dib Professeur à l'Université d'Oum El Bouaghi et enfin à M<sup>me</sup> Nouara Ouzraoui Maître de Conférences "A" à l'Université de Batna 2, pour avoir bien voulu me faire l'honneur d'examiner ce travail et de participer à ce jury.

Je voudrais, en particulier, exprimer ma reconnaissance et mon estime les plus sincères à M<sup>me</sup> Ouazraoui Nouara, pour son aide précieuse et ses encouragements incessants.

Que mon mari trouve ici mes vifs et profonds remerciements, d'avoir été toujours à mes côtés, de croire en moi plus que personne d'autre, de ne pas m'avoir laissé baisser les bras dans les moments les plus difficiles et bien sure d'avoir partagé aussi les moments les plus heureux.

Enfin, je n'oublie pas d'exprimer mes remerciements à tous mes amies et collègues enseignants et personnel de l'institut d'Hygiène et Sécurité Industrielle de l'université de Batna 2, qui m'ont soutenu, même de loin. Je leur en suis reconnaissante.

# Résumé

---

Dans les systèmes industriels, toutes les ressources disponibles sont sélectionnées pour améliorer les performances du système. Cependant, dans les systèmes critiques, tout type de défaut peut entraîner de graves conséquences. L'une des principales techniques pour améliorer la fiabilité des processus consiste à détecter et isoler précocement les défauts. La détection précoce des défauts peut aider à éviter un arrêt du système, des défaillances de composants et même des catastrophes entraînant d'importantes pertes économiques et en vies humaines. Un système qui donne la possibilité de détecter, d'isoler et d'identifier les défauts est appelé un système de diagnostic des défauts. La technique des Réseaux de Neurones Artificiels (*RNA*) est un bon outil pour la détection et le diagnostic de plusieurs types de défauts dans les systèmes industriels. Dans cette thèse, une description d'un système industriel à partir duquel il est possible de caractériser un couplage original de méthodes d'analyse et de réseaux de neurones, a été présentée, pour un diagnostic des défauts. Cette technique a été mise en œuvre et testée sur le système anti-éruption de puits l'un des éléments les plus importants de l'équipement de contrôle de puits de pétrole et de gaz. Trois modèles neuronaux ont été utilisés, le Perceptron Multi-Couche (*PMC*), le Réseau à Fonctions de base Radiales (*RFR*) et les Réseaux Neuronaux de Régression Généralisée (*RNRG*). Ces modèles ont été formés et testés, puis leurs performances comparatives ont été présentées. Enfin, l'éruption est l'un des scénarios accidentels critiques qui ont été identifiés à partir de l'analyse HAZOP, une évaluation du risque incendie lié à ce scénario est effectuée.

**Mots-clés:** Diagnostic des défauts, Réseaux de neurones, HAZOP, système anti-éruption de puits.

# Abstract

---

In industrial systems, all available resources are selected to improve system performance. However, in critical systems, any type of fault can lead to serious consequences. One of the main techniques for improving process reliability is to detect and isolate faults early. Detecting faults early can help prevent system downtime, component failures, and even disasters with significant economic and loss of life. A system that provides the ability to detect, isolate and identify faults is called a fault diagnosis system. The Artificial Neural Network (*ANN*) technique is a good tool for the detection and diagnosis of several types of faults in industrial systems. In this thesis, a description of an industrial system from which it is possible to characterize an original coupling of analysis methods and neural networks, was presented, for a fault diagnosis. This technique has been implemented and tested on the Blow-Out Preventer (*BOP*) system, one of the most important pieces of oil and gas well control equipment. Three neural models were used, the multilayer perceptron (*MLP*), the radial basis function network (*RBF*) and generalized regression neural networks (*GRNN*). These models were trained and tested, then their comparative performance was presented. Finally, the eruption is one of the critical accident scenarios that have been identified from the HAZard and OPerability (HAZOP) analysis, fire risk assessment related to this scenario is carried out.

**Keywords** - Fault diagnosis, Artificial neural networks, HAZOP, Blow-Out Preventer.

في الأنظمة الصناعية ، يتم اختيار جميع الموارد المتاحة لتحسين أداء النظام. ومع ذلك ، في الأنظمة الحرجة ، يمكن أن يؤدي أي نوع من الأخطاء إلى عواقب وخيمة. تتمثل إحدى التقنيات الرئيسية لتحسين موثوقية العملية هي اكتشاف الأخطاء وعزلها مبكرًا. يمكن أن يساعد اكتشاف الأعطال مبكرًا في منع تعطل النظام وفشل المكونات وحتى الكوارث ذات الخسائر الاقتصادية الكبيرة والخسائر في الأرواح. يُطلق على النظام الذي يوفر القدرة على اكتشاف الأخطاء وعزلها وتحديد نظام تشخيص الأعطال. تعد تقنية الشبكة العصبية الاصطناعية (ANN) أداة جيدة لاكتشاف وتشخيص عدة أنواع من العيوب في الأنظمة الصناعية. في هذه الأطروحة ، تم تقديم وصف لنظام صناعي يمكن من خلاله وصف اقتران أصلي لطرق التحليل والشبكات العصبية ، من أجل تشخيص الخطأ. تم تنفيذ هذه التقنية واختبارها على نظام مانع الانفجار (BOP) ، وهو أحد أهم قطع معدات التحكم في آبار النفط والغاز. تم استخدام ثلاثة نماذج عصبية ، الإدراك متعدد الطبقات (MLP) ، وشبكة وظيفة الأساس الشعاعي (RBF) والشبكات العصبية الانحدارية المعممة (GRNN). تم تدريب واختبار هذه النماذج ، ثم تم عرض أدائها المقارن. أخيرًا ، يعد الثوران أحد سيناريوهات الحوادث الخطيرة التي تم تحديدها من تحليل المخاطر وقابلية التشغيل (HAZOP) ، تم إجراء تقييم مخاطر الحريق المتعلقة بهذا السيناريو.

**الكلمات المفتاحية -** تشخيص الأعطال ، الشبكات العصبية الاصطناعية ، HAZOP ، مانع الانفجار.

# Table des matières

DEDICACE.....	i
Remerciements .....	ii
Résumé.....	iii
Abstract .....	iv
ملخص.....	v
Table des matières.....	vi
Table des Figures.....	x
Liste des tableaux.....	xi
Acronymes.....	xii
<b>Introduction Générale.....</b>	<b>1</b>
Cadre de l'étude.....	1
Organisation du rapport .....	3
<b>Chapitre 1: Etat de l'art sur le diagnostic.....</b>	<b>4</b>
1.1 Introduction .....	5
1.2 Définitions.....	5
1.3 Surveillance, Supervision et Diagnostic.....	8
1.4 Critère de performance d'un système de diagnostic .....	9
1.5 Classification des méthodes de diagnostic .....	10
1.5.1 Méthodes basées sur des modèles quantitatifs.....	11
1.5.1.1 Estimation de paramètres .....	13
1.5.1.2 Observateurs.....	13
1.5.1.3 Espace de parité .....	13
1.5.2 Méthodes basées sur des modèles qualitatifs.....	14
1.5.2.1 Graphes causaux .....	14
1.5.2.2 Arbres de défaillances et AMDE .....	15
1.5.2.3 Physique qualitative .....	17
1.5.2.4 Hiérarchie d'abstraction de la connaissance des processus.....	17
1.5.3 Les méthodes basées sur l'historique des processus.....	18
1.5.3.1 Système expert .....	19
1.5.3.2 Analyse Qualitative des Tendances ( <i>AQT</i> ) .....	20
1.5.3.3 Analyse en composantes principales / moindres carrés partiels .....	21
1.5.3.4 Réseaux de Neurones Artificiels ( <i>RNA</i> ).....	22
1.6 Choix d'une méthode de diagnostic.....	23
1.7 Conclusion.....	25

<b>Chapitre 2: Application des réseaux de neurones en diagnostic</b> .....	27
2.1 Introduction .....	28
2.2 Historique .....	28
2.3 Du neurone biologique au neurone formel.....	29
2.3.1 Le neurone biologique .....	29
2.3.2 Neurone formel.....	30
2.3.3 Fonction d'activation.....	31
2.4 Propriétés des réseaux de neurones .....	32
2.5 La règle de Hebb .....	32
2.6 Architectures neuronales .....	33
2.6.1 Réseaux de neurones non bouclés «Feed Forward» .....	34
2.6.2 Réseaux de neurones bouclés « Feed-Back » .....	35
2.7 Apprentissage des réseaux de neurones .....	35
2.8 Le Perceptron simple.....	37
2.8.1 Apprentissage du Perceptron .....	37
2.8.2 Règle de Delta.....	38
2.9 Le Perceptron Multi Couches ( <i>PMC</i> ).....	39
2.10 Apprentissage d'un réseau multicouche.....	40
2.10.1 La rétropropagation .....	40
2.10.2 Limites de l'algorithme de rétropropagation .....	41
2.10.3 Quelques algorithmes de rétropropagation .....	42
2.11 Les Réseaux de neurones à Fonctions de base Radiales ( <i>RFR</i> ) .....	43
2.11.1 Architecture .....	43
2.11.2 Apprentissage .....	45
2.12 Réseau de neurones de régression généralisée ( <i>RNRG</i> ) .....	46
2.13 La Carte Auto-Organisatrice de Kohonen ( <i>CAOK</i> ).....	48
2.14 Le réseau de Hopfield.....	49
2.15 Réseaux de neurones et diagnostic .....	50
2.16 Exemple.....	52
2.16.1 Principe du diagnostic.....	53
2.16.2 Modèle d'état du moteur à courant continu .....	53
2.16.3 Architecture du réseau de neurones .....	54
2.16.4 Base d'apprentissage .....	54
2.16.5 Apprentissage du réseau .....	54
2.16.6 Algorithmes d'apprentissage appliqués au réseau .....	55
2.16.7 Résultats de simulations .....	55
2.16.8 Comparaison des résultats .....	57



2.17 Conclusion.....	58
<b>Chapitre 3: Approche de diagnostic proposée.....</b>	<b>60</b>
3.1 Introduction .....	61
3.2 Notions de base relatives à la méthode HAZOP .....	62
3.2.1 Historique et domaine d'application .....	62
3.2.2 Principe et déroulement .....	63
3.3 Diagnostic par HAZOP .....	66
3.4 Diagnostic par réseaux de neurones .....	67
3.5 Approche de diagnostic proposée.....	67
3.5.1 Identification des causes et conséquences - Analyse HAZOP .....	69
3.5.2 Modèles neuronaux proposés .....	70
3.5.2.1 Apprentissage du modèle MLPN.....	70
3.5.2.2 Apprentissage du modèle RBFN.....	71
3.5.2.3 Apprentissage du modèle GRNN.....	71
3.5.3 Evaluation de la performance des modèles proposés .....	72
3.6 Exemple.....	72
3.6.1 Identification des causes et effets - AMDE .....	73
3.6.2 Résultats.....	73
3.7 Conclusion.....	75
<b>Chapitre 4: Application de la démarche proposée au diagnostic d'un système industriel- cas du BOP .....</b>	<b>76</b>
4.1 Introduction .....	77
4.2 Présentation du système BOP.....	77
4.2.1 Généralités .....	77
4.2.2 Fonctions de sécurité .....	78
4.2.3 Positionnement .....	79
4.2.4 Types d'obturateurs .....	79
4.2.5 Description du fonctionnement.....	80
4.2.5.1 Fonctionnement de l'obturateur à mâchoires (Cameron type U) .....	80
4.2.5.2 Fonctionnement de l'obturateur annulaire.....	81
4.2.5.3 Choke-line.....	82
4.2.5.4 Kill-line .....	82
4.2.5.5 Unité d'accumulation et de commande .....	82
4.3 Modes de fonctionnement du système BOP.....	86
4.4 Génération de la base d'apprentissage .....	86
4.5 L'analyse HAZOP.....	87
4.6 Mapping de HAZOP en RNA .....	87

4.7 Phases d'apprentissage.....	88
4.8 Résultats et discussions .....	89
4.9 Evaluation du risque incendie lié à une éruption.....	95
4.9.1 Exemples d'accidents d'éruption .....	95
4.9.2 Risque d'éruption (Risque majeur) .....	97
4.9.2.1 Prévention des venues .....	97
4.9.2.2 Détection de venue.....	98
4.9.2.3 Prévention des éruptions .....	98
4.9.2.4 Conséquences de l'échec du contrôle de puits .....	98
4.9.3 Risque d'incendie .....	98
4.9.4 Risque d'explosion.....	99
4.9.5 Evaluation du risque incendie.....	99
4.9.5.1 Arbre de défaillances pour l'occurrence de venue .....	99
4.9.5.2 Arbre des défaillances pour le système BOP .....	99
4.9.5.3 Analyse de l'Arbre d'événements ( <i>AdE</i> ) pour la détection de venue .....	100
4.9.5.4 Analyse quantitative dans des conditions de fonctionnement normales.....	102
4.9.5.5 Détermination de la fréquence du scénario « Incendie-explosion » .....	102
4.10 Conclusion.....	104
<b>Conclusion Générale et Perspectives .....</b>	<b>105</b>
<b>Bibliographie.....</b>	<b>107</b>
Annexe A.....	127
Annexe B .....	129
Annexe C .....	133
Annexe D.....	135
Annexe E .....	137
Annexe F .....	146

# Table des figures

---

- Figure 1.1: Différents types de défauts d'un processus physique
- Figure 1.2: Structure générale d'un système de diagnostic
- Figure 1.3: Classification des méthodes de diagnostic
- Figure 1.4: Principe de diagnostic basé sur la génération des résidus
- Figure 1.5: Exemple d'un SDG issu du comportement d'une voiture
- Figure 1.6: Architecture d'un système expert
- Figure 1.7: L'approche d'AQT pour le diagnostic de défaut
- Figure 2.1: Neurone biologique
- Figure 2.2: Mise en correspondance neurone biologique / neurone artificiel
- Figure 2.3: Différents types de fonctions de transfert pour le neurone artificiel
- Figure 2.4: Règle de Hebb
- Figure 2.5: Topologies des réseaux de neurones artificiels les plus populaires
- Figure 2.6: Réseau de neurones non bouclé
- Figure 2.7: Réseau de neurones bouclé
- Figure 2.8: Exemple d'un MLP
- Figure 2.9: Principe d'entraînement du réseau par rétro-propagation de l'erreur
- Figure 2.10: Architecture du réseau RBF
- Figure 2.11: Représentation d'une fonction gaussienne en 3 dimensions
- Figure 2.12: Architecture du GRNN
- Figure 2.13: Connexion des neurones dans un réseau de Hopfield
- Figure 2.14: Modèle du moteur à courant continu à aimant permanent
- Figure 2.15: Schéma de principe du diagnostic
- Figure 2.16: Représentation des classes de fonctionnement
- Figure 2.17: Représentation de la performance d'apprentissage par l'algorithme Trainlm
- Figure 3.1: Organigramme d'analyse HAZOP
- Figure 3.2: Méthodologie adoptée pour l'étude comparative de trois modèles neuronaux
- Figure 3.3: Organigramme des principales étapes de la méthode proposée
- Figure 3.4: Mécanisme de défaillance
- Figure 4.1: Exemple d'empilage avec 3 BOP "Cameron type U"
- Figure 4.2: Disposition conventionnelle pour le contrôle de la tête de puits de forage
- Figure 4.3: Ligne d'ouverture et ligne de fermeture du circuit hydraulique
- Figure 4.4: Schéma montrant la déformation du packing unit lors de la fermeture du BOP
- Figure 4.5: Schéma de fonctionnement d'une unité de commande reliée à un BOP
- Figure 4.6: Schéma de fonctionnement d'une unité avec commande pneumatique
- Figure 4.7: Entrées et sorties du système BOP
- Figure 4.8: Mapping graphique de HAZOP en RNA
- Figure 4.9: Les phases d'apprentissage et de test du RNA
- Figure 4.10: Performances du MLPN avec une couche cachée
- Figure 4.11: Performances du MLPN avec deux couches cachées
- Figure 4.12: Performances du MLPN avec trois couches cachées
- Figure 4.13: Diagrammes de dispersion des déviations calculés par rapport aux déviations observées pour les modèles MLPN, RBFN et GRNN pour les phases (a) d'apprentissage et (b) de test
- Figure 4.14: Arbre d'évènement des différentes catégories de conséquences initiales de l'occurrence de venue

# Liste des tableaux

---

- Tableau 1.1: Exemple de tableau AMDEC
- Tableau 1.2: Comparaison de diverses méthodes de diagnostic
- Tableau 2.1: Analogie entre le neurone artificiel et le neurone biologique
- Tableau 2.2: Exemple de différents types d'apprentissages en mode supervisé
- Tableau 2.3: Exemple de différents types d'apprentissages en mode non supervisé
- Tableau 2.4: Résultats d'apprentissage de l'algorithme TRAINLM
- Tableau 2.5: Résultats de généralisation
- Tableau 3.1: Exemples de paramètres pour HAZOP
- Tableau 3.2: Exemples de mots-guides pour HAZOP
- Tableau 3.3: Exemple de table HAZOP
- Tableau 3.4: Exemples de déviations, avec causes et conséquences possibles
- Tableau 3.5 : Caractéristiques des modèles MLPN, RBFN et GRNN
- Tableau 3.6 : Apprentissage et test du réseau RBF
- Tableau 3.7 : Résultat du codage de l'AMDE
- Tableau 4.1: Exemples de scénarios critiques de l'analyse HAZOP
- Tableau 4.2: Nombre d'itérations et temps d'apprentissage pour trois architectures du MLPN
- Tableau 4.3: Performances des modèles MLPN, RBFN et GRNN dans les phases d'apprentissage et de test
- Tableau 4.4: Événements de base des AdD, de la venue (A) et du système BOP (B)
- Tableau 4.5: Probabilités d'occurrence pour la venue et les éléments de détection de venue
- Tableau 4.6: Taux de défaillance des éléments du système BOP
- Tableau 4.7: Résultats d'application de l'AdE l'évaluation du risque incendie-explosion

# Acronymes

---

Adaline	ADApive LINear Element
AdD	Arbres de Défaillances
AdE	Arbre d'Evènements
ACP	Analyse en Composante Principale
AMDE	Analyse des Modes de Défaillance et de leurs Effets
AMDEC	Analyse des Modes de Défaillance et de leurs Effets et de leurs Criticités
ART	Adaptive Resonance Theory
BOP	Blow-Out Preventer
BP	Back Propagation
CAOK	Cartes Auto-Organisatrices de Kohonen
CDL	Cluster Detection and Labeling
CL	Choke Line
ENAFOR	ENtreprise NAational de FORage
FEM	Force Electro-Motrice
GRNN	Generalized Regression Neural Network
HAZOP	HAZard and OPerability
ICI	Imperial Chimecal Industries
KL	Kill Line
LM	Levenberg-Marquardt
LMS	Least Mean Squares
LVQ	Learning Vector Quantization
MCC	Moteur à Courant Continu
MLP	Multi-Layer Perceptron
MLPN	Multi-Layer Perceptron Network
MSE	Mean Square Error
PFD	Process Flow Diagrams
PMC	Perceptron Multi Couches
PLR	Perceptron Learning Rule
PSI	Pound per Square Inch
P&ID	Piping and Instrumentation Diagram
RBFN	Radial Basis Function Network
RFR	Réseau a Fonctions de base Radiales
RNA	Réseaux de Neurones Artificiel
SDG	Signed Directed Graph
SOM	Self-Organizing Map
SSE	Sum Squard Error

*”Le doute est le commencement de la sagesse.”*

*Aristote*

# Introduction Générale

---

## Cadre de l'étude

Les activités industrielles et humaines font presque quotidiennement les grands titres des actualités avec leurs cortèges d'incidents, d'accidents ou d'évènements catastrophiques, citons à titre d'exemple: la catastrophe de Seveso en 1976, la catastrophe de Bhopal en 1984, la catastrophe de Tchernobyl en 1986, la catastrophe d'AZF à Toulouse en 2001, la catastrophe du GNL/K de Skikda en 2004, la catastrophe de Buncefield en Grande Bretagne en 2005, l'explosion de la West Fertilizer Company en 2013, les explosions de Tianjin en 2015, ... . Compte tenu de ces catastrophes et d'autres, il est essentiel d'assurer le fonctionnement normal des installations industrielles. En effet, le risque zéro ou le zéro défaut n'existe malheureusement pas pour les activités industrielles à cause de l'occurrence de défaillances humaines ou matérielles. Des méthodes, des techniques et des outils scientifiques ont été développés dès le début du XX<sup>ème</sup> siècle pour évaluer les risques potentiels, prévoir l'occurrence des défaillances et tenter de minimiser les conséquences des situations catastrophiques lorsqu'elles se produisent.

Durant toute la durée de vie d'un système industriel, on recherche à ce que celui-ci fonctionne de manière sécurisée vis à vis de son environnement humain et matériel, ainsi que vis à vis de sa propre intégrité. Bien entendu, on recherche également à utiliser le système de manière optimale, afin de réduire différents coûts ou temps d'exécution et atteindre une viabilité économique du système. Cependant, des défauts peuvent survenir sur ce système, que ce soit sur l'instrumentation (capteurs et actionneurs) ou dans le système lui-même. Cela peut entraîner une dégradation des performances du système (qualité du produit, stabilité, disponibilité, etc.), ce qui pourrait faire échouer la mission du système en question. En effet, la détermination des conditions de fonctionnement d'une manière continue est nécessaire pour connaître le moment où le système s'écarte de son comportement normal et prendre les mesures nécessaires pour qu'il n'y ait pas d'interruption de service. Dans ce but, la surveillance des systèmes industriels permet la détection et le diagnostic des défauts. La première, la détection, permet de statuer sur la présence ou non d'une faute dans le système, entraînant un dysfonctionnement de celui-ci. La seconde phase, le diagnostic, permet de conclure sur la nature de la faute présente dans le système. Cette préoccupation doit être assurée tout au long de la vie d'un système.

Sur la base de tout ce qui précède et afin de mettre le travail dans sa bonne voie, l'objectif de cette thèse est de développer une méthode de diagnostic, qui détermine l'état actuel du système et identifie les causes probables des défauts, basée sur un couplage original d'une

méthode d'analyse des risques et d'un outil de classification particulier: les Réseaux de Neurones Artificiels (*RNA*).

L'idée forte du concept Réseaux de Neurones Artificiels que l'on appelle également réseaux neuronaux ou connexionnisme, est la suivante: plutôt que de donner des connaissances sophistiquées à un système, on le dote de capacités à en acquérir et/ou à améliorer des connaissances simples. Le connexionnisme est une modélisation très grossière, des plus imparfaites et extrêmement réductrice du fonctionnement des neurones du cerveau humain. Un système connexionniste est formé de plusieurs noyaux interconnectés. Ils sont appelés des neurones, ils sont reliés et organisés d'une certaine façon. Ce système est capable d'apprendre automatiquement à partir d'un certain nombre d'exemples puis de généraliser d'une façon empirique sans requérir une description explicite de la connaissance. De par leur architecture, les réseaux de neurones sont des systèmes opérationnels de modélisation non linéaire. Ils s'appuient sur des résultats mathématiques et statistiques importants qui révèlent une propriété des plus intéressantes: leur aptitude à représenter de fortes non linéarités avec un nombre réduit de paramètres. On comprend donc l'intérêt de leur utilisation pour appréhender les systèmes complexes, qu'ils soient par ailleurs linéaires ou non linéaires.

Les réseaux de neurones constituent aujourd'hui indéniablement une approche importante de la détection et du diagnostic des défauts. Dans la littérature, de nombreux travaux démontrent l'utilité des réseaux de neurones pour la détection et le diagnostic des défauts ainsi que pour la surveillance de processus complexes ([Samanta et Al-Balushi, 2003](#); [Bharadwaj et Parlos, 2004](#); [Samanta, 2004](#); [Boukra et al., 2009](#); [Kalyan et al., 2010](#); [Kankar et al., 2011](#); [Tang et al., 2012](#), [Chine et al., 2016](#); [Fentaye et al., 2018](#))

Dans cette thèse nous présentons une description d'un système industriel à partir duquel il est possible de caractériser un couplage original de l'analyse HAZOP (*HAZard and OPerability*) et de réseaux de neurones, pour un diagnostic des défauts. La principale application de ce travail de thèse concerne le suivi (détection et diagnostic) d'un système anti-éruption de puits (*BOP pour Blow-Out Preventer*) l'un des éléments les plus importants de l'équipement de contrôle de puits de pétrole et de gaz. Ce dispositif sert d'organe principal de sécurité durant les opérations de forage ou d'intervention lourde. Il comporte deux fonctions principales de sécurité:

- dans un premier temps, d'assurer la fermeture du puits en cas de venue;
- dans un second temps, de permettre la circulation de façon à reconditionner la boue et évacuer le fluide ayant pénétré dans le puits (c'est la procédure de contrôle de venues).

Les problèmes de sécurité associés à ce type de système sont de plus en plus présents dans les contraintes opérationnelles. La moindre défaillance du système BOP peut avoir des conséquences graves si elle n'est pas détectée rapidement. Il est particulièrement pertinent de pouvoir suivre ce système en temps réel afin d'assurer la sécurité des biens et des personnes en relation directe ou indirecte avec l'installation de forage, tout en atteignant les objectifs opérationnels fixés.

Enfin, l'éruption est l'un des scénarios accidentels critiques qui ont été identifiés à partir de la méthode d'analyse HAZOP, une évaluation du risque incendie lié à ce scénario est effectuée.

## Organisation du rapport

Le rapport est organisé en quatre chapitres qui peuvent être résumés comme suit:

Nous présentons, dans le premier chapitre, un état de l'art des différentes approches de diagnostic qui ont un objectif de diagnostic pour les systèmes industriels. Nous commençons par quelques définitions concernant le diagnostic. Puis nous décrivons trois grandes familles de méthodes: les méthodes qualitatives à base de modèle, les méthodes quantitatives à base de modèle et les méthodes basées sur l'historique du processus. Nous terminerons ce premier chapitre par une comparaison entre quelques techniques, en terme de caractéristiques souhaitables des systèmes de diagnostic.

Le second chapitre est l'objet d'une présentation plus approfondie des réseaux de neurones où il y est décrit le principe de fonctionnement de plusieurs modèles neuronaux et particulièrement les modèles qui ont été jugés les plus pertinents pour le domaine du diagnostic des systèmes industriels, à savoir: le Perceptron Multi Couches (*PMC*) et les Réseau à Fonctions de base Radiales (*RFR*) et avec un degré moindre, le modèle de *Kohonen* et celui de *Hopfield* ([Zemouri, 2003](#)). Nous verrons ensuite comment les réseaux de neurones sont appliqués en détection et diagnostic des défauts. Une comparaison entre divers algorithmes à rétropropagation est présentée via un exemple pédagogique.

Le troisième chapitre est consacré à la présentation de la méthodologie proposée pour le diagnostic des défauts basée sur la combinaison de l'analyse HAZOP et des réseaux de neurones. Avant d'aborder l'approche proposée, nous rappelons quelques définitions fondamentales relatives à la méthode HAZOP, ensuite nous présentons l'apport de cette méthode et des réseaux de neurones pour le diagnostic des défauts. Nous montrons ensuite, à travers l'exemple présenté au chapitre deux, la possibilité de combiner la méthode d'analyse AMDE (*Analyse des Modes de Défaillance et de leurs Effets*) et les réseaux de neurones de type RBF pour le diagnostic des défauts.

Le quatrième et dernier chapitre est une application de la méthode proposée sur l'un des systèmes les plus importants de l'entreprise SONATRACH, pouvant engendrer en cas de défaillance des conséquences humaines, matérielles et environnementales critiques voire catastrophiques. Il s'agit du système anti-éruption de puits-BOP. Nous présentons les performances en détection et diagnostic de trois modèles neuronaux face à ce système complexe. Enfin, une évaluation du risque incendie lié au scénario d'éruption identifié par l'analyse HAZOP, est effectuée.



*”L’homme et sa sécurité doivent constituer la première  
préoccupation de toute aventure technologique.”*  
*Albert Einstein*

## Chapitre 1: Etat de l'art sur le diagnostic

---

## 1.1 Introduction

La complexité croissante des systèmes automatisés (nucléaire, chimique, pétrochimique, aérospatiale) s'est accompagnée d'une demande toujours plus forte de la disponibilité et de la sécurité des installations industrielles. De ce fait, cette évolution a complexifié la tâche de diagnostic des installations industrielles. Étant données ces difficultés, l'opérateur peut commettre des erreurs décisives et prendre de mauvaises actions. Des statistiques industrielles montrent que 70% des accidents industriels sont causés par des erreurs humaines (Molina, 2005). Ces événements anormaux peuvent affecter indifféremment non seulement l'économie du payé, mais surtout la sécurité de l'homme et l'environnement. Malgré les avancées effectuées sur les commandes à distance des équipements industriels, plusieurs accidents survenus dans le monde posent le problème du développement des techniques de supervision. Parmi les accidents et catastrophes les plus spectaculaires on peut citer celle de l'Union Carbide à Bhopal en Inde en 1984 et d'Occidental Petroleum à Piper Alpha (Lees, 1996), ou Tchernobyl en 1986 ou encore l'explosion d'une unité de Kuwait Petrochemical à la raffinerie de Mine Al-Ahmedi refinery en juin 2000, laquelle causa près de 100 millions de dollars de dommages.

Lors du fonctionnement d'un système industriel, il est nécessaire de le gérer face à divers problèmes de fonctionnement, qu'il s'agisse de dysfonctionnements ou de pannes des différents capteurs ou actionneurs (vannes, pompes, agitateurs...). L'objectif du diagnostic est de constater l'apparition d'un défaut, d'en trouver la cause puis d'en déduire la marche à suivre afin d'assurer la sûreté de fonctionnement du système.

Dans ce chapitre, nous rappelons quelques définitions concernant le diagnostic. Puis nous énonçons le principe du diagnostic des systèmes et nous présentons une revue non exhaustive des méthodes appliquées au diagnostic issues de la communauté de l'ingénierie et de la recherche. Dans la plupart des cas, les méthodes de diagnostic sont liées à la connaissance disponible sur le procédé et à sa représentation et sont classées de différentes façons par de nombreux auteurs (Zwingelstein, 1995; Frank et Köppen-Seliger, 1997; Isermann, 1997; Chantler et al., 1998; Gentil, 2003; Venkatasubramanian et al., 2003a; Park et al., 2020). La terminologie et la classification ne sont pas toujours homogènes, elles sont influencées par les contextes et les terminologies particulières à chaque communauté et domaine d'application.

## 1.2 Définitions

Les définitions visent à poser de manière claire et précise les termes employés dans le domaine du diagnostic. La diversité (pluralité, variété, l'abondance) des définitions trouvées dans la littérature nous a amené à établir un lexique sur les termes qui seront utiles pour la compréhension de la suite de cette thèse. Certaines de ces définitions ont été extraites à partir des références suivantes: (Villemeur, 1988; Dubuisson, 1990; Combacau, 1991; Toguyeni, 1992; Zwingelstein, 1995; Basseville et al., 1996; Isermann et Ballé, 1997; Lefebvre, 2000; Elosta, 2005; Toscano, 2005; Lyonnet Patrick et al., 2012; Agrawal et al., 2015).

### **Défaillance**

Une défaillance est l'altération ou la cessation de l'aptitude d'un système à accomplir sa ou ses fonctions requises avec les performances définies dans les spécifications techniques. Elles sont détectées par leurs symptômes.

On peut classer les défaillances selon leur degré de sévérité par :

- *Défaillance mineur*: Elle nuit au bon fonctionnement du dispositif en causant des dommages négligeables telle qu'une fuite de liquide froid sur une bride d'une tuyauterie.
- *Défaillance majeur*: Appelée aussi défaillance significative. Elle nécessite un processus de traitement. Elle ne cause pas de dommage notable, à titre d'exemple la dégradation d'un palier d'un group motopompe, suite à un échauffement anormal.
- *Défaillance critique*: Nécessite une intervention d'urgence. Elle risque de causer des blessures aux personnes ou des dégâts importants aux matériels, à titre d'exemple la rupture d'une tuyauterie d'alimentation en vapeur vive d'une turbine.
- *Défaillance catastrophique* : Elle entraîne la perte d'une ou de plusieurs fonction essentielles d'un dispositif en causant des dommages importants au système, à l'environnement et peut entraîner la mort des personnes. Plusieurs exemples dans différents domaines illustrent ce type de défaillances tels que Tchernobyl, Bhopal, AZF,...

### **Panne**

La panne est l'inaptitude d'un dispositif (composant, sous-système, système) à accomplir une fonction requise. Une panne résulte toujours d'une défaillance et donc d'un défaut:

*Défaut* —→ *Défaillance* —→ *Panne*

La défaillance correspond à un événement et la panne à un état. Sur le plan temporel, la défaillance correspond à une date et la panne à une durée comprise entre la date d'occurrence de la défaillance et la date de fin de réparation.

### **Défaut**


Un défaut correspond à tout écart entre la caractéristique observée sur le dispositif et la caractéristique théorique. Cet écart est idéalement nul en l'absence de défaut.

Comme pour les défaillances et les pannes, il existe une progression dans la sévérité des défauts: mineur, majeur, critique et catastrophique. Lorsqu'un défaut mineur ou majeur se produit, le système de production fonctionne mais dans un mode dégradé. Dans le cas de défaillance, le système ne fonctionne plus et il doit être réparé.

Les défauts sont classés selon leur origine en (Figure 1.1):

- *Défauts de capteurs*: Ils se caractérisent par un écart entre la valeur réelle de la grandeur et sa mesure. On classe ces défauts en fonction de leur type en: biais, dérive, modification du gain de mesure, valeurs aberrantes, blocage du capteur à une valeur atteinte ou à une coupure électrique du capteur.

- *Défauts d'actionneurs* : Ils se traduisent par une incohérence entre les commandes et la sortie.
- *Défauts du processus physique* : Ils sont dues à des modifications de la structure ou des paramètres du modèle.



Sources de perturbation (bruit aléatoire, variations des paramètres, erreur de modèle ...)

**Figure 1.1-** Différents types de défauts d'un processus physique

### **Mode de fonctionnement**

Dans un système on peut observer généralement des modes de fonctionnement de plusieurs types parmi lesquels :

- *Mode de fonctionnement nominal* : c'est le mode où l'équipement ou le système industriel remplit sa mission dans les conditions de fonctionnement requises par le constructeur et avec les exigences attendues de l'exploitant.
- *Mode de fonctionnement dégradé* : qui correspond soit à l'accomplissement partiel de la mission, soit à l'accomplissement de celle-ci avec des performances moindre. En d'autres termes, il y a eu dégradation dans l'équipement ou le système mais pas de défaillance.
- *Mode de défaillance* : qui correspond à des mauvais fonctionnements du système, c'est-à-dire qu'il y a eu défaillance soit après dégradation soit défaillance brusque. Un mode de défaillance est caractérisé par les effets causés par cette défaillance. Les effets sont toutes les modifications qui découlent directement de l'apparition d'un évènement. Ces effets peuvent être mesurables ou qualifiables. En faisant une analyse de cause à effet de la défaillance, on peut associer le mode de défaillance à toute cette analyse faite par un expert.

### **Détection**

La détection d'un défaut consiste à être capable de classer les situations observables comme étant normales ou anormales.

### **Diagnostic**

Le diagnostic consiste à établir un lien de cause à effet entre le symptôme observé et la défaillance qui est survenue, ses causes et ses conséquences.

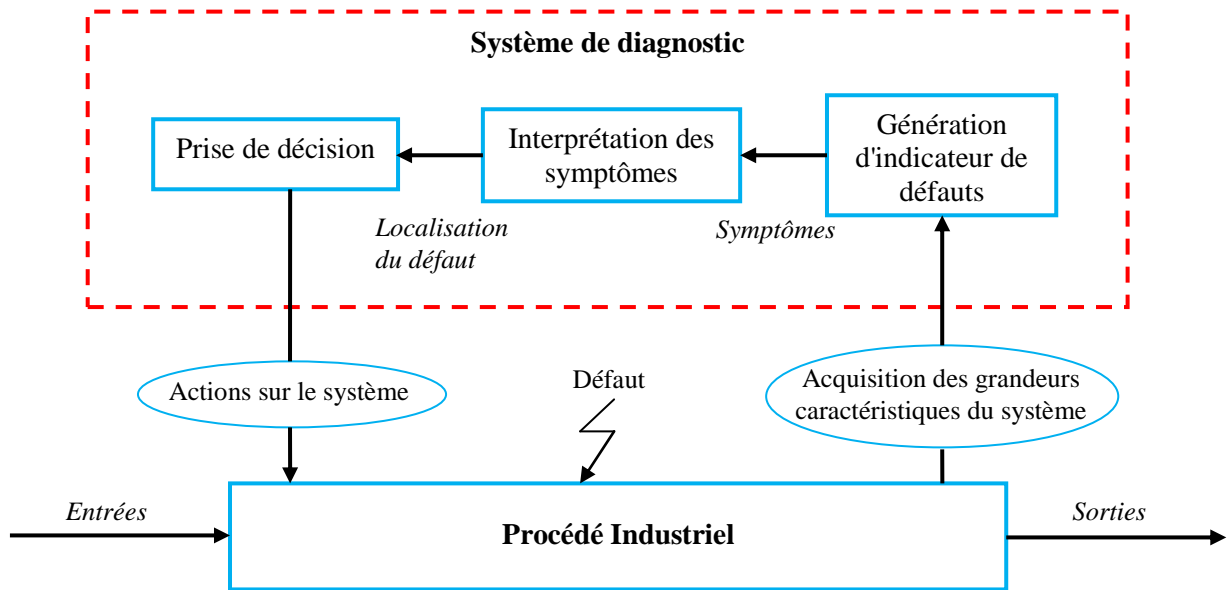
Cette fonction se décompose en deux fonctions élémentaires :

- *la localisation* : elle détermine le sous-système fonctionnel à l'origine de la défaillance et progressivement affiner cette détermination pour designer l'organe ou dispositif élémentaire défectueux;
- *l'identification des causes* : elle consiste à déterminer les causes qui ont mené à une situation anormale. Ces causes peuvent être internes (sous-ensembles défaillants faisant partie de l'équipement), ou bien externes à l'équipement.

### 1.3 Surveillance, Supervision et Diagnostic

La surveillance et la supervision constituent un complément du diagnostic. La surveillance est un dispositif passif, informationnel qui analyse l'état du système et fournit des indicateurs (Zemouri, 2003). Quant à la supervision, elle consiste en la prise de décisions appropriées, lors de l'étape de surveillance du système, afin de maintenir le fonctionnement nominal du système malgré l'apparition de défauts. L'ensemble de ces tâches vise à assurer les performances optimales du système, en termes de disponibilité, fiabilité et maintenabilité. Cela équivaut à prévenir la survenue de pannes. La surveillance en continue de l'évolution d'un système industriel nécessite la conception d'un système de diagnostic permettant la détection précoce de déviations faibles par rapport à une caractérisation du système en fonctionnement nominal, afin de prévenir un dysfonctionnement avant qu'il n'arrive. Diverses grandeurs peuvent être surveillées: une température, une pression, un débit, une concentration, un courant électrique, un niveau de vibration et bien d'autres encore. Mesurer régulièrement les valeurs d'une grandeur donnée permet de suivre son évolution dans le temps. Au cours du fonctionnement de l'installation, la grandeur surveillée peut subir deux types de variation: des fluctuations autour de sa valeur nominale qui sont dues aux diverses perturbations, une dérive qui peut être due à plusieurs phénomènes. Le suivi de cette grandeur permet alors de vérifier qu'elle ne s'écarte pas de sa valeur nominale, de façon significative. Dans le cas d'une déviation jugée anormale (étape de détection d'un défaut), il s'agit de localiser l'origine de cette anomalie (étape de diagnostic du défaut), puis de prendre, en conséquences les mesures qui s'imposent pour un retour à un fonctionnement normale du système (étape de prise de décision). Ces différentes étapes seront réalisées à l'aide de ce qu'on appelle système de diagnostic. Donc un système de diagnostic doit être en mesure de réaliser ces trois fonction principales pour un retour à la normale. Toute méthode de diagnostic repose sur l'analyse d'un certain nombre d'indicateur ou de symptômes qui permettent de caractériser l'état de fonctionnement du système. Ces symptômes doivent être générés et interprétés correctement afin de déterminer l'origine du défaut et par conséquent l'élément présentant un fonctionnement anormal et enfin prendre une décision pour un retour à un fonctionnement normal de l'installation (Figure 1.2).

La conception d'un système de diagnostic tel qu'il est présenté à la Figure 1.2 nécessite l'utilisation de l'ensemble des connaissances disponibles sur l'installation surveillée ainsi que d'autres informations qui peuvent être obtenues à partir des méthodes d'analyse telles que HAZOP, AMDEC, AdD ou des graphes fonctionnels et/ou de composantes (Toguyéni et Craye, 2000).



**Figure 1.2-** Structure générale d'un système de diagnostic  
(Lyonnet et al., 2012)

## 1.4 Critère de performance d'un système de diagnostic

Afin d'évaluer les performances des diverses approches de diagnostic, il est plus utile de s'assurer que le système de diagnostic développé est le plus efficace possible. La définition de certains critères de performance pour lesquels on peut évaluer n'importe quelle stratégie de surveillance est nécessaire. Il existe un ensemble commun de critères d'évaluation pour toute approche de surveillance et de diagnostic de défauts. Ces critères incluent les erreurs de détection, le temps de détection, et les exigences de calcul.

Pour ce qui est du premier critère de l'erreur de détection, dans toute procédure de modélisation, un modèle parfaitement précis et exact d'un système physique n'est jamais obtenu. Ceci peut être le résultat de plusieurs causes comme par exemple la variabilité des paramètres du système dans le temps, ou la méconnaissance de la nature des bruits. Par conséquent, en cas de défaut, il ya toujours un décalage entre le comportement observé sur le processus réel et son comportement prédit par le modèle construit. Cette incertitude peut causer à la fois soit de fausses alarmes ou des alarmes manquées. D'une manière générale, une réduction de la sensibilité aux incertitudes de modélisation influe sur les résidus, i.e. il peut être associé à une réduction de la sensibilité et par conséquent à la détection de défauts (Gertler, 1998; Chen et Patton, 1999). En fait, la formulation la plus significative de ce problème est d'augmenter l'insensibilité aux incertitudes de modélisation afin de fournir plus de sensibilité aux défauts.

Le deuxième critère est le temps de retard dans la détection de défauts. Il faut que les systèmes de surveillance répondent rapidement à la détection de défauts. Les techniques de diagnostic les plus rapides dans la prise de décision sont les plus souhaitables.

Enfin, réduire les exigences de stockage et de calcul joue également un rôle important dans l'évaluation des performances d'une méthode de surveillance et de diagnostic, et spécialement dans le cas de la surveillance des processus en temps réel. Il est donc souhaitable d'employer la procédure de surveillance en temps réel parce qu'elle offre un équilibre raisonnable entre les exigences de calcul par rapport aux obligations de stockage de données.

D'une manière générale, nous pouvons regrouper les différents critères de performance du système de diagnostic de la manière suivante (Patton, 1991; Theilliol, 2003; Chakour, 2016): détectabilité, isolabilité, sensibilité et robustesse.

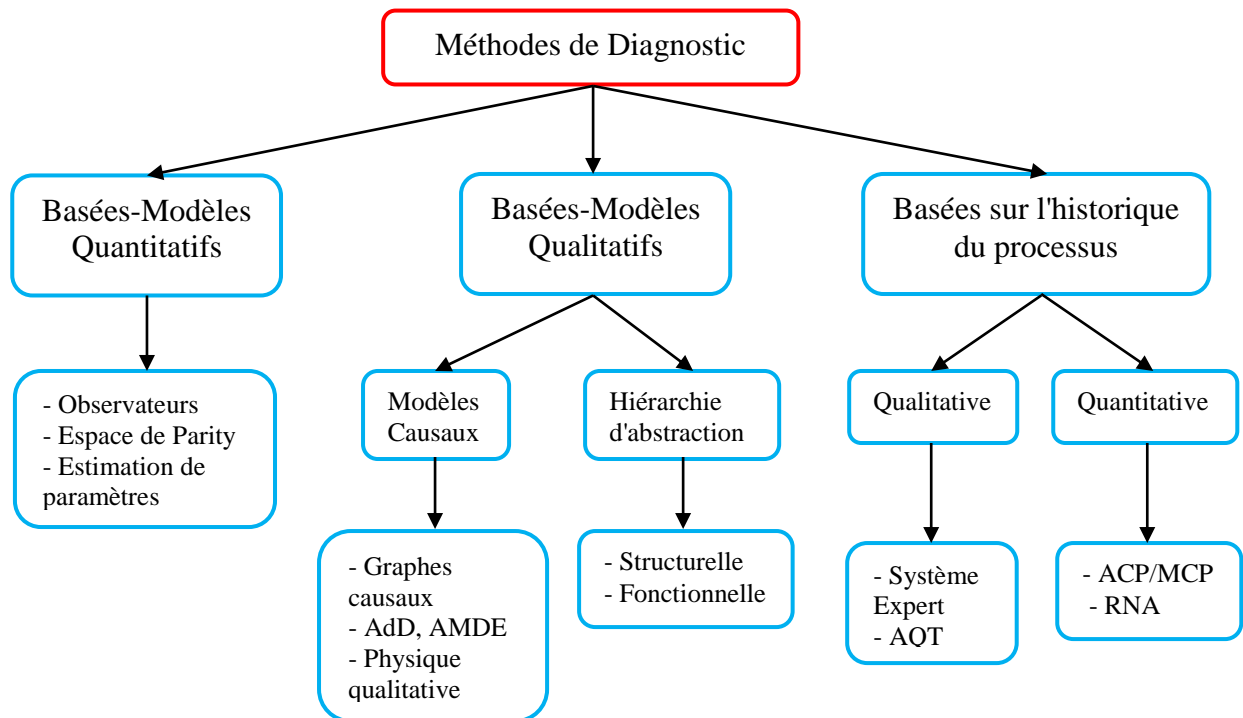
- *La détectabilité* est l'aptitude du système de diagnostic à pouvoir déceler la présence d'un défaut sur le procédé. Elle est fortement liée à la notion d'indicateurs de défauts (résidus).
- *L'isolabilité* est la capacité du système de diagnostic à remonter directement à l'origine du défaut. Une défaillance engendre souvent une cascade d'alarmes et il peut être difficile de remonter à l'organe défaillant. Le degré d'isolabilité des défaillances est lié à la structure des résidus rendus disponibles et à la procédure de détection mise en œuvre.
- *La sensibilité* caractérise l'aptitude du système de diagnostic à détecter et localiser des défauts d'une certaine amplitude correctement. Elle dépend non seulement de la structure des résidus mais aussi du rapport entre le bruit de mesure et le défaut.
- *La robustesse* est l'insensibilité du système de diagnostic aux bruits, aux erreurs de modélisation, et aux autres incertitudes (sensibilité du résidu aux défauts et insensibilité vis-à-vis des perturbations).

## 1.5 Classification des méthodes de diagnostic

Les méthodes de diagnostic dépendent de plusieurs facteurs tels que la nature des processus, des systèmes, des composants, des modèles établis, des données disponibles. . . en d'autres termes, du système à surveiller. Il faudra par conséquent mettre en œuvre à chaque fois des méthodes spécifiques en tenant compte des technologies employées.

Il existe une abondante littérature sur les méthodes de diagnostic des défauts de processus allant des méthodes analytiques à l'intelligence artificielle et aux approches statistiques. Du point de vue de la modélisation, il existe des méthodes qui nécessitent des modèles de processus précis, des modèles semi-quantitatifs ou des modèles qualitatifs. D'autre part, il existe des méthodes qui ne supposent aucune forme d'information de modèle et qui reposent uniquement sur des données de processus historiques. Le choix de l'une de ces méthodes est lié à la connaissance que l'on souhaite acquérir sur le système et aussi sur sa complexité. La classification des méthodes de diagnostic des défauts présentée dans cette thèse est basée sur les contributions des chercheurs (Vankatasubramania et al., 2001a,b,c; Katipamula et Brambley, 2005; Mousakitis, 2013; Park et al., 2020). D'une manière générale les méthodes de diagnostic des défauts sont classées en trois catégories: méthodes basées sur des modèles quantitatifs, méthodes basées sur des modèles qualitatifs et méthodes basées sur l'historique des processus. Le fait de distinguer ce qui est de l'ordre du quantitatif, du qualitatif et ce qui est basé sur l'historique des processus, ne doit pas laisser penser que ces trois aspects sont

disjoints. En réalité, ces trois types d'approches coexistent souvent au sein d'un même système de diagnostic. L'utilisation conjointe des trois méthodes permet l'exploitation de l'ensemble des connaissances disponibles concernant le fonctionnement du système. Le fait d'utiliser une méthode plutôt qu'une autre est plus dicté par le type de connaissances dont on dispose pour l'accomplissement de telle ou telle étape du diagnostic, qu'à un choix délibéré de la part du concepteur. Toutefois, plus par commodité nous conserverons cette distinction et parlerons donc de diagnostic basé: sur des modèles quantitatifs, sur des modèles qualitatifs et sur l'historique des processus. Nous présentons à la [Figure 1.3](#) un panorama général des différentes méthodes de diagnostic rentrant dans l'une ou l'autre des catégories précédemment présentées. Nous précisons que cet état de l'art n'est pas exhaustif car notre objectif est uniquement de fournir quelques outils pour la mise en œuvre d'un système de surveillance, destiné à la détection et la localisation des défauts d'un système industriel.



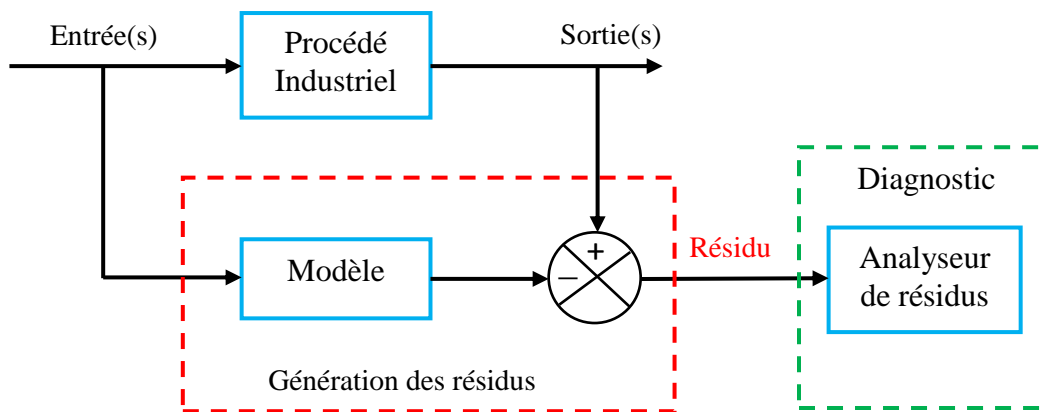
**Figure 1.3-** Classification des méthodes de diagnostic

### 1.5.1 Méthodes basées sur des modèles quantitatifs

Le principe de diagnostic à base de modèles quantitatifs consiste à comparer le comportement réel du procédé tel qu'il peut être observé par l'intermédiaire de capteurs et son comportement attendu tel qu'il peut être prédit grâce aux modèles de bon fonctionnement. Ces méthodes utilisent un modèle décrit par des relations mathématiques représentant les différentes relations physiques du procédé. Généralement, ces relations physiques découlent de l'application de lois fondamentales de divers domaines (physique, chimie, électricité, thermodynamique, mécanique, etc.). Ainsi, il est possible de créer une modélisation du



système qui, en lui appliquant des entrées similaires au système réel (lois de commande, paramètres du procédé, etc.), fournit une réponse estimée du système. Il est alors possible de calculer l'écart entre la réponse réelle du système et sa réponse estimée. Cet écart est usuellement appelé résidu. Un résidu est une grandeur obtenue explicitement à partir des mesures issues des capteurs et des signaux de commande du système, soit directement (espace de parité), soit indirectement (observateurs d'état, estimation paramétrique). En d'autres termes, on peut dire que les résidus sont les écarts entre les observations du système et le modèle mathématique (Figure 1.4). Ils sont relativement élevés lorsqu'une faute est présente dans le procédé, et sont plutôt faibles en l'absence de faute. Dans ce cas, la présence de faute est détectée en appliquant des seuils adéquats sur les résidus. Une procédure de détection et localisation de défauts à base de modèles peut être décomposée en deux étapes principales désignées sous le nom de "génération des résidus" et "prise de décision", comme illustré sur la Figure 1.4.



**Figure 1.4-** Principe de diagnostic basé sur la génération des résidus

Lorsque le modèle mathématique du système est disponible, ces méthodes à base de modèles quantitatifs sont très performantes. Elles sont généralement intitulées FDI (*Fault Detection and Isolation*). En effet, alors que pour la notion de détection de défauts toutes les communautés scientifiques partagent la même définition, pour ce qui est du diagnostic beaucoup de divergences apparaissent (Verron, 2007). L'isolation de défaut est définie comme étant la détermination du lieu exact du défaut afin de déterminer quel(s) composant(s) du système est/sont défectueux. L'isolation de défaut fournit plus d'informations que la phase d'identification définie au paragraphe 1.2, mais moins que la phase de diagnostic toute entière puisque celle-ci comprend également les notions d'emplacement, d'amplitude et de la durée du défaut.

Il existe dans la littérature une grande variété d'approches pour la génération de résidus, cependant trois sont particulièrement utilisées (Isermann, 1997; Leo H. Chiang, 2001; Cocquempot, 2004), il s'agit de:

### 1.5.1.1 Estimation de paramètres

L'estimation de paramètres permet de mesurer l'influence des défauts sur les paramètres structuraux du modèle. Les paramètres du système sont estimés en utilisant des procédures d'identification. Les résidus sont la différence entre les paramètres nominaux du modèle et les paramètres estimés du modèle (Isermann, 1993; Bachir, 2002; Alhaj Dibo, 2005; Toscano, 2005). Une variation trop grande du paramètre, indique la présence d'un défaut. Cette technique est particulièrement intéressante dans le cas de défauts intervenant sur les paramètres eux-mêmes (Höfling et Pfeufer, 1994; Höfling et Isermann, 1996; Zhai et al., 2015). Lorsque les valeurs nominales ne sont pas connues, une autre approche consiste à les remplacer par des valeurs estimées précédemment. Dans ce cas, l'écart des résidus par rapport à zéro est le résultat des variations de paramètres. Ces écarts sont ensuite analysés par la théorie de décision (Isermann, 1984). Cette méthode est bien adaptée aux types de défauts multiplicatifs qui influent sur les paramètres du système et elle permet d'avoir des informations sur l'ampleur des déviations. Cependant, cette méthode de diagnostic est difficilement utilisée pour les systèmes complexes à cause du grand nombre de variables mis en jeu. De plus, l'étape de la localisation de défauts est difficile.

### 1.5.1.2 Observateurs

Cette approche s'appuie sur une bonne connaissance du modèle et de ses paramètres. Elle consiste à reconstruire, à partir d'un modèle analytique et d'un ensemble d'observations partielles du système (entrées/sorties), les sorties non mesurables du système par une estimation de l'état du système. Un vecteur de résidus est obtenu représentant la différence entre les sorties mesurées et les sorties estimées. Le diagnostic basé sur les observateurs est une technique très populaire et très utilisée. Plusieurs travaux ont été développés dans ce sens (Franc, 1987; Frank, 1990; Boumegoura, 2001; Nait-Said et al., 2000; Guo et al., 2006; Olivier et al., 2014; Zhonghai et al., 2018).

### 1.5.1.3 Espace de parité

Le principe général de l'espace de parité est de vérifier la cohérence des estimations données par le modèle avec les mesures issues de capteurs (Maquin, 2005). Cette vérification est généralement effectuée par la méthode de génération de résidus (Chow, 1984; Gertler, 1997). En effet, en cas d'absence de défauts, le résidu tend vers zéro ou converge vers une certaine valeur, inférieure à la valeur seuil. Cependant, si le résidu dépasse la valeur seuil fixée, cela signifie qu'un défaut est produit dans le système. Potter et Suman (1977) ont tout d'abord développé cette méthode pour les systèmes statiques. Ensuite, les travaux de Chow et Willsky au début des années 80 (Chow, 1980; Chow et Willsky, 1984) ont permis de généraliser cette approche aux systèmes dynamiques en utilisant les relations temporelles entre les sorties et les entrées du système dans le but de générer des résidus. Le diagnostic par l'espace de parité a été utilisé dans plusieurs applications industrielles (Guernez et al., 1997; Hafaifa et al., 2015; Zhong et al., 2015; Han et al., 2018; Cui et Sun, 2019). A titre d'exemple, dans (Cui et Sun, 2019), l'espace de parité est utilisé pour la détection et l'isolation des défauts de capteurs dans un actionneur électromécanique.

## 1.5.2 Méthodes basées sur des modèles qualitatifs

Le modèle est généralement développé sur la base d'une compréhension fondamentale de la physique du processus. Dans les modèles quantitatifs, cette compréhension est exprimée en termes de relations fonctionnelles mathématiques entre les entrées et les sorties du système. En revanche, dans les modèles qualitatifs, ces relations sont exprimées en termes de fonctions qualitatives centrées autour de différentes unités dans un processus. Les modèles qualitatifs peuvent être développés sous forme de modèles causaux qualitatifs ou de modèles de hiérarchies d'abstraction.

Une limitation importante de ces méthodes réside dans la génération d'un grand nombre d'hypothèses pouvant conduire à une résolution erronée du problème ou à une solution très incertaine.

### 1.5.2.1 Graphes causaux

Le diagnostic est l'inverse de la simulation. La simulation concerne la déviation du comportement du processus compte tenu de ses aspects structurels et fonctionnels. En revanche, le diagnostic consiste à déduire la structure du comportement. Ce type de déduction nécessite un raisonnement sur les relations de cause à effet dans le processus. Les relations de cause à effet sous-jacentes du processus sont implicites dans cette forme de raisonnement.

Dans l'approche basée sur un modèle on commence par une description du système avec les observations faites à partir du processus de dysfonctionnement. Le raisonnement ici est d'identifier les changements fonctionnels qui ont abouti au dysfonctionnement du processus (Davis, 1984; Rich et Venkatasubramanian, 1987; Venkatasubramanian et Rich, 1988).

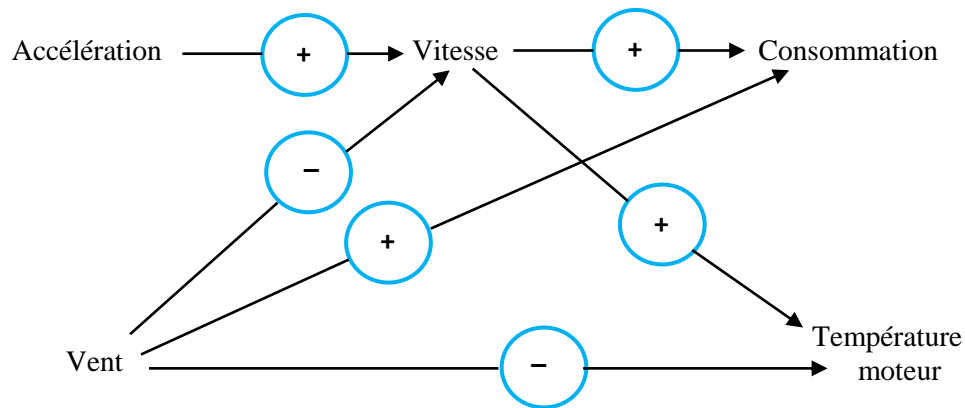
Les graphes causaux sont basés sur des relations de cause à effet: l'expression de telles relations est un principe naturel du raisonnement. Une définition générale de la causalité est de la considérer comme une relation spatio-temporelle qui lie la cause à son effet. Les modèles causaux ont donc l'avantage de représenter les relations et les interactions qui lient tous les éléments d'un modèle.

La structure la plus simple de graphe causal est celle du graphe signe orienté (*SDG pour Signed Directed Graph*). Les nœuds d'un SDG correspondent à l'état des variables, et les arcs orientés portent les signes des influences correspondantes :

- le signe est (+) lorsque les variables se rapportant à l'arc évoluent dans le même sens;
- le signe est (-) lorsque les variables se rapportant à l'arc évoluent en sens opposé.

L'état d'une variable appartient à l'ensemble  $\{+, 0, -\}$ , selon que la valeur est normale (0), trop haute (+) ou trop basse (-) (Figure 1.5).

Les graphes causaux apparaissent comme des outils adéquats pour la modélisation causale. Ils peuvent servir de support à des raisonnements variés, comme la simulation, le filtrage de défauts, la localisation de pannes, etc. Comme les arcs d'un graphe symbolisent les relations causales entre les variables, le graphe est une représentation de la causalité des phénomènes physiques dans l'installation.



**Figure 1.5-** Exemple d'un SDG issu du comportement d'une voiture

Le SDG peut être obtenu soit à partir du modèle mathématique du processus sous-jacent ou à partir des données opérationnelles (l'expérience de l'opérateur). D'un SDG, ils découlent ce qu'on appelle un graphe de cause à effet (*graphe CE*). Le graphe CE se compose uniquement de nœuds valides (nœuds qui sont anormaux) et d'arcs cohérents. [Iri et al. \(1979\)](#) ont été les premiers à utiliser le SDG pour le diagnostic des défauts. Les SDGs ont été la forme de connaissance causale la plus largement utilisée pour le diagnostic des défauts de processus ([Chang et Yu, 1990](#); [Wilcox et Himmelblau, 1994a,b](#); [Vedam et Venkatasubramanian, 1997](#); [Liu et al., 2016](#)).

### 1.5.2.2 Arbres de défaillances et AMDE

#### *Arbres de Défaillances*

Les arbres de défaillances (*AdD*) sont utilisés pour analyser la fiabilité, la disponibilité et la sécurité des systèmes, ils ont été développés à l'origine aux Bell Telephone Laboratories en 1961. Les AdD sont créés à l'aide d'une procédure déductive optimisée qui détermine des chemins critiques dans un système. Ces derniers correspondent aux diverses combinaisons possibles d'événements qui entraînent la réalisation d'un événement indésirable unique (événement non souhaité entraînant une panne du système). La représentation graphique des combinaisons est réalisée par une structure arborescente (*arbre*), permettant un traitement à la fois qualitatif et quantitatif. Un AdD est établi sous la forme d'un diagramme logique et comporte au sommet l'événement indésirable. Les causes immédiates qui produisent cet événement sont ensuite hiérarchisées à l'aide de symboles logiques « ET » et « OU ». De cette façon, l'arbre est créé pas à pas pour atteindre, à la base, un ensemble d'événements considérés comme élémentaires.

Pour effectuer un diagnostic cohérent à partir des AdD, les arbres doivent représenter globalement les relations de cause à effet de processus (expliquer tous les scénarios de défaut). La procédure qui utilise les arbres de défaillance à des fins de diagnostic est *abductive*, elle se focalise d'abord sur les événements indésirables pour identifier ensuite leurs causes ([Chiremsel et al. 2016](#)). Pour exécuter un diagnostic correct à partir des AdD, ceux-ci

doivent largement représenter toutes les relations causales du système, i.e. qu'ils doivent être capables d'expliquer tous les scénarios de défauts possibles. Il n'existe aucune méthode formelle pour vérifier l'exactitude de l'arbre de défaillances développé. Cette méthode déductive s'utilise difficilement pour les systèmes qui dépendent du temps (Yu, 2012).

### ***AMDE (Analyse des Modes de Défaillance et de leurs Effets)***

La méthode de l'Analyse des Modes de Défaillance et de leurs Effets fût employée pour la première fois, à partir des années 1960, dans le domaine de l'aéronautique pour l'analyse de la sécurité des avions (Recht, 1966). C'est une technique issue du domaine de la fiabilité. Elle repose sur la notion de mode de défaillance, définie comme l'effet par lequel une défaillance est observée sur un élément du système. Cette méthode permet une analyse systématique et très complète, composant par composant, de tous les modes de défaillance possibles et précise leurs effets sur le système global (Villemeur, 1988).

La démarche consiste d'abord à définir le système, ses fonctions et ses composants. Ensuite, l'ensemble des modes de défaillances des composants doit être établi. Pour chaque mode de défaillance, sont recherchées ensuite les causes possibles de son apparition. Finalement, une étude des effets sur le système et sur l'opérateur est faite pour chaque combinaison (cause, mode de défaillance). Les résultats sont présentés sous forme de tableau (Tableau 1.1).

L'AMDE est parfois complétée par une analyse de criticité; elle devient AMDEC (Analyse des Modes de Défaillance, de leurs Effets et de leur Criticité) (Jordan et Marshall, 1972). La criticité permet d'extraire les modes de défaillance les plus critiques. L'analyse de criticité est évaluée à partir du couple probabilité-gravité.

La méthode AMDEC se divise en quatre étapes (Zwinglestein, 1999) :

1. *Définition du système, de ses fonctions et de ses composants*: Il s'agit de définir les fonctions principales du système ainsi que ses spécifications.
2. *Recensement des modes de défaillances et détermination de leurs causes pour chacun des composants du système*: C'est l'étape la plus délicate car elle doit être la plus complète possible. Pour déterminer les modes de défaillances, on peut s'appuyer sur des modes de défaillances génériques prévues par (Zwinglestein, 1995; Flaus, 2004).
3. *Etude des effets des modes de défaillances*: Pour étudier les effets, on ne considère qu'un seul mode de défaillance pour le composant et on considère également que tous les autres composants fonctionnent correctement.
4. *Etude de la criticité*: A cette dernière étape on calcule les criticités pour ainsi hiérarchiser les modes de défaillances pour faire ressortir les plus critiques. La mise en place de moyens de préventions et de protections peut alors être décidée pour diminuer la criticité des points faibles de l'installation.

L'utilisation des tableaux AMDE(C) à des fins de diagnostic industriel conduit à utiliser une procédure déductive, c'est-à-dire à utiliser ces tableaux comme un outil d'identification des causes de défaillances à partir des effets observés (Zwinglestein, 1995). La modélisation des relations de cause à effet, réalisée par l'AMDEC rend cette démarche très puissante pour la résolution des problèmes de diagnostic de défaillances de procédés industriels. Cette approche est très efficace grâce à ses relations de causes à effets. Néanmoins, les limites d'une telle

approche résident dans le fait que les défauts et/ou les dysfonctionnements pouvant apparaître dans le système, doivent être définies à priori. Le recensement préalable de ces défaillances ne peut pas être exhaustif et nécessite une longue expérience. Le coût de construction des AMDEC est très élevé car cette construction peut être longue et très difficile à mettre en place. En outre, toute évolution ou modification du système implique une réécriture du tableau. Enfin, cette méthode ne peut traiter les cas de défaillances multiples et intégrer l'aspect fonctionnel.

L'Analyse de fonctionnement HAZOP (*Hazard and operability study*) est une autre extension de l'AMDE. La méthode HAZOP (Othman et al., 2016) explore systématiquement l'aspect fonctionnel d'un système en identifiant, à la fois, les dangers et les dysfonctionnements d'une installation. Elle est mise en œuvre à la fin de la phase de conception puisqu'elle s'appuie sur les schémas détaillés du système. La description de cette méthode sera présentée dans le chapitre 3.

<i>Composant</i>	<i>Fonction</i>	<i>Mode de défaillance</i>	<i>Causes</i>	<i>Effets</i>	<i>Mesures préventives</i>	<i>Probabilité</i>	<i>Gravité</i>	<i>Criticité</i>

**Tableau 1.1** - Exemple de tableau AMDEC

### 1.5.2.3 Physique qualitative

La physique qualitative ou le raisonnement de bon sens sur les systèmes physiques a été un domaine d'intérêt majeur pour la communauté de l'intelligence artificielle. Les connaissances qualitatives de la physique dans le diagnostic des défauts ont été représentées principalement de deux manières. La première approche consiste à dériver des équations qualitatives à partir des équations différentielles appelées équations de confluence. L'autre approche en physique qualitative est la dérivation du comportement qualitatif à partir des équations différentielles ordinaires. Ces comportements qualitatifs pour les différents défauts peuvent être utilisés comme une source de connaissances.

Les modèles qualitatifs ne nécessitent pas d'informations détaillées (telles que des expressions exactes et des valeurs numériques) sur le processus. Une information d'ordre de grandeur sur les valeurs de fonctionnement normales des paramètres de processus et des variables est souvent suffisante. À titre d'exemple, envisagez de prévoir le niveau du réservoir lorsque le débit d'entrée augmente. En utilisant un raisonnement qualitatif, on peut prédire que le niveau augmenterait également (au moins au début) sans connaître les valeurs numériques de la section transversale du réservoir, de la sortie, etc.

### 1.5.2.4 Hiérarchie d'abstraction de la connaissance des processus

Une autre forme de connaissance des modèles consiste à développer des hiérarchies d'abstraction basées sur la décomposition. L'idée de la décomposition est de pouvoir tirer des inférences sur le comportement du système global uniquement à partir des lois régissant le comportement de ses sous-systèmes. Dans une telle décomposition, le principe de structure

sans fonction est central: les lois du sous-système peuvent ne pas présumer le fonctionnement de l'ensemble du système (de Kleer et Brown, 1984). Dans une description hiérarchique, on pourrait représenter une description générique d'une classe d'unités de processus.

Les équations qui décrivent une classe entière d'unités de processus peuvent faire des hypothèses sur la classe dans son ensemble, mais ne peuvent faire aucune hypothèse sur le comportement d'unités particulières. Un autre principe important pour la décomposition des systèmes est le principe de localité. Le principe de localité permet de prédire le comportement sur la base uniquement d'informations locales.

Il y a deux dimensions selon lesquelles l'abstraction à différents niveaux est possible: *structurelle* et *fonctionnelle* (Rasmussen, 1986). La hiérarchie structurelle représente les informations de connectivité du système et de ses sous-systèmes. La hiérarchie d'abstraction fonctionnelle représente les relations moyen-fin entre un système et ses sous-systèmes. La majorité des travaux de diagnostic des défauts en génie chimique dépend du développement de la décomposition fonctionnelle. La décomposition structurelle est une décomposition efficace dans des systèmes où il existe une équivalence générale entre structure et fonction, comme par exemple dans un circuit électrique. La raison de la popularité de la décomposition fonctionnelle en génie chimique est due aux fonctionnalités complexes de diverses unités qui ne peuvent pas être exprimées en termes de structure.

### 1.5.3 Les méthodes basées sur l'historique des processus

Contrairement aux approches basées sur des modèles (quantitatifs ou qualitatifs) où des connaissances a priori sur le processus sont nécessaires, dans les méthodes basées sur l'historique des processus, seule la disponibilité d'une grande quantité de données de l'historique du processus est nécessaire. Il existe différentes manières de transformer ces données et de les présenter comme des connaissances a priori à un système de diagnostic. Ceci est connu sous le nom d'extraction de caractéristiques. Ce processus d'extraction peut être de nature qualitative ou quantitative. Les systèmes experts et les méthodes de modélisation des tendances sont deux des principales méthodes qui extraient des informations historiques qualitatives. Les méthodes d'extraction des informations quantitatives peuvent être globalement classées comme des méthodes non statistiques ou statistiques. Les réseaux de neurones sont une classe importante de classificateurs non statistiques. Quelques exemples de méthodes statistiques comprennent la régression linéaire et multiple, la régression polynomiale, l'Analyse en Composantes Principales (ACP), les Moindres Carrés Partiels (MCP) et la régression logistique. L'analyse en composantes principales et les moindres carrés partiels constituent une composante majeure des méthodes d'extraction de caractéristiques statistiques. Ces approches quantitatives forment essentiellement la résolution de problèmes de diagnostic comme un problème de reconnaissance de formes. L'objectif de la reconnaissance de formes est la classification des points de données en classes prédéterminées, en général. Les méthodes statistiques utilisent la connaissance des distributions de classes a priori pour effectuer la classification. Un exemple est le classifieur de Bayes qui utilise les fonctions de densité des classes respectives. Des approches comme l'analyse en composantes principales, en revanche, extraient des informations sur les principales tendances des données en utilisant un petit nombre de facteurs pertinents.

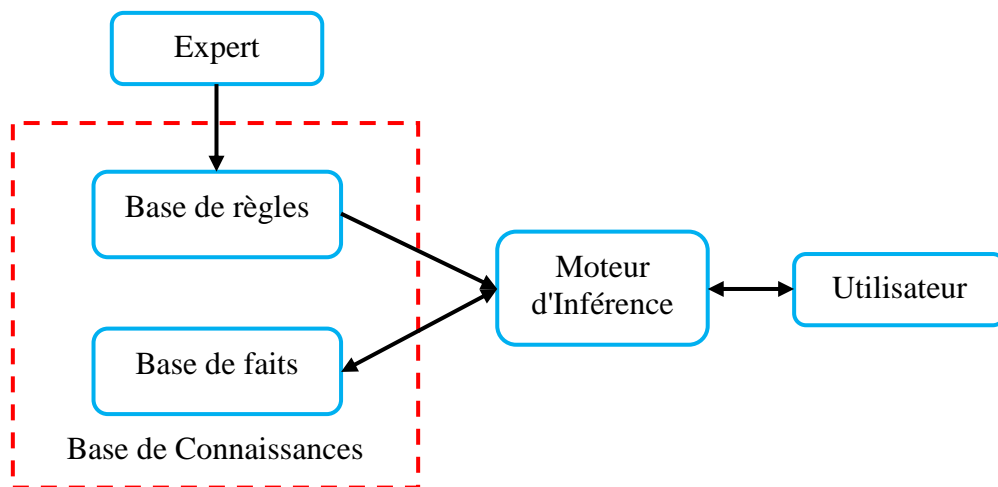
### 1.5.3.1 Système expert

Les systèmes experts sont des outils de l'intelligence artificielle, utilisés lorsqu'aucune méthode algorithmique exacte n'est disponible ou possible. La propriété principale de ces systèmes est de pouvoir représenter et restituer les connaissances acquises par un expert humain. De façon générale, nous pouvons dire qu'un système expert sert à codifier la connaissance humaine en termes: d'expérience, de raisonnement approximatif, d'analogie, de raisonnement par défaut, d'apprentissage, etc. La définition que nous retenons pour les systèmes experts est celle donnée par (Zwingelstein, 1995):

« Un système expert est un système informatique destiné à résoudre un problème précis à partir d'une analyse et d'une représentation des connaissances et du raisonnement d'un (ou plusieurs) spécialiste(s) de ce problème ».

Un système expert est composé de deux parties indépendantes (Figure 1.6):

- une *base de connaissance* elle-même composée d'une base de règles qui modélise la connaissance du domaine considéré et une base de faits qui contient les informations concernant le cas traité;
- un *moteur d'inférence* capable de raisonner à partir des informations contenues dans la base de connaissances, de faire des déductions, etc. Au fur et à mesure que les règles sont appliquées, des nouveaux faits se déduisent et se rajoutent à la base de faits.



**Figure 1.6** - Architecture d'un système expert

Les principales composantes dans un développement du système expert comprennent: l'acquisition de connaissances, le choix de la représentation des connaissances, le codage des connaissances dans une base de connaissances, le développement des procédures d'inférence pour le raisonnement diagnostique et le développement d'interfaces d'entrée / sortie.

La technique des systèmes experts est la plus répandue pour la supervision des systèmes complexes. 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 observés pour chaque défaillance du système (Aguilar-Martin, 1999). Néanmoins,



il est possible aussi d'utiliser les modèles fonctionnels décrivant les comportements des composantes de systèmes complexes (Chatain, 1993).

Les principaux avantages dans le développement de systèmes experts pour la résolution des problèmes de diagnostic sont: facilité de développement, le raisonnement transparent, la capacité à raisonner dans l'incertitude et la capacité de fournir des explications sur les solutions fournies.

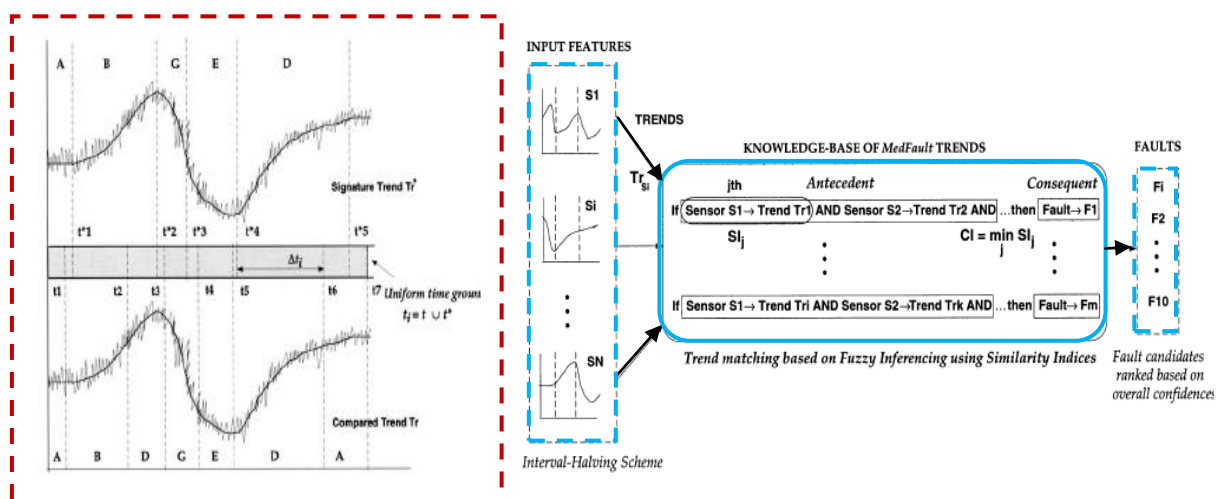
Cependant, ce type d'approche est adapté aux problèmes nécessitant la manipulation d'une quantité importante de données non homogènes. Ils ont beaucoup été utilisés dans le diagnostic des systèmes statiques. Pour des systèmes dynamiques, ce type d'approche est peu adapté pour des problèmes de temps-réel et de gestion dynamique de l'information.

### 1.5.3.2 Analyse Qualitative des Tendances (AQT)

L'analyse qualitative des tendances (QTA) des signaux est basée, en général, sur la segmentation temporelle des signaux en unités, appelées épisodes, dans lesquels chaque épisode est caractérisé par un point temporel de départ, un point temporel de fin et un état qualitatif unique. Relativement simple conceptuellement, l'AQT se trouve alourdie par certaines contraintes. L'observation des dérivées des signaux s'avère délicate. L'AQT implique la mise en œuvre d'un filtrage de bruits et de traitement des discontinuités ou même la suppression de l'information d'ordre supérieur (dérivées).

En raison de sa forme descriptive succincte et de sa notion simple et intuitive, QTA a été adopté dans de nombreux domaines du contrôle de processus, tels que l'exploration de données, la supervision et la surveillance de processus et le diagnostic des défauts (Zhou et Ye, 2017).

La représentation et l'analyse qualitative (symbolique) de signaux à travers l'information des dérivés de premier et deuxième ordre représentent l'une de principales techniques pour le diagnostic et la supervision basées sur des données et sur l'abstraction de la dynamique continue. La Figure 1.7 présente l'approche d'AQT pour le diagnostic de défauts.



**Figure 1.7-** L'approche d'AQT pour le diagnostic de défauts

L'AQT utilise l'information de type tendance présente dans les mesures issues des capteurs. Il y a deux étapes de base, l'identification de tendances dans les mesures et l'interprétation de

ces tendances en terme de scénarios de fautes. Pour les tâches de diagnostic, la représentation qualitative des tendances fournit souvent des informations valables qui facilitent le raisonnement sur le comportement du processus.

Dans la plupart des cas, les dysfonctionnements du procédé produisent une tendance distinctive dans les signaux issus des capteurs. Ces tendances peuvent être employées pour l'identification des situations anormales dans le processus et peuvent être transformées en fautes pour ainsi construire la base de connaissance utilisée pour le diagnostic (Hernandez, 2006). Ainsi, une analyse appropriée des tendances du processus peut permettre de détecter plus tôt une défaillance.

Bien que QTA fournisse un diagnostic rapide et précis - l'augmentation de la complexité de calcul de QTA avec l'augmentation du nombre de capteurs utilisés pour le diagnostic - peut interdire son application en temps réel pour les usines à très grande échelle (Maurya et al., 2005).

### 1.5.3.3 Analyse en composantes principales / moindres carrés partiels

L'Analyse en Composantes Principales (ACP) est une technique statistique multi-variable. Les techniques statistiques multi-variables sont des outils puissants, capables de comprimer des données et de réduire leur dimensionnalité de sorte que l'information essentielle soit maintenue et plus facile à analyser que dans l'ensemble original des données. Ces techniques peuvent également manipuler le bruit et la corrélation pour extraire l'information efficacement. La fonction principale de ce type de techniques est de transformer, par le biais d'une procédure mathématique, un certain nombre de variables corrélées en un ensemble plus petit de variables non corrélées.

Théoriquement, l'ACP est basée sur une décomposition orthogonale de la matrice de covariance des variables de processus selon des directions expliquant la variation maximale des données. Le but principal de l'utilisation de l'ACP est de trouver des facteurs qui ont une dimension beaucoup plus faible que l'ensemble de données d'origine qui peuvent décrire correctement les principales tendances dans l'ensemble de données d'origine. L'ACP est une procédure qui ne prend en compte que les variables du processus. Parfois, un ensemble additionnel de données est disponible, e.g. variables de qualité du produit. Il est souhaitable d'inclure toutes les données disponibles pour la surveillance du procédé et d'utiliser de cette façon les variables du processus pour prédire et détecter des changements dans les variables de qualité du produit. Pour cela, la méthode des Moindres Carrés Partiels (MCP) peut être utilisée (Venkatasubramanian et al, 2003b). Cette méthode modélise le rapport entre deux blocs de données tout en les comprimant simultanément. Elle est employée pour extraire les variables latentes qui expliquent la variation des données du processus. Divers travaux menés par MacAuley et MacGregor (1991), Nomokos et MacGregor (1994), MacGregor et Kourti (1995), Lee et al. (2004), Tharrault et al. (2008), Harmouche et al. (2015), Chakour (2016) et Anani (2019) ont montré l'application de l'ACP dans la détection de défauts, l'analyse et la commande de processus, la surveillance et le diagnostic de défaillances.

Une limitation majeure de la surveillance basée sur l'ACP est que le modèle obtenu est invariant dans le temps (statique), alors que la nature de la plupart des processus industriels est dynamique. Leurs comportements et/ou leurs caractéristiques statistiques varient dans le

temps (*time-varying behavior*), et ne sont pas préalablement connus ou entièrement compris, en raison des incertitudes sur le système, et des changements dans les conditions de fonctionnement (exemple, dans le vol d'un avion, la masse diminuera lentement en relation avec la consommation de carburant, d'où la nécessité d'une loi de commande qui s'adapte avec ces conditions changeantes ), etc. Par conséquent, le suivi et la surveillance en temps réel de ce type de processus avec un modèle ACP statique ne seront pas fiables. Ils engendreraient des interprétations erronées de l'état actuel du système, et augmenteraient le taux de fausses alarmes, ou de non détection de défauts. Ce problème peut être résolu à travers une mise à jour continue de tous les paramètres qui définissent la dynamique du système. Un autre inconvénient de cette méthode, est qu'elle ne possède pas des propriétés de signature pour le diagnostic, ce qui rend l'isolation des défaillances difficile.

#### 1.5.3.4 Réseaux de Neurones Artificiels (RNA)

Les Réseaux de Neurones Artificiels (RNA) sont des modèles informatiques qui imitent la structure du cerveau humain. Ils se composent d'éléments de traitement simples appelés «neurones» connectés dans une structure de couches complexe qui permet au modèle d'approximer une fonction non linéaire complexe avec des neurones d'entrée, de sortie et cachés. Leur principal avantage par rapport aux autres outils est leur capacité d'apprentissage et de généralisation de leurs connaissances à des entrées inconnues. Dans le fonctionnement d'un réseau de neurones, chaque neurone est connecté aux neurones de la couche suivante par des poids synaptiques adaptables (Kempowsky, 2004). Le processus de mise à jour des poids des connexions au sein du réseau de neurones est généralement appelé apprentissage. Il existe différentes techniques d'apprentissage, dont la plupart ont besoin d'une quantité considérable d'exemples et de beaucoup de temps de calcul. Une de ces techniques est l'apprentissage *supervisé*, dans lequel le réseau s'adapte par comparaison entre le résultat qu'il a calculé, en fonction des entrées fournies, et la réponse attendue en sortie. De cette façon, le réseau va modifier ses poids jusqu'à ce que le résultat soit le plus proche possible de la sortie attendue, correspondant à une entrée donnée. L'algorithme de *rétro-propagation* est le plus populaire parmi les techniques d'apprentissage supervisé utilisée dans le diagnostic des défaillances des systèmes industriels (Bishop, 1995; Roemer et al., 1996; Fan et Li, 2002; Yang et al. 2002). À l'autre extrémité du spectre se trouvent les architectures de réseaux neuronaux qui utilisent des techniques d'apprentissage *non supervisées*. Ces réseaux sont communément appelés réseaux de neurones auto-organisés car la structure est déterminée de manière adaptative en fonction de l'entrée du réseau. Parmi ces architectures nous trouvons le réseau ART2 (Carpenter et Grossberg, 1988), les réseaux auto-organisationnels (ou de Kohonen) (Kohonen, 1995) et les réseaux Cluster Detection and Labeling (CDL) (Eltoft et deFigueiredo, 1998).

Après la phase d'apprentissage à partir d'un ensemble de données, le réseau de neurones est prêt à être utilisé pour la prédiction ou pour la classification de nouveaux exemples dans les classes existantes.

Appliqué au problème de détection des défauts, les neurones d'entrée d'un réseau de neurones représentent souvent la mesure du capteur, les neurones cachés représentent l'espace de représentation, et les neurones de sortie représentent les types de défauts ou classes.

Habituellement, chacun des neurones de sortie correspond à une possibilité de défaut particulier, et l'apprentissage du modèle réseau de neurones pour la reconnaissance de formes utilise ces ensembles de symptômes et les défauts correspondants, appelés « vecteurs » de symptômes. Après la formation, le réseau déterminera la relation entre un symptôme spécifique et le défaut correspondant. Les sorties du réseau, appelées « vecteur de diagnostic », indiqueront le résultat du diagnostic pour les informations du processus (Zhang et Roberts, 1992).

Dans la littérature, de nombreux travaux démontrent l'utilité des RNA pour la détection et le diagnostic des défauts ainsi que pour la surveillance de processus complexes (Paya et al., 1997; Samanta et Al-Balushi, 2003; Bharadwaj et Parlos, 2004; Samanta, 2004; Boukra et al., 2009; Kalyan et al., 2010; Kankar et al., 2011; Tang et al., 2012, Loukil et al., 2013; Liu et al., 2014; Chine et al., 2016; Bekkari et Zeddouri, 2019; Sahu et Palei, 2020). Nous leur dédions l'ensemble du chapitre suivant. Nous présentons ainsi les deux architectures les plus utilisées en diagnostic industrielle, à savoir le Perceptron Multi Couches (PMC) et les réseaux à Fonctions de Base Radiales (*Radial Basis Functions- RBF*).

## 1.6 Choix d'une méthode de diagnostic

Le développement d'une stratégie de surveillance et de diagnostic avec une méthode choisie reste relativement une question importante. La décision du choix d'une méthode de diagnostic est une tâche très difficile. Elle dépend de plusieurs critères, à titre d'exemple nous pouvons citer: le type de diagnostic en ligne/hors ligne, la modélisation discrète, continue ou hybride, le comportement du système (régime stationnaire/régime non stationnaire), la nature de l'information (quantitative/qualitative), l'existence des connaissances a priori disponibles sur le système, la présence ou non d'un modèle mathématique des processus à diagnostiquer, les types de défauts à détecter, présence ou non d'entrées inconnues (bruits, incertitudes), etc. Pour les systèmes mécaniques et électriques et mécatroniques, il est souvent possible de concevoir un modèle mathématique, le choix des méthodes de diagnostic à base d'un modèle sera donc préféré. Par contre, pour certaines applications industrielles, la conception d'un modèle mathématique est difficile, voire impossible à obtenir, à cause des nombreuses reconfigurations intervenant dans le processus de production ou de la complexité des phénomènes mis en jeu (par exemple, les processus industriels chimiques). Dans ce cas, les méthodes de détection de défauts sans modèle de référence peuvent être appliquées. L'objectif est de déterminer la ou les méthodes les plus appropriées pour la résolution du problème de diagnostic posé. Dans cette section, nous présentons les points forts et les limitent des catégories de méthodes de diagnostic développées précédemment.

Les méthodes de diagnostic des défauts basées sur des modèles présentent les avantages suivants: elles fournissent les estimateurs ou les observateurs les plus précis lorsqu'elles sont bien mises en œuvre, des modèles détaillés peuvent modéliser les opérations normales et défectueuses du système considéré, le bruit du système et les erreurs de modélisation peuvent être modélisés et incorporés dans la stratégie de diagnostic des défauts. Ils présentent également les faiblesses suivantes: les modèles mathématiques pourraient être complexes et donc intensifs en calcul; les erreurs de modélisation pourraient avoir un impact significatif sur

les résultats finaux. Les types de modèles que les approches analytiques peuvent gérer sont limités à des modèles linéaires et dans certains cas, à des modèles non linéaires très spécifiques. Pour un modèle non linéaire général, les approximations linéaires peuvent s'avérer médiocres et par conséquent l'efficacité de ces méthodes pourrait être considérablement réduite.

L'un des avantages des méthodes qualitatives fondées sur une connaissance approfondie est qu'elles peuvent fournir une explication du chemin de propagation d'un défaut. C'est indispensable en matière d'aide à la décision pour les opérateurs. Ils peuvent également garantir l'exhaustivité des données, en ce sens que les défauts ne seront pas ignorés dans l'ensemble final des défauts identifiés. Cependant, ils souffrent des problèmes de résolution résultant de l'ambiguïté du raisonnement qualitatif. Lorsque l'information quantitative est disponible en partie, on pourrait l'utiliser pour améliorer la résolution de méthodes purement qualitatives.

Les méthodes de diagnostic des défauts basées sur l'historique présentent les avantages suivants: bien adaptées aux systèmes hautement non linéaires et ne nécessitent pas de compréhension de la physique du système modélisé. Ils présentent également les faiblesses suivantes: les modèles ne peuvent pas être utilisés au-delà de la plage de données d'apprentissage, les modèles sont spécifiques au système modélisé et les données d'apprentissage sont requises pour les opérations normales et défectueuses.

Alors, afin de "optimiser" le diagnostic, il est souhaitable de combiner les avantages de chaque méthode. En effet, cette fusion permet d'accueillir le maximum possible d'informations sur le comportement du système.

Le [Tableau 1.2](#) présente une comparaison des différentes méthodes en termes de caractéristiques souhaitables des systèmes de diagnostic ([Venkatasubramanian et al., 2003c](#)). Dans le tableau, seules quelques méthodes représentatives de chacune des trois approches (basées sur un modèle quantitatif, sur un modèle qualitatif, sur l'historique du processus) sont choisies pour comparaison. Une coche (✓) indiquerait que la méthode particulière en colonne satisfait la propriété souhaitable correspondante en ligne. Une croix (×) indiquerait que la propriété n'est pas satisfaite et un point d'interrogation (?) indiquerait que la satisfaisabilité de la propriété dépend du cas.

	<i>Observateur</i>	<i>Graphes causaux</i>	<i>Hierarchie d'abstraction</i>	<i>Systeme expert</i>	<i>AQT</i>	<i>ACP</i>	<i>RNA</i>
- Détection et diagnostic rapides	✓	?	?	✓	✓	✓	✓
- Isolabilité	✓	×	×	✓	✓	✓	✓
- Robustesse	✓	✓	✓	✓	✓	✓	✓
- Identifiabilité de la nouveauté	?	✓	✓	×	?	✓	✓
- Erreur de classification	×	×	×	×	×	×	×
- Adaptabilité	×	✓	✓	×	?	×	×
- Exigence de modélisation	?	✓	✓	✓	✓	✓	✓
- Stockage et calcul	✓	?	?	✓	✓	✓	✓
- Identification de multiples défauts	✓	✓	✓	×	×	×	×

**Tableau 1.2** - Comparaison de diverses méthodes de diagnostic

Prenons l'exemple des réseaux de neurones dans le [Tableau 1.2](#). La détection rapide, l'isolabilité et la robustesse au bruit sont des propriétés des réseaux de neurones qui ont été démontrées grâce à l'utilisation de nombreuses études de cas par différents chercheurs. Il a été démontré que les réseaux neuronaux qui génèrent des régions de décision bornées présentent la propriété d'identifiabilité de la nouveauté. En raison de la nature procédurale du développement du réseau neuronal, ils n'ont pas les propriétés d'adaptabilité. En outre, la génération d'estimations d'erreur de classification est difficile en utilisant l'approche de réseau neuronal. Étant donné que les réseaux de neurones fonctionnent principalement avec des données d'historique de processus, les exigences de modélisation sont minimales. En outre, une fois qu'un réseau neuronal est formé, les calculs en ligne sont de simples évaluations de fonctions et par conséquent, la complexité des calculs en ligne est minimale. Enfin, en ce qui concerne la propriété d'identification de multiples défauts, si la structure des données d'entrée est favorable, un diagnostic de défauts multiples est possible. Cependant, la procédure de développement de réseau de neurones en elle-même ne prend pas explicitement en compte l'idée de l'identification des défauts multiples. Cela peut être comparé à une approche basée sur l'observateur où l'on pourrait explicitement inclure l'identification de défauts multiples dans la procédure de conception.

En l'absence de modèle, les réseaux de neurones semblent donner les meilleurs résultats même si leur phase d'apprentissage reste délicate. Mais la encore, les approches de reconnaissance des formes par réseaux de neurones ([Bishop, 1995](#)) et de reconnaissance des formes par la logique floue ([Yager et Filev, 1994](#)) par exemple, sont utilisées pour classer le système dans un certain mode de fonctionnement et notamment de défauts, ce qui présuppose la connaissance des défaillances qui peuvent survenir sur le système. Néanmoins, ces approches peuvent servir également pour la détection et avoir un mode inconnu par exemple. Pour conclure, la plupart des approches portent sur un système spécifique, connu et cherchent à détecter et à localiser des défaillances également connues sur le système. Finalement, l'approche à employer dépend de la connaissance ou non du modèle, de sa précision, de la connaissance des défauts sur le système ou encore de la possibilité d'effectuer la phase d'apprentissage.

## 1.7 Conclusion

Un système de diagnostic doit être en mesure de réaliser trois fonctions principales pour un retour à la normale, à savoir: la détection, le diagnostic et la prise de décision. La détection de défauts consiste à signaler toute situation autre qu'une situation nominale. En d'autres termes, tout ce qui n'est pas normal doit être classé comme anormal. C'est alors que la fonction diagnostic doit *localiser* l'organe défaillant et *identifier* les causes ayant provoqué ces situations anormales et enfin, prendre en conséquences les mesures qui s'imposent pour un retour à un fonctionnement normale du système, c'est l'étape de prise de décision.

L'objectif de ce chapitre a été de donner un aperçu des techniques habituellement utilisées pour résoudre des problématiques de diagnostic des défauts. La première partie de ce chapitre a été dédiée à la présentation des définitions les plus importantes en diagnostic. Un ensemble

de critères d'évaluation de performances et leur impact sur les principales fonctions de la surveillance et du diagnostic ont été discutés.

Ce chapitre a fourni une étude bibliographique générale mais non exhaustive sur les méthodes de diagnostic de défauts. Trois catégories de méthodes ont été présentées: les méthodes basées sur des modèles quantitatifs, les méthodes basées sur des modèles qualitatifs et les méthodes basées sur l'historique des processus. Les techniques les plus populaires de chaque catégories ont été présentées, à savoir: l'espace de parité, les observateurs, les modèles causals, le système expert, l'ACP, les RNA, etc. Le choix d'une de ces méthodes dépend essentiellement des connaissances disponibles sur le procédé, sans oublier les considérations techniques et économiques. Des comparaisons entre les différentes méthodes sont réalisées dans plusieurs travaux, par exemple: [Gao et al. \(2015\)](#), [Sharma et Parey \(2016\)](#) et [Attoui et al. \(2017\)](#).

En conclusion, la question de l'adéquation de l'une des méthodes de diagnostic de défaut ci-dessus est principalement une question de la qualité du modèle mathématique disponible du système, de la connaissance du système et de la structure du système. De plus, la qualité atteignable de l'isolement des défauts dépend de manière décisive du nombre de mesures disponibles. Les systèmes de diagnostic basées sur l'historique du processus peuvent donc représenter d'excellents systèmes d'aide à la décision pour l'expert humain. Dans ce sens, le chapitre suivant sera consacré à la présentation des notions de base des réseaux de neurones, et de leur application en diagnostic des systèmes industriels.

*”Rendez les choses aussi simples que possible, mais pas plus simples.”*

*Albert Einstein*

## Chapitre 2: Application des réseaux de neurones en diagnostic

---



## 2.1 Introduction

La complexité des phénomènes physiques mis en jeu dans les systèmes surveillés, rend difficile l'obtention d'un modèle mathématique. Il a donc été développé des techniques ne faisant pas appel à la connaissance des modèles. Ils existent plusieurs techniques qui reposent sur l'intelligence artificielle. Ces techniques ont l'avantage de ne pas se baser sur les connaissances a priori des états de fonctionnement mais plutôt sur une phase d'apprentissage. Les Réseaux de Neurones Artificiel (*RNA*) sont les plus utilisés parmi ces techniques. Ils sont des champs d'évaluation avec des origines en neurobiologie. Les réseaux de neurones peuvent fournir une solution intéressante dans le domaine de la détection et du diagnostic des équipements industriels. En effet, le chapitre précédent montre que leur utilisation ne nécessite pas l'existence d'une modélisation formelle de cet équipement. Par ailleurs, leurs capacités de mémorisation, d'apprentissage et d'adaptation représentent des fonctions très utiles à tout système de diagnostic.

Ce chapitre est organisé en trois parties. La première partie est dédiée à la présentation des réseaux de neurones artificiels. Nous commençons par donner une brève présentation de l'évolution historique et du principe de fonctionnement des neurones biologiques et artificiels. Dans la deuxième partie de ce chapitre, le principe de fonctionnement de plusieurs modèles neuronaux est présenté. Étant donné que cette thèse se concentre sur le diagnostic par réseaux de neurones, les modèles décrits sont ceux qui ont été jugés les plus pertinents pour ce domaine spécifique ([Zemouri, 2003](#)), à savoir: le Perceptron Multi Couches (*PMC*) et les Réseau à Fonctions de base Radiales (*RFR*) et avec un degré moindre, le modèle de *Kohonen* et celui de *Hopfield*.

Dans la troisième partie, nous verrons comment les réseaux de neurones sont appliqués en détection et diagnostic des défauts. Ensuite, nous présentons à travers un exemple pédagogique une comparaison entre divers algorithmes à rétropropagation.

## 2.2 Historique

Les premières recherches de simulation des neurones ont commencé dans les années 40 lorsque Mac CULLOCH et PITTS ([McCulloch et Pitts, 1943](#)) ont inventé le premier neurone artificiel. Ce sont les premiers à montrer que des réseaux de neurones formels simples peuvent réaliser des fonctions logiques, arithmétiques et symboliques complexes. En parallèle, le psychanalyste HEBB a établi le premier mécanisme, qui met en évidence l'importance des synapses dans le processus d'apprentissage. Les premiers succès de cette discipline remontent à 1957, lorsque F. Rosenblatt développe le modèle du Perceptron. Il construit le premier neuro-ordinateur basé sur ce modèle et l'applique au domaine de la reconnaissance des formes. C'est alors qu'en 1960, l'automaticien Widrow développe le modèle Adaline (*Adaptive Linear Element*). Dans sa structure, le modèle ressemble au Perceptron, cependant la loi d'apprentissage est différente. En 1969 PAPER et MINSKY ont publié un ouvrage qui met en exergue les limitations théoriques du Perceptron et la nécessité de plusieurs couches identiques à celui-ci, pour résoudre ces problèmes. Ces limitations concernent l'impossibilité de traiter des problèmes non linéaires en utilisant ce modèle. Entre

1969 et 1978 les travaux sont orientés vers les mémoires associatives. Mais ces derniers sont confrontés aux problèmes d'instabilité. C'est en 1982 que le problème de stabilité des réseaux dynamiques est réglé, et cela par l'apparition du travail de HOPFIELD, un physicien reconnu. Au travers d'un article court, clair et bien écrit, il présente une théorie du fonctionnement et des possibilités des réseaux de neurones. En 1986 les résultats du travail de trois groupes de chercheurs indépendants, ont permis la résolution des anciens problèmes posés par MINSKY et PAPERTE en mettant en œuvre l'algorithme de rétropropagation (Bourret et al., 1991). C'est un algorithme d'apprentissage adapté au Perceptron Multi-Couches (PMC). Dès cette découverte, nous avons la possibilité de réaliser une fonction non linéaire d'entrée/sortie sur un réseau, en décomposant cette fonction en une suite d'étapes linéairement séparables. Enfin, en 1989 Moody et Darken exploitent quelques résultats de l'interpolation multi variables pour proposer le Réseau à Fonctions de base Radial (RFR), connu sous l'appellation anglophone *Radial Basis Function Network (RBFN)*.

## 2.3 Du neurone biologique au neurone formel

### 2.3.1 Le neurone biologique

Le système nerveux central se compose d'environ  $10^{12}$  neurones (*mille milliards*), fortement interconnectés entre eux. Un neurone est constitué de trois parties qui sont: le corps cellulaire (*Soma*), les dendrites, l'axone et les synapses (Figure 2.1). Le corps cellulaire contient le noyau du neurone et effectue les transformations biochimiques nécessaires à la synthèse des enzymes et des autres molécules qui assurent la vie du neurone. Les dendrites sont de fines extensions tubulaires ramifiées autour du corps cellulaire. Chaque neurone reçoit des informations, sous forme d'impulsions électriques : les influx nerveux, provenant de toutes les ramifications des dendrites. L'axone sert de moyen de transport pour les signaux émis par le neurone. Il se distingue des dendrites par sa forme et par les propriétés de sa membrane externe.




Figure 2.1 - Neurone biologique

La synapse est donc le lieu de passage des impulsions d'un neurone à l'autre (Mac Clelland et Rumelhart, 1988). Ce passage d'informations est réalisé par des procédés chimiques, car un

influx nerveux ne peut pas passer directement d'un corps cellulaire à un autre. Les vecteurs de cette transmission sont les neuro-transmetteurs. Une synapse peut être inhibitrice ou excitatrice. Dans le premier cas le neurone émetteur aura tendance à inhiber le neurone récepteur, alors que dans le second cas il aura tendance à l'activer. De plus, par sa géométrie, son lieu de ramification et les structures des processus chimiques, une synapse est caractérisée par l'efficacité avec laquelle elle assure la liaison.

### 2.3.2 Neurone formel

Le neurone formel (*ou artificiel*) est une modélisation mathématique qui reprend les principes de fonctionnement du neurone biologique. Mc CULLOCH et PITTS ont implémenté un système de réseaux neuronaux artificiels, qui est analogue aux neurones biologiques fondée sur une structure complexe (Tableau 2.1).

Le réseau de neurones artificiels est considéré comme un arrangement d'éléments de structure identique appelés neurones interconnectées par analogie avec cellules du système nerveux humain. Il est composé également d'une succession de couches connectées de manière à ce que chaque neurone tienne son entrée de la sortie du neurone précédant. Chaque neurone dans ce cas fonctionne indépendamment par rapport aux autres afin que l'ensemble forme un système compact. L'information est emmagasinée de façon répartie dans le réseau sous forme de coefficients synaptiques. Le neurone formel calcule régulièrement un résultat qu'il transmet ensuite aux neurones suivant, chaque calcul est associé à un poids qui définit la force de la connexion (Hagan et al. 1996).

Mathématiquement chaque neurone reçoit des entrées sous forme vectorielle en provenance des neurones situés en amont puis il calcule une somme pondérée de ses entrées pour que le résultat passe ensuite par la fonction d'activation afin de créer une sortie (qui est de nature binaire). A chacune de ses entrées ( $n$  en l'occurrence):  $x_1, x_2, x_3, \dots, x_n$  sont associé des poids ( $w_1, w_2, w_3, \dots, w_n$ ) représentatif de la force de connexion. Chaque entrée est pondérée par un poids (*weight*) propre  $w_i$  que l'on nomme poids synaptique (Verron, 2007).

Neurone artificiel	Neurone biologique
Poids de connexion	Synapses
Signal de sortie	Axones
Signal d'entrée	Dendrite
Fonction d'activation	Soma

**Tableau 2.1** - Analogie entre le neurone artificiel et le neurone biologique

La somme  $v$  représente l'état interne du neurone, à laquelle s'ajoute un terme constant " $w_0$ " appelé « biais ». Cette somme  $v$  s'exprime ainsi :

$$v = w_0 + \sum_{i=1}^{n-1} w_i x_i \quad (2.1)$$


La somme  $v$  est transmise à une fonction de transfert nommée fonction d'activation  $f$ . La sortie de cette fonction donne la sortie générale du neurone  $y$ . Le fonctionnement du neurone peut donc simplement s'écrire sous la forme de l'équation 2.2.

$$y = f[w_0 + \sum_{i=1}^{n-1} w_i x_i] \quad (2.2)$$

Le biais " $w_0$ " joue un rôle de seuil, quand le résultat de la somme pondérée dépasse ce seuil, l'argument de la fonction de transfert devient positif ou nul; dans le cas contraire, il est considéré négatif. Finalement si le résultat de la somme pondérée est:

1. en dessous du seuil, le neurone est considéré comme non-actif;
2. aux alentours du seuil, le neurone est considéré en phase de transition;
3. au-dessus du seuil, le neurone est considéré comme actif.

Tout l'intérêt d'un neurone formel réside dans ses poids synaptiques. Ces poids doivent être correctement ajustés pour mimer un comportement, pour reproduire le lien entre l'espace des entrées et l'espace de la sortie. La détermination des poids est appelée "*processus d'apprentissage*", elle suit une loi appelée "*règle d'apprentissage*". Lorsque les poids sont adaptés de manière itérative, ils sont mis à jour régulièrement et le neurone peut de ce fait prendre en compte l'aspect dynamique d'un processus. Le schéma classique d'une cellule nerveuse est donné par la [Figure 2.2](#) qui met en parallèle une description d'un neurone biologique avec un neurone artificiel.




**Figure 2.2** - Mise en correspondance neurone biologique / neurone artificiel (Touzet, 1992)

### 2.3.3 Fonction d'activation

La fonction d'activation (ou fonction de transfert) sert à convertir le résultat de la somme pondérée des entrées d'un neurone en une valeur de sortie, cette conversion s'effectue par un calcul de l'état du neurone en introduisant une non-linéarité dans le fonctionnement du neurone (Cybenko, 1989).

Il y a plusieurs types de fonctions de transfert qui peuvent être utilisées dans les réseaux de neurones (Duda et al., 2001), mais les plus courantes et les plus citées dans la littérature sont recensées dans la [Figure 2.3](#). On remarquera qu'à la différence des neurones biologiques dont

l'état est binaire, la plupart des fonctions de transfert sont continues, offrant une infinité de valeurs possibles comprises dans l'intervalle  $[0, +1]$  ou  $[-1, +1]$ .



**Figure 2.3** - Différents types de fonctions de transfert pour le neurone artificiel

## 2.4 Propriétés des réseaux de neurones

Un réseau de neurone est un ensemble d'éléments de traitement de l'information, avec une topologie spécifique d'interconnexions entre ces éléments et une loi d'apprentissage pour adapter les points de connexions. D'une manière générale, un réseau de neurones possède les propriétés suivantes :


1. *Le parallélisme*: Cette notion se situe à la base de l'architecture des réseaux de neurones considérés comme ensembles d'entrées élémentaires qui travaillent simultanément.
2. *La capacité d'adaptation*: Celle-ci se manifeste tout d'abord dans les réseaux de neurones par la capacité d'apprentissage qui permet au réseau de tenir compte des nouvelles contraintes ou des nouvelles données du monde extérieur. De plus, ils se caractérisent par leur capacité d'auto organisation qui assure leur stabilité en tant que système dynamique.
3. *La généralisation*: La capacité de généralisation d'un réseau de neurone est son aptitude de donner une réponse satisfaisante à une entrée qui ne fait pas partie des exemples à partir desquels il a appris.
4. *Structure de connexion*: Les connexions entre les neurones qui composent le réseau décrivent la "topologie" du modèle. Elles sont très variées, le nombre de connexions étant énorme. Cette topologie fait apparaître une certaine régularité de l'arrangement des neurones.

## 2.5 La règle de Hebb

Historiquement, le premier mécanisme d'évolution des synapses, donc le premier mécanisme d'apprentissage, fut proposé par D. Hebb en 1949 (Hebb, 1949). Dans un contexte neurobiologique, Hebb cherchait à établir une forme d'apprentissage associatif au niveau cellulaire. Dans le contexte des réseaux artificiels, on peut reformuler l'énoncé de Hebb sous la forme d'une règle d'apprentissage en deux parties :

1. *Si deux neurones de part et d'autre d'une synapse (connexion) sont activés simultanément (de manière synchrone), alors la force de la connexion doit être augmentée.*

2. Si les mêmes deux neurones sont activés d'une manière asynchrone, alors le synapse correspondant doit être affaibli ou carrément éliminé. La [Figure 2.4](#) schématise cette règle ([Poulard, 1996](#)).



**Figure 2.4** - Règle de Hebb


Un tel synapse est dit «synapse hebbien». Il utilise un mécanisme interactif, dépendant du temps et de l'espace, pour augmenter l'efficacité synaptique d'une manière proportionnelle à la corrélation des activités pré- et post-synaptiques. Cette règle d'apprentissage servira au début des années 80 sous sa forme originelle à l'apprentissage des réseaux bouclés.

## 2.6 Architectures neuronales

L'architecture est un concept très important qui joue un rôle déterminant dans la classification des réseaux de neurones. Dans la littérature on utilise souvent le mot structure comme synonyme d'architecture ([Maren et al. 1990](#); [Hertz et al. 1991](#)). Chaque architecture a sa propre organisation qui est adapté à des applications bien spécifiques ([Sarle 1994](#); [Haykin 1994](#)).

Les structures d'un réseau de neurones peuvent être très variées mais elles sont souvent réparties en deux grandes catégories, à savoir: les réseaux de neurones non bouclés et les réseaux de neurones bouclés ([Burns, 2001](#)). Nous allons présenter l'essentiel des concepts généraux liés aux architectures des réseaux de neurones. Les principes propres à chaque réseau sont accessibles à travers des ouvrages tels que ([Hertz et al., 1991](#); [Hérault et Jutten, 1994](#); [Haykin, 1994](#); [Jodouin, 1994](#) ; [Dreyfus et al., 2002](#); [Personnaz et Rivals, 2003](#)). Les auteurs ([Hagan et al., 1995](#)) ont par ailleurs développé une boîte à outils pour Matlab/Simulink. La [Figure 2.5](#) montre les principales topologies qui existent ([Wira, 2009](#)).

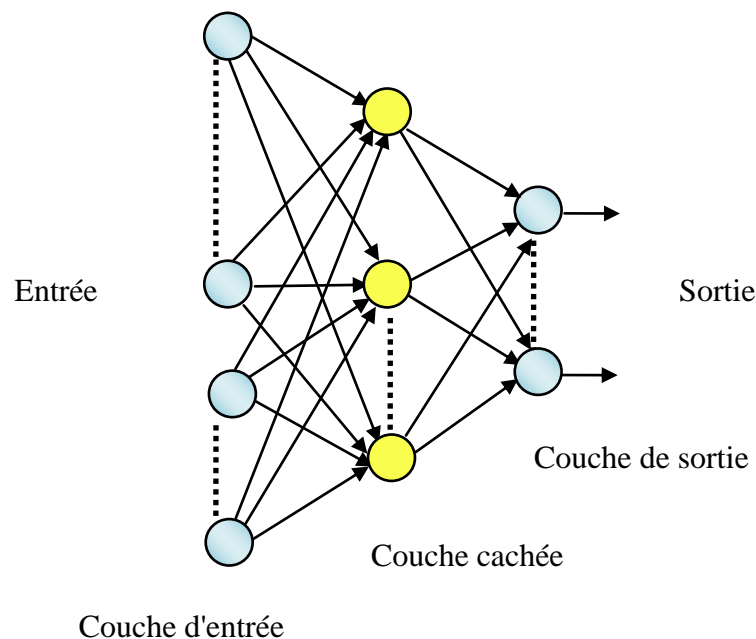
La Figure 2.5 montre quelques structures des réseaux de neurones.



**Figure 2.5** - Topologies des réseaux de neurones artificiels les plus populaires

### 2.6.1 Réseaux de neurones non bouclés «Feed Forward»

Dans un réseau de neurone non bouclé dit aussi statique, la propagation de l'information se fait uniquement de l'entrée vers la sortie sans aucune rétroaction. Ce type de réseau comprend deux groupes d'architectures: les réseaux Mono-Couches et les réseaux Multi-Couches. Ils diffèrent par l'existence ou non de neurones intermédiaires appelées neurones cachés entre les unités d'entrées et les unités de sorties appelées ou nœuds d'entrée et nœuds de sortie respectivement. Dans l'exemple de la Figure 2.6, nous présentons un réseaux de neurones à trois couches non bouclé. Les neurones de la première couche, nommée couche d'entrée, voient leur activation forcée à la valeur d'entrée. La dernière couche est appelée couche de sortie, elle regroupe les neurones dont les fonctions d'activation sont généralement de type linéaire. Les couches intermédiaires sont appelées couches cachées, elles constituent le cœur du réseau.



**Figure 2.6** - Réseau de neurones non bouclé

### 2.6.2 Réseaux de neurones bouclés « Feed-Back »

Ce type de réseaux appelés aussi dynamiques ou récurrents (Figure 2.7), se caractérisent par la présence d'au moins une boucle de rétroaction au niveau des neurones ou entre les couches. Les connexions rétroactives peuvent exister entre tous les neurones du réseau sans distinction, ou seulement entre certains neurones (les neurones de la couche de sortie et les neurones de la couche d'entrée ou les neurones de la même couche par exemple). Ils conviennent bien pour la modélisation dynamique de processus non linéaires où la notion du temps est un élément essentiel (Chemachema et Benghalia, 2012).




Figure 2.7 - Réseau de neurones bouclé

## 2.7 Apprentissage des réseaux de neurones

L'apprentissage est vraisemblablement la propriété la plus intéressante des réseaux de neurones. L'apprentissage est une phase du développement du réseau de neurones durant laquelle on calcule les poids des neurones de telle manière que les sorties du réseau soient aussi proches que possible des sorties désirées (Bekkari et Zeddouri, 2019). Autrement dit, le processus d'apprentissage consiste en la modification des poids de connexions (y compris les biais) ou plus rarement du nombre de couches et de neurones (Man et Halang, 1997), afin d'adapter le traitement effectué par le réseau à une tâche particulière. Un ensemble fixé de règles bien définies pour la solution d'un problème d'apprentissage est appelé "un algorithme d'apprentissage". Plusieurs algorithmes d'apprentissage ont été développés depuis la première règle d'apprentissage de Hebb en 1949. Au niveau de ces algorithmes d'apprentissage; il a été défini trois grands types d'apprentissage: *supervisé* et *non supervisé* et *apprentissage semi-supervisé*.

- **Apprentissage supervisé:** Dans l'apprentissage supervisé (ou apprentissage avec professeur), un superviseur fournit une valeur ou un vecteur de sortie (appelé cible ou sortie désirée) que le réseau de neurones doit associer au vecteur d'entrée. L'apprentissage



consiste dans ce cas à modifier les paramètres du réseau de neurones afin de minimiser l'erreur entre la sortie cible et la sortie réelle du réseau de neurones. En résumé, les paramètres du réseau s'adaptent par comparaison entre le résultat calculé, en fonction des entrées fournies et la réponse attendue en sortie. Ainsi, le réseau se modifie jusqu'à obtenir la meilleure sortie, par rapport à celle désirée, i.e. jusqu'à obtention d'une erreur minimale (Parizeau, 2004). Des exemples d'utilisations de différentes règles d'apprentissage, architectures et algorithmes qui sont reliés à ce type supervisé sont illustrés dans le [Tableau 2.2](#).

<i>Apprentissage</i>	<i>Architecture</i>	<i>Règle d'apprentissage</i>	<i>Algorithme</i>	<i>Domaines</i>
<i>Supervisé</i>	Perceptron simple ou multi-couches	Correction d'erreur	Perceptron, Rétro-propagation, Adaline, Madaline	Classification, Approximation de fonctions, Prédiction, Contrôle
	Récurrente	Boltzman	Apprentissage de Boltzman	Classification
	Multi-couches Non bouclés	Hebb	Analyse de discriminants linéaires	Analyse de données, Classification
	A compétition	Par compétition	LVQ	Catégorisation au sein d'une classe, Compression de données
	ART		ARTMap	Classification, Catégorisation au sein d'une classe

**Tableau 2.2** - Exemple de différents types d'apprentissages en mode supervisé

- **Apprentissage non supervisé:** L'apprentissage non supervisé (appelé aussi auto-organisateur ou apprentissage par compétition) est une forme d'extraction de caractéristiques des données. Contrairement à l'apprentissage supervisé, seules les valeurs d'entrée sont disponibles dans ce type d'apprentissage non supervisé. Dans ce cas, les exemples présentés à l'entrée provoquent une autoadaptation du réseau afin d'engendrer des valeurs de sortie qui soient proches en réponse à des valeurs d'entrée similaires. Des exemples d'utilisations de différentes règles d'apprentissage, architectures et algorithmes qui sont reliés à ce type non supervisé sont illustrés dans le [Tableau 2.3](#).

<i>Apprentissage</i>	<i>Architecture</i>	<i>Règle d'apprentissage</i>	<i>Algorithme</i>	<i>Domaines</i>
<i>Non Supervisé</i>	Multi-couches Non bouclés	Correction d'erreur	Projection de Sammon	Analyse de données
	Multi-couches ou à compétition	Hebb	Analyse en composante	Analyse de données
	A compétition	Par compétition	VQ	Catégorisation, Compression de données
	Carte de Kohonene		SOM	Catégorisation, Analyse de données
	ART		ART-1, ART-2	Catégorisation

**Tableau 2.3** - Exemple de différents types d'apprentissages en mode non supervisé

- **Apprentissage semi-supervisé:** Ce type d'apprentissage est un peu moins courant, il suppose qu'un comportement de référence n'est pas possible, mais en revanche, il est possible d'obtenir des indications qualitatives (vrai, faux, ...) sur les performances du réseau. Ce mode d'apprentissage comprend l'apprentissage par renforcement initié par Barto (1992); Sutton et Barto (1998).

Le choix de l'algorithme d'apprentissage pour un modèle connexionniste peut s'effectuer en fonction de plusieurs des critères suivants: la rapidité de convergence soit le nombre d'itérations nécessaires pour converger "suffisamment près" de la solution optimale, la mesure de cette "proximité" entre la solution optimale et la solution obtenue, la capacité de poursuite des variations (non-stationnarités) du système, la robustesse au bruit, la complexité et les coûts algorithmiques engendrés, etc.

## 2.8 Le Perceptron simple

Le perceptron, proposé par F. ROSENBLATT (Rosenblatt, 1958), fut le premier modèle de réseau de neurones doté d'un mécanisme d'apprentissage. C'est un réseau à deux couches (une couche d'entrée et une couche de sortie) de type *feedforward*. Les neurones de la couche d'entrée ont pour rôle de fournir au réseau les données externes. Chaque neurone de la couche de sortie effectue une somme pondérée de ses entrées :

$$y_i = f(a_i) = f\left(\sum_{k=1}^{k=N} w_{ik} x_k\right) \quad (2.3)$$

où  $w_{ik}$  est le poids de la connexion qui relie l'unité  $k$  à l'unité  $i$ ,  $a_i$  est l'activation de l'unité  $i$ ,  $f$  est la fonction d'activation des unités. La fonction d'activation  $f$  permet de définir l'état interne du neurone en fonction de son entrée totale, comme exemple on a la fonction seuil définie par l'expression suivante :

$$f(x) = \begin{cases} +1 & \text{si } x \geq 0 \\ -1 & \text{si } x < 0 \end{cases} \quad (2.4)$$

### 2.8.1 Apprentissage du Perceptron

L'apprentissage du perceptron est supervisé. Il consiste donc à modifier les poids des connexions entre les neurones d'entrée et ceux de sortie, de manière à obtenir une réponse que l'on souhaite reproduire par le réseau de neurones. Rosenblatt s'est inspiré de la règle de Hebb pour la modification des poids. Son principe est de rajouter, dans le cas où la sortie obtenue du réseau  $y_i^p$  est différente de la sortie désirée  $\zeta_i^p$ , une quantité  $\Delta w_{ik}$  aux poids de chaque connexion. Dans le cas contraire, les connexions demeurent inchangées. On peut exprimer ce principe par :

$$w_{ik}^{\text{nouveau}} = w_{ik}^{\text{ancien}} + \Delta w_{ik} \quad (2.5)$$

où  $\Delta w_{ik}$  est la quantité ajoutée au poids  $w_{ik}$ . Pour chaque exemple de l'ensemble des exemples d'apprentissage, on peut ainsi écrire :

$$\Delta w_{ik} = \eta(\zeta_i^p - y_i^p)x_k^p \quad (2.6)$$

Cette règle sera nommée PLR (*Perceptron Learning Rule*). Le paramètre  $\eta$  est appelé *taux d'apprentissage (learning rate)*. Ce paramètre peut varier au cours de l'apprentissage, mais dans ce cas il doit être décroissant. Il détermine la dynamique suivant laquelle les modifications vont avoir lieu.

La principale limite de ce réseau est qu'il ne peut résoudre que des problèmes linéairement séparables. Malheureusement, un grand nombre de problèmes rencontrés en pratique, ne sont pas linéairement séparables. Le Perceptron possède tout de même une bonne capacité de généralisation.

En 1969, Papert et Minsky démontrent les limites du Perceptron classique, incapable, par exemple de simuler la fonction OU exclusif (XOR), les réseaux multicouches peuvent être une solution alternative à ce problème.

## 2.8.2 Règle de Delta

La règle de Widrow-Hoff dite *règle de delta*, est une méthode de minimisation de l'erreur entre la sortie réelle et la sortie désirée. Cette règle est généralement utilisée dans le cas d'apprentissage supervisé. La règle de Widrow-Hoff donne une solution plus robuste que celle du Perceptron. Contrairement au modèle de Rosenblatt où les neurones ont des fonctions d'activation à seuils, Widrow et Hoff en 1960 ([Widrow et al., 1960](#)) ont proposé un modèle de Perceptron avec fonction d'activation linéaire :

$$f(a_i) = a_i \quad (2.7)$$

où  $a_i$  est l'activation de l'unité  $i$ ,  $f$  est la fonction d'activation des unités.

L'avantage d'utiliser des neurones linéaires est qu'elles permettent de calculer une fonction de coût qui évalue l'erreur que commet le réseau. Cette erreur peut être définie en fonction des erreurs entre réponses désirées et réponses obtenues par le réseau. Cette erreur est donc fonction des poids du réseau :

$$E(w) = \frac{1}{2}(\zeta_i^p - \sum_k w_{ik} x_k^p)^2 \quad (2.8)$$

où  $w_{ik}$  est le poids de la connexion qui relie l'unité  $k$  à l'unité  $i$ .

L'objectif de l'apprentissage est de modifier les valeurs des poids du réseau de façon à minimiser cette erreur. Il s'agit donc de descendre le long de la surface définie par l'erreur dans l'espace des poids du réseau. L'algorithme de descente du gradient suggère de changer chaque poids  $w_{ik}$  d'une quantité  $\Delta w_{ik}$  proportionnelle au gradient de l'erreur ([équation 2.6](#)).

La modification des poids peut également être effectuée à chaque exemple d'entrée  $p$ . On obtient alors :

$$\Delta w_{ik} = \eta(\zeta_i^p - y_i^p)x_k^p = \eta \vartheta_i^p x_k^p \quad (2.9)$$

avec  $\vartheta_i^p$  est définie par:


$$\vartheta_i^p = \zeta_i^p - y_i^p \quad (2.10)$$

Cette règle d'apprentissage est généralement appelée la règle *Delta*, ou règle de *Widrow-Hoff*. Elle converge vers la solution des moindres carrés qui minimise la fonction d'erreur  $E$ .

## 2.9 Le Perceptron Multi Couches (PMC)

L'architecture de réseau de neurones la plus répandue est le Perceptron Multi-Couches (*MLP pour Multi-Layer Perceptron*) (Bishop, 1995; Raudys, 2001; Dreyfus et al., 2002; Raghu et Sriraam, 2017; Bui et al., 2018). Un MLP est composé d'une ou plusieurs couches, comportant chacune un certain nombre de neurones ou nœuds. Les neurones y sont organisés en couches successives: une couche d'entrée, une couche de sortie et entre les deux une ou plusieurs couches intermédiaires, appelées aussi couches cachées. Chaque neurone dans une couche est connecté à tous les neurones de la couche précédente et de la couche suivante (excepté pour les couches d'entrée et de sortie) et il n'y a pas de connexions entre les neurones d'une même couche. Un exemple de perceptron multicouche est montré sur la [Figure 2.8](#).

Pour les fonctions d'activation utilisées dans ce type de réseaux il n'y pas de règle stricte permettant de choisir une fonction optimale. Mais, pour la plupart des problèmes, une fonction d'activation à seuil ou sigmoïdes permettent d'obtenir des résultats corrects.



**Figure 2.8** - Exemple d'un MLP

En effet, bien que le nombre de neurones de la couche d'entrée et de sortie soit imposé par le nombre d'entrées du système (pour la couche d'entrée) ainsi que par la codification des différentes classes (pour la couche de sortie), aucune règle mathématique au sens strict ne permet de déterminer, pour un problème donné, le nombre de couches cachées ainsi que le nombre de neurones dans chaque couches. Cependant, une pratique courante est l'utilisation

d'une seule couche cachée composée d'un nombre de neurones d'environ la moitié du nombre d'entrée du système plus un.

Pour l'apprentissage d'un MLP le but essentiel est de minimiser l'erreur quadratique (équation 2.8) et cela pour qu'il soit capable de reconnaître des exemples n'appartenant pas nécessairement à l'ensemble d'apprentissage.

Pour la couche de sortie, on peut appliquer l'apprentissage du Perceptron, le problème qui se pose est comment modifier les poids pour les connexions qui ne sont pas en relation avec un neurone de sortie. La rétropropagation du gradient est une solution à ce problème (Osorio, 1998; Jack et Nandj, 2000; Mokhnache, 2004).

## 2.10 Apprentissage d'un réseau multicouche

### 2.10.1 La rétropropagation

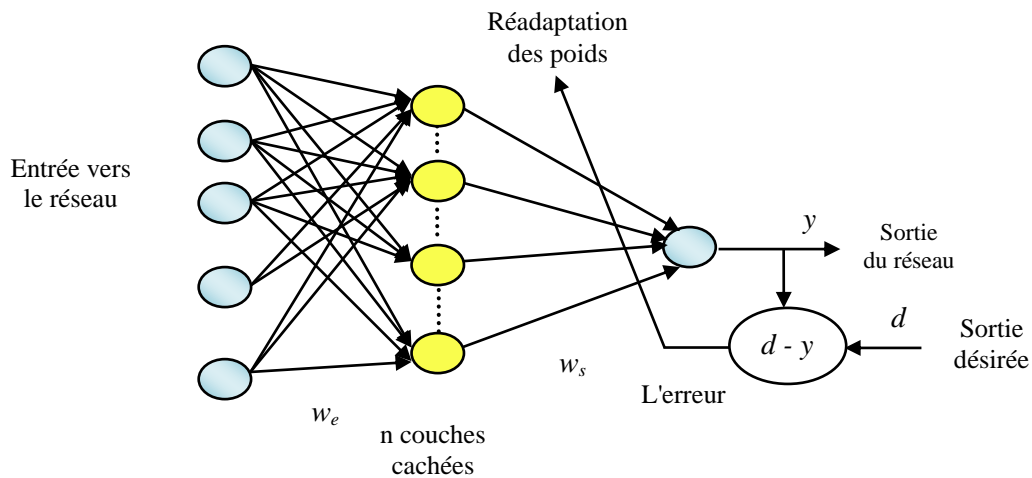
L'algorithme de rétropropagation (*backpropagation*) est l'un des algorithmes supervisés les plus utilisés pour l'apprentissage des réseaux de neurones. La rétropropagation constitue en fait la suite logique de l'enchaînement des règles d'apprentissage du Perceptron (*PLR*) et Widrow-Hoff (*de Delta*). L'objectif de cet algorithme est de modifier les poids du réseau dans le sens contraire du gradient du critère de performance.

Le problème du Perceptron est qu'il minimise une erreur en tout ou rien à cause de sa fonction d'activation sans prendre en compte une notion de distance. De ce fait, il est très peu robuste. La règle d'apprentissage de Widrow-Hoff ne travaille plus en tout ou rien mais minimise une fonction d'erreur quadratique, donc elle est plus robuste et donne des solutions approchées lorsqu'il n'y a pas de solutions. Mais le problème est que la fonction d'erreur de cette règle n'est pas une véritable fonction d'erreur, car le signal est pris avant le seuillage. De plus, et c'est ceci qui est très limitatif, les règles d'apprentissage du Perceptron et de Widrow-Hoff ne fonctionnent que sur des réseaux avec une seule couche de poids adaptatifs (Hunt et al., 1992; Zemouri, 2003).

Le problème était donc de trouver une véritable fonction d'erreur qui permet l'apprentissage des réseaux multi-couches. C'est donc en étendant la règle de Widrow-Hoff que plusieurs équipes de chercheurs Le Cun, (1985) et Werbos, (1974) ont développé un algorithme d'apprentissage appelé *rétropropagation du gradient de l'erreur*, qui a été généralisé ensuite par l'équipe de Rummelhart en 1986 (Rummelhart et al., 1986). Cet algorithme fournit une façon de modifier les poids des connexions de toutes les couches d'un MLP.

L'idée qui est à la base de cet algorithme est simple, elle consiste à l'utilisation d'une fonction dérivable (*fonction sigmoïde*) en remplacement de la fonction de seuil utilisée dans le neurone linéaire à seuil. Le principe de cet algorithme consiste dans un premier temps à circuler vers l'avant les données d'entrées jusqu'à l'obtention d'une sortie calculée par le réseau, puis la seconde étape est de comparer la sortie calculée à la sortie réelle connue (Figure 2.9). Les poids sont modifiés de telle sorte qu'à la prochaine itération, l'erreur commise entre la sortie calculée est minimisée, en prenant en considération la présence des couches cachées, l'erreur est rétro-propagée vers l'arrière jusqu'à la couche d'entrée tout en modifiant la pondération, d'où le nom rétro-propagation (Rummelhart et al., 1986).

Le processus est répété sur tous les exemples jusqu'au temps où l'on obtienne une erreur de sortie considérée comme négligeable.



**Figure 2.9** - Principe d'entraînement du réseau par rétro-propagation de l'erreur (Mokhnache, 2004)

Autrement dit, l'algorithme de rétro-propagation se divise en deux étapes :

- une phase de propagation, qui consiste à présenter les exemples à l'entrée du réseau, puis à propager cette entrée de proche en proche de la couche d'entrée à la couche de sortie en passant par les couches cachées;
- une phase de rétro-propagation, qui consiste à minimiser l'erreur (équation 2.8) commise sur l'ensemble des exemples présentés en modifiant les paramètres du réseau.

### 2.10.2 Limites de l'algorithme de rétropropagation

L'algorithme de rétro-propagation du gradient de l'erreur a permis de dépasser les limites du Perceptron simple. Il s'avère capable de résoudre un grand nombre de problèmes de classification et de reconnaissance des formes et à donné lieu à beaucoup d'applications. L'algorithme de rétropropagation souffre néanmoins de nombreux défauts, parmi lesquels (Zemouri, 2003; Zwinglestein, 1995):

- une des limitations importantes est le temps de calcul : le temps d'apprentissage est relativement long, de quelques minutes à quelques heures, suivant la complexité et le nombre d'exemples d'apprentissage;
- une grande sensibilité aux conditions initiales, c'est-à-dire à la manière dont sont initialisés les poids des connexions;
- l'algorithme peut converger vers des minima locaux. Ce problème est en partie résolu avec le gradient stochastique, mais il subsiste quand même;
- le problème de dimensionnement du réseau: La rétro-propagation apprend une base d'apprentissage sur un réseau dont la structure est fixée a priori. Un mauvais choix de structure peut dégrader considérablement les performances du réseau, s'il est sous-

- dimensionné, l'algorithme n'arrivera pas à apprendre. S'il est sur-dimensionné, la base d'apprentissage sera apprise mais ses performances en généralisation seront faible;
- l'erreur globale décroît rapidement au début de l'apprentissage puis se met à augmenter. Alors la mémorisation de la configuration des poids qui reflète l'erreur minimale est importante. Pratiquement il est préférable de partitionner l'ensemble des exemples en trois sous-ensembles: le premier pour l'apprentissage, le deuxième pour la généralisation et le dernier pour le test.

### 2.10.3 Quelques algorithmes de rétropropagation

L'implantation la plus simple de la rétropropagation effectue la mise à jour des poids et des biais du réseau dans la direction dans laquelle la fonction d'erreur diminue le plus rapidement. Il y a beaucoup de variantes de l'algorithme de rétropropagation, citons par exemple:

**Les algorithmes de descente de gradient Conjugué:** L'algorithme de rétropropagation de base ajuste les poids dans la direction de descente du gradient la plus raide (négatif du gradient). C'est la direction dans laquelle la fonction d'erreur diminue. Il s'avère que, ceci ne produit pas nécessairement la convergence la plus rapide. Dans les algorithmes de gradient conjugué une recherche est effectuée le long des directions conjuguées, qui produit une convergence généralement plus rapide. Parmi ces algorithmes nous citons les variantes suivantes avec leurs codes en MATLAB ([MATLAB 8.1, 2013](#)):

- Mise à jour de Fletcher-Reeves (Fletcher-Reeves Update – TRAINCGF);
- Mise à jour de Polak-Ribière (Polak-Ribière Update – TRAINCGP);
- Relancements de Powell-Beale (Powell-Beale Restarts – TRAINCGB);
- Gradient conjugué mesuré (Scaled Conjugate Gradient – TRAINSCG).

**Les algorithmes Quasi-newtoniens:** La méthode de Newton est une alternative aux méthodes de gradient conjugué pour une optimisation rapide. Le principe de base de la méthode de Newton est l'introduction des informations du second ordre ou la matrice Hessienne (*dérivés secondes*) de la fonction de performance. La méthode de Newton converge souvent plus rapidement que les méthodes de gradient conjugué. Il y a une classe d'algorithmes qui sont basés sur la méthode de Newton mais qui n'exige pas le calcul des dérivés secondes, qui s'appellent, algorithmes quasi-newtoniens. Ils mettent à jour une matrice approximative du Hessien à chaque itération de l'algorithme.

Parmi ces algorithmes nous citons:

- Broyden, Fletcher, Goldfarb, and Shanno algorithm (TRAINBFG);
- One step secant algorithm (TRAINOSS);
- Levenberg-Marquardt (TRAINLM);

**L'algorithme de Levenberg-Marquardt** a été conçu pour accélérer de manière significative la convergence de l'apprentissage, sans devoir calculer la matrice Hessienne. Cet algorithme semble être la méthode la plus rapide pour l'apprentissage des réseaux neuronaux de taille

modérée de type *feedforward* comprenant plusieurs centaines de poids. L'inconvénient principal de l'algorithme de Levenberg-Marquardt est qu'il exige le stockage de quelques matrices qui peuvent être tout à fait grandes pour certains problèmes.

## 2.11 Les Réseaux de neurones à Fonctions de base Radiales (RFR)

Les réseaux à fonction de base radiale (*RBF pour Radial Basis Function*) sont des réseaux de type *feedforward* avec une seule couche cachée (Figure 2.10). Ils ont comme origine une technique d'interpolation nommée méthode d'interpolation RBF (*RBF interpolation*). Employée pour la première fois dans le contexte des réseaux de neurones par Broomhead et Lowe. Les bases théoriques de ces réseaux ont été approfondies par (Powell, 1987; Poggio et al., 1989; Moody et al., 1989). D'autres travaux se sont succédés où l'application des RBF a été élargie à d'autres domaines, tels que la prédiction de l'évolution des systèmes dynamiques (Broomhead et al., 1988) et la classification de phonèmes (Renals et al., 1989).

Ces réseaux ont comme particularité qu'ils sont capables de fournir une représentation locale de l'espace grâce à des fonctions de base radiales  $\phi(\|\cdot\|)$  dont l'influence est restreinte à une certaine zone de cet espace ( $\|\cdot\|$  représente la norme euclidienne).

Les réseaux RBF font partie des réseaux à base de distance. Deux paramètres sont associés à la fonction de base radiale  $\phi(\|\cdot\|)$ : un vecteur de référence  $\gamma_j$  appelé centre ou *prototype* et un coefficient d'étalement  $\beta_j$  strictement positif. Les neurones sur lesquels sont basés ces réseaux sont appelés neurones à base radiale. La réponse de la fonction de base dépend donc de la distance du vecteur d'entrée  $\mathbf{x}$  au vecteur prototype  $\gamma_j$ , et de la taille du champ d'influence:

$$\phi_j(\mathbf{x}) = \phi_j(\|\mathbf{x} - \gamma_j\|, \beta_j) \quad 1 \leq j \leq N_c \quad (2.11)$$

où  $N_c$  est le nombre de neurones RBF, la fonction  $\phi_j(\mathbf{x})$  est généralement maximale lorsque  $\mathbf{x} = \gamma_j$  et tend vers 0 quand  $\|\mathbf{x} - \gamma_j\| \rightarrow \infty$ . Le paramètre  $\beta_j$  permet de régler la largeur de la gaussienne, plus  $\beta_j$  est petit, plus la fonction sera concentrée autour du point  $\gamma_j$  et proche de 0 ailleurs.

### 2.11.1 Architecture

Un réseau RBF est un réseau à trois couches (Figure 2.10):


- une couche d'entrée qui retransmet les entrées sans aucune modification;
- une couche RBF (couche cachée) qui contient les neurones RBF;
- une couche de sortie qui contient une fonction linéaire.

Sa sortie est donnée par :

$$f_w(\mathbf{x}) = \sum_{j=1}^{N_c} w_j g_j(\mathbf{x}) + w_0 \quad (2.12)$$

où  $g_j(\mathbf{x})$  possède une construction radiale,  $w_j$  le poids (scalaire) de la liaison entre la sortie et le neurone  $j$  et  $w_0$  son biais.





**Figure 2.10-** Architecture du réseau RBF

Chaque couche est complètement connectée à la suivante. Pour une entrée  $x_i$  donnée, la sortie du neurone RBF est l'amplitude de la gaussienne en ce point. La sortie du réseau est simplement une combinaison linéaire des sorties des neurones RBF pondérées par les poids  $\{w_i\}_{i=1}^{N_c}$  de leurs connexions respectives.

La fonction d'activation de la couche cachée est une fonction radiale. La fonction d'activation la plus communément utilisée est la fonction gaussienne (Figure 2.11). Elle s'exprime, sous sa forme la plus générale, par :


$$g_j(x) = \exp\left[-\frac{(\|x-\gamma_j\|^2)}{2\beta_j^2}\right] \quad (2.13)$$

où  $\beta_j^2$  désigne la variance associée à la cellule et  $\gamma_j$  représente les centres.

Pour des centres  $\gamma_j$  et des écarts-types  $\beta_j$  fixés, le modèle (2.12) est complètement linéaire par rapport aux poids  $\{w_i\}_{i=1}^{N_c}$ :

$$f_w(x) = \sum_{j=1}^{N_c} w_j \exp\left[-\frac{(\|x-\gamma_j\|^2)}{2\beta_j^2}\right] + w_0 \quad (2.14)$$

où  $\gamma_j$  est le centre du neurone numéro  $j$  de la couche cachée,  $\beta_j$  son coefficient d'étalement et  $w_0$  son biais.



**Figure 2.11-** Représentation d'une fonction gaussienne en 3 dimensions

Il a été montré que le réseau RBF est un approximateur universel (Parks et Sandberg, 1991), c'est à dire que le réseau est capable d'approximer n'importe quelle fonction douce avec une précision donnée, pourvu que l'on fournisse un nombre suffisant de neurones, et que l'on utilise un algorithme d'apprentissage adéquat. Lors de l'apprentissage d'un réseau RBF deux problèmes se posent: la constitution de la couche cachée (choix du nombre de neurones  $N_c$ , choix des prototypes  $\gamma_j$  et des coefficients d'étalement  $\beta_j$ ), et la détermination des poids et biais entre les neurones cachés et le neurone de sortie  $[w_0, w_1, \dots, w_{N_c}]^T$ .

### 2.11.2 Apprentissage

L'apprentissage des RBF permet de déterminer les paramètres de ces réseaux qui sont :

- le nombre de neurones RBF (nombre de neurones dans l'unique couche cachée);
- la position des centres des gaussiennes de chacun des neurones;
- la largeur de ces gaussiennes;
- le biais et les poids des connexions entre les neurones RBF et le neurone de sortie.

Toute modification d'un de ces paramètres entraîne directement un changement de comportement du réseau. Le nombre de neurones RBF et la position des centres sont intimement liés. Deux cas peuvent se présenter:

- Le nombre de neurones RBF est choisi égal au nombre d'exemples soumis au réseau ( $N_c=N$ ), s'il n'est pas trop grand. Les centres sont alors placés sur toutes les observations de la base d'apprentissage.
- Si  $N$  est grand, le positionnement des centres et le choix de leur nombre est un problème de clustering et plusieurs techniques peuvent être utilisées.

- L'algorithme de K-means est souvent utilisé pour la sélection des centres. Dans la méthode des K-means (Dreyfus et al., 2002), parmi les exemples donnés au réseau, les centres  $N_c$  sont choisis aléatoirement. Pour chacun des centres, on cherche les exemples les plus proches, au sens d'une certaine distance, et on groupe le centre et les exemples retenus. On détermine alors les centres de gravité des  $N_c$  groupements, qui remplacent les centres initiaux. Ces deux étapes sont recommencées jusqu'à convergence (pas de variation des centres). Les centres seront représentatifs de la dispersion des exemples de la base d'apprentissage.
- Une autre solution, permettant d'obtenir de meilleurs résultats, est de sélectionner les centres via une quantification vectorielle (*LVQ pour Learning Vector Quantization*) (Raudys, 2001). Elle permet d'obtenir une répartition des centres les plus éloignés les uns des autres, mais restant toujours représentatifs de leurs classes.

Ces deux algorithmes sont simples. Ils sont cependant sensibles à l'initialisation et à la métrique utilisée et surtout, ne déterminent pas le nombre de centres .

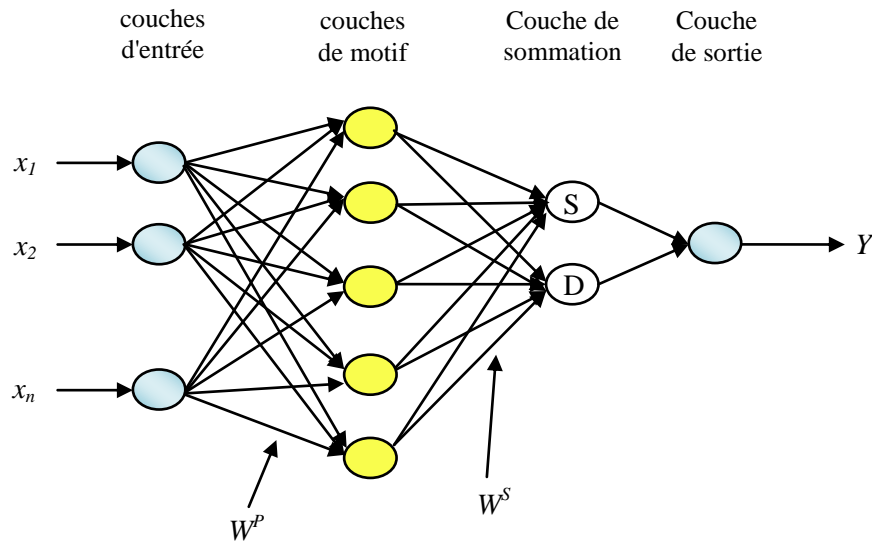
- La méthode Orthogonal Least Square (Chen et al., 1991) pour le classement des centres est utilisée dans (Oukhellou et Akinin, 1998). Cet algorithme effectue une sélection un par un des centres à partir de l'ensemble des données, jusqu'à ce qu'un réseau adéquat soit construit. Bien que cet algorithme permet de déterminer, d'une manière automatique, le nombre des neurones de la couche cachée nécessaires au problème considéré, son utilisation dans des applications en temps réel ou dans une identification récursive est impossible, car il nécessite la disposition a priori de toutes les données entrées-sorties.

## 2.12 Réseau de neurones de régression généralisée (RNRG)

Le réseau de neurones de régression généralisée (*GRNN pour Generalized Regression Neural Network*) tel que proposé par Donald Specht (Specht, 1991) est une sorte de réseau neuronal à fonction de base radiale, il entre dans la catégorie des réseaux neuronaux probabilistes. C'est un modèle neuronale qui peut résoudre tout problème d'approximation de fonction dans le sens d'estimer une fonction de distribution de probabilité (Kisi et al., 2014; Wang et al., 2016). Le GRNN est un approximateur universel pour les fonctions lisses, ce qui lui permet de résoudre toute approximation de fonction et d'estimer tout problème de variable continue lorsqu'on lui donne suffisamment de données (Park et Sandberg, 1991; Disornetiwat, 2001; Huang et al., 2018). Cette architecture est un algorithme d'apprentissage en un seul passage (*one-pass*) avec une structure hautement parallèle. Même avec des données rares dans un espace de mesure multidimensionnel, l'algorithme fournit des transitions en douceur d'une valeur observée à une autre (Specht, 1991). En raison de ses bonnes performances, le GRNN a été largement utilisé dans diverses tâches de prédiction et de prévision (Kim et al., 2003; Ladlani et al., 2012; Bendu et al., 2016; Huang et al., 2018).

Comme le montre la Figure 2.12, le GRNN se compose de quatre couches (Patterson, 1996): comprenant la couche d'entrée, la couche de motif, la couche de sommation et la couche de sortie. Le nombre de neurones d'entrée dans la première couche est égal à la dimension du

vecteur d'entrée dans l'échantillon d'apprentissage. La première couche est entièrement connectée à la seconde couche de motif via les poids de la couche de motif ( $W^p$ ), où chaque neurone représente un motif d'entrée d'apprentissage et sa sortie est une mesure de la distance entre l'entrée et les motifs stockés. Chaque neurone de la couche de motif est connectée via les poids de la couche de sommation ( $W^s$ ), aux deux neurones de la couche de sommation: le neurone de sommation S et le neurone de sommation D. Le neurone de sommation S calcule la somme des sorties pondérées de la couche de motif tandis que le neurone de sommation D calcule les sorties non pondérées des neurones de motif.



**Figure 2.12** - Architecture du GRNN

La couche de sortie divise simplement la sortie de chaque neurone de sommation S par celle de chaque neurone de sommation D, donnant la valeur prédite  $Y_i$  à un vecteur d'entrée inconnu  $x$  comme:

$$Y_i = \frac{\sum_{i=1}^n y_i \cdot \exp[-D(x, x_i)]}{\sum_{i=1}^n \exp[-D(x, x_i)]} \quad (2.15)$$

où  $y_i$  est la connexion pondérale entre le  $i^{\text{ème}}$  neurone de la couche de motif et le neurone de sommation S,  $n$  est le nombre de motifs d'apprentissage et la fonction Gaussienne  $D$  est définie par la relation suivante :

$$D(x, x_i) = \sum_{k=1}^m \left( \frac{x_k - x_{ik}}{\sigma} \right)^2 \quad (2.16)$$

où  $m$  est le nombre d'éléments d'un vecteur d'entrée, et  $x_k$  et  $x_{ik}$  sont le  $k^{\text{ème}}$  élément de  $x$  et  $x_i$ , respectivement. La notation  $\sigma$ , connue sous le nom de propagation ou largeur (*spread*), détermine les performances de généralisation du GRNN. En général, une valeur  $\sigma$  plus élevée peut entraîner une meilleure généralisation; sa valeur optimale est déterminée par essais et erreurs.

Comme l'a mentionné [Specht \(1991\)](#), le GRNN présente certains avantages par rapport à d'autres techniques de régression non linéaire, notamment l'apprentissage rapide sans procédure itérative, une estimation qui converge vers la surface de régression optimale

lorsque le nombre d'échantillons devient très grand, une estimation qui est limitée par le minimum et le maximum des observations, et une estimation qui ne peut pas converger vers des solutions médiocres correspondant aux minima locaux du critère d'erreur, ce qui se produit parfois avec le réseau neuronal *feedforward* entraîné par rétro-propagation (Chavarnakul et Enke, 2008).

### 2.13 La Carte Auto-Organisatrice de Kohonen (CAOK)

La carte auto-organisatrice, communément désignée carte SOM (pour Self-Organizing Map), est développée par Kohonen en 1982 (Kohonen, 1982). Ce réseau de neurones a largement montré son efficacité et différentes variantes notamment les algorithmes de quantification vectorielle (*LVQ*) par apprentissage, ont depuis été élaborés. Son application dépasse largement le cadre du contrôle robotique (Kohonen, 1995). Ce sont des réseaux à apprentissage non-supervisé qui établissent une carte discrète, ordonnée topologiquement, en fonction de modèles d'entrée.

La carte topologique de Kohonen est composée de deux couches dont la première constitue l'entrée du réseau, et la seconde (la carte même) la sortie. Les neurones de cette carte sont disposés en une topologie déterminée. Le fonctionnement du réseau de Kohonen s'effectue en deux étapes. Dans la première étape on identifie la cellule la plus sensible à l'entrée présentée et dans la deuxième étape on modifie les poids des cellules pour obtenir à la fin de l'apprentissage une partition des cellules en zones particulières sensibles à un sous-espace donné de l'ensemble des formes présentées à l'entrée. Le réseau de Kohonen construit ainsi des prototypes internes qui compriment les informations utiles.

Dans la plus part des applications, les neurones d'une carte de Kohonen sont disposés sur une grille 2D (Figure 2.5d). Chaque neurone  $i$  de la carte effectue un calcul de la distance euclidienne entre le vecteur d'entrée  $\xi$  et le vecteur poids  $w_i$ .

Dans les réseaux de Kohonen, la mise à jour des paramètres des neurones s'effectue sur tout un voisinage d'un neurone  $i$ . Un rayon de voisinage  $r$  représente donc la longueur du voisinage d'un neurone  $i$  en terme de nombre de neurones. On définit alors une fonction  $\delta(i, k)$  égale à 1 pour tous les neurones  $k$  voisins du neurone  $i$  compris dans le rayon  $r$  et égale à zéro pour tous les autres neurones. L'algorithme d'apprentissage de la carte de Kohonen est résumé comme suit:

1. Initialiser aléatoirement les vecteurs poids  $w_i$  avec de petite valeurs;
2. Fixer une valeur initiale au rayon  $r$  et au taux d'apprentissage  $\eta$ ;
3. Calculer la distance euclidienne entre le vecteur présenté  $\xi$  et le vecteur de poids de chaque neurone;
4. Choisir le neurone  $k$  ayant la distance la plus petite;
5. Mettre à jours les vecteurs de pondération de tous les neurones  $i$  de la carte de Kohonen selon l'équation :

$$w_i \leftarrow w_i + \eta \delta(i, k) (\xi - w_i) \quad (2.17)$$

6. Réduire la taille du voisinage et reprendre l'apprentissage du vecteur des pondérations.


La différence majeure entre ce réseau et de nombreux autres réseaux est que la carte auto-organisatrice apprend en mode non supervisé. Cependant, lorsque la topologie est combinée avec d'autres couches neuronales pour la prédiction ou la catégorisation, le réseau apprend d'abord de manière non supervisée puis bascule vers un mode supervisé (Anderson et McNeill, 1992).

L'originalité de la carte auto-organisatrice de Kohonen réside dans l'utilisation d'une fonction de voisinage. Ce principe est tellement intéressant qu'il a été repris dans le développement de nouveaux réseaux. Les propriétés essentielles de ces réseaux sont leurs interprétations géométriques; ils sont reconnus pour leur aptitude à traiter des grandeurs topologiques. L'inconvénient majeur des cartes auto-organisatrices de Kohonen provient du long temps exigé pendant la procédure d'apprentissage.

## 2.14 Le réseau de Hopfield

Les réseaux de Hopfield sont des réseaux récurrents et entièrement connectés. Présenté en 1982, ce réseau opère comme une *Mémoire Associative* non-linéaire qui a la capacité de discerner un objet stocké dans un espace de données. Chaque information mémorisée représente un point stable de l'espace d'état vers lequel l'évolution du système aboutit à partir d'un point initial voisin correspondant à une version déformée de l'information mémorisée. Les réseaux de Hopfield sont considérés comme des réseaux totalement connectés et il n'y a aucune différenciation entre les neurones d'entrée et de sortie (Davallo et Naim, 1989).

Le réseau de Hopfield est constitué d'un ensemble de neurones qui effectuent une somme pondérée de toutes les entrées et d'une fonction d'activation à seuil. Le réseau est complètement connecté par l'entremise de liens symétriques entre neurones; i.e. le poids  $w_{ij}$  de la connexion entre le neurone  $i$  et le neurone  $j$  est identique à  $w_{ji}$ , poids de la connexion entre les neurones  $j$  et  $i$ . L'architecture du réseau est telle que chaque neurone est connecté à tous les autres sauf à lui-même. La Figure 2.13 montre l'organisation d'un réseau de Hopfield possédant  $n$  cellules (Zwinglestein, 1995). Les différents poids  $w_{ij}$  identifient les sorties des cellules à prendre en compte.



**Figure 2.13** - Connexion des neurones dans un réseau de Hopfield

Les connexions entre les neurones d'un réseau à  $n$  cellules peuvent être représentées par une matrice  $n \times n$  :

$$w = \begin{bmatrix} 0 & w_{12} & \dots & w_{1n} \\ w_{21} & 0 & \dots & w_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ w_{n1} & w_{n2} & \dots & 0 \end{bmatrix} \quad (2.18)$$

où  $w_{ij}$  représente le poids de la connexion reliant le neurone  $j$  au neurone  $i$ . L'évolution de l'état  $u_i$  de chaque cellule  $i$  est donnée par la relation suivante :

$$u_i = \text{sgn}(\sum_j w_{ij} u_j - \theta_i) \quad (2.19)$$

$\theta_i$  le seuil du neurone  $i$  et  $\text{sgn}$  est la fonction *signe* définie par :

$$\text{sgn}(x) = \begin{cases} +1, & x \geq 0 \\ -1, & x < 0 \end{cases} \quad (2.20)$$

Tout le problème consiste donc à déterminer, s'il existe, l'ensemble des poids  $w_{ij}$  qui permettent au réseau de se comporter comme une mémoire adressée par le contenu. Une condition nécessaire de convergence du réseau de Hopfield vers un état stable est que la matrice des poids des connexions  $w$  (équation 2.18) soit symétrique et de diagonale égale à zéro (Hopfield, 1982). La particularité du réseau de Hopfield est que son évolution vers un état stable est caractérisée par une fonction  $\psi(u)$  appelée *fonction d'énergie*. La valeur de cette fonction d'énergie dépend du vecteur d'états  $u$  des neurones et de la matrice  $w$  :

$$\psi(u) = -\frac{1}{2} u w u^t + \theta u^t \quad (2.21)$$

En développant cette expression, on obtient:

$$\psi(u) = -\frac{1}{2} \sum_{j=1}^n \sum_{i=1}^n w_{ij} u_i u_j + \sum_{i=1}^n \theta_i u_i \quad (2.22)$$

Le réseau de Hopfield converge vers un des états stables correspondant à un minimum local de la fonction d'énergie  $\psi(u)$  (Rojas, 1996). Afin de définir les états stables à mémoriser par le réseau, il faut trouver la matrice des poids  $w$  qui minimise la fonction d'énergie (Zemouri, 2003). Les principales difficultés du réseau de Hopfield sont les états stables indésirables et les oublis catastrophiques (Zwinglestein, 1995).

## 2.15 Réseaux de neurones et diagnostic

Les réseaux de neurones constituent aujourd'hui indéniablement une approche importante de la détection et du diagnostic des défauts. Deux caractéristiques des réseaux neuronaux les rendent particulièrement intéressants, même si la dernière n'est pas toujours favorablement exploitée: ils sont adaptatifs et massivement parallèles. Les modèles neuronaux les plus

efficaces sont des systèmes non linéaires. La non-linéarité, qui est à l'origine de la puissance de ces systèmes, constitue l'obstacle principal pour l'apprentissage et pour l'interprétation des résultats.

Nous présentons dans cette partie une liste non exhaustive de quelques travaux sur les applications des réseaux de neurones artificiels en détection et diagnostic des défauts. D'autres références non citées dans cette partie peuvent être trouvées dans (Koivo, 1994; Bernauer, 1996; Dubuisson, 2001; Korbicz et al., 2004; Severson, 2016; Sahu et Palei, 2020).

Un perceptron multicouche a été utilisé pour détecter les fuites dans un entraînement de vérin électro-hydraulique dans un système hydraulique (Watton et Pham, 1997). Les auteurs ont montré que les informations de maintenance peuvent être obtenues à partir des données surveillées en utilisant des réseaux neuronaux au lieu d'un opérateur humain.

Crowther et al. (1998) ont présenté l'application des réseaux de neurones au diagnostic de pannes des actionneurs hydrauliques. Ils ont montré que les défauts expérimentaux peuvent être diagnostiqués par des réseaux de neurones formés uniquement sur des données de simulation.

À leur tour, Weerasinghe et al. (1998) ont étudié l'application d'un réseau neuronal unique au diagnostic de défauts non catastrophiques dans une usine de traitement nucléaire industrielle travaillant à différents points de fonctionnement.

Les réseaux de neurones dynamiques ont été appliqués à une détection de défauts en ligne des systèmes électriques (Korbicz et al., 1998).

Wang et Too (2002) ont appliqué les réseaux de neurones non supervisés, la carte auto-organisatrice (SOM) et la quantification vectorielle d'apprentissage à la détection de défauts des machines tournantes.

Sohn et al. (2002) ont utilisé un réseau neuronal auto-associatif pour séparer l'effet des dommages sur les caractéristiques extraites de ceux causés par les variations environnementales et vibratoires du système. Ensuite, un test de rapport de probabilité séquentiel a été effectué sur les caractéristiques normalisées pour la classification des dommages.

Zhou et al. (2003) ont discuté des méthodes de diagnostic des défauts pour deux procédés chimiques spéciaux. Dans cette recherche, ils ont d'abord analysé l'erreur de prédiction des modèles du réseaux de neurones pour le diagnostic de défauts de capteurs ou de composants, puis ils ont utilisé les réseaux de neurones RBF pour l'isolation des défauts. Afin d'évaluer les performances des modèles neuronaux, deux processus chimiques ont été utilisé comme exemple d'application.

Pirdashti et al. (2013) ont passé en revue l'architecture des modèles de réseaux neuronaux et leurs méthodes de développement, ainsi que les applications des réseaux de neurones dans différents domaines du génie chimique, tels que la modélisation directe de réseaux neuronaux, les capteurs logiciels, le contrôle de processus, la surveillance de processus et la détection de défauts. Par exemple, dans les applications de reconnaissance de formes, plusieurs types de réseaux de neurones ont été utilisés, tels que les réseaux RBF et les cartes auto-organisées (SOM).



Heo et Lee (2018) ont appliqué les réseaux de neurones profonds au problème de la détection et de la classification des défauts. Dans le cas de la détection de défaut, ils ont étudié les effets du nombre de couche cachée et du nombre de neurones dans la dernière couche cachée, sur les performances des réseaux. Ensuite, ils ont montré que l'augmentation des données peut être une clé pour augmenter encore la précision de détection des défauts, et cela s'est également avéré bénéfique pour le cas de classification des défauts.

Namigtle-Jiménez et al. (2019) ont formulé et appliqué expérimentalement un schéma de détection et de diagnostic de défauts pour isoler l'injecteur endommagé d'un moteur à combustion interne. L'arrangement du schéma se compose de trois réseaux neuronaux couplés pour classer correctement l'injecteur défectueux. Les réseaux de neurones ont été formés en considérant cinq scénarios différents, un scénario sans défaut dans le système d'injection et les quatre autres scénarios représentent un défaut par injecteur. Différents algorithmes d'apprentissage ont été testés afin de sélectionner le meilleur algorithme pour classer les défauts.


Ce que l'on peut retenir de cet état de l'art est que les réseaux de neurones sont utilisés comme outil principal de détection et du diagnostic, en l'occurrence tous les travaux de classification. Les réseaux de neurones peuvent fournir, dans certains cas, des solutions plus intéressantes que les autres outils de diagnostic des défauts, à condition de choisir judicieusement la structure du réseau neuronal, la fonction d'activation et surtout de bien mener le processus d'apprentissage.

Plusieurs avantages peuvent être attribuer à une application de diagnostic des défauts par réseaux de neurones, à savoir:

- la modélisation et l'estimation de fonctions non linéaires par apprentissage;
- le parallélisme et fusion de données;
- le pouvoir de généralisation.

## 2.16 Exemple

Afin de comparer les performances d'apprentissage des différents algorithmes à rétro-propagation, nous considérons un exemple pédagogique, le moteur à courant continu (MCC) qui entraîne un système industriel, illustré par la Figure 2.14.



**Figure 2.14** - Modèle du moteur à courant continu à aimant permanent

### 2.16.1 Principe du diagnostic

Le principe du diagnostic de cet exemple réside dans le fait que seules les grandeurs d'alimentation du moteur qui sont accessibles et facilement mesurables, i.e. le courant et la vitesse, seront utilisées pour élaborer les signatures qualifiant les modes de fonctionnement du système (Figure 2.15). Nous allons dans un premier temps définir les grandeurs qui permettent de caractériser aux mieux les modes de fonctionnement, tout en tenant compte des exigences préalablement fixées.

Notre choix c'est arrêté sur le courant et la vitesse du moteur à courant continu, car les variations de ces grandeurs comportent des informations fiables et crédibles permettant de réaliser le diagnostic en ligne d'un tel système. Il est donc nécessaire de dresser un modèle d'état du moteur à courant continu. Celui-ci nous permettra de créer une base d'apprentissage du réseau de neurones.




Figure 2.15 - Schéma de principe du diagnostic

### 2.16.2 Modèle d'état du moteur à courant continu

Conformément aux hypothèses classiques utilisées pour sa modélisation (Fouille, 1986), les équations mathématiques d'une machine à courant continu sont les suivantes:

$$\begin{cases} V(t) = R i(t) + L \frac{di(t)}{dt} + e \\ J \frac{d\omega(t)}{dt} + f\omega(t) = C_e - C_r \\ e = K_e \omega(t) \\ C_e = K_c i(t) \end{cases} \quad (2.23)$$

Où  $\omega(t)$  est la vitesse de rotation du moteur [ $\text{rad s}^{-1}$ ];  $R$  la résistance de l'induit [ $\Omega$ ];  $L$  son inductance [ $\text{H}$ ];  $V(t)$  la tension d'alimentation [ $\text{V}$ ];  $i(t)$  le courant d'induit [ $\text{A}$ ];  $C_r$  le couple de charge [ $\text{Nm}$ ];  $J$  le moment d'inertie de la partie tournante [ $\text{kg m}^2$ ];  $K_e$  et  $K_c$  sont respectivement les constantes de FEM (*Force Electro-Motrice*) et du couple [ $\text{V s rad}^{-1}$ ] et  $f$  le coefficient de frottement visqueux [ $\text{Nms rad}^{-1}$ ]. Les paramètres du modèle, du moteur à courant continu seront présentés en [Annexe B](#).

### 2.16.3 Architecture du réseau de neurones

Le réseau employé, dans cette application est du type réseau de neurones *feedforward* avec une couche cachée, deux entrées qui sont la vitesse  $\omega(t)$  et le courant  $i(t)$  et trois sorties représentant respectivement, la variation du moment d'inertie des parties tournantes du système, la variation de la résistance de l'induit du moteur et la classe de défaut correspondante. Le nombre de neurones de couche cachée pour minimiser l'erreur SSE (*Sum Squard Error*) a été choisi en utilisant simple essai-erreur (08, 12, 15). L'architecture optimale en terme de temps d'exécution est celle comprenant une couche cachée avec 8 neurones.

### 2.16.4 Base d'apprentissage

La base d'apprentissage du réseau constituée des entrées (*inputs*) et des cibles (*targets*) est obtenue en faisant varier séparément et simultanément les paramètres suivants :

- La résistance propre de l'induit de la machine;
- Le moment d'inertie des masses tournantes du système;
- Les sorties désirées (cibles) correspondent aux anomalies ( $\Delta J$  : variation du moment d'inertie,  $\Delta R$  : variation de la résistance) et à la classe de fonctionnement du système.

### 2.16.5 Apprentissage du réseau

Le réseau de neurones ainsi construit est entraîné durant l'apprentissage par quelques variantes de l'algorithme à rétropropagation (défini plus haut dans ce chapitre). L'initialisation des poids de connexion est effectué aléatoirement dans l'intervalle  $[-0.1, 0.1]$  et celle des biais du réseau est également réalisée de manière aléatoire. La fonction d'activation utilisée pour les neurones de la couche cachée est la fonction tangente sigmoïde (*tang-sigmoïde*) et celle associée aux neurones de la couche de sortie est du type linéaire.

La [Figure 2.16](#) représente la délimitation des différentes classes de fonctionnement considérées dans notre première application.

- 1° classe : Bon fonctionnement (fonctionnement normal);
- 2° classe : Fonctionnement critique;
- 3° classe : Mauvais fonctionnement (panne).

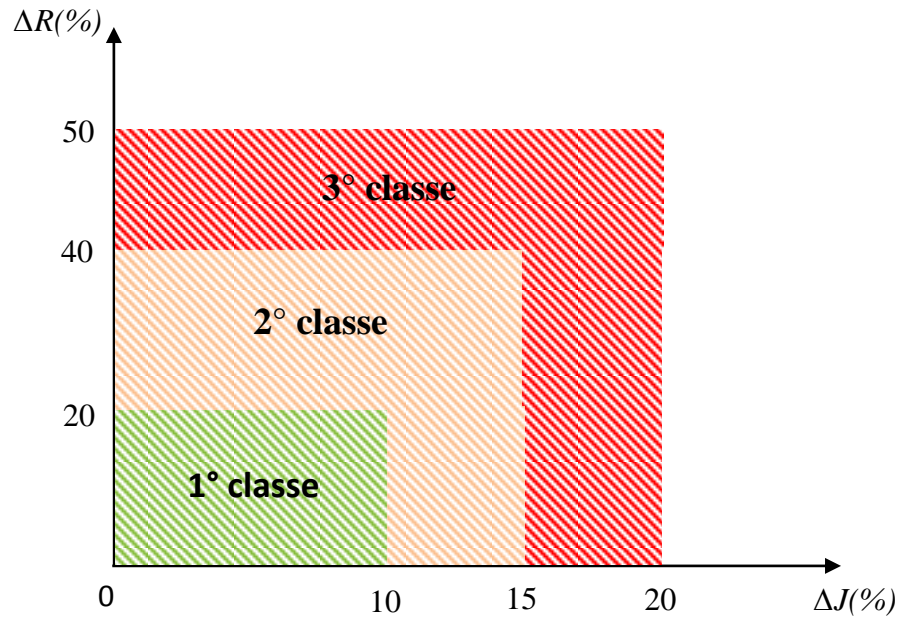


Figure 2.16 - Représentation des classes de fonctionnement

### 2.16.6 Algorithmes d'apprentissage appliqués au réseau

Les algorithmes d'apprentissage à rétropropagation du gradient utilisés :

- Descente de gradient par paquet (TRAINGD);
- Descente de gradient par paquet avec moment (TRAINGDM);
- Descente de gradient par paquet à taux variable (TRAINGDA);
- Descente de gradient par paquet à taux variable avec moment (TRAINGDX);
- L'algorithme quasi-newtonien (TRAINBFG);
- L'algorithme quasi-newtonien de Levenberg-Marquardt (TRAINLM).

### 2.16.7 Résultats de simulations

Toutes les étapes de traitement détaillées dans cet exemple sont présentées successivement (Figure 2.16). La première classe de bon fonctionnement est délimitée par le couple ( $\Delta J=10\%$ ,  $\Delta R=20\%$ ), la base de données de la deuxième classe de fonctionnement critique est définie par le couple ( $10\% < \Delta J \leq 15\%$ ,  $20\% < \Delta R \leq 40\%$ ) et la troisième classe de mauvais fonctionnement (ou panne) est constitué de ( $15\% < \Delta J \leq 20\%$ ,  $40\% < \Delta R \leq 50\%$ ).

Les résultats d'apprentissage de l'algorithme TRAINLM sont présentés sur le Tableau 2.4. Les résultats d'apprentissage des algorithmes TRAINGD, TRAINGDM, TRAINGDA, TRAINGDX, TRAINBFG seront présentés en Annexe B.

$\Delta J$ cibles (%)	$\Delta J$ obtenue (%)	$\Delta R$ cibles (%)	$\Delta R$ obtenue (%)	Classes cibles	Classes obtenues	Temps d'exécution (s)
0	-0.0042	0	0.4716	1	0.9845	07.500
10	9.9200	0	0.1225	1	1.0233	
15	15.1628	0	-0.2547	2	1.9536	
20	19.8254	0	-0.0394	3	2.9933	
0	0.0702	20	20.2567	1	0.9635	
0	0.3555	40	39.7163	2	2.0563	
0	0.0894	50	49.9632	3	2.9630	
10	9.8731	20	19.7569	1	0.9607	
15	14.9582	40	40.4503	2	2.0082	
20	20.0279	50	49.6747	3	2.9767	
5	4.8522	10	9.0504	1	0.9712	
5	4.5590	30	29.4629	2	1.9843	
10	10.3462	30	30.3997	2	1.9890	
5	5.0972	20	20.2317	1	1.0788	
5	4.9024	40	39.8528	2	1.9199	
5	4.7744	50	50.2235	3	3.0013	
10	9.9325	40	40.1913	2	2.0331	
10	9.9081	50	50.2172	3	3.0500	
15	15.1938	50	49.9666	3	2.9859	

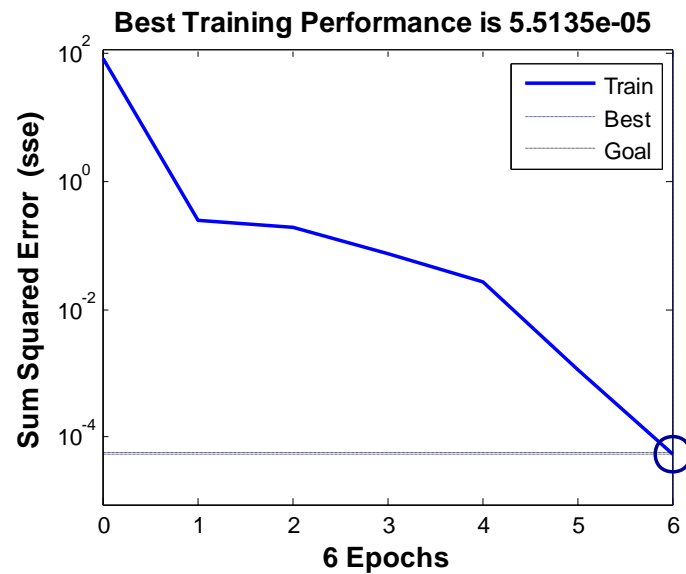
**Tableau 2.4** - Résultats d'apprentissage de l'algorithme TRAINLM

Le **Tableau 2.5** présente les résultats de généralisation correspondant à l'algorithme Trainlm.

$\Delta J$ test (%)	$\Delta J$ test obtenu (%)	$\Delta R$ test (%)	$\Delta R$ test obtenu (%)	Classes test	Classes test obtenues
0	- 0.0042	0	0.4716	1	0.9845
5	4.8884	25	24.8149	2	1.3768
13	13.2963	48	48.1087	3	2.5932
12	12.3175	48	48.1494	3	2.5958
12	12.2315	32	32.2033	2	1.9382
5	5.0176	21	21.2760	2	1.3626

**Tableau 2.5** - Résultats de généralisation

La **Figure 2.17** illustre la performance d'apprentissage par l'algorithme TRAINLM, avec une erreur désirée de ( $10^{-5}$ ). Les figures de la performance d'apprentissage des algorithmes TRAINGD, TRAINGDM, TRAINGDA, TRAINGDX, TRAINBFG seront présentés en **Annexe B**.



**Figure 2.17** - Représentation de la performance d'apprentissage par l'algorithme TRAINLM

### 2.16.8 Comparaison des résultats

Dans cette section, nous comparons les résultats d'apprentissage et de généralisation des divers algorithmes entraînés en termes de précision et du temps de calcul. Pour chaque type de base d'apprentissage et chaque algorithme, ces valeurs présentent le meilleur résultat de plusieurs essais sur la même base d'apprentissage. Le nombre d'essais réalisé pour chaque base d'apprentissage dépend de l'algorithme et du type de la base utilisée. Toutes les simulations ont été réalisées dans un même environnement MATLAB. Cet exemple nous a permis d'aborder l'application du diagnostic des défauts par réseaux de neurones à un système entraîné par un moteur à courant continu.

L'utilisation de la rétropropagation pose de nombreux problèmes. Une des limitations importantes est le temps de calcul : dans notre exemple l'apprentissage est très long notamment dans le cas des algorithmes TRAINGDM, TRAINGD et TRAINBFG. L'apprentissage par les algorithmes TRAINGDA et TRAINGDX est moins long que les autres, mais il est toujours moins rapide que l'apprentissage par l'algorithme TRAINLM qui présente une meilleure rapidité par rapport aux autres algorithmes. Le temps de calcul des algorithmes TRAINGDA et TRAINGDX croît de manière très importante avec le nombre de vecteurs d'entrée; le TRAINLM aussi mais de manière moins significative ce qui est dû au calcul du Hessien qui nécessite un espace mémoire supérieur aux autres algorithmes. Les résultats d'apprentissage de l'algorithme TRAINLM sont acceptables alors que les résultats de généralisation sont moins satisfaisants. De nombreux problèmes sont dus à la géométrie de la fonction d'erreur: minima locaux, un problème qui est en partie résolu avec le gradient stochastique, mais il subsiste quand même. L'algorithme à rétropropagation est très sensible aux conditions initiales, c'est à dire à la manière dont sont initialisés les poids du réseau. Les classes de fonctionnement, dans les algorithmes à rétropropagation, ne sont pas délimitées de manière parfaitement exacte, ce qui engendre une mauvaise classification pour les vecteurs

appartenant à deux classes différentes mais qui se rapprochent de l'espace de séparation de ces deux classes.

Le problème le plus important est celui du dimensionnement du réseau, la rétropropagation apprend une base d'apprentissage sur un réseau dont la structure est fixée *a priori*. Il s'agit donc de définir cette structure en fonction de la base d'apprentissage à apprendre. C'est un problème extrêmement difficile qui n'a pas de solutions pertinentes. De plus, une mauvaise structure dégrade considérablement les performances du réseau. S'il est sous-dimensionné, l'algorithme n'arrivera pas à apprendre. S'il est surdimensionné, la base d'apprentissage sera apprise mais ses performances en généralisation seront faibles, car le nombre de paramètres libres du réseau étant trop grand, la base d'apprentissage sera apprise *par cœur*.

La comparaison des différents algorithmes à rétropropagation a montré que l'algorithme de Levenberg Marquard donne un résultat meilleur par rapport aux autres algorithmes entraînés, en plus de sa rapidité de réponse. C'est ce qui justifie le choix d'utilisation de cet algorithme dans notre application industrielle qui fera l'objet du chapitre 4.

## 2.17 Conclusion

Dans ce chapitre, nous avons présenté les bases nécessaires à la compréhension des réseaux de neurones artificiels. Après avoir introduit leurs concepts de base, nous avons présenté l'application des réseaux de neurones pour le diagnostic industriel. En introduisant les réseaux de neurones artificiels, ce chapitre a permis de fournir une perception globale du problème et des mécanismes d'apprentissage. La principale caractéristique des réseaux de neurones est leurs facultés d'adaptation et de mémorisation. Sans connaissance préalable et au fur et à mesure que leur sont fournis des exemples, les réseaux de neurones se forgent un modèle de connaissance. Toute cette capacité d'assimilation des exemples réside dans la possibilité d'adapter les vecteurs des poids synaptiques.

Les réseaux de neurones, de part la quantité des travaux de recherche et des réalisations existantes, présentent plusieurs points forts. En premier lieu, ils constituent des approximateurs universels capables de modéliser des systèmes complexes avec la précision voulue à partir d'un jeu de données entrées /sorties et un processus d'optimisation. Dans le cas de systèmes complexes, leur capacité d'apprentissage représente un avantage indéniable par rapport à la plupart des autres méthodes qui s'attachent à utiliser un modèle mathématique souvent imprécis ou difficile à obtenir. Cependant, l'inconvénient majeur réside dans le fait que l'on ne peut pas incorporer les connaissances des experts, qualifiées d'une certaine intelligence, et qui peuvent être utiles soit pour accélérer le processus d'apprentissage, soit pour obtenir des structures interprétables.

L'usage des réseaux de neurones artificiels d'un point de vue méthodologique, n'est pas toujours simple. La difficulté réside dans le fait que les dimensions d'un réseau dépendent fortement de la nature ou de la complexité du système à traiter. La taille d'un réseau a une influence sur la convergence. Avec des paramètres adaptés au problème à traiter, les réseaux de neurones permettent souvent d'atteindre, et en apprentissage et en généralisation, des taux de succès supérieurs à d'autres méthodes, qu'elles soient statistiques ou analytiques. En fait,

pour la mise en œuvre d'un réseau de neurones, on cherchera à utiliser au maximum des connaissances disponibles sur le système malgré que les modèles neuronaux soient doués de capacités d'apprentissage. Enfin, le choix de l'architecture de réseau de neurones ainsi que le choix des fonctions d'activations sont parmi les facteurs fondamentaux de la réussite d'une application basée sur les réseaux de neurones.

Le PMC et les RBF sont deux bonnes architectures neuronales utilisées massivement dans le domaine de diagnostic de défauts, leur avantage réside dans leur capacité d'apprentissage, ainsi que la capacité de résoudre les problèmes de classification non linéaire.

Le chapitre suivant a pour objet de présenter la méthodologie de diagnostic proposée, basée sur l'analyse HAZOP et les réseaux de neurones.



*”Le courage est un juste milieu entre la crainte et la témérité.”*

*Aristote*

## Chapitre 3: Approche de diagnostic proposée

---

### 3.1 Introduction

Les systèmes industriels sont de plus en plus complexes et doivent relever des défis majeurs en termes de fiabilité afin de garantir leur bon fonctionnement (Dai et Gao, 2013; Cai et al., 2016). Quelles que soient leurs performances, ces systèmes sont appelés systèmes tolérants aux pannes (Li et al., 2016; Shu et al., 2017). Pour anticiper ces pannes techniques, le diagnostic a pour rôle en premier lieu de détecter et localiser les défaillances susceptibles de générer les pannes des installations industrielles (Kleer et Williams, 1987; Franceschini et al., 2013). Par conséquent, le diagnostic joue un rôle clé en contribuant à la détection précoce des défauts afin de garantir la fiabilité et la sécurité des processus et d'assurer des gains en termes de disponibilité et de productivité tout en réduisant le niveau de capital investi dans les systèmes de production (Das et al., 2012). Au cours des dernières années, de nombreux chercheurs se sont concentrés sur les approches de surveillance des processus et de diagnostic des défauts (Shah, 2011; Wong et al., 2014; Wang et al., 2014; Yin et al., 2014; Ding, 2014; Hu et al., 2015; Zhang et Geng, 2015; Vileiniskis et al., 2016; Shu et al., 2017). Diverses techniques de surveillance des processus et de diagnostic des défauts ont été développées comme nous l'avons vu au chapitre 1, telles que les techniques basées sur des modèles mathématiques et les techniques basées sur la connaissance et les données. Cependant, l'application des approches basées sur les modèles mathématiques sont également limitées car un modèle mathématique précis est difficile à réaliser ou peut même ne pas être disponible pour certains processus industriels complexes. Avec les progrès du contrôle informatique et de l'intelligence artificielle, des approches basées sur les données et les connaissances ont été développées ces dernières années. Ces approches sont construites sur la base des informations historiques des variables de processus et des connaissances a priori, respectivement. Ces approches sont largement appliquées dans la surveillance des processus et le diagnostic des défauts dans les usines industrielles (Zhang et al., 2014).

Les réseaux de neurones sont une des techniques basées sur les connaissances, ils sont largement utilisés dans la reconnaissance de formes et la classification d'un système complexe non linéaire en raison de leur forte capacité d'auto-apprentissage et de leur modélisation non linéaire. Les réseaux de neurones occupent une place importante dans le diagnostic et la littérature spécifiée dans ce domaine est riche en études consacrées aux réseaux de neurones (Guh, 2002; Subhasis et al., 2005; Sukthomya et Tannock, 2005; Guo, 2010; Zhang et al., 2014; Fentaye et al., 2018). Ces derniers ont de plus en plus de succès et prouvent leur efficacité dans plusieurs domaines tels que le traitement du signal, le contrôle de processus, l'estimation et la détection et le diagnostic de défauts. Différents modèles des réseaux neuronaux sont développés en fonction des problèmes et applications où ils sont utilisés. Dans cette étude, trois types de modèles à savoir, le perceptron multi couches (*MLP*), les réseaux à fonctions de base radiales (*RBF*) et les réseaux de neurones de régression généralisée (*GRNN*) sont utilisés et évalués sur leur performance et leur commodité. Ces trois modèles ont été pleinement utilisés avec succès dans de nombreuses études dans le domaine du diagnostic des défauts.

Les méthodes d'analyse des risques telles que l'Analyse des Modes de Défaillance, de leurs Effets et de leur Criticité (*AMDEC*), Hazard and Operability (*HAZOP*), Arbres de

Défaillances (*AdD*),..., permettent la résolution des problèmes de diagnostic de défauts. Le principe de ces méthodes consiste à établir a priori et de manière formelle les liens entre les causes et leurs effets mesurables par les opérateurs ou les systèmes de traitement de l'information. Dans notre étude, nous avons opté pour l'analyse HAZOP. Cette méthode est de même type que l'AMDE, mais elle est mieux adaptée pour l'analyse des circuits thermo-hydrauliques. Elle a pour objectif l'identification des risques et l'étude de leur prévention/protection en s'appuyant sur un modèle entité/flux physique du système, et en étudiant chacune des déviations possibles. Dans un objectif de diagnostic HAZOP est donc utilisée de façon déductive i.e. que l'on part des effets observés pour remonter aux causes de déviations possibles. Cette approche est très efficace grâce à ses relations de causes à effets. Dans notre étude les résultats de l'analyse HAZOP seront pris en compte en tant que connaissances expertes du système étudié et puis utilisées comme base de données pour le réseaux de neurones.

Ce chapitre, a pour objectif de présenter la méthodologie proposée pour le diagnostic des défauts basée sur l'analyse HAZOP et les réseaux de neurones. Avant d'aborder l'approche proposée, nous rappelons quelques définitions fondamentales relatives à la méthode HAZOP, ensuite nous présentons l'apport de cette méthode et des réseaux de neurones pour le diagnostic de défauts. Ensuite, nous montrons à travers l'exemple présenté au chapitre deux, la possibilité de combiner la méthode d'analyse AMDE et les réseaux de neurones.

## 3.2 Notions de base relatives à la méthode HAZOP

### 3.2.1 Historique et domaine d'application

L'analyse de danger et d'opérabilité (*HAZOP pour HAZard and OPerability*) a été initialement développée au début des années 1970 par la société Imperial Chemical Industries (ICI) (Lawley, 1974; Lawley, 1976), l'une des plus grosses entreprises de l'industrie chimique au monde, qui a décidé d'améliorer les performances de ses processus et la sécurité de ses installations. Pour ce faire, la méthode HAZOP a été mise au point. Son objectif est d'identifier l'ensemble des dangers et des risques pouvant menacer un site industriel afin de pouvoir éviter tout événement indésirable. Cette méthode est utilisée pour l'examen de systèmes thermo-hydrauliques pour lesquels des paramètres comme le débit, la température, la pression, le niveau, la concentration sont particulièrement importants pour la sécurité de l'installation. Elle a fait l'objet d'une norme IEC61882 (2001) et est largement utilisée aujourd'hui. Son succès tient à sa simplicité et à la possibilité de réaliser des HAZOP très tôt dans le processus de développement. Elle a également comme avantage d'être adaptable au formalisme utilisé pour décrire un système. Cette technique s'est développée hors des limites de la société ICI, au sein de l'industrie chimique et pétrochimique après l'explosion catastrophique en 1974, d'un nuage de 40 tonnes de cyclohexane à Flux borough en Grande-Bretagne qui a fait 28 morts et 89 blessés. De simple technique, la méthode HAZOP est devenue une pratique d'identification des dangers et des problèmes d'exploitabilité, adoptée par de nombreuses industries à risques (notamment dans la chimie et la pétrochimie, le nucléaire ou encore les transports).

### 3.2.2 Principe et déroulement

La méthode HAZOP (IEC61882, 2001), est une technique structurée et systématique qui fournit une identification des événements accidentels et des problèmes d'opérabilité à l'aide de séquences logiques de cause-déviations-conséquence des paramètres de processus (Srinivasan et Venkatasubramanian, 1998; Dunj3 et al., 2010; Guo et Kang, 2015b; O Herrera, 2018; Marhaviilas et al., 2019). Ce type d'analyse est généralement réalisé par une équipe multidisciplinaire d'experts dont les connaissances doivent couvrir suffisamment le système et ses applications (Guo et Kang, 2015a) et à qui revient la responsabilité d'analyser et de concevoir les documents d'exploitation, tels que les diagrammes de tuyauterie et d'instrumentation (*P&ID pour Piping and Instrumentation Diagram*), les diagrammes de flux de processus (*PFID pour Process Flow Diagrams*), les diagrammes de flux de matériaux et les manuels d'exploitation (entre autres) décrivant le système sous étude (Kletz, 2009). Elle est dédiée à l'analyse des risques des systèmes thermo-hydrauliques pour lesquels il est indispensable de maîtriser des paramètres tels que la température, la vitesse, la pression, le débit, le niveau, la concentration, etc. (Tableau 3.1) mais également le temps ou des opérations à effectuer. HAZOP nécessite de la créativité afin d'imaginer les déviations possibles. Son principe est de décomposer un système donné en sous-systèmes appelés «nœuds» puis de faire varier les paramètres autour de ses consignes au moyen de mots clés (mots-guides) tels que:

<i>Exemples de paramètres</i>	
Température	Fréquence
Pression	Viscosité
Débit	Tension
Niveau	Information
Temps	Concentration
Composition	Propriétés physiques
Vitesse	Agitation

**Tableau 3.1** - Exemples de paramètres pour HAZOP

pas de, plus de, trop de, etc. pour s'assurer que tous les dangers et problèmes de fonctionnement possibles sont identifiés (Tableau 3.2). Les mots-guides, accolés aux paramètres importants pour le procédé, permettent de générer de manière systématique les dérives à considérer. La combinaison de ces paramètres avec les mots-guides permet donc de générer des dérives de ces paramètres comme par exemple:

- Plus de et Température = Température trop haute
- Moins de et Pression = Pression trop basse
- Inverse et Débit = Retour de produit
- Pas de et Niveau = Capacité vide

Type de déviation	Mot-Guide	Exemples d'interprétation
Négative	NE PAS FAIRE	Aucune partie de l'intention n'est remplie
Modification quantitative	PLUS	Augmentation quantitative
	MOINS	Diminution quantitative
Modification qualitative	EN PLUS DE	Présence d'impuretés-Exécution simultanée d'une autre opération/étape
	PARTIE DE	Une partie seulement de l'intention est réalisée
Substitution	INVERSE	S'applique à l'inversion de l'écoulement dans les canalisations ou à l'inversion des réactions chimiques
	AUTRE QUE	Un résultat différent de l'intention originale est obtenu
Temps	PLUS TOT	Un évènement se produit avant l'heure prévue
	PLUS TARD	Un évènement se produit après l'heure prévue
Ordre séquence	AVANT	Un évènement se produit trop tôt dans une séquence
	APRES	Un évènement se produit trop tard dans une séquence

**Tableau 3.2** - Exemples de mots-guides pour HAZOP extrait de IEC61882 (2001)

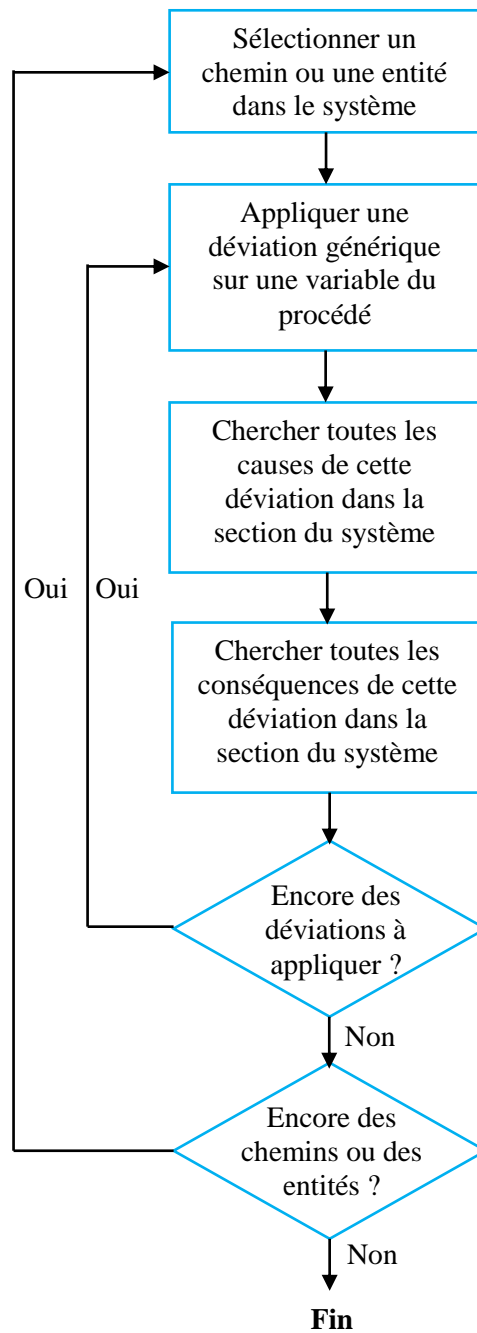
Les paramètres auxquels sont accolés les mots-guides dépendent bien sûr du système considéré. Généralement, l'ensemble des paramètres pouvant avoir une incidence sur la sécurité de l'installation doivent être sélectionnés. Une fois la déviation envisagée, l'analyste doit identifier les causes de cette déviation, puis les conséquences potentielles de cette déviation, ainsi que les moyens de détection et les actions correctrices possibles (Hoepffner, 1989). Les résultats de cette conjonction sont stockés dans une table nommée table de déviations, base indispensable pour la mise en place ultérieure des actions recommandées par le groupe de travail. Le Tableau 3.3 présente un exemple de table HAZOP, mais de nombreuses variantes existent à partir de cette base.

La méthode HAZOP originelle se limitait à l'identification des dangers elle ne fait appel qu'à des notions qualitatives. En revanche, la méthode HAZOP peut devenir «semi-quantitative» dès lors que l'on fait apparaître les notions de probabilité d'occurrence et de gravité des conséquences. Des descriptions détaillées de la procédure d'analyse HAZOP avec des exemples illustratifs sont données dans CCPS (1985), Knowlton (1989) et Kletz (1986).

N°	Déviation	Causes	Conséquences	Prévention Existante	Actions à prendre	Probabilité	Gravité

**Tableau 3.3** - Exemple de table HAZOP

La démarche générale de la méthode HAZOP est décrite par l'organigramme en Figure 3.1 (Froquet, 2005).



**Figure 3.1** - Organigramme d'analyse HAZOP

Le [Tableau 3.4](#) présente des exemples de déviations possibles avec les causes et conséquences possibles pour cinq paramètres de grandeurs physiques.

Paramètres	Température	Pression	Débit	Niveau	Concentration
Déviations possibles	Haute température Basse température Exothermie Endothermie Écart de température Erreur de mesure	Surpression Dépression Vide Pression atmosphérique Erreur de mesure	Débit élevé Débit réduit Débit nul Débit inverse Flux inattendu Erreur de mesure	Haut Bas Moussage Débordement Réacteur vide Erreur de mesure	Augmentation de concentration Dilution Présence d'impuretés
Causes possibles	Excès de chauffage Excès de refroidissement Défaut de chauffage Défaut de refroidissement Combustion Erreur opérateur	Perte de confinement Expansion Bouchage Erreur opérateur	Fuite Pollution Vanne ouverte Erreur opérateur	Ajout Soutirage Évaporation Cristallisation Erreur opérateur	Ajout Oubli d'ajout Fuite Erreur opérateur
Conséquences possibles	Inflammation Explosion Perte de confinement	Explosion Rejet toxique Implosion	Débordement Mélange Échauffement	Débordement Cavitation Dépression	Réaction parasite Emballement thermique Corrosion

Tableau 3.4 - Exemples de déviations, avec causes et conséquences possibles

### 3.3 Diagnostic par HAZOP

Un système qui comprend la capacité de détection et de diagnostic des défauts est appelé «système de diagnostic de défauts» comme nous l'avons vu au paragraphe 1.3 (Teodor et Letitia, 1997). Un tel système doit effectuer deux tâches, à savoir la détection des défauts et l'isolement. Le premier objectif est de reconnaître qu'une défaillance s'est produite dans le système, puis de la localiser. Le domaine de la sûreté de fonctionnement offre diverses méthodes facilitant le diagnostic des systèmes industriels. Cependant, il est important de tenir compte des exigences auxquelles doit répondre le système de diagnostic pour pouvoir garantir l'efficacité voulue. Parmi les méthodes de raisonnement qualitatif, l'analyse HAZOP est l'approche privilégiée dans l'industrie des procédés chimiques (Diego et al., 2001). Une analyse HAZOP permet d'identifier les modes de défaut et les variables de processus surveillées (Guo et Kang, 2015). Par conséquent, l'intégration des approches fondées sur l'analyse HAZOP est d'un grand intérêt en tant que solution intéressante pour l'analyse des risques et le diagnostic des défauts (Venkatasubramanian et al., 2000). Plusieurs travaux ont été développés ces dernières années portant sur cette approche (Yang et al., 2012; Wang et al., 2013; Baybutt, 2015; Giardina et Morale, 2015; Guo et Kang, 2015a). L'analyse HAZOP est également une méthode d'analyse bidirectionnelle. À chaque étape de l'analyse, une analyse bidirectionnelle est utilisée pour identifier les scénarios de danger comprenant les causes et les conséquences de chaque déviation. Les raisons qui pourraient causer l'événement anormal sont identifiées par une analyse inverse et les conséquences négatives sont également prédites par une analyse aval le long des scénarios de danger en fonction de chaque déviation des paramètres du processus. L'utilisation de l'analyse HAZOP à des fins de diagnostic des défauts conduit à utiliser une procédure déductive, i.e. utiliser HAZOP comme un outil d'identification des causes de déviations à partir des conséquences (effets) observées. La modélisation des relations cause à effet réalisée par HAZOP rend cette démarche très puissante pour la résolution des problèmes de diagnostic de défauts de processus industriels. Dans notre étude nous avons choisi d'utiliser la méthode HAZOP pour un diagnostic à base de réseaux de neurones. Les connaissances causales obtenus à partir de HAZOP sont utilisés

pour construire les modes de défaut qui composent la base de connaissances du système de diagnostic.

### 3.4 Diagnostic par réseaux de neurones

Leur faible sensibilité aux bruits de mesure, leur capacité à résoudre des problèmes non linéaires et multi-variables, à stocker les connaissances de manière compacte, à «apprendre» en ligne et en temps réel, sont des propriétés qui rendent l'utilisation des réseaux de neurones attrayante pour la détection et le diagnostic de défauts (Raudys, 2001).

Les réseaux de neurones artificiels ont fait l'objet d'un intérêt soutenu à cause de leurs caractéristiques d'apprentissage et leur capacité de généralisation. Comme il a été mentionné précédemment (voir chapitre 2), l'apprentissage des réseaux de neurones est une phase qui permet de déterminer ou de modifier les paramètres du réseau, afin d'adopter un comportement désiré, quant à la généralisation d'un réseaux de neurones c'est la capacité d'élargir ces connaissances acquises après apprentissage, à des données nouvellement rencontrées (phase de validation du réseaux). Le principe de base d'une telle technique de diagnostic à base de réseaux de neurones est de trouver une relation entre les variables d'entrée et les variables de sortie. Selon les variables d'entrées, le réseau de neurones donne une réponse caractérisée par les variables de sortie. Les variables de sortie caractérisent l'état de fonctionnement du système (fonctionnement normal ou pas). De nombreux travaux qui démontrent l'utilité des réseaux de neurones pour la détection et le diagnostic de défauts et pour la surveillance de processus complexes, ont été présenté au chapitre 2.

### 3.5 Approche de diagnostic proposée

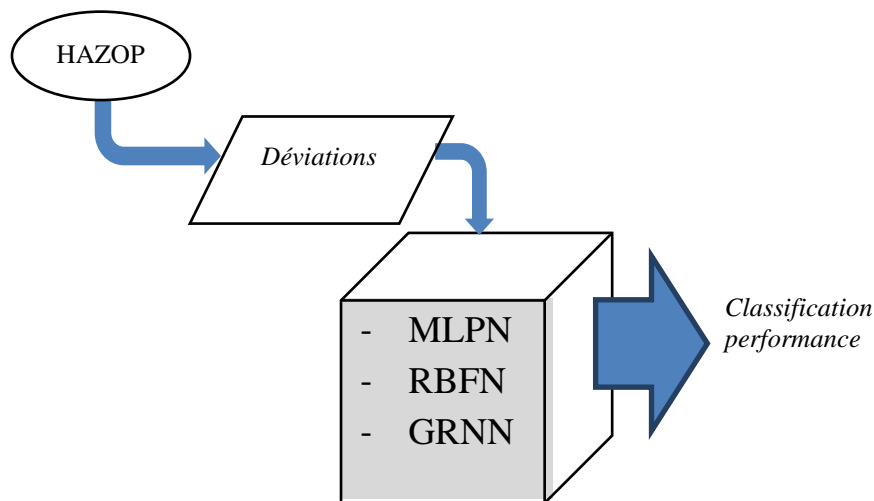
Tout système industriel est soumis à des défauts ou des défaillances. Les défauts, comme nous l'avons défini au paragraphe 1.2, peuvent se produire soit dans les capteurs, soit dans les actionneurs ou dans les composants du processus lui-même. Dans tous les cas sauf les plus insignifiants, l'existence d'un défaut peut conduire à des situations dégradées liées à la sécurité des personnes, à l'environnement, aux finances ou aux implications juridiques. Bien que les bonnes pratiques de conception tentent de minimiser l'occurrence des défauts et des pannes, la reconnaissance que de tels événements se produisent permet aux concepteurs de systèmes de développer des stratégies, afin de minimiser l'effet de ces événements. Le diagnostic des défauts devient une tâche cruciale lorsque l'opérateur n'est pas familiarisé avec ces systèmes et/ou a des difficultés à identifier l'état du système. Il est donc nécessaire de construire un système de diagnostic basé sur des connaissances structurées pour détecter et localiser tout défaut révélé.

L'approche hybride basée sur les techniques à base de connaissance (HAZOP, AMDEC, AdD,...) et les réseaux de neurones est largement utilisée dans le diagnostic des défauts soit pour identifier les causes et les conséquences des défauts sur le système globale, soit pour produire des modèles de diagnostic pour les systèmes industriels.



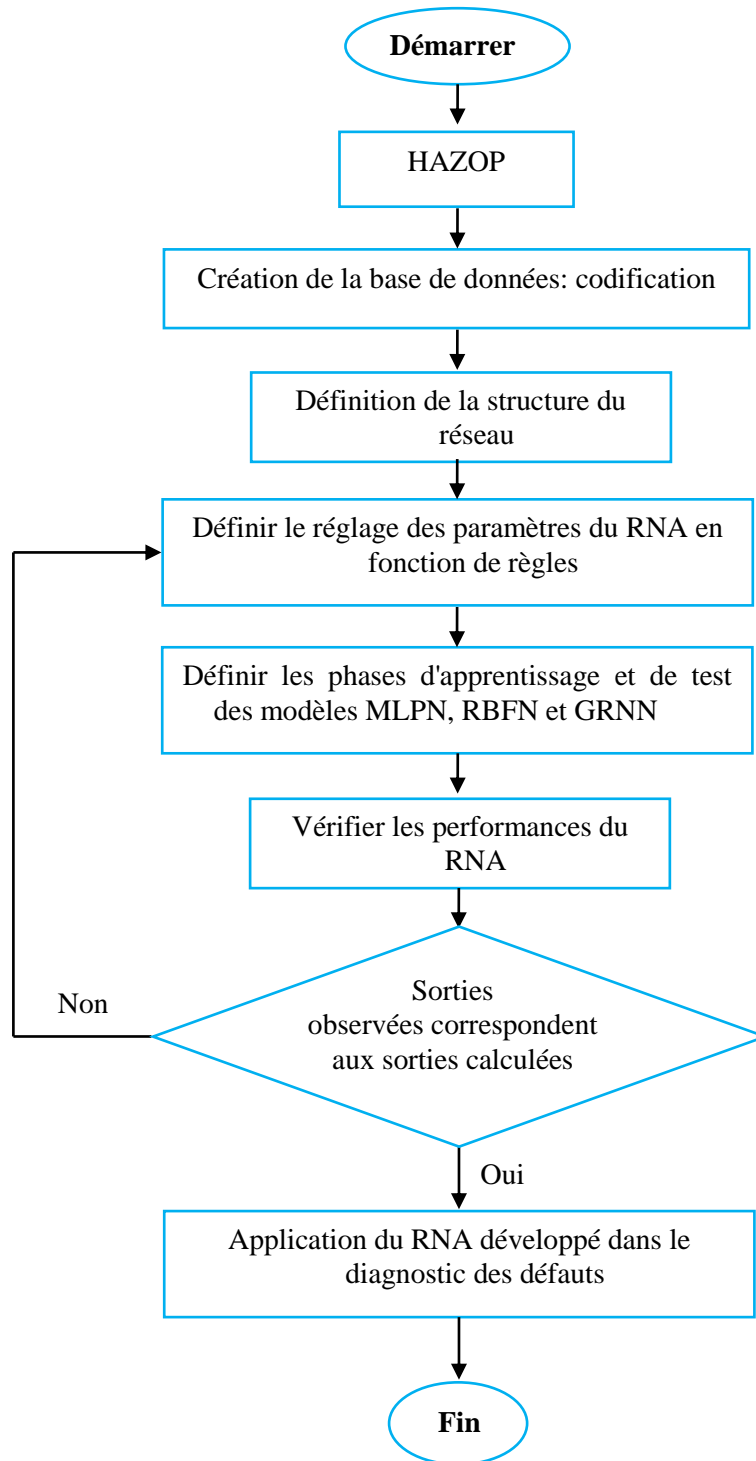
Dans cette étude, nous proposons une approche basée sur la combinaison de l'analyse HAZOP et des réseaux de neurones. Ces deux techniques sont combinées afin d'obtenir un modèle de diagnostic d'un système industriel. HAZOP est utilisée pour analyser les déviations des différents paramètres du système, les déviations obtenues à partir de cette analyse sont utilisées pour construire la base de connaissances du système de diagnostic. En effet, les données de départ sont extraites des résultats de l'analyse HAZOP, où seuls les déviations critiques sont retenues et associées à une base de règles initiale pour établir les relations de cause à effet entre les organes défaillants et les symptômes observés.

La méthodologie proposée pour la détection et le diagnostic des défauts, représentée sur la [Figure 3.2](#), est basée sur la combinaison de l'analyse HAZOP et des réseaux de neurones. Trois modèles neuronaux sont utilisés, à savoir: le MLP, le RBF et le GRNN. Une comparaison de la performance des trois modèles sera effectuée sous les mêmes données obtenues à partir des tables HAZOP, afin d'établir un modèle de diagnostic permettant la détection et la localisation en temps réel de tout défauts susceptibles d'affecter le système industriel.



**Figure 3.2** - Méthodologie adoptée pour l'étude comparative de trois modèles neuronaux (Chebira et al., 2020)

Les principales étapes et règles de la méthode proposée consiste en: l'identification des causes et des conséquences des déviations des paramètres du système par l'analyse HAZOP, l'apprentissage des trois modèles neuronaux, l'évaluation de la performance des modèles et le diagnostic des défauts ([Figure 3.3](#)). Ces étapes et règles sont décrites ci-dessous.



**Figure 3.3** - Organigramme des principales étapes de la méthode proposée

### 3.5.1 Identification des causes et conséquences - Analyse HAZOP

Cette première étape a pour objectif l'identification des dysfonctionnements pouvant affecter la mission d'un système industriel. En effet, l'identification des causes et des conséquences de défaillances qui peuvent conduire à des scénarios dangereux liés à un

système industriel, est réalisée à l'aide de la méthode HAZOP (IEC 61882, 2001; Giardina et Morale, 2015; Guo et Kang, 2015). Cette méthode est un outil puissant qui fournit une identification des événements accidentels et des problèmes d'opérabilité à l'aide de séquences logiques de cause-déviations-conséquence des paramètres du système.

### 3.5.2 Modèles neuronaux proposés

Différents modèles sont développés dans le domaine des réseaux de neurones en fonction des différents problèmes et applications où ils ont été utilisés. Dans cette étude, trois modèles différents de réseaux de neurones, à savoir le MLPN (*Multi-Layer Perceptron Network*), le RBFN (*Radial Basis Function Network*) et le GRNN (*Generalized Regression Neural Network*), sont utilisés et évalués sur leurs performances. Le [Tableau 3.5](#) présente les caractéristiques de ces trois modèles, en plus de quelques travaux de recherche liés aux domaines d'application de ces modèles.

<i>ANNs Models</i>	<i>Layer numbers</i>	<i>Transfer functions</i>	<i>Extract from application domains</i>	<i>Extract of references</i>
<i>MLPN</i>	- An input layer - One or more hidden layers - An output layer	- Hyperbolic - Tangent - Logistic function	- Pattern recognition - Classification - Function approximation - Fault diagnosis - Data compression	(Paya et al, 1997; Hagan and Menhaj, 1994; Zhou et al, 2003; Rumelhart et al, 1986; Bui et al., 2018)
<i>RBFN</i>	- An input layer - A hidden layer - An output layer	- Gaussian	- Classification - Pattern recognition - Image processing - Signal processing - Faults diagnosis	(Chang, 2013; Zhang et al, 2010; Yun et al, 2008; Vahed and Demirel, 2017)
<i>GRNN</i>	- An input layer - A pattern layer - A summation layer - An output layer	- Gaussian	- Regression - Prediction - Classification	(Kim et al, 2003; Ladlani et al, 2012; Huang et al., 2018)

**Tableau 3.5** - Caractéristiques des modèles MLPN, RBFN et GRNN (Chebira et al., 2020)

#### 3.5.2.1 Apprentissage du modèle MLPN

Dans le modèle MLPN, un algorithme d'apprentissage est nécessaire. Dans notre application nous avons opté pour l'algorithme de rétropropagation largement utilisé dans la littérature (Rumelhart et McClelland, 1986). Le principe de base de cette technique consiste à minimiser l'erreur entre la sortie calculée et celle désirée. Cet ajustement se fait en agissant directement sur les poids du réseau. L'algorithme de Levenberg-Marquardt (*LM*), est utilisé pour l'apprentissage, car il est plus puissant que les techniques classiques de descente de gradient en terme de performance, de rapidité de convergence et qu'il converge vers l'erreur la

plus faible (Hagan et Menhaj, 1994; Hagan et Demuth, 1995; Cigizoglu et Kişi, 2004; Esen et al., 2008a). L'algorithme de LM applique le Jacobien dans les calculs qui nécessitent l'utilisation de la moyenne ou de la somme des erreurs au carré comme indicateur de performance. L'expression mathématique de l'optimisation de LM est donnée par l'équation 3.1 (Hagan et Menhaj, 1994; Hagan et Menhaj, 1999):

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e \quad (3.1)$$

Où  $J^T$  est le Jacobien de la fonction de performance pour les poids et biais des variables  $x$ ,  $J^T e$  est la matrice de toutes les erreurs,  $I$  est la matrice identité et le coefficient  $\mu$  est la valeur scalaire qui est adaptée à chaque itération pendant l'apprentissage afin de réduire la valeur de la fonction de performance à une valeur spécifiée.

Le nombre de neurones de la couche cachée est trouvé à l'aide d'une simple méthode d'essai et d'erreur dans toutes les applications. Le réseau avec une couche cachée peut généralement se rapprocher de n'importe quelle fonction qui représente un mappage de données d'un espace limité à un autre. Par conséquent, une couche cachée est choisie dans ce modèle.

### 3.5.2.2 Apprentissage du modèle RBFN

Le modèle RBFN n'effectue pas l'apprentissage des paramètres comme dans l'algorithme de rétropropagation, mais effectue simplement un ajustement linéaire des poids pour la base radiale (Poggio et Girosi, 1990; Lee et Chang, 2003; Kocabas et Unal, 2010). Cette caractéristique du modèle RBF donne l'avantage d'une convergence très rapide sans minima locaux puisque sa fonction d'erreur est toujours convexe (Kisi, 2008). Les entrées et sorties du modèle MLPN ont également été utilisées comme entrées et sorties du modèle RBFN. L'architecture du modèle RBFN utilisée dans cette application contient une couche d'entrée, une couche de sortie et une couche cachée. Différents nombres de neurones de couche cachée et de constantes de propagation ont été examinés avec une méthode d'essai et d'erreur simple ajoutant des boucles aux codes de programme.

### 3.5.2.3 Apprentissage du modèle GRNN

L'architecture du GRNN (Specht, 1991) est un cas particulier des réseaux RBF. Il se rapproche de toute fonction arbitraire entre les vecteurs d'entrée et de sortie, en tirant l'estimation de la fonction directement à partir de données d'apprentissage. L'ensemble d'apprentissage du GRNN se compose de valeurs d'entrées  $x$ , chacune avec une valeur correspondante d'une sortie  $y$ . Contrairement au modèle RBFN, les données d'entraînement du GRNN ne sont propagés à travers le réseau qu'une seule fois et par conséquent, la formation est réalisée très rapidement.

Par rapport aux réseaux de neurones standards *feedforward*, le GRNN a une structure relativement simple et statique (Beale et Demuth, 2007). Les performances de la méthode de rétro-propagation sont très sensibles aux valeurs de poids initiales attribuées de manière aléatoire. Cependant, ce problème ainsi que le problème des minima locaux n'ont pas été rencontré dans les simulations GRNN (Cigizoglu, 2005).

Le modèle GRNN est sélectionnée dans cette étude en raison de son apprentissage rapide et de sa convergence à la surface de régression optimale. Les entrées et sorties des modèles MLPN et RBFN ont également été utilisées comme entrées et sorties du modèle GRNN. L'architecture du modèle GRNN utilisée dans cette étude contient une couche d'entrée, une couche de motif, une couche de sommation et une couche de sortie.

La particularité du GRNN est l'utilisation du facteur de lissage " $\sigma$ " qui modifie le degré de généralisation du réseau. Ce facteur permet une transition en douceur d'une valeur observée à une autre, même avec des données rares dans un espace multidimensionnel (Gourine et al., 2012). Des facteurs de lissage élevés, approchant 1, vont redresser la trajectoire de la ligne de prédiction, tandis que des facteurs de lissage approchant 0 créent essentiellement une carte point à point. Si des facteurs de lissage élevés augmentent la capacité du réseau à généraliser, ils peuvent aussi dégrader l'erreur de prédiction. Inversement, de faibles facteurs de lissage dégradent la capacité du réseau à généraliser ou à faire des prédictions. Donc le succès du GRNN dépend du choix des valeurs appropriées du facteur de lissage (Wasserman, 1993). Par conséquent, une série de facteurs de lissage sont testés dans cette étude, afin de déterminer les plus optimaux pour les entrées du modèle. Le facteur de lissage doit être supérieur à 0 et peut généralement aller de 0,1 à 1 avec de bons résultats (Taboli et al., 2011).

### 3.5.3 Evaluation de la performance des modèles proposés

Afin d'évaluer et de comparer les performances des trois modèles proposées (MLPN, RBFN et GRNN), trois critères d'évaluation ont été retenus à cet effet: le coefficient de détermination ( $R^2$ ), l'erreur quadratique moyenne ( $RMSE$ ) et l'erreur absolue moyenne ( $MAE$ ). Le  $R^2$  mesure le degré auquel deux variables sont linéairement liées. Un très bon ajustement donne une valeur de  $R^2$  égale à 1, alors qu'un mauvais ajustement donne une valeur proche de 0. Une  $RMSE$  et une  $MAE$  sont utilisés pour mesurer la précision du modèle. Les expressions pour le calcul de  $R^2$ ,  $RMSE$  et  $MAE$  sont données ci-dessous:

$$R^2 = 1 - \frac{\sum_{i=1}^N (O_i - P_i)^2}{\sum_{i=1}^N (O_i)^2} \quad (3.2)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (O_i - P_i)^2} \quad (3.3)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |O_i - P_i| \quad (3.4)$$

où  $N$  est le nombre de points dans l'ensemble de données,  $O_i$  est une des valeur mesurée et  $P_i$  est la prédiction du modèle correspondante (Willmott, 1981; Willmott, 1982).

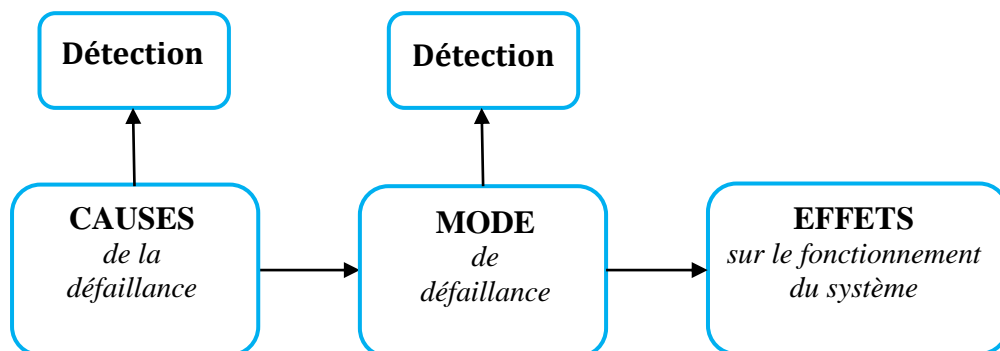
## 3.6 Exemple

Afin d'illustrer la combinaison de la méthode AMDE avec les réseaux de neurones, nous allons exploiter les résultats de cette méthode pour un diagnostic des défauts du moteur à courant continu de l'exemple présenté au chapitre deux ( Exemple 2.16).

Les tableaux de la méthode AMDE décrivant les causes et les effets des défaillances du moteur à courant continu seront présentés en [Annexe C](#).

### 3.6.1 Identification des causes et effets - AMDE

L'adaptation de la méthode AMDE au diagnostic a fait l'objet des améliorations apportées récemment. Le diagnostic utilise les liens entre les effets d'une défaillance, perçus comme une altération d'une fonction du système et les causes à l'origine de cette défaillance. Il s'effectue par ajout de tests de détection (alarmes visuelles ou sonores, mesure de signaux, etc.) attribués à chaque combinaison cause-mode de défaillance ([Figure 3.4](#)).



**Figure 3.4** - Mécanisme de défaillance

L'AMDE est particulièrement utile pour le diagnostic de système opérationnels. Si elle est bien faite, elle doit contenir toutes les défaillances possibles reliées à leurs causes. Le problème du diagnostic est alors la démarche déductive qui consiste à analyser le tableau et à déterminer toutes les causes possibles d'une défaillance observée. L'avantage de cette méthode, qui est son exhaustivité dans la détermination des liens de cause à effet, devient aussi un inconvénient dû à son extrême lourdeur d'utilisation. Pour des système industriels complexes, une AMDE peut conduire à la réalisation de milliers de tableaux. Dans ces conditions, l'utilisation de l'AMDE pour le diagnostic impose l'utilisation de méthodes informatisées qui permettent de générer automatiquement les connaissances nécessaires à la conception d'un outil d'aide au diagnostic.

### 3.6.2 Résultats

Après l'obtention de résultats significatifs par simulation, nous avons combiné la méthode AMDE à un réseaux de neurones de type RBF. La base d'apprentissage du réseau RBF est construite à partir des données extraites de l'analyse AMDE correspondant au moteur à courant continu ([Annexe C](#)).

Dans cet exemple les effets sur le système représentent les entrées du réseau, ils sont sous forme de vecteurs binaires composés de 0 ou 1. Ces derniers font le résultat d'un codage binaire des causes et effets tirés de l'AMDE ([Tableau 3.6](#)).

Afin de tester le pouvoir de généralisation du réseau de neurones RBF, nous avons choisis d'effectuer le test sur plusieurs vecteurs (7, 4, 3, 5) entachés d'erreur de mesure.

Les résultats présentés sur le tableau [Tableau 3.6](#) montrent que le réseau a bien généraliser le vecteur 7.

<i>Causes</i> <i>Effets</i>	1	2	3	4	5	6	7
1	1	1	0	0	0	0	0
2	0	0	1	0	0	0	0
3	0	1	0	1	0	0	0
4	0	1	0	0	0	0	0
5	0	1	1	0	0	0	0
6	0	1	0	0	1	0	0
7	0	0	1	0	0	1	0
8	0	1	1	0	0	0	1
<i>Vecteur</i> <i>Test (7)</i>	0	0	1	0	0	1	1
<i>Vecteur</i> <i>obtenu (7)</i>	0	0	1	0	0	1	0

**Tableau 3.6** - Résultat du codage de l'AMDE avec un test effectué sur le vecteur 7

Le [Tableau 3.7](#) présente les sorties de test obtenues (après apprentissage) du réseau RBF.

<i>Vecteurs cibles</i>	1	2	3	4	5	6	7	8
<i>Vecteurs obtenus</i>	1	2	3	4	5	6	7	8
<i>Vecteurs test cibles</i>	7	4	3	5				
<i>Vecteurs test obtenus</i>	7	4	3	5				
<i>Temps de calcul (s)</i>	1.3800							

**Tableau 3.7** - Apprentissage et test du réseau RBF

Les résultats du modèle RBFN présentés sur les [Tableau 3.6](#) et [3.7](#), sont très satisfaisant tant en apprentissage qu'en généralisation, ce qui montre l'efficacité d'utilisation d'un réseau de neurones de type RBF associé à la méthode AMDE pour le diagnostic des défauts.

### 3.7 Conclusion

Ce chapitre a présenté un aperçu sur méthodologie suivie dans cette thèse pour résoudre le problème de détection et de diagnostic des défauts dans un système industriel. Face à la pluralité des outils d'analyses de risque existants, nous avons opté pour l'analyse HAZOP qui est une technique très populaire d'identification des dangers et de classement des risques dans les installations dangereuses. Nous avons commencé par rappeler le principe et le déroulement de la méthode HAZOP ainsi que l'apport de cette méthode comme support de diagnostic des défauts. L'apport des réseaux de neurones pour le diagnostic des défauts est également abordé. Les résultats de l'analyse HAZOP seront pris en compte en tant que connaissances expertes lors de la procédure de diagnostic grâce à l'information provenant des relations de type cause/effet. L'exemple présenté a bien montré l'efficacité de la combinaison de la méthode AMDE et des réseaux de neurones du type RBF pour le diagnostic du MCC.

Enfin, il est nécessaire de tester si une telle approche est réellement applicable sur un système concret. Dans ce but, le prochain chapitre présente l'application de notre approche sur un système industriel : Le Blow-Out Preventer -BOP.



*”En toute chose, c’est la fin qui est essentiel.”*

*Aristote*

## Chapitre 4: Application de la démarche proposée au diagnostic d'un système industriel- cas du BOP

---

## 4.1 Introduction

Ce chapitre a pour but d'illustrer la méthodologie de diagnostic proposée dans le chapitre précédent à un système industriel. Notre choix s'est porté sur l'un des systèmes parmi les plus importants de l'entreprise SONATRACH (Société Nationale pour la Recherche, la Production, le Transport, la Transformation et la Commercialisation des Hydrocarbures), pouvant engendrer en cas de défaillance des conséquences humaines, matérielles et environnementales critiques voire catastrophiques. Il s'agit du système anti-éruption de puits - BOP d'un chantier de forage au sein de l'Entreprise National de Forage (ENAFOR) à Hassi Messaoud.

## 4.2 Présentation du système BOP

### 4.2.1 Généralités

Le contrôle des puits de pétrole consiste à gérer les rejets inattendus de fluide de formation (pétrole brut et /ou gaz naturel) et le contrôle de leurs effets dangereux sur l'équipement à la surface où se trouvent la plate-forme de forage et leur fuite dans l'atmosphère. Techniquement, le contrôle des puits de pétrole consiste à empêcher le fluide de formation, également appelé venue, de pénétrer dans le puits pendant l'opération de forage. Cette pénétration peut survenir si la pression exercée par la colonne de fluide de forage n'est pas suffisamment élevée pour surmonter la pression exercée par les fluides dans la formation en cours de forage (Luo et al., 2012). Le contrôle de puits de pétrole comprend également leur surveillance pour détecter les signes d'un afflux imminent de fluide de formation pendant le forage et des procédures pour empêcher le puits de couler lorsque cela se produit en prenant les mesures correctives appropriées. Si les effets de pression ne sont pas contrôlés et gérés de manière appropriée, ils peuvent entraîner des blessures et des pertes de vie ainsi que des dommages matériels graves (Ouyang et al., 2009). Des situations de contrôle de puits mal gérées peuvent provoquer des éruptions, qui sont des expulsions incontrôlées et explosives du fluide de formation, pouvant potentiellement provoquer un incendie catastrophique (Ozbayoglua, 2009) ainsi que des pertes considérables de ressources précieuses d'une valeur de plusieurs millions de dollars américains, et pire encore, des pertes de vies et des catastrophes environnementales (William et al., 2005; Oil and Gas glossary, 2010). Egalement, dans de telles situations, le fluide en question peut atteindre plusieurs mètres de haut dans l'air et parfois le gaz expulsé par un puits de forage contenant du sulfure d'hydrogène et d'autres gaz toxiques empoisonne les populations voisines.

La première réponse à une éruption est l'utilisation d'obturateurs pour fermer le puits le plus rapidement possible de manière à limiter au maximum la quantité de fluide intrus (Han et Zhang, 2013). Ensuite, l'équipe de forage doit pomper de la boue lourde dans le trou de forage pour équilibrer la pression de la formation, permettant ainsi aux fluides d'afflux de circuler lentement sous contrôle. Les BOP assurent le contrôle comme deuxième barrière de sécurité, alors que la boue assure le contrôle comme première barrière.

Les éruptions sont très dangereuses dans les accidents d'exploitation pétrolière ou gazière après la défaillance du système anti-éruption et la non-détection d'une venue (Khakzad et al., 2013b; He et al., 2018).

Le Bloc Obturateur de Puits (Blow Out Preventer - BOP) est l'un des éléments les plus importants de l'équipement de contrôle de puits; l'efficacité et le bon fonctionnement du BOP affectent considérablement le contrôle des puits de pétrole et de gaz. Le BOP a reçu une attention accrue après l'éruption du puits de Macondo en 2010, et les estimations des performances de sécurité et de fiabilité du BOP ont été remises en question (Strand et Lundteigen, 2015).

En effet, des accidents récents et des accidents qui ont été évités difficilement montrent également que le BOP échoue de temps à autre. L'industrie du pétrole et du gaz a recueilli des données d'expérience pour les systèmes BOP au cours de nombreuses décennies, et plusieurs travaux sur la sécurité, sur la fiabilité et sur le diagnostic des défauts des BOP, ont été publiés à partir de ces données (Cai et al., 2012; Cai et al., 2013; Liu et al., 2014; Sunghee et al., 2014; Liu et al., 2015; Strand et Lundteigen, 2015).

#### 4.2.2 Fonctions de sécurité

Les blocs obturateurs de puits (*BOP*), sont des valves de sécurité utilisées sur les appareils de forage de l'industrie pétrolière. Installés à la tête de puits, ils sont les derniers recours en cas d'éruption dans un puits. Le BOP est utilisé à de nombreuses étapes de la vie d'un puits: lors du forage, de la complétion, des interventions sur puits ou encore lors des procédures de fermeture définitive d'un puits. Un BOP est un dispositif (ou un assemblage d'obturateurs) constitué au moment des travaux et spécifique au puits en travaux (notamment quant à la pression susceptible d'être rencontrée).

Ce dispositif sert d'organe principal de sécurité durant les opérations de forage ou d'intervention lourde. Il comporte deux fonctions principales de sécurité:

- dans un premier temps, d'assurer la fermeture du puits en cas de venue ;
- dans un second temps, de permettre la circulation de façon à reconditionner la boue et évacuer le fluide ayant pénétré dans le puits (c'est la procédure de contrôle de venues).

Un obturateur est défini, par :

- sa marque (les principaux fabricant étant : Cameron, Shaffer, Hydril) ;
- son type ;
- sa dimension nominale : il s'agit du diamètre de passage dans l'obturateur. Les principaux diamètres sont : 7 1/16", 11", 13 5/8", 16 3/4", 18 3/4", 20 3/4", 21 1/4", 29", 30";
- sa série : il s'agit de la pression de service ou autrement dit, la pression maximale de travail et de test de l'obturateur en psi. Les séries les plus courantes sont : 1000, 2000, 3000, 5000, 10 000, 15 000, 20 000 PSI (*Pond per Square Inch*).

Ces deux dernières caractéristiques permettent de connaître la dimension nominale des brides de raccordement et des joints tores à utiliser.

Les BOP sont contrôlés par les commandes de l'unité d'accumulation hydraulique ou «Koomey» ou celles du panneau à distance, situé à proximité de la cabine du chef de poste.

### 4.2.3 Positionnement

Les BOP sont positionnés entre la tête de puits (extrémité du puits en surface) et le plancher de forage (*rotary table*) permettant les opérations de forage proprement dites. La Figure 4.1 présente un exemple de configuration avec deux obturateurs à mâchoires (*rams*), un obturateur annulaire (*annular*) ainsi que les départs des lignes de contrôle Kill Line (*KL*) et de décharge Choke Line (*CL*). Celles-ci sont des conduites qui partent latéralement du BOP et permettent la circulation des fluides dans le puits lorsque le BOP est fermé.

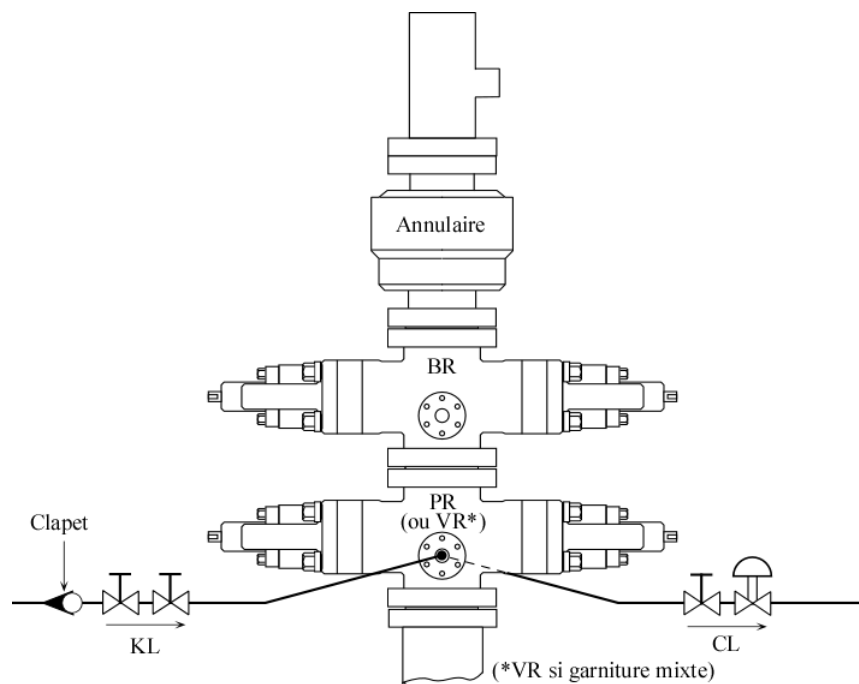


Figure 4.1- Exemple d'empilage des obturateurs "Cameron type U"

### 4.2.4 Types d'obturateurs

La fonction de fermeture de puits est assurée par plusieurs types de BOP, les plus couramment utilisés sont:


- **Les Obturateurs à Mâchoires (*rams BOP*)** : Il s'agit de mâchoires en caoutchouc ou en acier actionnées par des vérins hydrauliques pour se fermer contre les éléments de garniture. Ces mâchoires peuvent supporter des pressions très importantes qui peuvent atteindre les 1000 bar. Ils peuvent être équipés de différents types de mâchoires:
  - Fermeture sur une dimension donnée : "pipe rams".
  - Fermeture totale "blind rams".
  - Fermeture totale et cisailante "blind shear rams".
  - Fermeture sur une gamme de diamètres donnés "variable rams, flex packer".

- **Les obturateurs annulaires (annular preventers):** ils se localise toujours au sommet de l'empilage, ils ont une forme cylindrique et constituent le premier élément actionner au cours d'une éruption. Leur pression de service est généralement inférieure à la pression de service des BOP à mâchoires. Le système de fermeture de ces obturateurs est uniquement hydraulique et Ils peuvent se fermer et faire étanchéité sur des équipements de section régulière de différents diamètres (tubulaire et câbles). Ils permettent la manœuvre du train de tiges, le puits étant fermé et sous pression (*stripping*).

Le nombre et le type d'obturateurs à mettre sur l'assemblage (*stack*) est dépendant de la pression maximale attendue en tête de puits.

#### 4.2.5 Description du fonctionnement


Le système analysé dans cette étude comme exemple d'application est un réel qui est utilisé à l'ENAFOR - Hassi Messaoud. C'est le système de contrôle de puits, il est composé de trois sous-systèmes principaux, à savoir: les obturateurs à mâchoires (*Cameron type U*) et annulaires, les choke & kill lines, et l'unité d'accumulation et de commande [Figure 4.2](#).



**Figure 4.2** - Disposition conventionnelle pour le contrôle de la tête de puits de forage ([Chebira et al., 2020](#))

##### 4.2.5.1 Fonctionnement de l'obturateur à mâchoires (Cameron type U)

La manœuvre de l'obturateur est commandée par une vanne à quatre voies de l'unité de commande des BOP. Un piston et une chemise délimitent une chambre d'ouverture et de fermeture. La mâchoire montée à l'extrémité de la tige de piston suit le mouvement du piston. Un fluide hydraulique incompressible sous pression (1 500 PSI) permet de déplacer le piston. Un circuit hydraulique permet d'envoyer du fluide de chaque côté du piston ([Figure 4.3](#)). Lorsqu'une des chambres est en pression, l'autre est purgée.




**Figure 4.3** - Ligne d'ouverture et ligne de fermeture du circuit hydraulique

Les BOP à mâchoires sont conçus pour être étanches du bas vers le haut. La pression dans le puits aide à la fermeture du BOP, elle passe sous la mâchoire et vient s'appliquer derrière celle-ci. Théoriquement, à partir d'une certaine valeur, elle permet même de maintenir le BOP fermé après avoir purgé la pression hydraulique dans le circuit de fermeture. Le système hydraulique du type U est conçu pour travailler sous une pression de 1500 psi. Le rapport de fermeture pour un BOP à mâchoires indique la pression hydraulique à appliquer pour fermer le BOP en fonction de la pression dans le puits.

#### 4.2.5.2 Fonctionnement de l'obturateur annulaire

Cet obturateur est composé d'un corps dans lequel peut coulisser verticalement un piston. Le piston et le corps du BOP délimitent une chambre d'ouverture et de fermeture. Ce piston est guidé extérieurement par le corps et le couvercle vissé sur ce corps, et intérieurement par un guide cylindrique portant à sa partie inférieure des ouvertures permettant le passage des fluides pour la fermeture et l'ouverture.

L'envoi du fluide de manœuvre sous pression dans la chambre de fermeture pousse le piston vers le haut, comprimant la garniture élastique (*packing unit*) qui, bloquée en haut et en bas, ne peut que se refermer vers l'intérieur de l'obturateur (Figure 4.4).



**Figure 4.4** - Schéma montrant la déformation de la garniture élastique lors de la fermeture du BOP

L'élasticité de la garniture lui permet de faire étanchéité sur n'importe quel tubulaire (à condition qu'il ait une forme régulière) ou sur câble ou même sans équipement dans le puits (utilisation en fermeture totale - Complete Shut Off), mais cela n'est pas recommandé par le fabricant. L'envoi du fluide de manœuvre sous pression dans la chambre d'ouverture repousse le piston vers le bas, décomprimant la garniture élastique qui reprend sa forme initiale.

Lorsqu'une des chambres est en pression, l'autre est purgée. En cas de venue, le fluide du puits sous pression, aide à la fermeture en passant par des orifices situés à la base du guide intérieur. Un régulateur de pression, placé sur le circuit hydraulique, permet de régler la pression sur la garniture pour permettre la manœuvre de la garniture de forage (*Stipping*) et éviter ainsi l'usure rapide de la garniture en caoutchouc.

#### 4.2.5.3 Choke-line

C'est la ligne qui relie les obturateurs au manifold de duses. Sa pression de travail doit être la même que celle des obturateurs. Elle est équipée de 2 vannes situées le plus près possible de l'obturateur. Une de ces vannes peut être commandée hydrauliquement et à distance.

#### 4.2.5.4 Kill-line

C'est une ligne haute pression qui permet de pomper dans l'annulaire dans le cas où on ne peut pas circuler normalement par les tiges de forage. Cette ligne doit se trouver branchée en dessous de l'obturateur à mâchoire utilisé pour contrôler une venue. Toutes les vannes et les lignes de la kill-line doivent avoir une pression de travail égale ou supérieure à celle des obturateurs.

La kill-line ne doit en aucun cas être utilisée comme ligne de remplissage du puits. En effet une utilisation continuelle risque de provoquer une usure par érosion préjudiciable à son utilisation en cas de problème grave.

#### 4.2.5.5 Unité d'accumulation et de commande

L'unité de commande fournit le fluide hydraulique sous pression pour opérer les différents obturateurs de surface et les vannes annexes. La pression de fonctionnement du système habituellement utilisé est de 3000 PSI. Un poste de commande à distance permettant de réaliser toutes les fonctions est installé sur le plancher de forage.

Cette unité permet de disposer en permanence d'une réserve de fluide sous pression (accumulateurs) pour opérer et maintenir en pression les différents composants de l'assemblage du BOP (*BOP stack*).


Tous les BOP sont à commande hydraulique et fonctionnent suivant le principe de vérins hydraulique double effet, c'est-à-dire ayant deux directions de travail. Le principe est d'avoir une réserve de fluide sous pression, qui doit être disponible à chaque instant pour assurer l'ouverture et la fermeture à distance des obturateurs.

L'unité de commande comprend (Figure 4.5):

- un réservoir de stockage contenant le fluide hydraulique à pression;

- deux systèmes de pompage qui aspirent le fluide hydraulique dans le réservoir pour le porter à la pression de fonctionnement de l'unité (en général 3 000 PSI);
- un ensemble de bouteilles (accumulateurs oléopneumatiques) pour stocker ce fluide à la pression de fonctionnement de l'unité;
- un manifold de commande hydraulique pour réguler la pression du fluide de commande et opérer les différentes fonctions du système (BOP, vannes de choke line et de kill line);
- des panneaux de commande à distance pour opérer l'unité de commande à distance;
- un fluide de commande hydraulique.

L'unité doit être placée dans un endroit protégé à distance du plancher de forage (hors du périmètre de sécurité) et facilement accessible au personnel du chantier en cas d'urgence (Nguyen, 1993).



**Figure 4.5** - Schéma de fonctionnement d'une unité de commande reliée à un BOP

**Système de pompage:** Le système de pompage consiste en plusieurs pompes (pompes pneumatiques à air et pompes électriques triplex) qui se mettent en marche et s'arrêtent automatiquement, de manière à maintenir la pression constante (en général 1500 psi) dans les accumulateurs qui constituent la réserve de fluide hydraulique moteur (Lahaie, 2015).

Les pompes aspirent le fluide hydraulique dans le réservoir. Elles doivent être capables de le refouler au moins à la pression (maximum) de fonctionnement de l'unité.

Chaque système de pompage permet d'actionner les obturateurs en l'absence d'accumulateurs. Ils sont équipés de dispositifs de protection de pression haute (pour prévenir l'éclatement des accumulateurs).



**Bouteilles d'accumulation:** Elles permettent de stocker l'huile hydraulique sous pression. Elles restituent du fluide hydraulique lorsque l'on abaisse la pression dans l'accumulateur. Les bouteilles utilisées ont une capacité intérieure de 11 gallons.

Les bouteilles sont protégées par une soupape de sécurité. Un manomètre indique la pression du fluide hydraulique stocké dans les bouteilles. Un transmetteur de pression permet de transmettre cette valeur vers les panneaux de commande à distance. Des vannes d'isolation et de purge sont placées sur chaque rangée pour faciliter le contrôle de la pression de pré-charge ou pour vider les bouteilles dans le réservoir du fluide de commande.

**Distribution du fluide hydraulique:** Le fluide hydraulique est distribué jusqu'aux obturateurs par un jeu de vannes 4 voies (une vanne par obturateur) et un manifold.

Une fois le puits fermé, le contrôle des venues est généralement assuré via deux groupes de conduites annexes, la ligne de décharge (CL) et la ligne de contrôle (KL). Celles-ci permettent respectivement:

- de réguler l'évacuation de la surpression provenant du puits par l'intermédiaire d'une duse;
- l'injection d'eau, de boue de plus haute densité ou de ciment.

**Réservoir:** Un réservoir rectangulaire est utilisé pour le stockage du fluide d'approvisionnement pour les pompes à haute pression. Il contient des baffles, des orifices de remplissage et de purge, une jauge visuelle de niveau du fluide, des orifices d'inspection/remplissage et un trou pour permettre le nettoyage à l'homme.

**fluide hydraulique:** Le fluide utilisé doit permettre le fonctionnement de l'unité dans toutes les circonstances. Il peut être nécessaire d'ajouter des produits comme le glycol pour éviter le gel du fluide.

**Panneau de commande à distance:** Le panneau de commande hydraulique est l'équipement clé de la tête de puits et des installations de surface, c'est un système d'arrêt à sécurité intégrée pour protéger le personnel et l'environnement. Le chantier doit être équipé d'au moins un panneau de commande à distance pour que l'on puisse commander tous les BOP et les vannes de kill et de choke line de deux endroits différents. Ce panneau doit être accessible au chef de poste pendant les opérations de forage et représenter fidèlement l'empilage BOP.

Le panneau de commande à distance doit :

- permettre d'opérer tous les BOP et les vannes des lignes de contrôle (KL) et de décharge (CL);
- permettre de régler la pression du BOP annulaire;
- permettre d'opérer la vanne de by pass;
- indiquer la pression de l'accumulateur, du manifold, de l'annulaire et la pression d'air.

**Conduites:** Les lignes reliant l'unité et le bloc d'obturation doivent avoir une pression de service égale à la pression de fonctionnement de l'unité (3 000 psi). Les flexibles, les conduites rigides et les connections constituant ces lignes doivent résister au feu.

La Figure 4.6 représente le circuit de transmission (pneumatique puis hydraulique) de l'ordre de fermeture d'un BOP à mâchoires (pour les autres composants, le schéma reste le même).


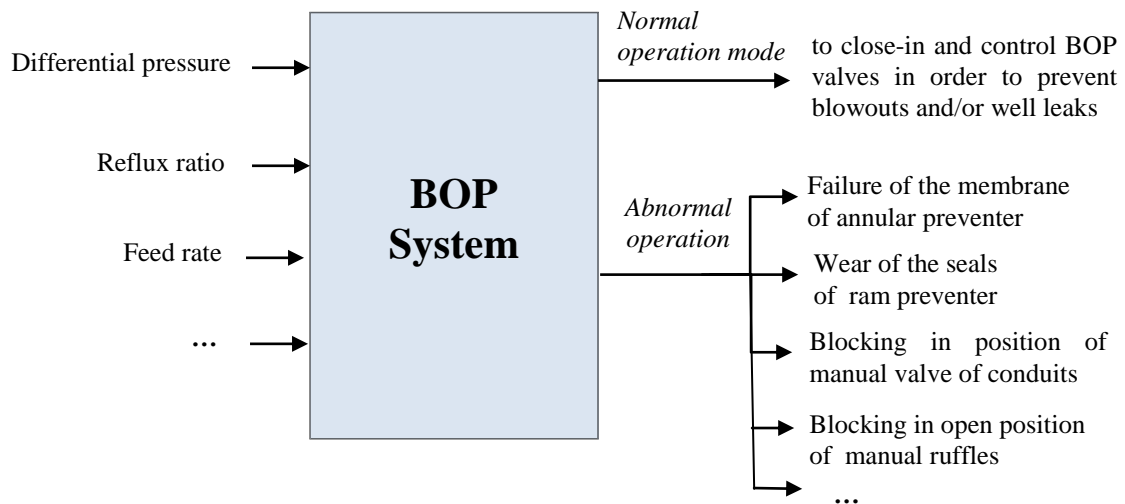


Figure 4.6 - Schéma de fonctionnement d'une unité avec commande pneumatique

### 4.3 Modes de fonctionnement du système BOP

Pour pouvoir élaborer une base de données servant, d'une part comme base d'apprentissage et d'autre part comme base de test, constituée de deux modes de fonctionnement: *mode de fonctionnement normal* et *mode de fonctionnement anormal*, nous définissons les entrées et les sorties du système BOP comme illustré sur la [Figure 4.7](#).



**Figure 4.7** - Entrées et sorties du système BOP ([Chebira et al., 2020](#))

Les entrées et les sorties obtenus à partir des deux modes de fonctionnement du système BOP, sont utilisés pour l'élaboration de la base de données du réseaux de neurones.

### 4.4 Génération de la base d'apprentissage

Comme nous le savons, les entrées d'un réseau de neurones sont spécifiques à chaque système étudié, un prétraitement des données de ce dernier doit être fait afin d'aboutir à la construction d'une base d'apprentissage. Dans notre application, les vecteurs de données construisant la base d'apprentissage du système de diagnostic, sont le résultat d'un codage binaire des informations collectées de l'analyse HAZOP. Les liens de cause à effet sont codifiés par deux symboles (1, 0), le symbole "1" signifie qu'il existe un lien entre l'effet et la cause et le symbole "0" signifie qu'il n'existe pas de lien entre l'effet et la cause.

Après le codage que nous avons adapté pour le prétraitement des données, nous avons obtenus une matrice  $E_{mn}$  qui va être utilisée comme matrice d'entrée du réseau. La matrice  $E_{mn}$  est une interprétation d'un tableau à deux dimensions tel que  $m$  représente le nombre d'effets possibles sur le système et  $n$  représente le nombre de causes de défaillances possibles.

Le tableau représentant le codage des données extraites à partir de l'analyse HAZOP lié système BOP, est présenté en [Annexe D](#).

## 4.5 L'analyse HAZOP

L'analyse HAZOP est une technique très utilisée en particulier dans l'industrie pétrochimique. Elle consiste à détecter des problèmes potentiels qui peuvent causer une déviation par rapport à la conception d'origine et à identifier les causes et les conséquences de ces déviations.

L'objectif principale d'utilisation de l'analyse HAZOP dans cette étude est:

- d'effectuer une recherche des causes possibles de dérives des principaux paramètres de fonctionnement du système BOP;
- de déterminer toutes leurs éventuelles conséquences.

Afin d'établir notre système de diagnostic, nous allons prendre en considération que les déviations les plus critiques, i.e. celles qui peuvent entraîner la perte de la fonction de fermeture du système BOP, ce qui peut conduire à une éruption en cas de venue.

Les résultats de l'analyse HAZOP ([Annexe E](#)) et plus précisément les relations de type cause/effet, sont ensuite utilisées comme base de données pour le réseaux de neurones. Il ressort de cette analyse que plusieurs incidents et/ou accidents peuvent se produire à causes des déviations du paramètre "pression".

Plusieurs scénarios accidentels critiques sont obtenus par cette analyse, dans le [Tableau 4.1](#) nous présentons quatre exemples de ces scénarios.

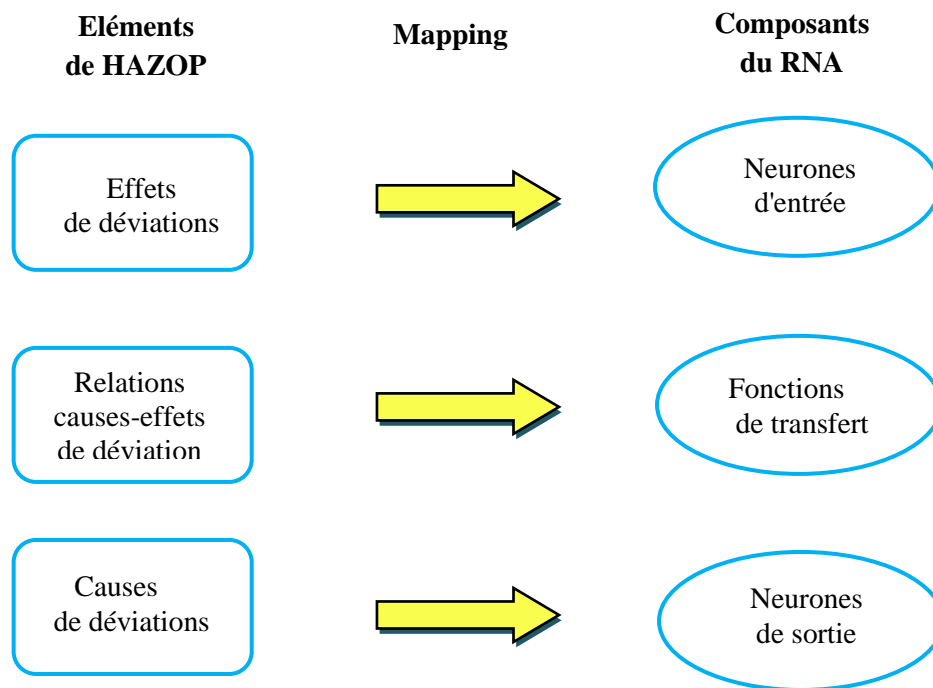
<i>Scénario</i>	<i>Événement initiateur</i>	<i>Conséquence</i>
1	- Fuite dans le circuit de pression	- Blocage en position ouverte du BOP et donc risque d'éruption en cas de venue
2	- Défaillance du régulateur de pression du manifold	- Fluide sous pression de 3000 PSI et par conséquent surpression et risque d'explosion
3	- Fuite dans la vanne 4 voies	- Fermeture très lente du BOP à mâchoires entraînant un volume de gain très élevé (indicateur de venue)
4	- Défaillance du régulateur de pression de l'annulaire	- Blocage en position ouverte du BOP et donc risque d'éruption en cas de venue

**Tableau 4.1** - Exemples de scénarios critiques de l'analyse HAZOP

## 4.6 Mapping de HAZOP en RNA

Dans notre application, après avoir établi les tableaux HAZOP, les éléments de l'analyse HAZOP sont transformés en composants du réseau neuronal dans l'étape de mapping (cartographie) montrée dans la [Figure 4.8](#). Les effets et les causes des déviations de HAZOP sont cartographiés pour être les neurones d'entrée et de sortie du réseau de neurones, respectivement. Une déviation peut entraîner plusieurs effets différents, tandis qu'un effet peut être causé par deux déviations ou plus. Les relations entre les causes et les effets de HAZOP

sont utilisées comme fonctions de transfert dans le réseau de neurones. Le seuil de la fonction de transfert et les poids synaptiques sont estimés lors de l'entraînement à l'aide d'algorithmes d'apprentissage.



**Figure 4.8** - Mapping graphique de HAZOP en RNA

Les fonctions de transfert utilisées pour le mapping de HAZOP en réseaux de neurones sont: non linéaires pour les neurones des couches cachées dans les trois modèles neuronaux (MLPN, RBFN, GRNN). La fonction tangente-sigmoïde (*tansigmoid*) est utilisée pour le MLPN et la fonction *gaussienne* est utilisée pour les modèles RBFN et GRNN. L'utilisation des fonctions de transfert *tansigmoïde* et *gaussienne* dans les couches cachées permet l'apprentissage de relations non linéaires entre les vecteurs d'entrée et de sortie dans l'apprentissage des trois modèles entraînés . Une fonction de transfert linéaire est utilisée pour les trois modèles dans la couche de sortie. Une fonction de transfert linéaire pour les neurones de sortie, est utilisée à des fins d'ajustement de fonction ([The MathWorks, 2018](#)).

## 4.7 Phases d'apprentissage

L'approche neuronale proposée dans cette étude comporte deux phases: l'apprentissage et le test ([Figure 4.9](#)). Pendant la phase d'apprentissage, le réseau neuronal est formé pour saisir les relations de cause à effet entre les entrées et les sorties désirées. Une fois la phase d'apprentissage achevée, le réseau est testé avec un ensemble de données de test qui n'a pas été utilisé pour l'apprentissage de manière à vérifier sa faculté de généralisation. Le processus de test consiste en un calcul à l'aide de l'ensemble de données de test et en une comparaison des résultats avec les données de sortie réelles.

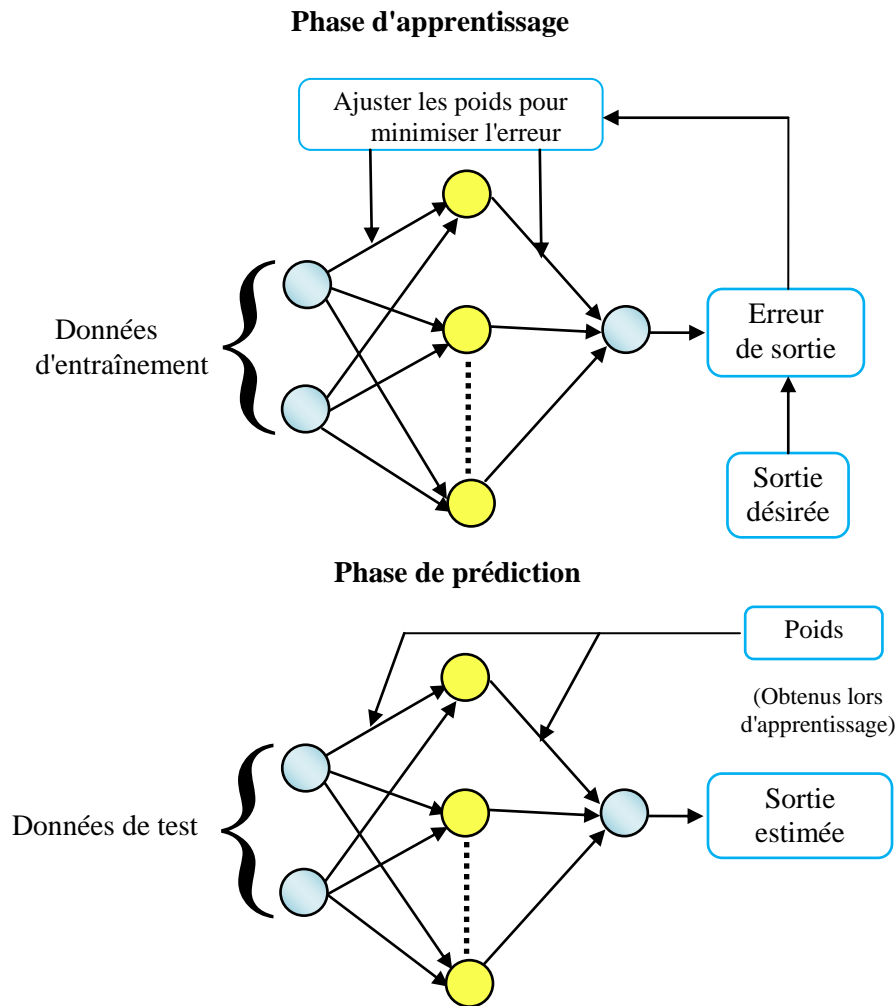


Figure 4.9 - Les phases d'apprentissage et de test du RNA

Une fois que le réseau est formé et testé, il est prêt à détecter et diagnostiquer les défauts dans différentes conditions de fonctionnement. Enfin, la détection des anomalies est représentée sous forme de messages d'alarme destinés à annoncer à l'opérateur l'apparition d'anomalie (s) et permet d'en identifier les causes au moyen d'une base de données qui stock toutes les informations fournies par l'analyse HAZOP.

## 4.8 Résultats et discussions

Cette section présente les résultats d'apprentissage et de test des modèles: MLPN, RBFN et GRNN pour le diagnostic des défauts du système BOP. Toutes les simulations sont effectuées avec une base de données composée de 48 vecteurs. Dans les trois modèles étudiés, 80% de l'ensemble de données ont été assignés au hasard comme ensemble d'apprentissage, et 20% ont été utilisés pour tester les performances de généralisation des modèles. Pour une comparaison appropriée des performances, tous les modèles utilisent les mêmes ensembles de données d'apprentissage et de test. Le réseau de neurones est développé à l'aide de MATLAB 8.1 Neural Network Toolbox (MATLAB 8.1, 2013).

Le MLPN utilisé dans cette application est composé d'une couche d'entrée et d'une couche de sortie qui contiennent respectivement les effets et les causes des déviations obtenus à partir de l'analyse HAZOP. Le MLPN peut avoir plus d'une couche cachée, par conséquent, le nombre de neurones de couche cachée pour minimiser l'erreur "MSE" a été trouvé en utilisant simple essai-erreur (*simple trial and error*). Pour cela, différentes architectures sont testées pour déterminer le nombre de couches et le nombre de neurones cachés appropriés.


D'après les résultats obtenus (Tableau 4.2), nous constatons que l'architecture optimale du modèle MLPN, en terme de temps d'exécution et du nombre d'itération, est celle comprenant une couche cachée avec 20 neurones. De plus la Figure 4.10, montre que l'architecture (01,20) a les meilleures performances d'apprentissage ( $2,941 \times 10^{-29}$ ) et a donc été considéré comme optimal pour notre étude.

Les fonctions d'activation *tansigmoïde* et linéaire ont été utilisées respectivement dans la couche d'entrée et la couche de sortie et la fonction d'activation *tansigmoïde* a été choisie pour la couche cachée.

MLPN	Architecture du réseau		Nombre d'itérations	Temps (s)
	Nombre de couches cachées	Nombre de neurones cachés		
Algorithme Levenberg-Marquardt	01	20	07	2.750
	02	(15,7)	26	5.844
	03	(12,4,2)	55	7.578


**Tableau 4.2** - Nombre d'itérations et temps d'apprentissage pour trois architectures du MLPN

La Figure 4.10 présente les performances du processus d'apprentissage du modèle MLPN pour une couche cachée.




**Figure 4.10** - Performances du MLPN avec une couche cachée

La [Figure 4.11](#) présente les performances du processus d'apprentissage du modèle MLPN pour deux couches cachées.



**Figure 4.11** - Performances du MLPN avec deux couches cachées

La [Figure 4.12](#) présente les performances du processus d'apprentissage du modèle MLPN pour trois couches cachées.




**Figure 4.12** - Performances du MLPN avec trois couches cachées

Dans les deux modèles RBFN et GRNN, le paramètre clé est le coefficient d'étalement. Ce paramètre joue un rôle crucial dans l'établissement d'un bon modèle de régression des réseaux de neurones avec une précision et une stabilité de prédiction élevées. Par conséquent, ce paramètre doit être correctement déterminé sur la base des critères d'évaluation pour optimiser les performances de prédiction. L'optimisation du coefficient d'étalement est le but du processus d'apprentissage.

Pour le modèle RBFN, différents nombres de neurones cachés et de constantes d'étalement (entre 0,01 et 1) ont été examinés avec une méthode simple d'essai-erreur en ajoutant des boucles aux codes du programme. la [Figure 4.13](#), montre que l'architecture (01,44) a les meilleures performances d'apprentissage ( $3,367 \times 10^{-31}$ ) et a donc été considéré comme optimale pour notre étude.



La valeur du paramètre d'étalement fournissant les meilleures performances de test du RBFN est égale à «1».



**Figure 4.13** - Performances du RBFN avec une couche cachée

Pour le modèle GRNN différentes valeurs du paramètre d'étalement (entre 0,02 et 0,7) ont été essayés pour trouver la meilleure valeur en terme de performance de prédiction. Les meilleures performances de test du GRNN ont été obtenues lorsque le paramètre d'étalement est égal à «0,1».

Les performances en terme de statistiques  $R^2$ , RMSE et MAE et de temps d'exécution pour les phases d'apprentissage et de test des modèles MLPN, RBFN et GRNN sont indiqués dans le [Tableau 4.3](#).

ANNs Models	Training			Testing			Time (s)
	$R^2$	RMSE	MAE	$R^2$	RMSE	MAE	
MLPN	0.8273	5.7152	1.7414	0.9931	1.2481	0.3462	3.8125
RBFN	0.7443	0.0463	0.0043	0.9988	0.0283	0.0016	3.9219
GRNN	0.9872	0.0328	0.0022	1	0.0273	0.0015	1.2031

**Tableau 4.3** - Performances des modèles MLPN, RBFN et GRNN dans les phases de d'apprentissage et de test ([Chebira et al., 2020](#))

Les valeurs  $R^2$ , RMSE et MAE du modèle MLPN sont supérieures aux valeurs correspondantes du modèle RBFN. Une valeur  $R^2$  plus élevée, pendant la phase d'apprentissage du modèle MLPN, signifie qu'il a une meilleure relation linéaire entre les valeurs des déviations observées et prévues, par rapport au modèle RBFN. Cependant, des

valeurs RMSE et MAE plus élevées, pendant les phases d'apprentissage et de test, du modèle MLPN signifient que la précision du modèle MLPN est inférieure à celle du modèle RBFN.

Les résultats du [Tableau 4.3](#) révèlent que, l'erreur produite par le modèle MLPN est plus élevée que celle du modèle RBFN et que le modèle GRNN a mieux fonctionné pendant les phases d'apprentissage et de test, il surpasse les modèles RBFN et MLPN en termes du temps d'exécution et de toutes les mesures statistiques standard.

Une RMSE fournit une mesure pour juger de la précision de l'ajustement des modèles. Une RMSE inférieure indique un meilleur ajustement. Une valeur  $R^2$  élevée plus proche de l'unité indique une prédiction plus cohérente. Les résultats du [Tableau 4.3](#) indiquent que le modèle GRNN, pendant la phase de test a les valeurs de RMSE (0,0273) et de MAE (0,0015) les plus petites ainsi qu'une valeur de  $R^2$  égale à «1» la plus élevée. Selon les résultats de test, les modèles GRNN et RBFN fournissent des valeurs  $R^2$ , RMSE et MAE proches les unes des autres.

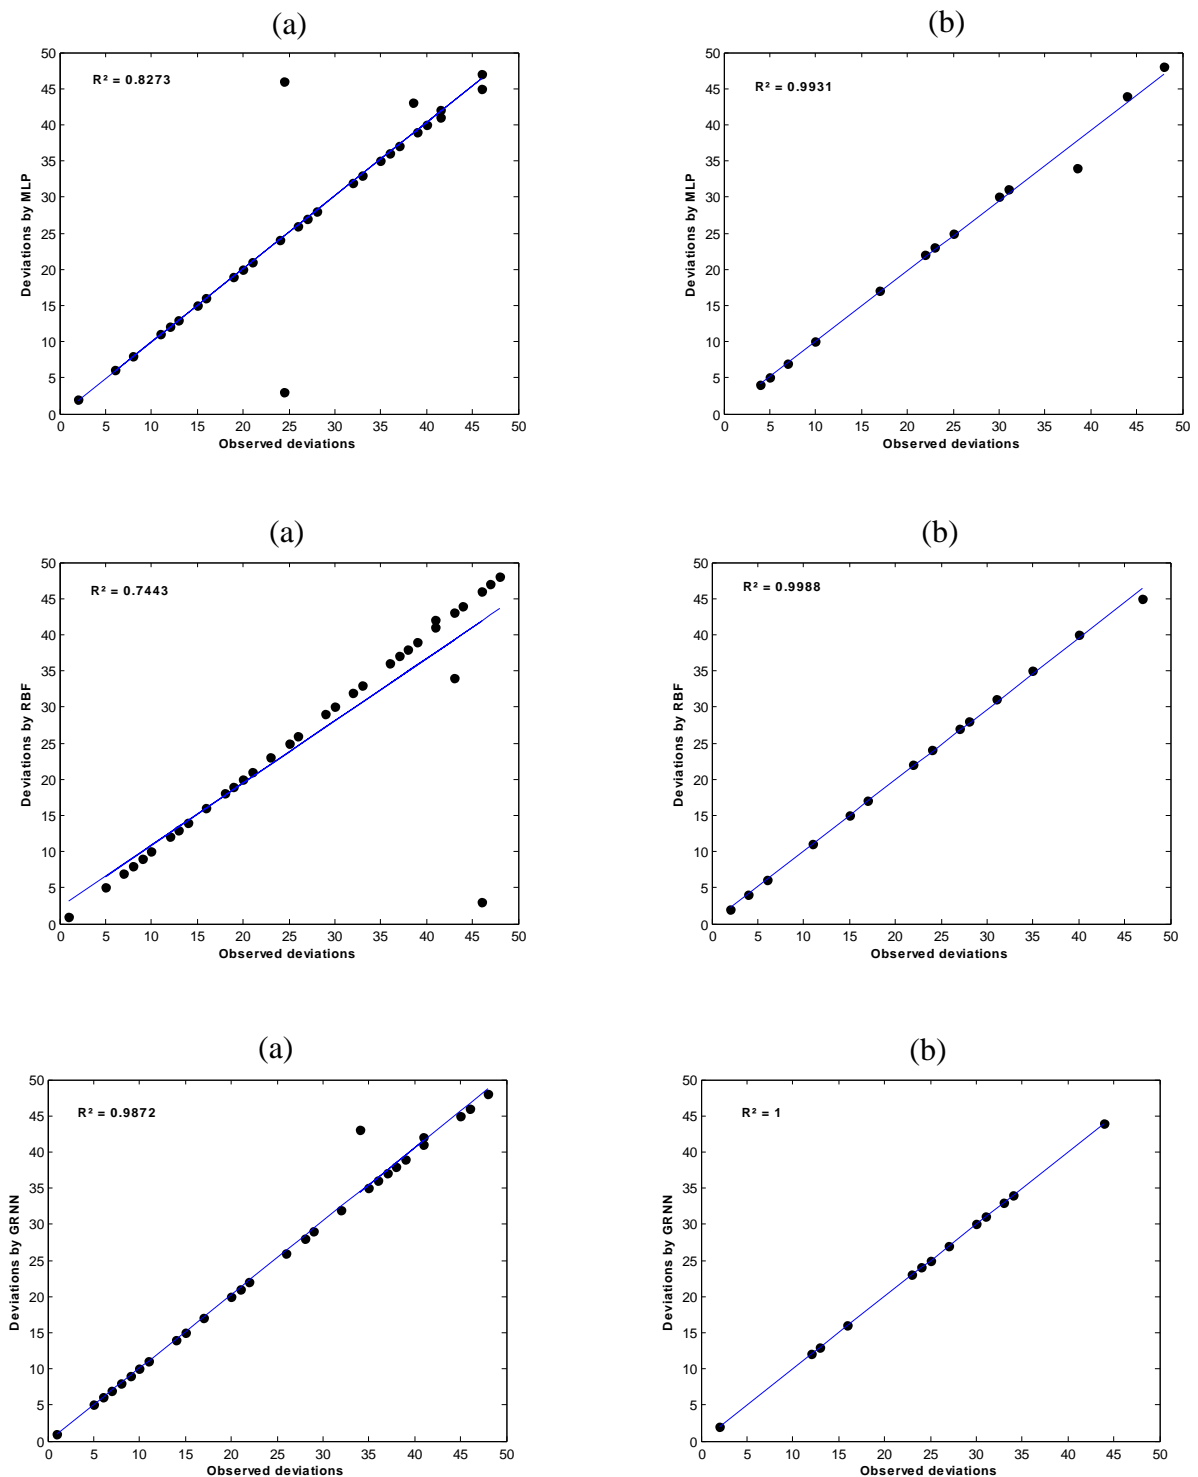
Ces évaluations indiquent que les modèles utilisés pour le diagnostic des défauts du système BOP pourraient être classés, du meilleur au moins favorable, comme suit: GRNN, RBFN et MLPN.

Pour mieux illustrer les résultats, nous portons dans les figures ci-après les diagrammes de dispersion des déviations calculés par rapport aux déviations observées pour les modèles MLPN, RBFN et GRNN pour les phases (a) d'apprentissage et (b) de test ([Figure 4.14](#)).

On peut évidemment le voir sur la [Figures 4.14](#) que les simulations GRNN sont plus proches des déviations observées correspondantes que celles du MLPN et du RBFN. Pour la phase de test, une coïncidence totale est observée avec la ligne d'ajustement du modèle GRNN par rapport aux modèles MLPN et RBFN.

La [Figures 4.14](#) montrent que les performances des trois modèles sont en général satisfaisantes et que le modèle GRNN est systématiquement supérieur aux modèles MLPN et RBFN en particulier dans la phase de test. Il est clair que si une base de données plus grande avait été utilisée pour fournir une plus grande quantité de données pour l'entraînement, les performances de prédictions du MLPN, RBFN et GRNN auraient été encore meilleures.

Les résultats montrent bien que le modèle GRNN peut être appliqué avec de meilleures performances pour établir un modèle de diagnostic capable de détecter et d'identifier les différentes causes de défaillances du système BOP.



**Figure 4.14** - Diagrammes de dispersion des déviations calculés par rapport aux déviations observées pour les modèles MLPN, RBFN et GRNN pour les phases (a) d'apprentissage et (b) de test

## 4.9 Evaluation du risque incendie lié à une éruption

### 4.9.1 Exemples d'accidents d'éruption

#### *Nezla 19 (2006)*

Le 15 septembre 2006, l'incendie survenu dans la plateforme du forage gazier Nezla 159 de Gassi Touil a tué deux personnes sur le coup et a fait six blessés. Dans cette zone de production située à 130 km de Hassi Messaoud se déroulaient des travaux de forage en partenariat entre SONATRACH et la compagnie pétrolière espagnole Repsol quand le feu s'est déclaré suite à une importante déflagration. L'explosion a provoqué une éruption incontrôlée avec incendie, dégageant une flamme de 50 à 60 m de hauteur, selon la protection civile d'Ouargla. La première intervention effectuée par les services de sécurité de SONATRACH aurait permis de dégager les baraques d'habitation proches du lieu de l'incident ainsi que les citernes de carburant afin d'éviter la propagation du feu. Le périmètre de sécurité du puits est de 1600 m à la ronde.

#### Conséquences:

- Deux morts;
- Sept blessés;
- Grande perte de matériel de forage;
- Cet incident a coûté à SONATRACH plus de 04 millions \$.

#### *Explosion de la plate-forme pétrolière deepwater ( 2010)*

Le 20 avril 2010 vers 21h50, la plate-forme pétrolière Deepwater Horizon de type "offshore profond" est victime d'une explosion suivie d'un incendie. Lors d'une opération de fermeture provisoire du puits Macondo, dans le golfe du Mexique, à 70 km au large des côtes de la Louisiane. Le gaz explose et provoque un incendie, qui s'étend sur toute la plate-forme. La plupart des 126 employés présents sont évacués par bateau de survie mais 11 personnes ne sont pas retrouvées. 17 autres personnes sont blessées, dont 3 gravement. Malgré la mobilisation de nombreux bateaux, l'incendie ne peut être éteint et après 36 heures d'efforts, la plate-forme coule le matin du 22 avril 2010. L'éruption s'est poursuivie au fond de la mer pendant 87 jours avant que le puits réussisse à être colmaté par un puits de secours. Cet accident a causé une marée noire sans précédent, avec environ 4,5 millions de barils de pétrole déversés dans la mer, un impact majeur sur l'environnement et une déstabilisation de l'économie de toute la région du sud des Etats-Unis (Boemre, 2011; Transocean, 2011).

#### Conséquences:

- 11 morts et 17 blessés, dont 3 gravement.
- 4,5 millions de barils de pétrole déversés dans la mer
- Le devenir du pétrole en mer diffère selon les études:
  - 74 % du pétrole évaporé – 26 % résiduel
  - 30 % du pétrole éliminé – 70 % résiduel
- La faune et la flore sont fortement impactées du fait notamment de :
  - la toxicité intrinsèque du pétrole et des sous-produits

- la toxicité du dispersant
- l'anoxie induite sur le milieu marin
- la modification de l'habitat naturel et des flux migratoires
- Coût direct de 40 milliards de dollars pour l'opérateur BP plus le coût d'indemnisation

### ***Campo de Frade (2011)***

Le 7 Novembre 2011, sur le champ pétrolifère de Campo de Frade, à 120 km au large du Brésil, une venue suivie d'une éruption souterraine s'est produite en phase d'exploitation au cours du forage du puits n°9-FR-50DPRJS, situé sous 1 200 m d'eau et d'une profondeur totale de 2 220 m. À la suite de cette éruption, les hydrocarbures ont migré à travers la formation géologique, occasionnant un écoulement de pétrole au fond de la mer. Une nappe de pétrole s'est répandue autour du puits et les observations réalisées au fond de la mer ont mis en évidence la présence de huit fissures (dont l'une par laquelle s'échappait le pétrole). L'exploitant a alors entrepris de colmater et de fermer définitivement le puits. Le contrôle du puits a été repris en 6 jours. La procédure d'abandon définitif du puits a été close le 12 février 2012. Le 4 mars 2012, une nouvelle fuite a été observée, émanant d'une faille située à environ 3 km du premier point de fuite.

#### Conséquences:

- Aucune victime;
- 590 m<sup>3</sup>, soit 470 tonnes, de pétrole déversé en mer.
- Nappe de pétrole de 1,8 km<sup>2</sup>;
- Suspension de toutes les opérations de forage de Chevron au Brésil le 23 novembre 2011;
- Amende de 25 millions \$ et 10 milliards \$ de dommages et intérêts réclamés à Chevron.

### ***ELGIN (2012)***

Suite à une éruption brutale de boue et de gaz, un rejet de gaz naturel et de condensats a lieu le 25 mars 2012, vers 12 h, au niveau de la tête d'un puits provisoirement fermé d'une plate-forme du champ gazier d'Elgin, en mer du Nord. Le gaz s'échappe à proximité d'une torchère située en hauteur sur la plate-forme, entraînant un risque d'explosion. Le gaz entraînant la fuite ne provient pas du réservoir mais d'une couche de gaz situé au dessus du réservoir. Une partie des 238 employés non-indispensables est évacuée dans la journée. Le débit de fuite est estimé à 200 000 m<sup>3</sup>/jour et le 27 mars, une nappe d'hydrocarbure de 4,8 km<sup>2</sup> est observée. La torchère s'éteint d'elle-même le 31 mars réduisant ainsi le risque d'explosion et permettant à l'exploitant de forer 2 puits de secours en parallèle pour tenter de colmater la fuite. Le puits est sous contrôle le 15 mai 2012.

#### Conséquences:

- Evacuation de 238 personnes;
- Rejet de 200 000 m<sup>3</sup> de gaz/jour au début de l'accident. L'intensité de la fuite a ensuite diminué. La fuite a duré 52 jours et la quantité totale d'hydrocarbures rejetés a été estimée à 6172 tonnes (gaz et condensats);

- Rejet de 5 à 9 tonnes par jour de condensats au début de l'accident. Le volume de condensats restant après évaporation est estimé à 7 m<sup>3</sup>. Le condensat se répand à la surface de l'eau en formant une nappe très étendue et très fine (quelques microns). Le pourcentage de condensat évaporé est estimé à environ 75%. Les niveaux de concentration des produits restants ne sont pas jugés susceptibles d'avoir un impact significatif sur l'environnement marin.
- L'impact de la fuite de gaz sur l'atmosphère est jugé limité localement (dispersion par le vent) mais important globalement (gaz à effet de serre);
- Coûts des opérations de réhabilitation plus les coûts de l'arrêt de la production pour Total.

#### 4.9.2 Risque d'éruption (Risque majeur)

Une éruption (*blowout*) est une sortie incontrôlée d'effluents à partir d'un puits. Le point de sortie des effluents peut se situer en tête de puits (éruption de surface) ou le long du puits, au droit de formations souterraines vulnérables (éruption souterraine), pouvant potentiellement provoquer un incendie (Ozbayoglua, 2009). Les éruptions sont les accidents les plus tragiques et les plus coûteux de l'industrie pétrolière. Ils mettent en danger la vie, l'environnement et la production future du puits.

Une éruption est causée par la combinaison de deux phénomènes: un afflux de fluides indésirables dans le puits (*venue*) autorisé par la défaillance de la barrière de sécurité primaire du puits (poids de la colonne de boue); un contrôle inefficace de la venue du fait de la défaillance des barrières secondaires (Bloc d'Obturation de Puits). Une venue est le fait d'un déséquilibre de pression, la pression exercée par la colonne de boue au fond du puits devenant insuffisante pour contrer la pression interstitielle des fluides contenus dans les formations. C'est dans la phase de forage que le risque d'éruption de puits est le plus fort.

##### 4.9.2.1 Prévention des venues

Lors d'une opération de forage déséquilibrée, la prévention des venues se rapporte au processus de maintien de la pression dans le puits à un niveau supérieur à la pression dans la formation environnante. Si la pression interstitielle de la formation forée dépasse la pression au fond du puits de forage, les fluides de la formation entreront dans le puits. Il est cependant important que la pression dans le puits ne dépasse pas la pression de rupture de formation. En cas de rupture, la boue de forage sera perdue dans formation, la pression hydrostatique dans le puits diminuera et il y aura une augmentation de la possibilité d'une venue (Khakzad et al., 2013).

En général, une venue peut résulter de l'une des causes suivantes (Grace et al., 2003):

- Pression interstitielle de formation supérieure au poids de la boue;
- Trou non rempli de boue lors de l'extraction;
- Écouvillonnage pendant le déclenchement;
- Perte de circulation;
- Coupe de boue.

#### 4.9.2.2 Détection de venue

En cas d'apparition d'une venue de puits, il est essentiel que la venue soit détecté à un stade précoce. Sinon, les fluides de formation continueront à déplacer les fluides plus lourds dans le puits de forage et la pression dans le puits diminuera davantage, permettant au cycle de se nourrir de lui-même et à la venue de s'intensifier (Fraser et al., 2014). Plus la venue est détecté tard, plus l'afflux entrera dans le puits de forage, dépassant le BOP et montera dans la colonne montante et dans le pire des cas, dégènera en éruption. Les signes d'occurrence courants d'une venue de puits sont: une augmentation immédiate du taux de pénétration, une augmentation du volume dans le réservoir du trou ou une augmentation du débit, une modification de la pression de la pompe et une réduction du poids de la tige de forage (Grace et al., 2003).

#### 4.9.2.3 Prévention des éruptions

Une fois qu'une venue a été détecté, l'étape suivante consiste à fermer le puits de forage en actionnant le bloc obturateur de puits (BOP) pour empêcher une éruption. Le système de contrôle de puits comprend, comme nous l'avons déjà présenté, les obturateurs à mâchoires et annulaires, les choke & kill lines, et l'unité d'accumulation et de commande. Une fois, le puits a été fermé, les fluides de la formation pénètrent dans le puits de forage jusqu'à ce que la pression de fond du trou devienne égale à la pression de la formation.

#### 4.9.2.4 Conséquences de l'échec du contrôle de puits

Si une venue n'est pas découverte ou si la barrière de contrôle du puits ne remplit pas sa fonction, une éruption se produira. En termes d'éruption majeure, de déversements d'hydrocarbures, d'allumage et d'explosion de gaz, et de décès majeurs est le pire des cas. L'accident de Macondo dans le golfe du Mexique est un exemple d'un tel scénario (DeepwaterHorizonStudyGroup, 2011).

Afin de réduire ces conséquences graves, on peut, du point de vue du risque, se concentrer sur la diminution de la probabilité d'avoir des éruptions. Comme une éruption commence avec l'occurrence d'une venue, il est d'une importance cruciale d'identifier les facteurs qui peuvent conduire à une venue. De plus, en effectuant une évaluation des risques, il est possible de catégoriser les conséquences d'une venue puis de mettre en place des barrières adéquates. Le but du processus est de s'assurer que les risques sont maîtrisés et réduits à un niveau acceptable.

#### 4.9.3 Risque d'incendie

L'incendie est une combustion qui se développe d'une manière incontrôlée, dans le temps et dans l'espace. Elle engendre de grandes quantités de chaleur, des fumées et des gaz polluants, voire toxiques, qui sont liés aux caractéristiques et à la nature des matières, stockées et mises en œuvre. L'énergie émise par la réaction de combustion favorise le développement de l'incendie. La plupart des sites industriels présentent des risques d'incendie.

Dans l'exploitation d'un gisement une fausse manœuvre, ou une erreur peuvent donner naissance à un incendie. Les conséquences d'un incendie sont lourdes à la fois sur le plan humain et sur le plan économique, l'importance des investissements consentis explique l'importance de la sécurité dans cette industrie.

Un incendie non maîtrisé, se déclarant dans un chantier de forage, peut engendrer des conséquences graves et dramatiques au personnel opérants sur les lieux, aux matériels et à l'environnement.

#### 4.9.4 Risque d'explosion

L'explosion, à la différence de l'incendie, est une combustion quasiment instantanée. Elle provoque un effet de souffle accompagné de flammes et de chaleur. Elle ne peut survenir qu'après la formation d'une atmosphère explosive (ATEX). Celle-ci résulte d'un mélange avec l'air de substances combustibles, dans des proportions telles qu'une source d'inflammation d'énergie suffisante produise son explosion. Dans le forage pétrolier ou gazier, une explosion survient généralement suite à une éruption incontrôlée.

#### 4.9.5 Evaluation du risque incendie

Pour évaluer les risques associés aux opérations de contrôle des puits, deux méthodes d'analyse des risques ont été appliquées, la méthode AdD et la méthode de l'Arbre d'Evènement (*AdE*). Tout d'abord, un terme important à clarifier est le terme risque. Dans le contexte de l'analyse des risques en ingénierie, le risque est défini comme la combinaison de la probabilité d'un événement indésirable et de ses conséquences (ISO, 2002), ce qui signifie que la probabilité et la conséquence doivent être évaluées dans la détermination du niveau de risque.

##### 4.9.5.1 Arbre de défaillances pour l'occurrence de venue

Selon la discussion présentée plus haut, pour les causes d'une venue le modèle d'arbre de défaillances, illustré à la Figure 4.15, est réalisé. Lorsqu'une venue a lieu, la barrière principale de contrôle du puits est défaillante.

Tel qu'illustré dans la figure, cela peut se produire de différentes manières à partir de divers événements de base énumérés dans le Tableau 4.4, partie A.

##### 4.9.5.2 Arbre des défaillances pour le système BOP

Si la venue a été détecté, l'étape suivante de la procédure de contrôle de puits implique l'activation et l'utilisation du système BOP. Le BOP et ses éléments associés, discutés dans les sections précédentes, forment la prochaine barrière de sécurité pour empêcher une éruption de puits. Un modèle d'arbre de défaillances peut être développé, sur la base duquel on peut évaluer la probabilité du système BOP, et identifier les causes et leurs interactions qui peuvent conduire à la défaillance de ce système. L'arbre de défaillances construit est donné par la Figure 4.15. Comme illustré dans le modèle, une défaillance du système de fermeture du puits (ensemble BOP) ou une défaillance de commande ou une défaillance du chock-manifold peut entraîner une défaillance du système BOP. En ce qui concerne l'empilage BOP,



on suppose que l'obturateur annulaire et les obturateurs à mâchoires doivent tomber en panne simultanément pour provoquer une défaillance de l'empilage. Les événements de base de l'arbre de défaillances et leurs descriptions sont donnés dans le [Tableau 4.4](#), partie B.

<b>A</b>		<b>B</b>	
<i>Indice</i>	<i>Description</i>	<i>Indice</i>	<i>Description</i>
1	Ne pas garder le trou plein pendant l'extraction	1	Membrane de l'annulaire endommagée
2	Nettoyage pendant l'extraction	2	Défaillance de la garniture du piston annulaire
3	Volume de boue trop faible	3	Pression de commande annulaire insuffisante
4	Trop faible densité de boue	4	Défaillance des mâchoires
5	Perte de retours à la formation	5	Pression de commande insuffisante
6	Anneau bouché	6	Défaillance de la garniture de piston
7	Coupe d'eau	7	Pression de service insuffisante
8	Coupe d'huile	8	Défaillance des vannes de commande
9	Coupure de gaz	9	Défaillance des vannes de commande du panneau de commande
		10	Défaut de détection des manomètres
		11	Fuite d'air au niveau des panneaux
		12	Défaillance des duses
		13	Erreur humaine
		14	Défaillance de la vanne de décharge (chok valve)
		15	Défaillance de la vanne de contrôle (Kill valve)

**Tableau 4.4** - Evénements de base des AdD, de la venue (A) et du système BOP (B)

#### 4.9.5.3 Analyse de l'Arbre d'événements (AdE) pour la détection de venue

Cette analyse a pour objectif, en partant d'un événement initiateur, de déterminer l'ensemble des séquences accidentelles susceptibles de se réaliser suivant que les barrières de protection remplissent, ou non, leurs fonctions de sécurité. Les arbres se propagent à partir d'un événement indésirable à travers un système choisi et considèrent toutes les manières potentielles que cet événement peut avoir sur le comportement du système ([Bedford et Cooke, 2001](#)). Le système est constitué de sous-systèmes ou barrières de sécurité, présentés comme des en-têtes d'événements. Les résultats de l'arbre des événements dépendent du fait que ces barrières remplissent ou non leur fonction prévue.

La découverte d'une venue de puits peut être considérée comme la première barrière de sécurité pour empêcher une éruption. Les performances de cette barrière peuvent être facilement analysées grâce à un modèle d'arbre d'événements. Les principaux indicateurs de venue qui feront très probablement partie de l'image de détection précoce de cette dernière sont sélectionnés pour le développement de l'arbre des événements ([Figure 4.15](#)).

En général, pour le cas de l'AdE de la [Figure 4.15](#), le capteur de débit et les instruments indicateurs doivent indiquer la présence possible d'une venue pour les actions à entreprendre. Cependant, si un flux très important est détecté par les instruments indicateurs, ce sera un indicateur autonome et le puits sera fermé ([Fraser et al., 2014](#)).

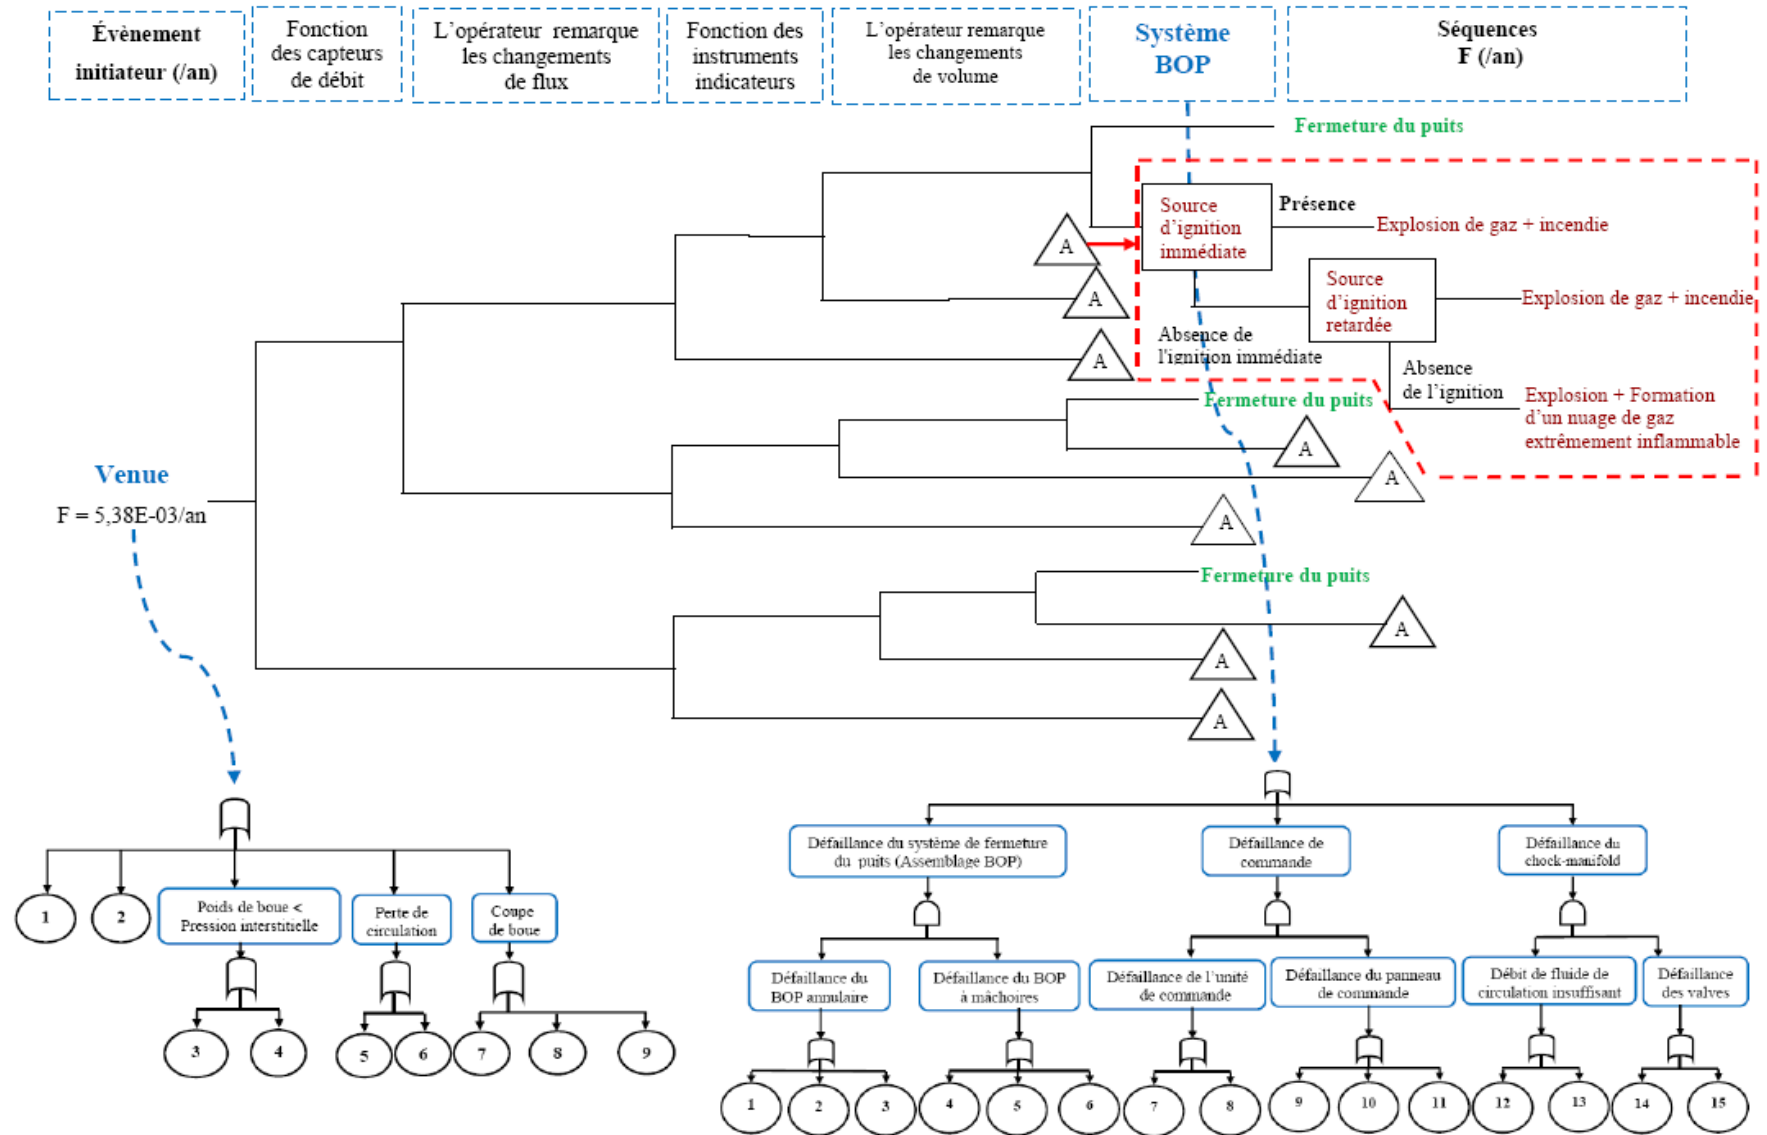


Figure 4.15 - Arbre d'évènement des différentes catégories de conséquences initiales de l'occurrence de venue

#### 4.9.5.4 Analyse quantitative dans des conditions de fonctionnement normales

##### *Données de probabilité et statistiques de défaillance*

Afin de quantifier les résultats possibles du modèle de risque développé, plusieurs bases de données et rapports ont été étudiés et examinés. Ces sources d'information documentent et discutent des données sur le risque et la probabilité des différents éléments du système BOP, et fournissent des statistiques sur les occurrences de venue.

- *Données de probabilité d'occurrence de venue*: En raison du manque de données sur certains des événements de base entraînant une occurrence de venue (Tableau 4.4), la fréquence globale d'occurrence de venue a été utilisée. Les données de fréquence d'occurrence de venue proviennent de Holand et Awan (2012).
- *Données de probabilité de l'échec de détection de venue*: En ce qui concerne la procédure de détection de venue, les probabilités de défaillance des indicateurs de venue et des opérateurs, sont donnés dans une étude de contrôle de puits (Khakzad et al., 2013).

Sur la base de ces données, la probabilité qu'une venue soit détectée peut être estimée en utilisant le modèle d'arbre d'événements développé au paragraphe 4.9.5.3 (Figure 4.15). Les données de défaillance sur les barrières de détection de venue, ainsi que les données sur la probabilité d'occurrence de venue, sont données dans le Tableau 4.5.

<i>Indice</i>	<i>Evènement</i>	<i>Probabilité</i>
1	- Fonctions du capteur de débit	0.99989
2	- L'opérateur remarque les changements de flux	0.99500
3	- Fonction des instrument d'indication	0.99986
4	- L'opérateur remarque les changements de volume	0.90000

**Tableau 4.5** - Probabilités d'occurrence pour la venue et les éléments de détection de venue (Holand et Awan, 2012; Khakzad et al., 2013)

- *Système BOP - Probabilité de Défaillance*: Pour le système BOP, des données détaillées sur la probabilité de défaillance de ses éléments étaient disponibles. La probabilité de défaillance du système BOP est estimée en se basant sur le modèle d'arbre de défaillances développé au paragraphe 4.9.5.2 (Figure 4.15).

#### 4.9.5.5 Détermination de la fréquence du scénario « Incendie-explosion »

Afin d'estimer la fréquence du scénario « Incendie-explosion », ce dernier est représenté sur l'AdE de la Figure 4.15.

Les résultats d'application de la méthode arbre des événements pour l'analyse et l'évaluation du risque incendie-explosion provoqué par la défaillance des systèmes de détection de venue

et le système BOP et en se référant aux données du [Tableaux 4.5](#), sont résumés dans le [Tableaux 4.6](#).

<i>Conséquence</i>	<i>Fréquence (/an)</i>
- Fermeture du puits	0.00483
- Explosion de gaz + incendie	0.000534
- Explosion + Formation d'un nuage de gaz extrêmement inflammable	0.0000165

**Tableau 4.6** - Résultats d'application de l'AdE l'évaluation du risque incendie-explosion

Au vu des résultats obtenus ([Tableaux 4.6](#)), il ressort que la survenance de l'une des causes suivantes :

- Pression interstitielle de formation supérieure au poids de la boue;
- Trou non rempli de boue lors de l'extraction;
- Écouvillonnage pendant le déclenchement;
- Perte de circulation de boue ;
- Coupe de boue;

Peut conduire à une venue et par conséquent provoquer un incendie et une explosion selon la réponse des barrières de sécurité de prévention disponibles. Notons à ce niveau que la fréquence d'occurrence de la venue et la probabilité de défaillance du système BOP sont des données de l'entreprise SONATRACH.

Dans la première séquence par exemple, la survenue de l'évènement initiateur (venue) est détectée par les capteurs de débit de boue en sortie du puits: c'est la méthode de détection la plus directe et la plus précoce d'une venue. Elle repose sur la comparaison du débit de boue en entrée ( $Q_{in}$ ) et en sortie du puits ( $Q_{out}$ ). Si  $Q_{in} > Q_{out}$ : indice de perte; si  $Q_{in} < Q_{out}$ : indice de venue. L'opérateur remarque également les changements de flux et les changements de volume. En effet, une modification du volume de boue dans les bacs sera donc un signe de déséquilibre du puits. En particulier, une venue se manifestera par une augmentation du niveau des bacs et les seuils d'alarmes sont réglés par le foreur dans cet objectif. Lorsqu'une venue est détectée, le puits doit être fermé par le système BOP. La non réponse de ce dernier conduira à une éruption et en cas de présence d'une source d'ignition immédiate ou retardée une explosion de gaz et un incendie peuvent se produire.

En comparant la fréquence d'occurrence du phénomène accidentel « explosion de gaz – incendie » au risque tolérable (0.00001/an) établi par l'entreprise SONATRACH ([SOF CONSEIL et al., 2008](#)), le risque globale d'incendie est jugé inacceptable avec une fréquence de 0.000534/an.

D'où la nécessité d'une analyse plus approfondie des barrières de sécurité afin de réduire leurs probabilités de défaillance et améliorer ainsi la sécurité du système étudié.

#### 4.10 Conclusion

L'application proposée dans ce chapitre a permis de valider et d'illustrer notre approche dédiée au diagnostic des défauts d'un système industriel complexe en utilisant les réseaux de neurones. Le système industriel choisi pour l'application est très utile dans le forage des puits de pétrole et de gaz, c'est le système anti-éruption «BOP». En premier lieu nous avons présenté en détail le fonctionnement ainsi que les différents composants du système BOP et puis nous avons appliqué l'approche proposée à la détection et le diagnostic des défauts du BOP. L'utilisation de l'analyse HAZOP nous a permis de tirer les données nécessaires à l'apprentissage du réseau neuronal. Vous avons utilisé trois modèles neuronaux à savoir MLPN, RBFN et GRNN, pour détecter et diagnostiquer les causes des défaillances du système BOP. Une comparaison des performances d'apprentissage et de test des ces trois modèles est effectuée. Les performances des modèles ont été évaluées à l'aide de trois mesures statistiques:  $R^2$ , RMSE et MAE. La valeur élevée de  $R^2$  et la faible valeur de RMSE dans l'ensemble de test indiquent que les modèles appliqués peuvent être utilisés pour la détection et le diagnostic de défauts. Cette étude a montré que le modèle GRNN est le meilleur parmi les trois modèles neuronaux en ce qui concerne les statistiques  $R^2$ , RMSE et MAE et aussi le temps d'exécution. En conséquence, le modèle GRNN offre une précision et des performances nettement meilleures que le RBFN et le MLPN. Les résultats de cette étude ne se limitent pas au système BOP uniquement, ils peuvent être améliorés pour couvrir d'autres systèmes industriels.

Enfin, une évaluation du risque incendie lié à l'éruption du puits pétro-gazier, a été effectuée en utilisant les méthodes d'analyse des risques AdD et AdE. Les résultats de cette évaluation ont montré que le risque globale d'incendie est jugé inacceptable par rapport au risque tolérable établi par l'entreprise SONATRACH. D'où la nécessité d'une analyse plus approfondie des barrières de sécurité, afin de réduire leurs probabilités de défaillance et améliorer ainsi la sécurité du système étudié.

# Conclusion Générale et Perspectives

---

De nos jours, les systèmes industriels se sont multipliés de manière large et complexe, qu'il s'agisse d'unités de production (raffineries de pétrole, centrales nucléaires), de moyens de transport (avions, trains), ou autres ... Ils résultent souvent de l'interconnexion de plusieurs sous-systèmes. Ainsi, il est évident ou intuitif de savoir si tout se passe bien dans un système. Dans ce but, la surveillance des systèmes industriels permet la détection et le diagnostic de défauts. Ainsi, plus un défaut est rapidement détecté, et correctement diagnostiqué, et plus la production du système sera conforme aux exigences requises, dans les conditions de sécurité requises. Nous avons ainsi proposé un modèle de diagnostic des défauts d'un système industriel par réseaux de neurones. L'objectif de cette thèse était de développer une nouvelle approche qui combine les méthodes d'analyse de risque et les outils de diagnostic dans un algorithme commun dans le but de détecter les défauts révélés et de les classer en temps réel. L'outil utilisé à cette fin était MATLAB, utilisant des outils de la boîte à outils de réseau neuronal artificiel.

Il a été démontré, tel qu'il est indiqué dans la littérature et dans le contenu de ce document, que les réseaux de neurones constituent une bonne méthode de détection des défauts et qu'elle identifie précisément les défauts. La présente étude a également confirmé leur application et que de bons résultats peuvent être obtenus en utilisant les réseaux de neurones, avec un apprentissage approprié à l'aide de données d'apprentissage validées. Trois modèles neuronaux à savoir: le MLPN, le RBFN et le GRNN, ont été utilisés pour détecter et diagnostiquer les causes des défaillances du système BOP, en utilisant les données de l'analyse HAZOP. Une comparaison des performances d'apprentissage et de test des trois modèles a été effectuée. Les performances des modèles ont été évaluées en terme de critères statistiques  $R^2$ , RMSE et MAE et de temps d'exécution pour les phases d'apprentissage et de test. Cette étude a montré que le modèle GRNN est le meilleur parmi les trois modèles neuronaux en ce qui concerne les critères statistiques et le temps d'exécution. En conséquence, le modèle GRNN offre une précision et des performances nettement meilleures que le RBFN et le MLPN.

Dans le premier chapitre, nous avons présenté un aperçu des techniques habituellement utilisées pour résoudre des problématiques de diagnostic des défauts. Un ensemble de critères d'évaluation de performances et leur impact sur les principales fonctions de la surveillance et du diagnostic ont été discutés. Ce chapitre a fourni une étude bibliographique générale mais non exhaustive sur les méthodes de diagnostic de défauts. Les techniques les plus populaires de chaque catégories ont été présentées, telles que l'espace de parité, les observateurs, les modèles causaux, le système expert, l'ACP, les RNA, etc. Nous avons alors, sur la base de plusieurs critères, effectué un choix parmi les outils présentés dans les méthodes basées sur l'historique du processus. Ce choix s'est porté sur les réseaux de neurones.

Suite au choix de cet outil, nous avons présenté les réseaux de neurones de manière plus approfondie dans le second chapitre. Après la définition du principe de fonctionnement de plusieurs modèles neuronaux et particulièrement les modèles, PMC et RBF. Une comparaison de la performance de cinq algorithmes à rétropropagation (TRAINGDM, TRAINGD, TRAINBFG, TRAINGDA, TRAINGDX et TRAINLM) a été effectuée à l'aide d'un exemple

courant. Il a été constaté que la méthode de Levenberg-Marquardt TRAINLM a obtenu les meilleures performances par rapport aux autres algorithmes.

Dans un troisième chapitre, nous nous sommes intéressés à la présentation de notre approche relative au diagnostic des défauts d'un système industriel en utilisant les réseaux de neurones. Nous avons proposé une méthodologie qui combine un outil d'analyse des risques et les réseaux de neurones. Trois modèles neuronaux ont été proposés, à savoir: le MLP, le RBF et le GRNN. Face à la pluralité des outils d'analyses de risque existants, nous avons opté pour l'analyse HAZOP. Les résultats de l'analyse HAZOP sont pris en compte en tant que connaissances expertes lors de la procédure de diagnostic grâce à l'information provenant des relations de type cause/effet. Enfin, nous avons montré à travers un exemple l'efficacité de la combinaison de la méthode AMDE et des réseaux de neurones du type RBF pour le diagnostic du MCC.

Le dernier chapitre a permis d'illustrer la méthodologie proposée sur un exemple concret: le système anti-éruption - BOP. Nous avons alors pu voir les résultats de notre approche sur l'un des éléments les plus importants de l'équipement de contrôle de puits. En plus, une comparaison de la performance des trois modèles neuronaux qui ont été appliqués au diagnostic des défauts du système BOP a été faite. Les résultats obtenus ont montré que le modèle GRNN offre une précision et des performances nettement meilleures que les modèles RBFN et le MLPN, il semble être plus robuste pour la détection et le diagnostic des défauts susceptibles d'affecter le fonctionnement du système BOP. Enfin, une évaluation du risque incendie lié à l'éruption du puits pétro-gazier, a été effectuée. Les résultats de cette évaluation ont montré que le risque global d'incendie est jugé inacceptable. D'où la nécessité d'une analyse plus approfondie des barrières de sécurité, afin de réduire leurs probabilités de défaillance et améliorer ainsi la sécurité du système étudié.

Le travail mené durant cette thèse a ouvert le champ à plusieurs perspectives :

La piste de détection et diagnostic à l'aide des réseaux de neurones a été testée sur un exemple réel. Les résultats nous encouragent à approfondir la méthode et à l'améliorer, par exemple en la testant sur une base de données d'apprentissage et de validation de plus grande taille. Dans ce travail, nous nous sommes intéressés au diagnostic du système dans le cas où le défaut détecté est un défaut connu. En pratique, ceci n'est pas toujours vrai. De plus l'analyse HAZOP considère simplement les dérives de paramètres de fonctionnement du système, elle ne permet pas d'analyser les événements résultants de la combinaison simultanée de plusieurs défaillances. Ainsi, dans nos prochains travaux nous allons nous intéresser à l'amélioration de la base de connaissances du réseau neuronal pour être capable de proposer les actions de détection et de diagnostic:

- dans le cas d'apparition d'un nouveau défaut,
- et dans le cas d'apparition d'évènements résultants de la combinaison simultanée de plusieurs défaillances,

et cela en utilisant la combinaison d'autres méthodes, tel que, par exemple la méthode AdD.

L'approche proposée ne se limite pas au système BOP uniquement; elle peut être améliorée pour couvrir d'autres systèmes industriels.

# Bibliographie

---

- Agrawal, V., Panigrahi, B.K. & Subbarao, P.M.V. (2015). Review of control and fault diagnosis methods applied to coal mills. *Journal of Process Control*, 32, pp. 138-153.
- Aguilar-Martin. J, (1999). Knowledge-based supervision and diagnosis of complex process. *IEEE International Symposium on Intelligent Control, Intelligent Systems and Semiotics (ISI'99)*, Cambridge, USA, pp. 225-230.
- Alhaj Dibo, M. (2005). *Validation de données et diagnostic des systèmes incertains à l'aide de l'analyse par intervalle*. Doctorat de l'Institut National Polytechnique de Lorraine, Nancy, France.
- Anani, K . (2019). *Diagnostic de systèmes non linéaires par analyse en composantes principales à noyau*. Thèse de doctorat de l'Université de Lorraine. France.
- Anderson, D. & McNeill G. (1992). *Artificial neural networks technology*. utica, new york : Griffiss AFB.
- Attoui, I., Oudjani, B., Richi, W., Chettah, K., Fergani, N. & Boutassetta, N. (2017). Fault diagnosis of rotating machinery based on vibration signal analysis. Dans *3rd International Conference On Advances in Mechanical Engineering*.
- Bachir, S. (2002). *Contribution au diagnostic de la machine asynchrone par estimation paramétrique*. Thèse de doctorat de l'université de Poitiers.
- Basseville, M. & Cordier M.O. (1996). *Surveillance et diagnostic de systèmes dynamiques: approche complémentaire du traitement de signal et de l'intelligence artificielle*, Rapport INRIA N°2861.
- Barto, A. G. (1992). *Reinforcement learning and adaptive critic methods*. In D. White & D.
- Baybutt, P. (2015). A critique of the Hazard and Operability (HAZOP) study. *J. Loss Prev. Process Ind.* 33, pp. 52–58.
- Beale, M.H., & Demuth, H.B. (2007). *Neural Network Toolbox User's Guide, version 5.1*. The MathWorks Inc.
- Bekkari, N. & Zeddouri, A. (2019). Using artificial neural network for predicting and controlling the effluent chemical oxygen demand in wastewater treatment plant. *Management of Environmental Quality: An International Journal*, 30 (3), pp. 593-608.
- Bedford, T. & Cooke, R. (2001). *Probabilistic Risk Analysis: Foundations and methods*. Cambridge University Press.



- Bendu, H., Deepak, B.B.V.L. & Murugan, S. (2016). Application of GRNN for the prediction of performance and exhaust emissions in HCCI engine using ethanol. *Energy Conversion and Management*, 122, pp. 165-173.
- Bernauer, E. (1996). *Les réseaux de neurones et l'aide au diagnostic : un modèle de neurones bouclés pour l'apprentissage de séquences temporelles*. Thèse de doctorat, LAAS/Toulouse.
- Bhavaraju, K. M., Kankar, P.K, Sharma, S. C. & Harsha. S.P. (2010). A Comparative Study on Bearings Faults Classification by Artificial Neural Networks and Self-Organizing Maps using Wavelets. *International Journal of Engineering Science and Technology*, 2 (5), pp. 1001-1008.
- Bharadwaj, R. M. & Parlos, A. G. (2004). Neural Speed Filtering for Induction Motors With Anomalies and Incipient Faults. *IEEE/ASME Transactions On Mechatronics*, 9(4), 679-688.
- Boukra T., Lebaroud, A. & Guy, C. (2009). Statistical and Neural-Network Approaches for the Classification of Induction Machine Faults Using the Ambiguity Plane Representation. *IEEE Transactions on Industrial Electronics*, 60, pp. 4034 – 4042.
- Boumegoura, T. (2001). *Recherche de signature électromagnétique des défauts dans une machine asynchrone et synthèse d'observateurs en vue du diagnostic*. Thèse de doctorat de l'école centrale de Lyon, France.
- Bourret, P., Reggia, J. & Samuelides, M. (1991). *Réseaux neuronaux*. Une approche connexionniste de l'intelligence artificielle. Teknea, Toulouse, Octobre 1991.
- Bishop. C. M. (1995). *Neural Networks for Pattern Recognition*. Oxford University Press, New York, USA.
- Broomhead, D.S. & Lowe, D. (1988). Multivariable functional interpolation and adaptive networks. *Complex Systems*, 2, pp. 321-355.
- Bui, K.-T.T., Bui, D.T., Zou, J., Doan, C.V. & Revhaug, I. (2018). A novel hybrid artificial intelligent approach based on neural fuzzy inference model and particle swarm optimization for horizontal displacement modeling of hydropower dam. *Neural Computing and Applications*, 29, pp. 1495-1506.
- Burns, R. (2001). *Advanced Control Engineering*. butterworth-heinemann.
- Cai, B., Liu, Y., Fan, Q., Zhang, Y., Yu, S., Liu, Z. & Dong, X. (2013). Performance evaluation of subsea BOP control systems using dynamic Bayesian networks with imperfect repair and preventive maintenance. *Eng. Appl. Artif. Intell.*, 26(10), pp. 2661-2672.
- Cai, BP., Liu, YH., Liu, ZK., Tian, XJ. & Zhang, YZ.( 2012). Performance evaluation of subsea blowout preventer systems with common-cause failures. *Journal of Petroleum Science and Engineering*, 90-91, pp. 18-25.
- Cai, B., Liu H., & Xie, M. (2016). A real-time fault diagnosis methodology of complex systems using object-oriented Bayesian networks. *Mech. Syst. Signal Process.*, 80, pp. 31-44.

- Cai, B., Liu, Y., Zhang, Y., Fan, Q. & Yu, S. (2013). Dynamic Bayesian networks based performance evaluation of subsea blowout preventers in presence of imperfect repair. *Expert Systems with Applications*, 40(18), pp. 7544-7554.
- Carpenter, C. A. & Grossberg, S. (1988). The art of adaptive pattern recognition by a self-organizing neural network. *Computer*, 21 (3), pp. 77- 88.
- Chakour, C. (2016). *Diagnostic et surveillance des procédés industriels et de leur environnement sur la base de l'analyse de données*. Thèse de doctorat de Faculté des Sciences de l'Ingénierat, Département d'Electronique, Annaba, Algérie.
- Chang, W.Y. (2013). Wind energy conversion system power forecasting using radial basis function neural network. *Applied Mechanics and Materials*, 284-287, pp. 1067-1071.
- Chang, C. C. & Yu, C. C. (1990). On-line fault diagnosis using the signed directed graph. *Industrial and Engineering Chemistry Research*, 29 (7), pp. 1290 -1299.
- Chantler, M. J., Coghill, G. M., Shen, Q. & Leitch, R. R. (1998). Selecting tools and techniques for model-based diagnosis. *Artificial Intelligence in Engineering*, 12(1-2), pp. 81-98.
- Chatain. J. N. (1993). *Diagnostic par systèmes experts*. Hermes, Paris.
- Chavarnakul, T. & Enke, D. (2008). Intelligent technical analysis based equivolume charting for stock trading using neural networks. *Expert Syst Appl*, 34(2), pp. 1004–1017.
- Center for Chemical Process Safety (CCPS) (1985). *Guidelines for hazard evaluation procedures*. New York: American Institute of Chemical Engineering.
- Chebira, S., Bourmada, N., Boughaba, A. & Djebabra, M. (2020). Fault diagnosis of blowout preventer system using artificial neural networks: a comparative study. *International Journal of Quality & Reliability Management*; Vol. ahead-of-print No. ahead-of-print. <https://doi.org/10.1108/IJQRM-07-2019-0249>
- Chemachema, K. & Benghalia, A. (2012). Neural models for Input Impedance of Aperture Coupled Rectangular Patch Antenna. *International Review of Aerospace Engineering*, 5(3), pp. 89-93.
- Chen, S., Cowan, S.F. & Grant, P.M. (1991). Orthogonal least squares learning algorithm for radial basis function networks. *Neural Networks*, 2 (2), pp. 302-309.
- Chen, J. & Patton, R. J. (1999). *Robust Model-Based Fault Diagnosis for Dynamic Systems*. Kluwer Academic Publishers.
- Chiang, L. H., Evan, Russell, L. & Braatz, R. D. (2001). *Fault detection and diagnosis in industrial systems*. New York : Springer-Verlag.
- Chine, W., Mellit, A., Lughy, V., Malek, A., Sulligoi, G. & Pavan, A. M. (2016). A novel fault diagnosis technique for photovoltaic systems based on artificial neural networks. *Renewable Energy*, 90, pp. 501-512.

- Chiremsel, Z., Nait Said, R. & Chiremsel, R. (2016). Probabilistic fault diagnosis of safety instrumented systems based on fault tree analysis and Bayesian network. *J Fail Anal Prev.*, 16(5), pp. 747-760.
- Chow, E.Y. (1980). *A failure detection system design methodology*. PhD thesis. Department of Electrical Engineering and Computer Science, Massachusetts Institute of Technology. Cambridge, Massachusetts.
- Chow, E. Y. & Willsky, A. S. (1984). Analytical redundancy and the design of robust failure detection systems. *IEEE Transactions on Automatic Control*, 29 (7), pp. 603-614.
- Cigizoğlu, H. K. (2005). Application of generalized regression neural networks to intermittent flow forecasting and estimation. *J. Hydrol. Engng ASCE*, 10(4), pp. 336-341.
- Cigizoglu, H. K. & Kişi, O. (2004). Flow prediction by three back propagation techniques using k-fold partitioning of neural network training data. *Nordic Hydrol.*, 36(1), pp. 49-64.
- Cocquempot, V. (2004). *Contribution à la surveillance des systèmes industriels complexes*. habilitation à diriger des recherches, université des sciences et technologies de Lille, France.
- Combacau M. (1991). *Commande et surveillance des systèmes à événements discrets complexes: application aux ateliers flexibles*. Thèse de Doctorat, Université P. Sabatier de Toulouse.
- Crowther, W.J., Edge, K.A., Burrows, C.R., Atkinson, R.M. & Woollons, D.J. (1998). Fault diagnosis of a hydraulic actuator circuit using neural networks: An output vector space classification approach. *Journal of Systems and Control Engineering*, 212(1), pp. 57-68.
- Cui, S. & Sun, L. (2019). Sensor fault detection and isolation of electromechanical actuator based on structural residual parity space. *The Proceedings of the 2018 Asia-Pacific International Symposium on Aerospace Technology (APISAT 2018)*, pp. 2574-2585.
- Cybenko, G. (1989). Approximation by superpositions of a sigmoidal function. *Mathematics of Control. Signals and Systems*, 2 , pp. 303-314.
- Dai, X. & Gao, Z. (2013). From model, signal to knowledge :a data-driven perspective of fault detection and diagnosis. *IEEE Trans. Ind. Inf.*, 9 (4), pp. 2226-2238.
- Das, A., Maiti, J. & Banerjee, R.N. (2012). Process monitoring and fault detection strategies: a review. *International Journal of Quality & Reliability Management*, 29 (7), pp. 720-752.
- Davalo, E. & Naim, P. (1989). *Des réseaux de neurones*, Editions Eyrolles.
- Davis, R. (1984). Diagnosis reasoning based on structure and behavior. *Artificial Intelligence*, 24 (1-3), pp. 347- 410.
- De Kleer, J. & Brown, S. (1984). A qualitative physics based on confluences. *Artificial Intelligence*, 24 (1-3), 7-83.

- De León, H-R-H. (2006). Supervision et diagnostic des procédés de production d'eau potable. Thèse de doctorat de l'institut des sciences appliquées de Toulouse, France.
- DeepwaterHorizonStudyGroup, DHSG. (2011). *Final report on the investigation of the Macondo well blowout*. University of California, Berkeley, USA: Center for Catastrophic Risk Management (CCRM).
- Ding, S.X. (2014). Data-driven design of monitoring and diagnosis systems for dynamic processes: a review of subspace technique based schemes and some recent results. *Journal of Process Control*, 24(2), pp. 431–449.
- Disornetiwat, P. (2001). *Global stock index forecasting using multiple generalized regression neural networks with a gating network*. PhD Thesis, University of Missouri-Rolla, USA.
- Dreyfus, G., Martinez, J., Samuelides, M., Gordon, M., Badran, F., Thiria, S. & Héroult, L. (2002). *Réseaux de neurones : méthodologie et applications*. Eyrolles, Paris.
- Dubuisson B. (1990). *Diagnostic et reconnaissance des formes*, Editions Hermès, Paris.
- Dubuisson, B., Boutleux, E., Dague, P., Denoeux, T., Didelet, E., Gandvalet, Y. & Masson, M. (2001). Diagnostic, Intelligence Artificielle et reconnaissance des formes. *Editions Hermès*, Paris.
- Duda, R. O., Hart, P. E. & Stork, D. G. (2001). *Pattern Classification 2nd edition*. Wiley.
- Elosta, W. (2005). *Surveillabilité structurelle et platitude pour le diagnostic des modèles Bond Graph couplés*, Thèse de doctorat, Université des sciences et technologie de Lille, France.
- Dunjó, J., Fthenakis, V., Vilchez, J.A. & Arnaldos, J. (2010). Hazard and operability (HAZOP) analysis. A literature review. *Journal of Hazardous Materials*, 173(1-3), pp. 19-32.
- Eltoft, T. & deFigueiredo R. (1998). A new neural network for cluster detection and labeling. *IEEE Transactions on neural networks*, 9(1), pp. 1021-1035.
- Esen, H., Inalli, M., Sengur, A. & Esen, M. (2008). Artificial neural networks and adaptive neuro-fuzzy assessments for ground-coupled heat pump system. *Energy and Buildings*, 40(6), pp. 1074-1083.
- Fan, Y. & Li, C.J. (2002). Diagnostic rule extraction from trained feedforward neural networks. *Mechanical Systems and Signal Processing*, 16(6), pp. 1073-1081.
- Fentaye, A.D., Baheta, A.T. & Gilani, S.I.U-H. (2018). Gas turbine gas-path fault identification using nested artificial neural networks. *Aircraft Engineering and Aerospace Technology*, 90(6), pp. 992-999.
- Flaus, J. (2004). Cours de sécurité générale, filière PRIHSE, Grenoble.
- Fouille, A. (1986). Electrotechnique à l'usage des ingénieurs. *Machines continues, électronique de puissance, tome III*. Dunod, Paris.

- Franceschini, F., Galetto, M. & Turina, E. (2013). Techniques for impact evaluation of performance measurement systems. *International Journal of Quality & Reliability Management*, 30 (2), pp. 197-220.
- Frank, P.M. (1990). Fault diagnosis in dynamic systems using analytical and knowledge based redundancy. a survey and some new results. *Automatica*, 26(3), pp.459-474.
- Frank, M. P. & Köppen-Seliger, B. (1997). New Developments Using AI in Fault Diagnosis, *Engng Applic. Artif. Intell.*, 10(1), pp. 3-14.
- Frank, P. (1987). Advanced Fault Detection and Isolation Schemes Using Nonlinear and Robust Observers. *Proceedings of 10th IFAC Congress on automatic control*, Munich, Germany, 20(5), part 3, pp. 63-68.
- Fraser, D., Lindley, R., Moore, D. & Staak, M.V. (2014). Early kick detection methods and technologies. *In SPE Annual technical conference and exhibition*.
- Froquet, L. (2005). *Contribution a l'analyse des risques : proposition d'une méthode par scénarios et capitalisation de connaissance*. PhD thesis, Automation Laboratory of Grenoble (LAG), INPG, Grenoble, France.
- Gao, Z., Cecati, C. & Ding, S. X. (2015). A survey of fault diagnosis and fault-tolerant techniques—part I : Fault diagnosis with model-based and signal-based approaches. *IEEE Transactions on Industrial Electronics*, 62(6), pp. 3757-3767.
- Gentil, S. (2003). *Commande et supervision – les procédés agroalimentaires 2*, Traité IC2 Systèmes Automatisés, Editions Hermes, Chapitre 4: Supervision et diagnostic, pp. 101-135.
- Gertler, J. (1997). Fault detection and isolation using parity relations. *Control Engineering Practice*, 5(5), pp. 653-661.
- Gertler, J. J. (1998). *Fault Detection and Diagnosis in Engineering Systems*. New York: Marcel Dekker.
- Giardina, M. & Morale, M. (2015). Safety study of an LNG regasification plant using an FMECA and HAZOP integrated methodology. *Journal of Loss Prevention in the Process Industries*, 35, pp. 35-45.
- Gourine, B., Mahi, H., Khoudiri, A. & Laksari, Y. (2012). The GRNN and the RBF Neural Networks for 2D Displacement Field Modelling. Case study: GPS Auscultation Network of LNG reservoir (GL4/Z industrial complex – Arzew, Algeria). *TSOIF - Dam and Reservoir Engineering Surveying*, 5684, pp. (2/17, 17/17).
- Grace, R., Cudd, D., Carden, R. S. & Shursen, J. L. (2003). *Blowout and well control handbook*. 1st Edition, Elsevier.
- Guernez, C., Cassar, J. P. & Staroswiecki, M. (1997). Extension of parity space to non linear polynomial dynamic systems. *IFAC Proceedings Volumes*, 30(18), pp. 857-862.

- Guh, R. (2002). Robustness of the neural network based control chart pattern recognition system to non-normality. *International Journal of Quality & Reliability Management*, 19(1), pp. 97-112.
- Guo, J., Liu, Y., Xu, X. & Chen, Q. (2010). Integrated distributed bond graph modeling and neural network for fault diagnosis system of hydro turbine governors. *Kybernetes*, 39 (6), pp. 925-934.
- Guo, L. & Kang, J. (2015). An extended HAZOP analysis approach with dynamic fault tree. *Journal of Loss Prevention in the Process Industries*, 38, pp. 224-232.
- Guo, L.J. & Kang, J.X. (2015). A hybrid process monitoring and fault diagnosis approach for chemical plants. *Int. J. Chem. Eng.*, vol. 2015.
- Guo, L., Zhang, Y.-M, Wang, H. & Fang, J.-C. (2006). Observer-based optimal fault detection and diagnosis using conditional probability distributions. *IEEE Transactions on Signal Processing*, 54(10) , pp. 3712–3719.
- Hafaifa, A., Guemana, M. & Daoudi, A. (2015). Vibrations supervision in gas turbine based on parity space approach to increasing efficiency, *Journal of Vibration and Control*, 21(8), pp.1622-1632.
- Hagan, M., Demuth, H. & Beale M. (1995). *Neural Network Design*. PWS Publishing Company.
- Hagan, M.T., Demuth, H.B. & Beale, M. (1996). *Neural network design*. PWS Publishing Company, Boston, Massachusetts.
- Hagan, M.T. & Menhaj, M. (1994). Training feed-forward networks with the Marquardt algorithm. *IEEE Trans. Neural Netw.* 5 (6), pp. 989-993.
- Han, W., Wang, Z. & Shen, Y. (2018). Fault estimation for a quadrotor unmanned aerial vehicle by integrating the parity space approach with recursive least squares. *Proceedings of the Institution of Mechanical Engineers, Part G : Journal of Aerospace Engineering*, 232(4), pp. 783–796.
- Han, C.J. & Zhang, J. (2013). Study on well hard shut-in experiment based on similarity principle and erosion of ram rubber. *Eng. Fail. Anal.* 32, 202-208.
- Harmouche, J., Delpha, C. & Diallo, D. (2015). Incipient fault detection and diagnosis based on Kullback-Leibler divergence using principal component analysis: Part II. *Signal Process*, 109, pp. 334-344.
- Haykin, S. (1994). *Neural Networks: A comprehensive Foundation*. Macmillan College Publishing Company, Inc., New York.
- He, R., Li, X., Chen, G., Wang, Y., Jiang, S. & Zhi, C. (2018). A quantitative risk analysis model considering uncertain information. *Process Saf. Environ. Protect.* 118, 361–370.
- Hebb, D.O. (1949). *The organization of behavior*. John Wiley & son, New York, USA.

- Heo, S. & Lee, J. H. (2018). Fault detection and classification using artificial neural networks. *IFAC-PapersOnLine*, 51(18), pp. 470-475.
- Hertz, J., Krogh, A. & Palmer, R.G. (1991). *Introduction to the theory of neural computation*. Addison-Wesley, Reading, Assachusetts.
- Hérault, J. & Jutten, C. (1994). *Réseaux neuronaux et traitement du signal*. Hermès, Paris.
- Hertz, J., Krogh, A. & Palmer, R. G. (1991). *Introduction to the Theory of Neural Computation*. volume 1. Addison-Wesley, Redwood City, C.A.
- Höfling, T. & Pfeufer, T. (1994). Detection of additive and multiplicative faults, parity space vs. parameter estimation. In *IFAC Symposium on Fault Detection Supervision and Safety for Technical Process*, pp. 539–544, Helsinki, Finland.
- Höfling, T. & Isermann, R. (1996). Fault detection based on adaptative parity equations and single-parameter tracking. *Control Engineering Practice*, 4(10), pp.1361-1369.
- Holand, P. & Awan, H. (2012). *Reliability of Deepwater Subsea BOP systems and Well Kicks*. Technical report, Exprosoft AS.
- Hoepffner, L. (1989). Analysis of the HAZOP study and comparison with similar safety analysis systems. *Gas Separation & Purification*, 3(3), pp. 148-151.
- Hopfield, J.J. (1982). Neural networks and physical Systems with emergent collective computational abilities. *Proceeding Nat. Acad. Sci. USA, Biophysics*, 79, pp. 2554-2558.
- Hu, J., Zhang, L., Cai, Z. & Wang, Y. (2015). An intelligent fault diagnosis system for process plant using a functional HAZOP and DBN integrated methodology. *Engineering Applications of Artificial Intelligence*, 45, pp. 119-135.
- Huang, Y.Z., Huang, R.-M., Bing, M.-O. & Wen Yean, F.-U. (2018). Research on human motion recognition based on GRNN and PNN. *Computer Knowledge and Technology*, 1(1), pp. 264-267.
- Hunt, K. J., Sbarbaro, D., Zbikowski, R. & Gawthrop, P. J. (1992). Neural networks for control systems- A survey. *Automatica*, 28(6), pp. 1083-1112.
- IEC61882. *Hazard and Operability Studies (HAZOP studies)–Application Guide*. (2001). International Electrotechnical Commission (IEC).
- Iri, M., Aoki, K., O’Shima, E. & Matsuyama, H. (1979). An algorithm for diagnosis of system failures in the chemical process. *Computers and Chemical Engineering*, 3 (1-4), pp. 489-493.
- Isermann, R. (1993). Fault diagnosis of machines via parameter estimation and knowledge processing - tutorial paper. *Automatica*, 29(4), pp. 815–835.
- Isermann, R. (1997). Supervision, Fault-Detection and Fault-Diagnosis Methods – An Introduction. *Control Eng. Practice*, 5, pp. 639-652.

- Isermann, R. (1984). Process fault detection based on modeling and estimation methods—a survey. *Automatica*, 20(4), pp. 387-404.
- Isermann, R. (2006). *Fault-diagnosis systems: an introduction from fault detection to fault tolerance*. Springer Verlag.
- Isermann, R. & Ballé, P. (1997). Trends in the application of model-based fault detection and diagnosis of technical processes. *Control Eng. Practice*, 5(5), pp. 709–719.
- ISO, PD/IEC. (2002). *Guide 73:2002 Risk management - Vocabulary - Guidelines for use in standards*. British standards institution.
- Jack, L.B. & Nandj, A.K. (2000). Genetic algorithms for feature extraction in machine condition monitoring with vibration signals. *IEE Proceedings of Vision and Image Signal Processing*, 147 (3), pp. 205-212.
- Jodouin, J.-F. (1994). *Les Réseaux de Neurones : Principes et Définitions*. Hermès, Paris.
- Jordan, W. & Marshall, G. (1972), Failure modes, effects and criticality analysis, in *Annual Reliability and Maintainability Symposium*, San Francisco, California.
- Kankar, P.K., Satish, C. Sharma & Harsha, S.P. (2011). Fault diagnosis of ball bearings using machine learning methods. *Expert Systems with Applications*, 38, pp.1876–1886.
- Katipamula, S. & Brambley, M. (2005). Methods for fault detection, diagnosis, and prognostics for building systems – A review, Part I. *International Journal of HVAC&R Research*, 11(1), pp. 3-25.
- Kempowsky, T. (2004). Surveillance de procédés à base des méthodes de classification: Conception d'un outil d'aide pour la détection et le diagnostic de défaillances. Thèse de doctorat de l'institut des sciences appliquées de Toulouse.
- Khakzad, N., Khan, F. & Amyotte, P. (2013). Quantitative risk analysis of offshore drilling operations: A bayesian approach. *Safety Science*, 57, pp. 108-117.
- Khan, F.I. & Abbasi, S.A. (1997). OptHAZOP: an effective and optimum approach for HAZOP study. *J Loss Prevent Proc.*, 10(3), pp. 191-204.
- Kim, S., Chung, S. & Yang, Y. (2014). Availability analysis of subsea blowout preventer using Markov model considering demand rate. *Int. J. Nav. Archit. Ocean Eng.*, 6(4), pp.775-787.
- Kim, B., Kim, S. & Kim, K. (2003). Modeling of plasma etching using a generalized regression neural network. *Vacuum*, 71(4), pp. 497–503.
- Kisi, O. (2008) .The potential of different ANN techniques in evapotranspiration modeling. *Hydrol. Process*. 22(14), pp. 2449–2460.
- Kisi, O., Tombul, M. & Kermani, M.Z. (2014). Modeling soil temperatures at different depths by using three different neural computing techniques. *Theoretical and Applied Climatology*, 121(1–2), pp. 377-387.



- Kleer, J.D. & Williams, B.C. (1987). Diagnosing multiple faults. *Artificial intelligence*, 32(1), pp. 97-130.
- Kletz, T.A. (1986). *HAZOP & HAZAN notes on the identification and assessment of hazards*. Rugby, UK: The Institution of Chemical Engineers.
- Kletz, T.A. (2009). ICI's contribution to process safety. *Rugby: IChemE*. (Symposium series, Vol. 155).
- Kocabas, F. & Unal, S. (2010). Compared techniques for the critical submergence of an intake in water flow. *Adv Eng Softw*, 41(5), pp. 802–809.
- Kohonen T. (1982). Analysis of a simple self-organizing process. *Biological Cybernetics*, 44(2), pp. 135-140.
- Kohonen, T. (1995). Self-organizing maps. *Springer Series in Information Sciences*. 30.
- Koivo, H.N. (1994). Artificial neural networks in fault diagnosis and control. *Control Engineering Practice*, 2(1), pp. 89-101.
- Korbicz J., Koscielny J.M., Kowalczyk Z. & Cholewa W. (Eds.). (2004). *Fault Diagnosis, Models, Artificial Intelligence, Applications*. Springer.
- Korbicz, J., Obuchowicz, A. & Patan, K. (1998). Network of dynamic neurons in fault detection systems. *Proc. IEEE Int. Conf. Systems, Man and Cybernetics*, San Diego, USA, CD-ROM.
- Knowlton, R.E. (1989). *Hazard and operability studies: the guide word approach*. Vancouver: Chematics International Company.
- Ladlani, I., Houichi, L., Djemili, L., Heddami, S. & Belouz, K. (2012). Modeling daily reference evapotranspiration (ET<sub>0</sub>) in the north of Algeria using generalized regression neural networks (GRNN) and radial basis function neural networks (RBFNN): a comparative study. *Meteorology and Atmospheric Physics*, 118 (3-4), pp. 163-178.
- Lahaie, F. (2015). Contexte et aspects fondamentaux du forage et de l'exploitation des puits d'hydrocarbures, *rapport INERIS réf. DRS-15-149641-01420A*.
- Lawley, H.G. (1974). Operability studies and Hazard Analysis. *Chemical Engineering Progress*, 70(4), pp. 45–56.
- Lawley, H.G. (1976). Size up plant hazards this way. *Hydrocarbon Processing*, pp. 247-261.
- Le Cun Y. (1985). Une procédure d'apprentissage pour réseau à seuil asymétrique. *Cognitiva*, 85, pp. 599-604.
- Lees, F. (2004). *Lees' loss prevention in process industries: hazard identification, assessment and control*. Butterworth-Heinemann.

- Lee, G.C. & Chang, S.H. (2003). Radial basis function networks applied to DNBR calculation in digital core protection systems. *Annals of Nuclear Energy*, 30(15), pp. 1561-1572.
- Lee, J. M., Yoo, C. & Lee, I. B. (2004). Statistical monitoring of dynamic processes based on dynamic independent component analysis. *Chemical engineering science*, 59(14), pp. 2995-3006.
- Lefebvre, D. (2000). *Contribution à la modélisation des systèmes dynamiques à événements discrets pour la commande et la surveillance*, Habilitation à Diriger des Recherches, Université de Franche Comté/ IUT Belfort - Montbéliard.
- Li, B., Shi, S., Wang, B., Wang, G., Wang, W. & Xu, D. (2016). Fault Diagnosis and Tolerant Control of Single IGBT Open-Circuit Failure in Modular Multilevel Converters. *in IEEE Transactions on Power Electronics*, 31(4), pp. 3165-3176.
- Luo, YR., Chen, M., Liu, DS., Jin, Y., Du, MH. & Hou, J. (2012). Technology and applications of foam drilling fluid in fractured and complex formations. *Pet Sci Technol*, 30(16), pp. 1747–1754.
- Liu, Z., Liu, Y., Cai, B., Li, X. & Tian, X. (2015). Application of Petri nets to performance evaluation of subsea blowout preventer system. *ISA transactions*. 54, pp. 240-249.
- Liu, Z., Liu, Y., Cai, B., Zhang, D. & Li, J. (2014). Fault Diagnosis of Subsea Blowout Preventer Based on Artificial Neural Networks. *International Journal of Security and Its Applications*, 8(2), pp. 49-58.
- Liu, Y.-K., Wu, G.-H., Xie, C.-L., Duan, Z.-Y., Peng, M.-J. & Li, M.-K. (2016). A fault diagnosis method based on signed directed graph and matrix for nuclear power plants. *Nucl. Eng. Design*, 297, pp. 166-174.
- Loukil, R., Chtourou, M. & Damak, T. (2013). Fault diagnosis and isolation of a complex system using a neural network observer. *International Journal of Automation and Control*, 7(3), pp. 147-165.
- Lyonnet, P., Thomas, M. & Toscano, R. (2012). *Fiabilité, diagnostic et maintenance prédictive des systèmes*. Editions Tech & Doc Lavoisier; France.
- Mac Clelland, J. & Rumelhart, D.E. (1988). *Explorations in parallel distributed processing: a handbook of models, programs, and exercises*. Vol. 2. The MIT Press, Cambridge, Massachusetts.
- Mac Gregor, J. F & Kourti, T. (1995). Statistical process control of multivariate processes. *Control Engineering Practice*, 3(3), pp. 403-414.
- MATLAB 8.1 (2013), *Neural Network Toolbox*, The Math Works, Natick, Massachusetts.
- Man, K. F. & Halang, W.A. (1997). Genetic algorithms for control and signal processing. In: *Proceedings of the 23rd International Conference on Industrial Electronics, Control and Instrumentation*. 4. New Orleans, LA, USA. pp. 1541–1555.

- Maquin, D. (2005). Cours de Master Automatique, Diagnostic, Signal, Bio-Imagerie: Surveillance des Processus. Institut National Polytechnique de Lorraine, *Centre de Recherche en Automatique de Nancy*. Vandoeuvre-lès-Nancy, France.
- Marhavilas, P.K., Filippidis, M., Koulinas, G.K. & Koulouriotis, D.E. (2019). The integration of HAZOP study with risk-matrix and the analytical-hierarchy process for identifying critical control-points and prioritizing risks in industry—A case study. *J. Loss Prev. Process. Ind.*, 62, pp. 103981.
- Maren, A.J., Harston, C.T. & Pap, R.M. (1990). *Handbook of neural computing applications*. Academic Press Inc., San-Diego, California.
- McAuley K.B. & MacGregor J.F. (1991). On-line inference of polymer properties in an industrial polyethylene reactor. *AIChE Journal*, 37(6), pp. 825-835.
- McCulloch, W. & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5, pp. 115-133.
- Molina, A. (1996). *Méthodologie pour le placement des capteurs à base de méthodes de classification en vue du diagnostic*. Thèse de Doctorat université de Toulouse, France.
- Mokhnache, L. (2004). *Application de RN dans le diagnostic et la prédiction des isolations HT*. Thèse Doctorat, école nationale polytechnique.
- Moody, J. & Darken, J. (1989). Fast Learning in networks of locally tuned processing units. *Neural Computation*, 1, pp. 281-194.
- Mousakitis, A. (2013). Classification of Fault Diagnosis Methods for Control Systems. *Measurement and Control*, 46(10), pp. 303–308.
- Maurya, M.R., Rengaswamy, R. & Venkatasubramanian, V. (2005). Fault Diagnosis by Qualitative Trend Analysis of the Principal Components. *Chemical Engineering Research and Design*, 83(9), pp. 1122-1132.
- Namigtle-Jiménez, A., Escobar-Jiménez, R.F., Gómez-Aguilar, J.F., García-Beltrán, C.D. & Téllez-Anguiano, A.C. (2020). Online ANN-based fault diagnosis implementation using an FPGA: application in the EFI system of a vehicle. *ISA Transactions*, 100, pp. 358-372.
- Nait-Said, M.S., Benbouzid, E.M. & Benchaib, A. (2000). Detection of broken bars in induction motors using an extended Kalman filter for rotor resistance sensorless estimation. *IEEE transactions on energy conversion*, 15(1), pp. 66-70.
- Nguyen, Jean-Paul. (1993). *Techniques d'exploitation pétrolière. Le forage*. Edition Technip; France.
- Nomikos, P. & MacGregor J. (1994). Monitoring batch processes using multiway principal component analysis. *American Institute of Chemical Engineers Journal*, 40(8), pp.1361-1375.
- IEC61882 (2001). *Hazard and operability studies (HAZOP studies) – Application guide*. International Electrotechnical Commission (IEC).

- O Herrera, M. A. d. I., Luna, A. S., Costa, A.C.A.D. & Lemes, E.M.B. (2018). *Risk Analysis: A generalized Hazop methodology state-of-the-art, applications, and perspective in the process industry*.
- Oil and Gas glossary. (2010). *Kick, Oil and Gas Field Technical Terms Glossary*. Retrieved 8 April 2011.
- Olivier, B., Emmanuel, G., Ivan, R., Bruno, N., Amira, T. M., Mohamad, K. & Younane, N. (2014). A new state-observer of the inner PEM fuel cell pressures for enhanced system monitoring. *European Physical Journal Applied Physics*, 66(3), 30901.
- Osorio, F. S. (1998). *Un système hybride neuro-symbolique pour l'apprentissage automatique constructif*. l'institut national polytechnique de Grenoble-II.N.P.G. Laboratoire leibniz–imag.
- Othman, M.R., Idris, R., Hassim, M.H. & Ibrahim, W.H.W. (2016). Prioritizing HAZOP analysis using analytic hierarchy process (AHP). *Clean Technol. Environ. Policy*, 18, 1345-1360.
- Oukhellou, L. & Aknin, P. (1998). Optimisation de l'espace de représentation dans un problème de classification par réseaux de neurones. *Journal Européen des Systèmes Automatisés*, 32, pp. 915-938.
- Ouyang, LC., Sun, D. & Ouyang, LB. (2009). Numerical investigation of the impacts of wall fluid entry on fluid flow characteristics and pressure drop along a wellbore. *Petroleum Science and Technology*, 27(18), pp. 2109–2133.
- Ozbayoglua, EM. (2009). Pressure loss at the bit while drilling with foam. *Petroleum Science and Technology*, 27(7), pp. 687–698.
- Pham, B.T., Nguyen, M.D., Bui, K.-T.T., Prakash, I., Chapi, K. & Bui, D.T. (2019). A novel artificial intelligence approach based on Multi-layer Perceptron Neural Network and Biogeography based Optimization for predicting coefficient of consolidation of soil. *Catena*, 173, pp. 302-311.
- Park, Y.J., Fan, S.K.S. & Hsu, C.Y. (2020). A Review on Fault Detection and Process Diagnostics in Industrial Processes. *Processes* 2020, 8, 1123.
- Parks, J. & Sandberg, I.W. (1991). Universal Approximation using Radial-Basis Function Network. *Neural Computation*. 3(2). pp. 246-257.
- Parizeau, M. (2004). *Réseaux de Neurones GIF-21140 et GIF-64326*. Université de Laval.
- Patterson, D.W. (1996). *Artificial Neural Networks Theory and Applications*. Prentice Hall International Editions, Korea.
- Patton, R.J. & Chen, J. (1991). An review of parity space approaches to fault diagnosis. *Dans le IFAC Symposium on Fault Detection Supervision and Safety for Technical Processes SAFEPROCESS*, Baden Baden, Germany, 1, pp. 239-255.

- Personnaz, L. & Rivals, I. (2003). *Réseaux de neurones formels pour la modélisation, la commande et la classification*. Sciences et Techniques de l'Ingénieur. CNRS Éditions, Paris.
- Pirdashti, M., Curteanu, S., Kamangar, M.H., Hassim, M.H. & Khatami, M.A. (2013). Artificial neural networks: applications in chemical engineering. *Rev Chem Eng*, 29, pp. 205–239.
- Poggio, T. & Girosi, F. (1989). *A Theory of Networks for Approximation and Learning*, AI Memo N°1140. Massachusetts Institute of Technology, Artificial Intelligence Laboratory and Center for Biological Information Processing Whitaker College.
- Poggio, T. & Girosi, F.(1990). Regularization algorithms for learning that are equivalent to multilayer networks. *Science*, 247( 4945), pp. 978–982.
- Potter, J. E. & Suman, M. C. (1977). Thresholdless redundancy management with array of skewed instruments. Technical report. *Integrity in Electronic Flight Control Systems*, AGARDOGRAPH-224.
- Poulard, H. (1996). *Statistiques et réseaux de neurones pour un système de diagnostic : application au diagnostic de pannes automobiles*. Thèse de doctorat préparée au LAAS du CNRS, Toulouse, France.
- Powell, M.J.D. (1987). *Radial Basis Functions for multivariable interpolation: a review*. J.C. Masson and M.G. Gox editors, algorithms for approximation. Clarendon Press, Oxford.
- Raghu, S. & Sriraam, N. (2017). Optimal configuration of multilayer perceptron neural network classifier for recognition of intracranial epileptic seizures. *Expert Systems with Applications*, 89, pp. 205-221.
- Rasmussen, J. (1986). *Information processing and human-machine interaction*. New York: North Holland.
- Raudys, S. (2001). *Statistical and Neural Classifiers: An integrated approach to design*. Springer-Verlag, London, 2001.
- Recht, J. L. (1966). Failure Mode and Effect. *National Safety Council*, 1966.
- Rich, S. H. & Venkatasubramanian, V. (1987). Model-based reasoning in diagnostic expert systems for chemical process plants. *Computers and Chemical Engineering*, 11 (2), pp. 111-122.
- Roemer, M.J., Hong, C. & Hesler, S.H. (1996). Machine health monitoring and life management using finite element-based neural networks. *Journal of Engineering for Gas Turbines and Power—Transactions of the ASME*, 118, pp. 830-835.
- Rojas, R. (1996). *Neural Networks : A Systematic Introduction*, Springer-Verlag Berlin Heidelberg.
- Rosenblatt, F. (1958). The Perceptron :a probabilistic model for information storage in the brain. *Psychological Review*, 65, pp. 386-408.

Ruiz, D., Cantón, J., Nougues, J.M., Espuña, A. & Puigjaner, L. (2001). On-line fault diagnosis system support for reactive scheduling in multipurpose batch chemical plants. *Computers & Chemical Engineering*, 25(4-6), pp. 829-837.

Rummelhart, D.E, Hinton, G.E. & Williams, R.J. (1986). Learning Internal Representation by Error Propagation. in *Parallel Distributed Processing Explorations in the Microstructure of Cognition*, 1, The MIT Press/Bradford Books, D.E. Rumelhart and J.L.McClelland, pp. 318-362.

Rumelhart, D.E., McClelland, J.L. & PDP Research Group,(1986). *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, 1: Foundations, MA: MIT Press, Cambridge.

Sahu, A.R. & Palei, S.K. (2020). Fault prediction of drag system using artificial neural network for prevention of dragline failure. *Engineering Failure Analysis*, 113, p. 104542.

Samanta, B. (2004). Gear fault detection using artificial neural networks and support vector machines with genetic algorithms. *Mechanical Systems and Signal Processing*, 18(3), pp. 625-644.

Samanta, B. & Al-Balushi, K.R. (2003). Artificial neural network based fault diagnostics of rolling element bearings using time-domain features. *Mechanical Systems and Signal Processing*, 17, pp. 317-328.

Sarle, W.S. (1994). Neural networks and statistical models. *Proceedings of the Nineteenth Annual SAS Users Group International Conference (SAS Institute )*, Cary, North Carolina, pp. 1538-1550.

Severson, K., Chaiwatanodom, P. & Braatz, R.D. (2016). Perspectives on process monitoring of industrial systems. *Annu Rev Control*, 42, pp. 190-200.

Shah, M.D. (2011). Fault detection and diagnosis in nuclear power plant-A brief introduction. *International Conference On Current Trends in Technology*, pp. 1-5.

Sharma, V. & Parey, A. (2016). A review of gear fault diagnosis using various condition indicators. *Procedia Engineering*, 144, pp. 253 – 263.

Shu, C., Wei, L., Rong-Jun, D. & Te-Fang, C. (2017). Fault Diagnosis and Fault Tolerant Control Scheme for Open-Circuit Faults in Three-Stepped Bridge Converters. in *IEEE Transactions on Power Electronics*, 32 (3), pp. 2203-2214.

Sofge, editors, *Handbook of Intelligent Control : Neural, Fuzzy, and Adaptive Approaches*, pp. 469–491. Van Nostrand Reinhold, New York.

SOF CONSEIL, Fernandez, M. & Armengaud, F. (2008). Étude de Dangers, Réalisation d'une Unité de Traitement de Brut à Hassi Messaoud Sud. *Document Sonatrach DP/UTBS/HMD*, 30-Avril-2008, 697 pages.

Sohn, H., Worden, K. & Farrar, C.R. (2002). Statistical damage classification under changing environmental and operational conditions. *Journal of Intelligent Material Systems and Structures*, 13, pp. 561–574.

Specht, D.F. (1991). A general regression neural network. *IEEE Transactions on Neural Networks*, 2 (6), pp. 568-576.

- Srinivasan, R. & Venkatasubramanian, V. (1998). Automating HAZOP analysis of batch chemical plants: part I. The knowledge representation framework. *Comput. Chem. Eng.*, 22(9), pp. 1345-1355.
- Strand, G.-O. & Lundteigen, M.A. (2015), Risk control in the well drilling phase: BOP system reliability assesment, *European Safety and Reliability Conference ESREL 2015*, Zurich, Switzerland.
- Subhasis, N., Toliyat, H.A. & Li, X. (2005). Condition Monitoring and Fault Diagnosis of Electrical Motors – A Review. *IEEE Transactions on Energy Conversion*, 20 (4), pp. 719-729.
- Sukthomya, W. & Tannock, J.D.T. (2005). Taguchi experimental design for manufacturing process optimisation using historical data and a neural network process model. *International Journal of Quality & Reliability Management*, 22 (5), pp. 485-502.
- Sutton, R. S. & Barto, A. G. (1998). *Reinforcement Learning: An Introduction*. Adaptive computation and machine learning. MIT Press, Cambridge, MA.
- Taboli, H., Morteza, J., Paghaleh, A., Afshar, J., Gholami, R. & Gholami, R. (2011). Specification and Prediction of Net Income using by Generalized Regression Neural Network (A Case Study). *Australian Journal of Basic and Applied Sciences*, 5(6), pp. 1553-1557.
- Tang, S. H., Hakim, N., Khaksar, W., Sulaiman, S., Ariffin, M. K. A. & Samin, R. (2012). Artificial Neural Network (ANN) Approach for Predicting Friction Coefficient of Roller Burnishing AL6061. *International Journal of Machine Learning and Computing*, 2(6), pp. 825- 830.
- 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(4), pp. 429-442.
- Teodor, M. & Letitia, M. (1997). Detection and isolation of process faults using neural networks. *IEEE Control Systems*, 17 (5), pp. 72-79.
- The Bureau of Ocean Energy Management, *Regulation and Enforcement (BOEMRE)*, (2011). Report regarding the causes of the april 20, 2010 Macondo well blowout, p. 217.
- Theilliol, D. (2003). *Contribution à l'étude et au développement des systèmes tolérants aux défauts: diagnostic et accommodation à base de modèles linéaires et au-delà*. Habilitation à diriger des recherches de l'Université de Henri Poincaré, Nancy 1, France.
- The MathWorks, Inc. (2018). *Multilayer shallow neural network architecture*. <https://www.mathworks.com/help/deeplearning/ug/multilayer-neuralnetwork-rchitecture.html>.
- Toguyeni, A.K.A. (1992). *Surveillance et diagnostic en ligne dans les ateliers flexibles de l'industrie manufacturière*, Thèse de doctorat, Université de Lille, France.
- Toguyéni, A.K.A. & Craye, R. (2000). Alarm processing and faults recovery based on functional modeling. *Proceeding of Word Automation Congress*, Maui, Hawaii.

- Toscano, R. (2005). *Commande et diagnostic des systèmes dynamiques: Modélisation, analyse, commande par PID et par retour d'état, diagnostic*. Ellipses édition Marketing, S. A.
- Touzet, C. (1992). *Les réseaux de neurones artificiels, introduction au connexionnisme*. EC2.
- Transocean, (2011). Macondo Well Incident – *Transocean Investigation Report*. Volume 1, 218 p.
- Vahed, A.T. & Demirel, N. (2017). Classification of draglines failure types using multilayer perceptron and radial basis function. *25th Int. Min. Congr. Turkey New Trends Mining, IMCET*, pp. 266-271.
- Vedam, H. & Venkatasubramanian, V. (1997). Signed digraph based multiple fault diagnosis. *Computers and Chemical Engineering*, 21, pp. S655-S660.
- Venkatasubramanian, V., Rengaswamy, R., Kavuri, N. & Yin, K. (2003). A review of process fault detection and diagnosis Part I: Quantitative model-based methods. *Computers and Chemical Engineering*, 27(3), pp. 293-311.
- Venkatasubramanian, V., Rengaswamy, R. & Kavuri, S.N. (2003). A review of process fault detection and diagnosis Part II : Qualitative models and search strategies. *Computers and Chemical Engineering*, 27(3), pp. 313–326.
- Venkatasubramanian, V., Rengaswamy, R., Kavuri, S.N. & Yin, K. (2003). A review of process fault detection and diagnosis Part III : Process history based methods. *Computers and Chemical Engineering*, 27(3), pp.327-346.
- Venkatasubramanian, V. & Rich, S. H. (1988). An object-oriented two-tier architecture for integrating compiled and deep-level knowledge for process diagnosis. *Computers and Chemical Engineering*, 12 (9-10), pp. 903-921.
- Venkatasubramanian, V., Zhao, J. & Viswanathan, S. (2000). Intelligent systems for HAZOP analysis of complex process plants. *Comput. Chem. Eng.* 24 (9-10), pp. 2291-2302.
- Verron, S. (2007). *Diagnostic et surveillance des processus complexes par réseaux bayésiens*. PhD thesis, ISTIA - Université d'Angers.
- Vileiniskis, M., Remenyte-Prescott, R., Rama, D.& Andrews, J. (2016). Fault detection and diagnostics of a three-phase separator. *Journal of Loss Prevention in the Process Industries*, 41, pp. 215-230.
- Villemeur, A. (1988). *Sûreté de fonctionnement des systèmes industriels*, Edition EYROLLES.
- Wang, F., Gao, J. & Wang, H. (2012). A new intelligent assistant system for HAZOP analysis of complex process plant. *J Loss Prevent Proc*, 25 (3), pp. 636-42.
- Wang, L., Kisi, O., Kermani, M.Z., Salazar, G.A., Zhu, Z. & Gong, W. (2016). Solar radiation prediction using different techniques: model evaluation and comparison. *Renewable and Sustainable Energy Reviews*, 61, pp. 384-397.



- Wang, C.-C. & Too, G.-P.J. (2002). Rotating machine fault detection based on HOS and artificial neural networks. *Journal of Intelligent Manufacturing*, 13, pp. 283-293.
- Wang, G., Yin, S. & Kaynak, O.(2014). An LWPR-based data-driven fault detection approach for nonlinear process monitoring. *IEEE Transactions on Industrial Informatics*, 10(4), pp. 2016-2023.
- Wang, F., Zhao, Y., Yang, O., Cai, J. & Deng, M. (2013). Process safety data management program based on HAZOP analysis and its application to an ethylene oxide/ethylene glycol plant. *J Loss Prevent Proc*, 26(6), pp. 1399-406.
- Wasserman P.D. (1993). *Advanced Methods in Neural Computing*. Van Nostrand Reinhold, New York, USA, 155-161.
- Watton, J. & Pham, D.T. (1997). An artificial NN based approach to fault diagnosis and classification of fluid power systems. *J. Syst. and Control Engineering*, 211(4), pp. 307-317.
- Weerasinghe, M., Gomm, J.B. & Williams, D. (1998). Neural networks for fault diagnosis of a nuclear fuel processing plant at different operating points. *Control Engineering Practice*, 6(2), pp. 281-289.
- Werbos, P.J. (1974). *Beyond regression: New tools for prediction and analysis in the behavioral science*. Thèse de doctorat, Harvard University.
- Wilcox, N. A. & Himmelblau, D. M. (1994a). Possible cause and effect graphs (PCEG) model for fault diagnosis I. Methodology. *Computers and Chemical Engineering*, 18 (2), pp. 103-116.
- Wilcox, N. A. & Himmelblau, D. M. (1994b). Possible cause and effect graphs (PCEG) model for fault diagnosis II. Applications. *Computers and Chemical Engineering*, 18 (2), pp. 117-127.
- William, C., Lyons, G. & Plisga, J. (2005). *Standard Handbook of Petroleum and Natural Gas Engineering*. 2nd ed. Elsevier, 4-371.
- Willmott, C.J. (1981). On the validation of models. *Physical Geography*, 2, pp. 184-194.
- Willmott, C.J. (1982). Some comments on the evaluation of model performance. *Bulletin American Meteorological Society*, 63, pp. 1309-1313.
- Wira, P. (2009). *Approches neuromimétiques pour l'identification et la commande*. Thèse en vue d'obtenir l'Habilitation à Diriger des Recherches à l'université de Haute Alsace.
- Wong, P.K., Yang, Z., Vong, C.M. & Zhong, J. (2014). Real-time fault diagnosis for gas turbine generator systems using extreme learning machine. *Neurocomputing*, 128, pp. 249-257.
- Yager, R. & Filev, D.P. (1994). *Essentials of fuzzy modeling and control*. Wiley-Interscience. New York, NY, USA.

- Yang, F., Shah, S.L. & Xiao, D. (2012). Signed directed graph based modeling and its validation from process knowledge and process data. *Int J Appl Math Comp.* 22(1), pp. 41-53.
- Yang, D.-M., Stronach, A.F., Macconnell, P. & Penman J. (2002). Third-order spectral techniques for the diagnosis of motor bearing condition using artificial neural networks. *Mechanical Systems and Signal Processing*, 16, pp. 391– 411.
- Yin, S., Ding, S.X., Xie, X.C. & Luo, H.L.(2014). A review on basic data-driven approaches for industrial process monitoring. *IEEE Transactions on Industrial Electronics*, 61(11), pp. 6414-6428.
- Yu, J. (2012). Local and Nonlocal Preserving Projection for Bearing Defect Classification and Performance Assessment. *IEEE Transactions on Industrial Electronics*, 59(5), pp. 2363-2376.
- Yun, Z., Quan, Z., Caixin, S., Shaolan, L., Yuming, L. & Yang, S. (2008). RBF neural network and ANFIS-based short-term load forecasting approach in real-time price environment. *IEEE Transactions on Power Systems*, 23(3), pp. 853-858.
- Zhai, S., Wang, W. & Ye, H. (2015). Fault diagnosis based on parameter estimation in closed-loop systems. *IET Control Theory Appl.*, 9(7), pp. 1146-1153.
- Zemouri, M. (2003). *Contribution à la surveillance des systèmes de production à l'aide des réseaux de neurones dynamiques : application à la maintenance*. Thèse de doctorat de l'université de Franche-Comté, France.
- Zhang, Q. & Geng, S. (2015). Dynamic uncertain causality graph applied to dynamic fault diagnoses of large and complex systems. *IEEE Transactions on Reliability*, 64(3), pp. 910-927.
- Zhang, J. & Roberts, P.D. (1992). On-line process fault diagnosis using neural network techniques. *Trans Inst MC*, 14(4), pp. 179 -188.
- Zhang, Y.W., Yang, N. & Li, S.P. (2014). Fault isolation of nonlinear processes based on fault directions and features. *IEEE Transactions on Control Systems Technology*, 22(4), pp. 1567-1572.
- Zhang, Y.M., Zhang, Y.B. & Lin, L.Z. (2010). Application of genetic algorithm and RBF neural network in network flow prediction. *Proceeding of the 3rd IEEE International Conference on Computer Science and Information Technology (ICCSIT '10)*, pp. 298-301.
- Zhong, M., Song, Y. & Ding, S. X. (2015). Parity space-based fault detection for linear discrete time-varying systems with unknown input. *Automatica*, 59(1), pp. 120-126.
- Zhonghai, M., Shaoping, W., Jian, S., Tongyang, L. & Xingjian, W. (2018). Fault diagnosis of an intelligent hydraulic pump based on a nonlinear unknown input observer. *Chinese Journal of Aeronautics*, 31(2), pp. 385-394.
- Zhou, Y., Hahn, J. & Mannan, M.S. (2003). Fault detection and classification in chemical processes based on neural networks with feature extraction. *ISA Transactions*, 42 (4), pp. 651-664.

Zhou, B. & Ye, H. (2017). A New Qualitative Trend Analysis Algorithm Based on Global Polynomial Fit. *AIChE Journal*, 63(8), pp. 3374-3383.

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

Zwingelstein, G. (1999). *Sûreté de fonctionnement des systèmes industriels complexes*, Techniques de l'Ingénieur, S8250.

## Annexe A

# La méthode des moindres carrés

La méthode des moindres carrés, indépendamment élaborée par Legendre et Gauss au début du XIX<sup>e</sup> siècle, permet de comparer des données expérimentales, généralement entachées d'erreurs de mesure, à un modèle mathématique censé décrire ces données.

Il s'agit d'un algorithme d'optimisation extrêmement puissant qui permet d'entraîner les modèles de régression linéaire, régression logistiques ou encore les réseaux de neurones.


Dans le cas le plus courant, le modèle théorique est une famille de fonctions  $f(x; \theta)$  d'une ou plusieurs variables muettes  $x$ , indexées par un ou plusieurs paramètres  $\theta$  inconnus. La méthode des moindres carrés permet de sélectionner parmi ces fonctions celle qui reproduit le mieux les données expérimentales. On parle dans ce cas d'ajustement par la méthode des moindres carrés. Si les paramètres  $\theta$  ont un sens physique, la procédure d'ajustement donne également une estimation indirecte de la valeur de ces paramètres.

La méthode consiste en une prescription (initialement empirique), qui fait que la fonction  $f(x; \theta)$  qui décrit « le mieux » les données est celle qui minimise la somme quadratique des déviations des mesures aux prédictions de  $f(x; \theta)$ . Si, par exemple, nous disposons de  $N$  mesures  $(Y^{(i)})$  où  $i = 1, \dots, m$ , les paramètres  $\theta$  « optimaux » au sens de la méthode des moindres carrés sont ceux qui minimisent les quantités:

- la fonction de notre modèle :  $f(\theta) = X \cdot \theta$
- la fonction Coût :  $J(\theta) = \frac{1}{2m} \sum_i (X^{(i)} \cdot \theta - Y^{(i)})^2$
- le gradient :  $\frac{\partial J(\theta)}{\partial \theta} = \frac{1}{m} X^T (X \cdot \theta - Y)$
- la descente de gradient :  $\theta = \theta - \alpha \frac{\partial J(\theta)}{\partial \theta}$

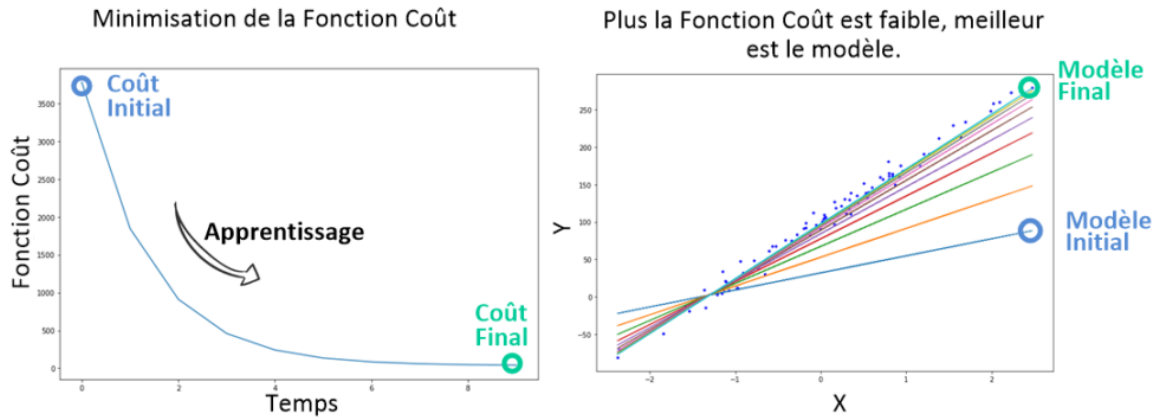
### ***Pourquoi la descente de gradient est si importante en apprentissage du réseau:***

En apprentissage, on va utiliser l'algorithme de la descente de gradient dans les problèmes d'apprentissage supervisé pour minimiser la fonction coût  $J(\theta)$ , qui est une fonction convexe (par exemple l'erreur quadratique moyenne) comme illustré sur la [Figure A.1](#).



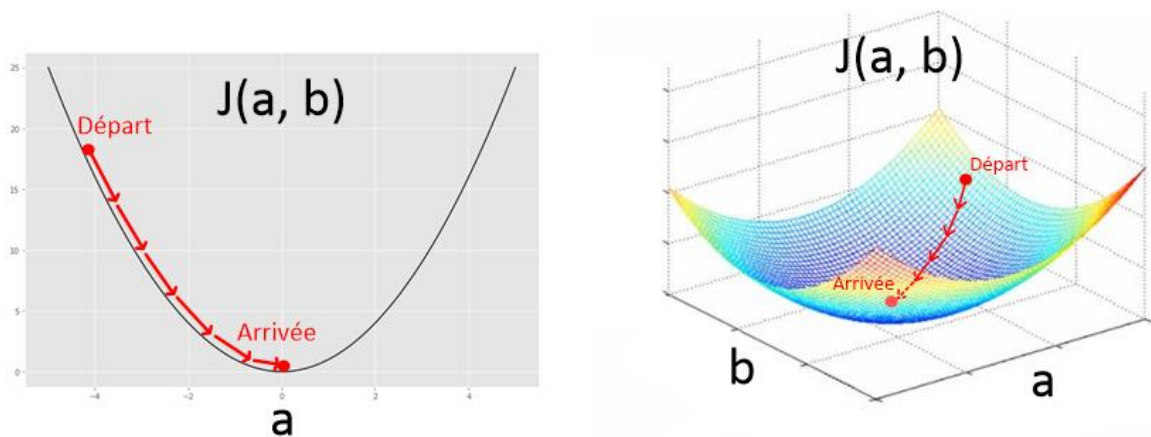
**Figure A.1** - Illustration de la méthode des moindres carrés. Les données suivent la courbe figurée en pointillés et sont affectées par un bruit gaussien centré, de variance 1. Le meilleur ajustement déterminé par la méthode des moindres carrés est représenté en rouge

C'est grâce à cet algorithme que le réseau apprend, i.e. trouve le meilleur modèle. En effet, rappelez-vous que minimiser la fonction coût revient à trouver les paramètres (a, b, c...) qui donnent les plus petites erreurs entre notre modèle et les points du Dataset (Figure A.2).



**Figure A.2** - Illustration de la fonction coût

En répétant les deux dernières étapes en boucle, l'algorithme de descente de Gradient est donc un algorithme itératif. Pour l'illustrer sur un graphique, on peut prendre l'exemple de la fonction coût  $J(a,b)$  d'une régression linéaire simple. L'algorithme permet de trouver la valeur idéale pour les paramètres (a,b).



**Figure A.3** - Exemple de la fonction coût  $J(a,b)$  d'une régression linéaire simple

## Annexe B

# Paramètres du moteur à courant continu

$$\begin{cases} V(t) = R i(t) + L \frac{d i(t)}{dt} + e \\ J \frac{d \omega(t)}{dt} + f \omega(t) = C_e - C_r \\ e = K_e \omega(t) \\ C_e = K_c i(t) \end{cases} \quad (\text{B.1})$$

$$R = 1,2 \, \Omega ;$$

$$L = 25 \, \text{mH} ;$$

$$J = 0,208 \, \text{kg m}^2 ;$$

$$K = 1,21 \, \text{V s rad}^{-1} ;$$

$$f = 0,008 \, \text{Nms rad}^{-1} ;$$

$$P_r = 5 \, \text{kW}.$$


## Résultats de simulation

- Résultats d'apprentissage des algorithmes TRAINGD, TRAINGDM, TRAINGDA, TRAINGDx, TRAINBFG et TRAINLM


Algorithmes	Epoques	Erreur désirée (SSE)	Nombre de neurones	Fonction d'activation (couche d'entrée)	Fonction d'activation (couche de sortie)	Temps d'exécution (seconde)
TRAINGD	25737.10 <sup>4</sup>	0.001	8	Tansigmoïde	Linéaire	1471.80
TRAINGDM	7515	0.001	8	Tansigmoïde	Linéaire	322.9100
TRAINGDA	724	0.001	8	Tansigmoïde	Linéaire	28.7800
TRAINGDx	1222	0.001	8	Tansigmoïde	Linéaire	41.8500
TRAINBFG	1044	0.001	8	Tansigmoïde	Linéaire	711.2900
TRAINLM	11	0.001	8	Tansigmoïde	Linéaire	11.4800

Tableau B.1 - Résultats d'apprentissage

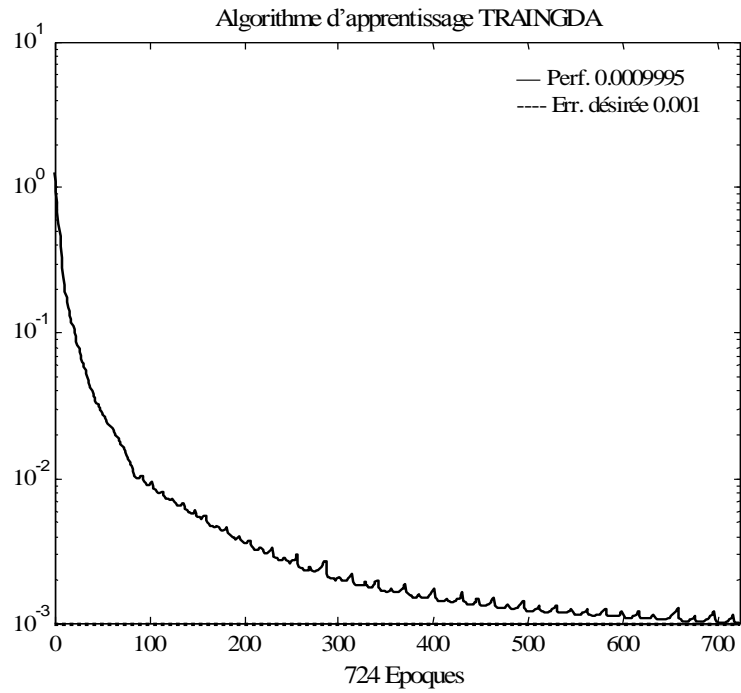
- Représentation de la performance d'apprentissage des algorithmes TRAINGD, TRAINGDM, TRAINGDA, TRAINGDX, TRAINBFG et TRAINLM




**Figure B.1-** Représentation de la performance d'apprentissage par l'algorithme TRAINGD



**Figure B.2 -** Représentation de la performance d'apprentissage par l'algorithme TRAINGDM




**Figure B.3** - Représentation de la performance d'apprentissage par l'algorithme TRAINGDA




**Figure B.4** - Représentation de la performance d'apprentissage par l'algorithme TRAINGDX





**Figure B.5** - Représentation de la performance d'apprentissage par l'algorithme TRAINBFG



**Figure B.6** - Représentation de la performance d'apprentissage par l'algorithme TRAINLM

## Annexe C

# AMDE moteur à courant continu

<b>ANALYSE DES MODES DE DEFAILLANCE ET DE LEURS EFFETS</b>					
Système : <b>MOTEUR A COURANT CONTINU</b>				Phase de fonctionnement : <b>MARCHE NORMALE</b>	
<i>Elément</i>	<i>Fonction</i>	<i>Modes de défaillance</i>	<i>Cause de la défaillance</i>	<i>Effets de la défaillance</i>	<i>observation</i>
Bobines de l'inducteur	Création du champ magnétique	Usure des isolants	Echauffement	Court-circuit en totalité. Arrêt du moteur. Variation de la vitesse et du couple, Court-circuit en partie. Accélération du moteur. Variation de la vitesse et du couple	
		Coupure du fil	Défaut mécanique	Ouverture du circuit et par conséquent arrêt du moteur	
Partie magnétique de l'inducteur	Passage du champ magnétique	Fissures	Défaillance mécanique	Augmentation des fuites magnétiques et par conséquent variation du couple et de la vitesse  Augmentation des courants de Foucault et par conséquent suréchauffement du moteur et diminution de la résistance	

		<b>ANALYSE DES MODES DE DEFAILLANCE ET DE LEURS EFFETS</b>			<b>Page : 2</b>
		Système : <b>MOTEUR A COURANT CONTINU</b>	Phase de fonctionnement : <b>MARCHE NORMALE</b>		
<i>Elément</i>	<i>Fonction</i>	<i>Modes de défaillance</i>	<i>Cause de la défaillance</i>	<i>Effets de la défaillance</i>	<i>observation</i>
Bobines de l'induit	Création d'un couple de rotation	Usure des isolants Coupure (ouverture du circuit)	Echauffement Défaillance mécanique	Variation du couple et de la vitesse Arrêt du moteur	
Collecteur	Commutation du courant dans l'induit	Usure dans les isolants Usure des lames du collecteur et/ou des balais en charbon	Forte intensité du courant Mauvaise isolation	Changement du sens de rotation Variation du couple et de la vitesse Apparition d'étincelles (incendie) Arrêt du moteur	
Partie magnétique de l'induit	Passage du champ magnétique	Fissures Variation de l'entrefer	Défaillance mécanique Mauvais serrage	Augmentation des fuites magnétiques. Variation du couple et de la vitesse. Augmentation des courants de Foucault. suréchauffement du moteur et diminution de la résistance Variation du couple et de la vitesse pouvant aller jusqu'à l'arrêt du moteur	

**Tableau C.1** - Résultat de l'AMDE Moteur à courant continu

# Annexe D

## Résultat du Codage

Causes Effets	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39		
1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		
2	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
3	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
4	1	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
5	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
6	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
7	0	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
8	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
9	0	0	0	0	0	0	0	0	0	1	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
10	0	0	0	0	1	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
11	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
12	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	
13	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
14	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
16	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
17	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	
18	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	
19	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	
20	1	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	1	0	0	0	0	
21	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	
22	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	1	0	0	1	0	0	
23	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	1	0	0	1	0	0	1	0	
24	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	1	0	0	1	0	0	1	0	
25	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	1	0	0	1	0	0	1	0	0	
26	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
27	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
28	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
29	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
30	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
31	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
32	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
33	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
34	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

35	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1			
36	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0			
37	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0			
38	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	1	0	0	0	0	0	0	0	1	0		
39	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0		
40	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		
41	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0		
42	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	1	0	0	0	0	
43	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
44	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	1	0	0	1	0	0	1	0	0	0	0	
45	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	1	0	0	1	0	0	1	0	0	0	
46	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
47	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	1	0	0	1	0	0	1	0	0	1	0
48	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	1	0	0	1	0	0	1	0	0	1

**Tableau D.1 - Résultat du codage**

## Annexe E

# L'analyse HAZOP

<b>Equipement</b> : BOP à mâchoires					
<b>Paramètre</b> : Pression					
<i>Mot-clé</i>	<i>Déviaton</i>	<i>Cause</i>	<i>Conséquence</i>	<i>Détection</i>	<i>Actions correctives</i>
Basse	Basse Pression fournit au BOP	- Fuite de la vanne à quatre voies	- Fermeture très lente du BOP à mâchoire voire un volume de gain très élevé	- Visuelle	- Indicateur de niveau des bacs couplé à un enregistreur
		- Fuite dans les flexibles	- Pas de connexion entre l'unité de commande et les BOP et perte de la fonction fermeture	- Visuelle	- Vérification périodique
		- Fuite dans le circuit sous-pression	- Blocage en position ouverte du BOP et donc risque d'éruption en cas de venue	- Visuelle	- Test périodique des BOP - Fermer le puits avec la grue valve ou avec BOP à rams
		- Défaillance du régulateur de pression manifold	- Fluide sous pression de 3000 psi et par conséquent surpression et risque d'explosion	- Visuelle	- Maintenance périodique - Assurer les pièces de rechanges
		- Fuite des bouteilles d'accumulations (perte de pression de précharge)	- Chute de pression au dessous de 3000 psi dans le système de commande des BOP ce qui conduit à une mauvaise commande des BOP	- Visuelle	- Assurer les pièces de rechanges
		- Fuite ou encombrement dans la chambre d'ouverture et de fermeture du piston	- Fermeture et ouverture incomplète ou intempestive du piston ce qui donne un test négatif des chambres		- Vérification périodique
	Haute Pression fournit au BOP	- Blocage en position ouverte de la vanne 4 voies	- Blocage en position fermée du BOP - Arrêt du forage	- Visuelle	- Vérification périodique - Assurer les pièces de rechanges
		- Défaillance du régulateur de pression manifold	- Perte de la commande - Blocage en position fermée du BOP - Arrêt du forage	- Visuelle	- Maintenance périodique
		- Déchirure des joints d'étanchéité	- Fuite d'huile	- Visuelle	- Vérification périodique - Rechanger les joints
		- Usure des rams	- Perte de la fonction de fermeture du BOP à mâchoires et risque d'éruption en cas de venue	- Visuelle	-Maintenance périodique -Test périodique du BOP

<b>Equipement : BOP Annulaire</b>					
<b>Paramètre : Pression</b>					
<i>Mot-clé</i>	<i>Déviaton</i>	<i>Cause</i>	<i>Conséquence</i>	<i>Détection</i>	<i>Actions correctives</i>
Basse	Basse pression fournit au BOP	- Défaillance du régulateur de pression annulaire	- Fermeture très lente du BOP annulaire engendrant un volume très élevé du gain	- Visuelle	- Indicateur de niveau des bacs couplé à un enregistreur
		- Fuite dans la vanne 4 voies	- Blocage en position ouverte du BOP et risque d'éruption en cas de venue	- Visuelle	- Assurer les pièces de rechanges
		- Fuite dans les flexibles	- Perte de connexion entre l'unité de commande et les BOP	- Visuelle	- Vérification périodique
		- Fuite dans le circuit sous-pression	- Blocage en position ouverte du BOP et donc risque d'éruption en cas de venue	- Visuelle	- Test périodique des BOP
		- Fuite des bouteilles d'accumulations (perte de pression de précharge)	- Chute de pression au dessous de 3000 psi dans le système de commande des BOP ce qui conduit à une mauvaise commande des BOP	- Visuelle	- Assurer les pièces de rechanges
		- Fuite ou encombrement dans la chambre d'ouverture et de fermeture du piston	- Fermeture et ouverture incomplète ou intempestive du piston et par conséquent fermeture incomplète du puits		- Vérification périodique
		- Surpression dans la chambre de fermeture	- Fuite dans la chambre de fermeture et par conséquent perte de pression au niveau du BOP - Ouverture incomplète du puits		- Vérification périodique
		- Défaillance du régulateur de pression annulaire	- Blocage en position fermée du BOP - Détérioration de la membrane annulaire et donc situation non maîtrisée en cas de venue	- Visuelle	- Maintenance périodique
		- Fuite des joints d'étanchéité	- Perte de pression ce qui entraîne une mauvaise fermeture et ouverture du BOP	- Visuelle	- Vérification périodique - Rechanger les joints
		- Défaillance ou blocage en position ouverte de la vanne by-pass	- Surpression et risque d'explosion	- Visuelle	- Vérification périodique - Vérifier la vanne by-pass

<b>Equipement</b> : Accumulateurs					
<b>Paramètre</b> : Pression					
<i>Mot-clé</i>	<i>Déviaton</i>	<i>Cause</i>	<i>Conséquence</i>	<i>Détection</i>	<i>Actions correctives</i>
Basse	Pas/basse pression fournit aux accumulats- eurs	- Pression du fluide inférieur à 2700 psi	- Perte de la fonction compression du fluide	- Visuelle	- Vérification périodique
		- Défaillance de la pompe triplex	- Pas de refoulement du fluide vers les accumulateurs	- Visuelle	- Assurer les pièces de rechanges
		- Défaillance des pompes pneumatiques	- Les pompes ne produisent aucune pression et donc pas de refoulement de fluide vers les accumulateurs	- Auditive	- Vérification périodique
		- Vanne manuelle d'isolement et d'aspiration de la pompe à air, fermée ou bouchée	- Perte d'amorçage des pompes - Pas de démarrage de la pompe pneumatique au seuil voulu	/	- Test périodique des BOP
		- Blocage en position fermée de la vanne d'admission d'air	- les pompes ne parviennent pas à atteindre la pleine pression	- Visuelle	- Maintenance périodique - Assurer les pièces de rechanges
		- Défaillance du clapet anti-retour	- Eclatement des accumulateurs	- Visuelle	- Assurer les pièces de rechanges
		- Contamination du fluide du réservoir	- Arrêt des pompes - Défaillance des pompes	- Visuelle	- Vérification périodique
		- Arrêt de rotation du moteur	- Arrêt des pompes électriques		- Maintenance périodique - Assurer les pièces de rechanges
		- Les manocontacts des pompes pneumatiques sont déréglés	- Pression dans le manifold inférieur à celle requise	- Visuelle	- Contrôle et réglage du manocontact
		- le manocontact électrique est dérégulé	- Commande erronée	- Visuelle	- Assurer les pièces de rechanges
		- Soupape de pré-charge défectueuse ce qui permet à l'azote de s'échapper	- Arrêt du système de sécurité BOP - Fuite de la pompe	- Visuelle	- Vérification périodique
		- Rupture de vessie	- Perte de pression de précharge	/	- Assurer les pièces de rechanges



	Haute Pression	- Défaillance de la soupape de sécurité	- Surpression, fuite et possibilité d'éclatement des accumulateurs	- Visuelle	- Vérification périodique
		- Vanne de pré-charge défectueuse	- Perte de pression de pré-charge	- Visuelle	- Maintenance périodique
		- Fuite de la vanne de contrôle à quatre voies	- Blocage en position ouverte du BOP et risque d'éruption en cas de venue	- Visuelle	- Assurer les pièces de rechanges
		- Fonctionnement excessif des pompes	- Surpression et risque d'explosion	- Visuelle	- Assurer les pièces de rechanges

**Equipement** : Circuit hydraulique

**Paramètre** : Pression hydraulique

<i>Mot-clé</i>	<i>Déviaton</i>	<i>Cause</i>	<i>Conséquence</i>	<i>Détection</i>	<i>Actions correctives</i>
Basse	Basse pression	- Vanne d'admission hydropneumatique automatique dérégler	- Lecture erroné de la pression dans le circuit hydraulique de 3000 psi - mauvaise commande des BOP et risque d'éruption en cas de venue	- Manomètre du circuit hydraulique à haute pression (3000 psi)	- Tester le système à chaque opération de montage du système
		- Pompes pneumatique défectueuse	- Pression insuffisante pour une meilleur commande des BOP et par conséquent fermeture non complète des BOP	- Visuelle	- Assurer une maintenance périodique des pompes à air
		- Niveau de fluide hydraulique dans le réservoir insuffisant	- Pression de commande des BOP insuffisante et par conséquent risque d'éruption en cas de venue	- Indicateur de niveau d'huile	- Vérification du niveau d'huile dans le réservoir
		- Fuite au niveau de la vanne d'isolement	- Débit de fluide hydraulique d'aspiration insuffisant ce qui conduit à une pression insuffisante pour une la commande des BOP	- Visuelle	- Inspection régulière par les gents responsables du système
		- Filtres à huile bouchés	- Débit d'aspiration insuffisant ce qui donne une mauvaise fermeture des BOP	- Visuelle (une durée bien déterminé)	- Respecter la duré de vie des filtres - Assurer les pièces de rechanges

	- Fuite de la soupape de sécurité sur la ligne auxiliaire avec retour au réservoir de stockage du fluide hydraulique	- Chute de pression au niveau du circuit à haute pression ce qui conduit à une fermeture incomplète des BOP	- Visuelle	- Inspection périodique du système d'accumulation
	- Fuite des bouteilles d'accumulations (perte de pression de précharge)	- Chute de pression au dessous de 3000 psi dans le système de commande des BOP ce qui conduit à une mauvaise commande des BOP	- Visuelle	- Assurer les pièces de rechanges
	- Vanne de précharge défectueuse (séparateur de type vessie)	- Chute de pression au dessous de 3000 psi dans le système de commande des BOP ce qui conduit à une mauvaise commande des BOP	- Visuelle	- Inspection périodique du système d'accumulation - Assurer les pièces de rechanges
	- Mauvaise étanchéité et fuite des vannes à quatre voies	- Chute de pression de commande des BOP	- Visuelle	- Inspection périodique du système d'accumulation - Assurer les pièces de rechanges
	- Fuite au niveau du Détendeur	- Chute de pression au dessous de celle requise pour le fonctionnement des BOP ce qui conduit à une mauvaise commande des BOP	- Visuelle	- Inspection périodique du système d'accumulation - Assurer les pièces de rechanges
	- Fuite au niveau de la vanne de purge	- Chute de pression au dessous de 3000 psi dans le système de commande des BOP ce qui conduit à une mauvaise commande des BOP	- Visuelle	- Inspection périodique du système d'accumulation - Assurer les pièces de rechanges
	- Perte d'étanchéité des pompes d'aspiration du fluide hydraulique	- Pression insuffisante dans le circuit haut pression	- Visuelle	- Maintenance préventive - Assurer les pièces de rechange
	- Fuite dans le système hydraulique (connexion et tuyauteries)	- Chute de pression au dessous de 3000 psi dans le système de commande des BOP conduit à une mauvaise commande aux BOP	- Visuelle	- Inspection périodique du système hydraulique

<b>Equipement</b> : Circuit pneumatique					
<b>Paramètre</b> : Pression d'air					
<i>Mot-clé</i>	<i>Déviaton</i>	<i>Causes</i>	<i>Conséquences</i>	<i>Détection</i>	<i>Actions correctives</i>
Basse	Basse pression	- Alimentation en air insuffisante à l'entrée de l'unité de commande au dessous de 75 psi	- Perte d'amorçage des pompes pneumatique - Pas de pression de service et donc perte de contrôle en cas de venue et risque d'éruption	- Manomètre de pression d'air à l'entrée du système	- Vérification périodique des connexions, du circuit d'air et du compresseur
		- La vanne qui permet de by passer la vanne d'admission automatique fermée (erreur humaine)	- Pas d'alimentation en air des pompes pneumatiques - Perte d'amorçage des pompes pneumatique - Pas de pression de service et donc perte de contrôle en cas de venue et risque d'éruption	- Visuelle	- Teste périodique du système d'accumulation
		- Blocage en position fermée des vannes manuelle d'isolement des pompes à air	- Pas d'alimentation en air des pompes pneumatiques - Perte d'amorçage des pompes pneumatique - Pas de pression de service et donc perte de contrôle en cas de venue et risque d'éruption	- Visuelle	- Vérification rigoureuse des positions des vannes (vannes d'isolement sont normalement toujours en position ouverte)
		- Perte d'étanchéité des vannes manuelle d'isolement des pompes à air	- Alimentation insuffisante en air pour les pompes pneumatiques - Perte d'amorçage des pompes pneumatique - Pas de pression de service et donc perte de contrôle en cas de venue et risque d'éruption	- Visuelle	- Inspection périodique du système d'accumulation - Assurer les pièces de rechanges

<b>Équipement</b> : Réservoir de stockage du fluide hydraulique					
<b>Paramètre</b> : Niveau du fluide hydraulique					
<i>Mot-clé</i>	<i>Déviaton</i>	<i>Causes</i>	<i>Conséquences</i>	<i>Détection</i>	<i>Actions correctives</i>
Bas	Niveau de fluide hydraulique dans le réservoir bas	- Mauvais remplissage du réservoir (erreur humaine)	- Débit et pression du fluide hydraulique de service insuffisants - Mauvaise commande des BOP ce qui conduit à une perte de contrôle en cas de venue et risque d'éruption	- Indicateur de niveau d'huile	- Le niveau de fluide hydraulique dans le réservoir doit toujours être vérifié avant l'utilisation du système - Teste périodique du système
		- Fuite au niveau du réservoir	- Débit et pression du fluide hydraulique de service insuffisante - Mauvaise commande des BOP ce qui conduit à une perte de contrôle en cas de venue et risque d'éruption	- Visuelle	-Inspection périodique du système d'accumulation
		- Perte d'étanchéité de la vanne de purge	- Débit et pression du fluide hydraulique de service insuffisante - Mauvaise commande des BOP ce qui conduit à une perte de contrôle en cas de venue et risque d'éruption	- Visuelle	-Inspection périodique du système d'accumulation - Assurer les pièces de rechange
		- Fuite dans les annexes du système de fluide (tuyauteries, connexions)	-Débit et pression du fluide hydraulique de service insuffisante - Mauvaise commande des BOP ce qui conduit à une perte de contrôle en cas de venue et risque d'éruption	- Visuelle	-Inspection périodique du système d'accumulation

<b>Equipement</b> : BOP à mâchoires et annulaire					
<b>Paramètre</b> : Temps de réponse des BOP					
<i>Mot-clé</i>	<i>Déviaton</i>	<i>Causes</i>	<i>Conséquences</i>	<i>Détections</i>	<i>Actions correctives</i>
Retard	Réponse en retard	- Réaction lente ou mauvaise de l'opérateur (erreur humaine), ce qui conduit à une commande retardée des BOP annulaire et à mâchoires	-Perte de contrôle de venue et risque d'éruption	- Visuelle	- les gents responsables de manipulation du système de contrôle de venue doivent avoir le réflexe de réagir rapidement
		- La pression provenant de l'unité de commande est insuffisante pour opérer les différents BOP	-Perte de contrôle de venue et risque d'éruption	- Visuelle	- Assurer une pression de service permanente au niveau de l'unité de commande
		- Usure ou coincement des mâchoires par manque de lubrification ou de graissage	-Perte de contrôle de venue et risque d'éruption	- Visuelle	- Tester les BOP périodiquement - Lubrification et graissage des pistons des BOP à mâchoires
		- Coincement des vannes de contrôle à 4 voies	-Perte de contrôle de venue et risque d'éruption	- Visuelle	- Maintenance préventive

<b>Equipement : Réservoir</b>					
<b>Paramètre : Contamination du fluide hydraulique</b>					
<i>Mot-clé</i>	<i>Déviaton</i>	<i>Causes</i>	<i>Conséquences</i>	<i>Détection</i>	<i>Propositions d'amélioration</i>
Contam- ination	Change- ment des caracté- ristiques du fluide hydraulique	- Entré des débris, d'eau, de poussières, dans le réservoir stockage de fluide hydraulique	- Bouchage des vannes - Bouchage du circuit de fluide hydraulique - Changement des caractéristiques physiques du fluide ce qui le rend inutile - Mauvaise commande des BOP	/	- Le réservoir doit être bien fermé et ne jamais laisser les orifices de remplissage et d'inspection ouvertes - L'utilisation des filtres à huile est nécessaire avec respect de leur durée d'utilisation et leur nettoyage périodique
		- Fluide hydraulique de remplissage contaminé, à cause des mauvaises conditions de stockage ou par manque de contrôle de l'opérateur (ignorance- erreur humaine)	-Bouchage des vannes -Bouchage du circuit de fluide hydraulique -Changement des caractéristiques physiques du fluide hydraulique rendant le fluide inutile - Mauvaise commande des BOP	/	- Le réservoir doit être bien fermé et ne jamais laisser les orifices de remplissage et d'inspection ouvertes - L'utilisation des filtres à huile est nécessaire avec respect de leur durée d'utilisation et leur nettoyage périodique

**Tableau E.1 - Résultat de l'analyse HAZOP**

## Algorithme des K-moyennes

L'algorithme le plus simple et le plus répandu en classification automatique est celui des K-moyennes. Cet algorithme suppose que le nombre de classe est connu a priori et se propose de partitionner l'ensemble des observations en K classes  $\{C_1, C_2, C_3, \dots, C_k, \dots, C_K\}$ , Chacune est représentée par un point appelé centre de la classe. Soient  $\{W_1, W_2, \dots, W_k, \dots, W_K\}$ , l'ensemble des K centres des classes et  $W_k = (w_{k1}, \dots, w_{kn}, \dots, w_{kN})$ , le vecteur dans  $R^N$  des coordonnées du centre de la classe  $C_k$ . On décide d'affecter une observation  $X_p$  à la classe  $C_j$ , si son centre  $W_j$  est le plus proche de cette observation. C'est la règle du plus proche voisin :

$$X_p \in C_j \text{ si } \|X_p - W_j\| = \min_{k=1, K} \|X_p - W_k\| \quad (\text{F.1})$$

où  $\| \cdot \|$  est une distance qui est souvent supposée Euclidienne :

$$\|X_p - W_k\| = \sqrt{\sum_{n=1}^N (x_{pn} - w_{kn})^2} \quad (\text{F.2})$$

La règle du plus proche voisin (F.3) s'écrit aussi :

$$X_p \in C_j \text{ si } j = \text{Arg} \min_{k=1, K} \|X_p - W_k\| \quad (\text{F.3})$$

Soit  $U_{pj}$  la fonction indicatrice de l'appartenance de l'observation  $X_p$  à la classe  $C_j$ .

$$U_{pj} = \begin{cases} 1 & \text{si } X_p \in C_j \\ 0 & \text{sinon} \end{cases} \quad (\text{F.4})$$

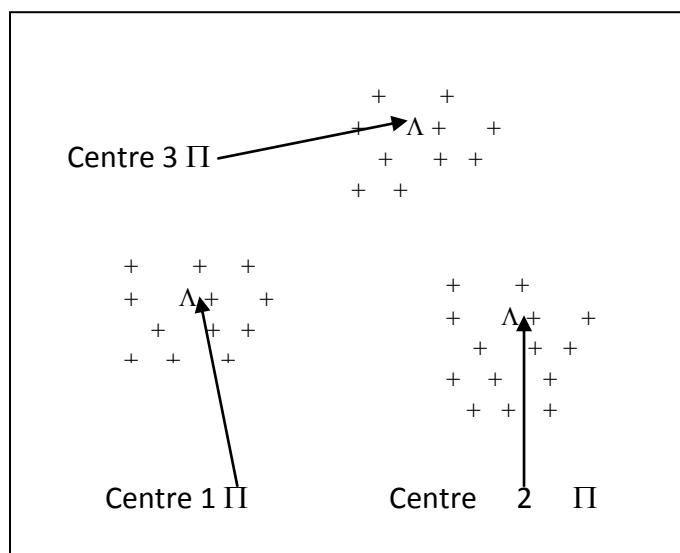
L'algorithme des K-moyennes se propose de rechercher les centres  $W_j$  qui minimisent le critère d'optimisation défini par :

$$E_{KM} = \frac{1}{2} \sum_{p=1}^P \sum_{k=1}^K \|X_p - W_k\|^2 U_{pk} \quad (\text{F.5})$$

La valeur de  $W_j$  qui annule le gradient de  $E_{KM}$  par rapport à  $W_j$  est :

$$W_j = \frac{1}{\sum_{p=1}^P U_{pj}} \sum_{p=1}^P X_p U_{pj} \quad (\text{F.6})$$

$W_j$  est le centre de gravité des observations affectée à la classe  $C_j$ ,  $j = 1, \dots, K$ , (Figure **F.1**)



**Figure F.1** - Schéma de principe de l'algorithme des K-moyennes  
Pour K = 3

Présentons maintenant l'algorithme des K-moyennes :

- 1° Initialiser les centres à des valeurs aléatoires dans l'espace d'observation.
- 2° Affecter les observations aux classes des centres qui leurs sont les plus proches.
- 3° Actualiser les centres des classes une fois toutes les observations sont affectées.
- 4° Stopper l'algorithme lorsque les centres ne changent plus, sinon aller en 2°.

Cet algorithme converge en un nombre fini d'itérations mais la solution obtenue peut dépendre de l'initialisation de l'algorithme.

Une version itérative de l'algorithme des K-moyennes suppose que les observations arrivent séquentiellement. Soit  $X(t+1)$  l'observation disponible à l'itération de rang  $t+1$ . Dans ce cas, le centre  $W_j$  est calculé par :

$$W_j(t+1) = W_j(t) + \frac{1}{q_j(t+1)} \times [X(t+1)U_{t+1,j} - W_j(t)] \quad (\text{F.7})$$

où  $q_j(t+1) = \sum_{t=1}^{t+1} U_{jt}$  est le nombre d'observations assignées à la classe  $C_j$  à l'itération de rang  $t+1$ , qui s'exprime aussi sous une forme itérative par :

$$q_j(t+1) = q_j(t) + U_{j,t+1} \quad (\text{F.8})$$

Seul le centre  $W_j$  est actualisé par les équations (F.7) et (F.8). Les autres centres restent inchangés.