

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



Université du 20 Août 1955 Skikda

Faculté de Technologie

Département de Génie Mécanique



N° d'ordre : D012123007D

THESE

Présentée en vue de l'obtention du diplôme de

Doctorat en Sciences

Spécialité : Electromécanique

Par :

Mr. DJEGHADER REDA

**Utilisation des méthodes de l'intelligence artificielle en vue
d'identification de défauts dans les systèmes énergétiques.**

Soutenue le : 25/05/2023

Devant le Jury composé par :

SEBBAGH TOUFIK	MCA	PRESEDENT	UNIVERSITE 20 AOUT 1955 SKIKDA
METATLA ABDERREZAK	PR	RAPPORTEUR	UNIVERSITE 20 AOUT 1955 SKIKDA
KELIAIAIA RIDHA	PR	CO_RAPPORTEUR	UNIVERSITE 20 AOUT 1955 SKIKDA
SOUFI YUCEF	PR	EXAMINATEUR	UNIVERSITE DE TEBESSA
MENECEUR REDHA	MCA	EXAMINATEUR	UNIVERSITE DE ELOUDI
ABENE ABDERRAHMENE	PR	EXAMINATEUR	UNIVERSITE DE VALENCIENE FRANCE
TALBI NABIL	MCA	EXAMINATEUR	UNIVERSITE 20 AOUT 1955 SKIKDA

Remerciements

Je tiens premièrement à remercier avec prosternation, Allah le tout puissant de m'avoir donné le courage et la patience pour terminer ce travail.

Cette thèse est le résultat de l'engagement de plusieurs personnes qui m'ont accompagné dans ce passionnant parcours. Je voudrais profiter de leur exprimer toute ma gratitude et ma reconnaissance.

Je tiens tout d'abord à remercier sincèrement mon Encadreur de thèse, le Professeur Abd rezeq METATLA et mon Co-Encadreur, le Professeur Rēdha KELIAIA ,pour avoir diriger mes travaux de recherche ainsi que pour leurs disponibilités, leur patience et leurs précieux conseils. Je remercie aussi les membres de jury .

Je remercie mes amis et collègues de laboratoire de l'équipe PRFU de l'université de SKIKDA, spécialement Mr Louahem Msabih Ilyes pour l'ambiance conviviale qu'ils ont contribué à entretenir, les bons moments passés en leur compagnie ainsi que leur sympathie.

Enfin, je me permets d'adresser mes remerciements à ma très chère famille à qui je dédie ce travail. Merci à mes parents (SAAD & MAHBOUBA) qui m'ont toujours soutenu et m'ont accompagné, tout au long de ce chemin, Je remercie aussi mes deux précieux enfants MAJD & MAHBOUBA JOURI ainsi que ma femme pour leur encouragement, sacrifice et leur patience pour finaliser ce travail.

Je tiens également à remercier tous mes frères et sœurs et mes amis pour leurs encouragements.

R. DJEGHADER

SOMMAIRE

Sommaire

Liste des Figures	
Liste des tableaux	
Notions	
Abréviations	
Résumé	
Introduction générale	1

Chapitre I: Recherche bibliographique sur le diagnostic des systèmes

I.1 Introduction.....	4
I.2 Terminologie et définition	4
I.2.1. Fonctionnement normal d'un système	4
I.2.2. Dysfonctionnement	4
I.2.3. Défaut.....	4
I.2.4. Défaillance	5
I.2.5. Panne.....	5
I.2.6. Perturbation.....	5
I.2.7. Résidu	5
I.2.8. Symptôme analytique.....	5
I.3 Types de défaut	6
a. Défauts capteurs	6
b. Défauts actionneurs	7
c. Défauts composants.....	7
I.4 Les méthodes de diagnostic	8
I.4.1 Les méthodes à base de modèle	11
a) Estimation paramétrique	12
b) Observation d'état.....	13
c) Espace de parité.....	14
I.4.2 Les méthodes à base de connaissances	15
a) Reconnaissance des formes.....	15
b) Système expert	18
I.5 Les étapes de diagnostic.....	19
a. Génération des résidus.....	19
b. Détection de défauts	19
c. La localisation de défauts	19
d. L'identification de défaut.....	20
I. 5 Conclusion	20

Chapitre II: Choix de la méthode de diagnostic et application par réseaux de neurones

II .1 Introduction	21
II. 2 Neurone formel.....	21
- Fonction d'activation.....	22
II.3 Architecture de réseaux de neurones	22
I.3.1 Les réseaux de neurones non bouclés	22
II.3.2 Les réseaux de neurones bouclés.....	23
II.4 Apprentissage des réseaux de neurones.....	23
II.4.1 Le mode non supervise	23
II.4.2 Le mode supervise	24
II.5 Algorithme d'apprentissage.....	24
II.5 .1 La rétro-propagation du gradient de l'erreur.....	24
II.5.2 Méthode de Lenvenberg-Marquardt	25
II.6 La classification par les réseaux de neurone	26
III.6.1 Classification linéaire.....	26
III.6.2 Classification non linéaire	28
II.7 Identification par réseau de neurone.....	29
II.7.1 Procédure d'identification	29
II.7.2 Structures de modèles non linéaires	29
II.8 Application des RDN dans le diagnostic	32
II.8.1 Génération de résidus a base de modèle neuronal	32
II.8.2 Classification	34
II.9 Conclusion	34

Chapitre III: Modélisation et types des défauts d'un système photovoltaïque

III.1 Introduction	35
III.2 Chaîne de conversion d'un système photovoltaïque	35
III.3 Description d'un système photovoltaïque	35
III.3.1 Générateur PV	35
- Cellule PV.....	36
- Module PV.....	36
- String PV	37
- Champ PV.....	37
III.3.2 Convertisseur.....	37
- Principe de fonctionnement du MPPT.....	37
III.3.3 Câblage et boîte de jonction	38
III.3.4 Système de protection	38
- Diode de by-pass	38
- Diode anti-retour.....	39

III.4 Les différents types des systèmes photovoltaïques	39
III.4.1 Système PV autonome	39
III.4.2 Système PV en connection directe avec le réseau.....	39
III.4.3 Système PV hybride	40
III.5 Modélisation électrique d'une cellule photovoltaïque	41
III.5.1 Modèle à une diode	41
III.5.2 Modèle à deux diodes.....	42
III.5.3 Modèle de Bishop.....	43
III.6 Les défauts des panneaux photovoltaïques	43
III.6.1 L'augmentation de la résistance série (R_s)	44
III.6.2 Défaut d'ombrage.....	44
III.6.2.1 L'ombrage partiel.....	44
III.6.3 Défauts de la diode de by-pass de diode anti-retour	46
III.6.4 Défaut de module	46
III.6.5 Défaut de connectique.....	47
III.6.6 Défaut de diode anti-retour	47
III.7 Classification des défauts d'un générateur photovoltaïque.....	48
III.8 Conclusion.....	48

Chapitre IV: Etude et simulation de diagnostic de défauts d'un système PV

IV.1 Introduction	49
IV.2 Description du système PV	49
IV.2.1 Les caractéristiques électriques du module photovoltaïque.....	50
IV.2.2 Description de défauts de capteurs et leurs influences dans le système PV	51
IV.2.3 Description de défauts physique et leurs influences sur les strings dans le système PV.....	51
IV.3 Modélisation de système PV	52
IV.4 Influence de la variation de la température et de l'ensoleillement sur le point maximal de puissance (PPM).....	53
IV.5 Influence du phénomène d'ombrage sur la température et de l'ensoleillement du système PV.....	55
IV.6 L'évolution de courant du système PV dans le mode défaillant.....	55
IV.7 L'évolution des caractéristiques I-V et P-V dans le mode défaillant	56
IV.8 Détection et identification de défauts par réseaux de neurones	57
IV.8.1 Génération des résidus	57
IV.8.1.1 Identification par réseau de neurones	57
A. Architecture du réseau de neurones	59
B. Apprentissage du réseau	60
IV.8.1.2 Génération des résidus du système PV par les réseaux de neurones.....	61
IV.9 Détection et classification des défauts	63
- Structure du réseau :	64
- Apprentissage du réseau :	65
VI.9.1 Cas du system sain	65
VI.9.2 Localisation et identification des défauts du système PV dans le cas des défauts capteurs.....	66

VI.9.3	Détection et identification des défauts du système PV dans le cas de défauts physiques	78
VI.9.3.1.	Cas de défaut simple	78
-	Shunt (résistif).....	78
-	Cas de phénomène d'ombrage	79
-	Cas de phénomène d'ombrage au niveau string III	80
-	Cas de phénomène shunt (résistif)intermittent au niveau string I	81
VI.9.3.2	Cas de défauts combinés	82
-	Cas de défaut d'ombrage combiné	82
-	cas de défaut shunt et ombrage.....	83
-	cas de défaut shunt de type intermittent et ombrage	84
VI.10	Conclusion.....	87
	Conclusion générale	88
	Bibliographie	

Références personnelles

Conférence International:

- **Djghader Reda , Metatla Abdrezak (2019),**"Génération de résidus par réseaux de neurones artificielles ",**CIER-2019**, 7^{ième} Conférence Internationale des Energies Renouvelables , Sousse -Tunisie.
- **Djghader Reda , Metatla Abdrezak (2019),**"Fault diagnosis of photovoltaic system using recurrent neural networks",**ATS-2019**, 8^{ième} Conférence Internationale en Automatique & Traitement de signal , Sousse -Tunisie.

Publication International:

- **Djghader, R, Louahem Msabah,I, Benzahioul,S, Metatla, Ab,(2022),**" Fault diagnosis of a photovoltaic system using recurrent neural networks", Bulletin of Electrical Engineering and Informatics (**BEEI**),Vol. 11, No. 6, December 2022, pp. 3079~3090 ISSN: 2302-9285, DOI: 10.11591/eei.v11i6.4295.

Liste des Figures

Figure I.1: Types de défauts d'un système physique.....	6
Figure I.2: Classification des défauts : multiplicatifs et additifs.....	8
Figure I.3: modules d'une procédure de surveillance.....	10
Figure I.4: les différentes méthodes de diagnostic.....	11
Figure I.5 : Procédure Détection et isolation de défaut (FDI).....	12
Figure I.6: principe de la génération de résidus par estimation paramétrique.....	13
Figure I.7 : Principe de la génération du résidus à l'aide d'un observateur.....	14
Figure I.8 : Diagnostic par espace de parité.....	15
Figure I.9: Les observations x_i est leurs classe C_i	16
Figure I.10: Schéma de diagnostic d'un système par reconnaissance de formes.....	17
Figure I.11 : Structure générale d'un système expert de diagnostic.....	18
Figure I.12 : L'étape de génération de résidus.....	19
Figure II.1 : Neurone formel.....	21
Figure II.2: Fonction d'activation.....	22
Figure II.3 : Séparation de deux classes avec adaptateur linéaire.....	27
Figure II.4: Architecture d'un réseau a couches.....	28
Figure II.5: La procédure de base d'identification du système.....	29
Figure II.6: Les structures des modèles NNFIR (a) et NNARX (b).....	30
Figure II.7: La structure du modèle NNARMAX.....	31
Figure II.8: La structure du modèle NNOE.....	32
Figure II.9 :Génération de résidu par le modèle neuronal.....	33
Figure III.1 : Schéma de conversion d'énergie d'un système PV connecté au réseau.....	35
Figure III.2 : Des cellules PV dans le module mise en série.....	36
Figure III.3 : Différents phases de convertisseurs.....	37
Figure III.4 : Courbe I-V d'un champ PV en fonctionnement normal.....	38
Figure III.5: Scéma d'installation photovoltaïque autonome.....	39
Figure III.6: Installation photovoltaïque couplée au réseau.....	40
Figure III.7: Système PV hybride (PV, Eolienne et Moteur diesel biocarburant).....	40
Figure III.8: Montage à une diode d'une cellule PV.....	41
Figure III.9: Montage à deux diodes d'une cellule PV.....	42
Figure III.10: Montage de Bishop.....	43
Figure III.11: Défaut d'augmentation de la résistance R_s	44
Figure III.12: Schéma de défaut d'ombrage partiel.....	45
Figure III.13: Montage de défaut de la diode de by-pass.....	46
Figure III.14: Montage de défaut module.....	46
Figure III.15 :Montage d'un string PV avec la résistance de connectique non nulle.....	47
Figure III.16 :Montage d'un champ PV avec la diode anti-retour défaillante.....	47
Figure IV.1: La configuration du string de PV étudié.....	52
Figure IV.2 : La configuration retenu pour la modélisation.....	53
Figure IV.3 : Influence de la température sur le courant de court- circuit (I_{cc}).....	54
Figure IV.4 : Influence d'irradiation sur le point de puissance maimal (PPM).....	54
Figure IV.5 : Température et l'irradiation dans le cas sain et avec phénomène d'ombrage	55
Figure IV.6 : Courant en fonction de temps cas sain, ombrage et défaut de résistance.....	56

Figure IV.7: Caractéristiques I-V & P-V de système PV avec les trois mode de fonctionnement.....	56
Figure IV.8: Principe d'isolation et de classification de défauts.....	57
Figure IV.9 : Schéma bloc d'identification par réseau de neurones.....	58
Figure IV.10: L'organigramme d'élaboration d'un modèle neuronale.....	58
Figure IV.11: Architecture du réseau de neurone	59
Figure IV.12: L'erreur quadratique d'apprentissage du modèle neuronal	60
Figure IV.13: Courant de string1 réel est estimée et l'erreur de prédiction.....	60
Figure IV.14: Courant de string2 réel est estimée et l'erreur de prédiction.....	61
Figure IV.15: Courant de string3 réel est estimée et l'erreur de prédiction.....	61
Figure IV.16: Génération des résidus par les réseaux de neurones.....	62
Figure IV.17 : Les résidus du système PV en absence de défaut	62
Figure IV. 18: Procédure générale pour la classification et l'identification des défauts	63
Figure VI. 19 : Evaluation du résidus par le réseau RNN.....	64
Figure IV.20 : L'erreur quadratique d'apprentissage du réseaux.....	65
Figure IV.21: Résidus et décision en absence de défauts.....	66
Figure IV.22: Résidus et décisions du réseu en présence de défauts sur le capteur1.....	66
Figure IV.23: Résidus et décisions du réseu en présence de défauts sur le capteur2.....	67
Figure IV.24: Résidus et décisions du réseu en présence de défauts sur le capteur3.....	68
Figure IV.25: Résidus et décisions du réseau en présence des défauts sur le capteur1 et capteur2	70
Figure IV.26: Résidus et décisions du réseau en présence des défauts sur le capteur2 et capteur3	71
Figure IV.27: Résidus et décisions du réseau en présence des défauts sur les trois capteurs ..	72
Figure IV.28: Résidus et décisions du réseau en présence de défauts de bruit de mesure sur le capteur1	72
Figure IV.29: Résidus et décisions du réseau en présence de défaut sur le capteur2	73
Figure IV.30: Résidus et décisions du réseau en présence de défaut sur le capteur2.	74
Figure IV.31: Résidus et décisions du réseau en présence de défaut sur le capteur3	75
Figure IV.32: Résidus et décisions du réseau en présence de défaut sur le capteur1	75
Figure IV.33: Résidus et décisions du réseau en présence de défaut sur le capteur1.	76
Figure IV.34: Evolution du RNN en fonction des défauts capteurs.....	77
Figure IV.35: Résidus d'identification et la décision du réseau : cas défaut shunt.....	78
Figure IV.36: Résidus d'identification et la décision du réseau : cas de phénomène d'ombrage	79
Figure IV.37: Résidus d'identification et la décision du réseau : cas de phénomène d'ombrage	80
Figure IV.38: Résidus d'identification et la décision du réseau : cas défaut shunt de type intermittent	81
Figure IV.39: Résidus d'identification et la décision du réseau : cas de défaut d'ombrage combine	82
Figure IV.40: Résidus d'identification et la décision du réseau : cas de défaut Shunt et d'ombrage combiné	83
FigureIV.41 :Résidus d'identification et la décision du réseau : cas de défaut shunt de type intermittent et d'ombrage combiné	84
Figure IV.42 :Résidus d'identification et la classification du réseau : cas de défaut shunt de type intermittent et d'ombrage combiné.	85
Figure IV.43: Evolution du RNN en fonction des défauts physiques	86

Liste des Tableaux

Table III . : La classification des défauts selon leurs catégories.	48
Table IV.1: Description de la base de données du système PV	50
Table IV.2 : Caractéristique électriques du module CLS220P	50
Table IV.3: Description de défauts capteur et leurs influences sur les strings.....	51
Table IV.4: Description de défauts physique et leurs influences sur les strings	51
Table IV.5: Table de signatures des défauts capteurs	76
Table IV.6 : Identification de défaut physique du système PV	85

Notations

$x(t)$	Signal d'observée
$y(t)$	Signal de sortie
$u(t)$	Signale d'entrée
$y_m(t)$	Signale mesurée
$r(t)$	Résidus
$\hat{y}(t)$	Signale d'estimation
$f(t)$	Signale de défaut
$d(t)$	Signale de perturbation
$e(t)$	Erreur
θ_n	Vecteur paramètre nominale
$\hat{\theta}$	Vecteur paramètre estimée
$A \in R^{n \times n}$	La matrice d'état ou d'évolution
$B \in R^{n \times m}$	La matrice d'entrée
$C \in R^{p \times n}$	La matrice de sortie ou d'observation
D_x	La matrice d'action des perturbation
F_x	La matrice d'action des défauts
F_y	La matrice d'action des défauts
L	La matrice du gain de l'observateur.
W	La Matrice de paramètre.
w^T	La matrice du poids du réseau.
g	La fonction non linéaire des réseaux.
d_k	La sortie désirée du réseau.
F	La fonction de transfert du neurone.
α	Le coefficient d'apprentissage.
Voc	Le point de tension de circuit ouvert.
Isc	Le point de courant de court-circuit.
T	La température [°C]
G	Irradiation de solaire [W/m ²].
I	Le courant fourni par la cellule [A]
V	La tension à la borne de la cellule [V].
I_{ph}	Le courant équivalent proportionnel à l'ensoleillement reçu par la cellule [A] .
I_0	Le courant de saturation inverse de la diode [A] .
V_t	La tension thermique de la diode [V].
R_s	La résistance série de la cellule [Ω] .
R_{sh}	La résistance shunt de la cellule [Ω].
a_1	Le facteur d'idéalité de diode D1.
a_2	Le facteurs d'idéalité de diode D2 .

Abréviations

FDI	Fault Detection and Isolation.
MLP	Multi- Layer Perceptron.
RNN	Recurrent Neural Network.
RDN	Réseau de Neurone
MIMO	Multi Input-Multi Output.
NNFIR	Identify a neural network FIR model.
FIR	Modèle a réponse impulsionelle finie.
NNARX	Identify a neural network ARX (or AR) model.
ARX	Modele Autoregressif a entree eXogene .
NNARMAX	Identify a multi-output neural network ARX (or AR) model.
ARMAX	Modèle Autorégressif a Moyenne mobile et entrée eXogène.
NNOE	Identify a neural network Output Error model.
OE	Modèle Erreur de sortie.
PV	Photovoltaïques .
GPV	Générateur PV.
MPPT	Maximum Power Point Tracker .

Résumé : Les défauts existant dans le système PV, sont des défauts de composants ou des défauts produit par les phénomènes physiques. Ces défauts peuvent réduire considérablement l'efficacité, le rendement énergétique, ainsi que la sécurité et la fiabilité de l'ensemble de l'installation photovoltaïque s'ils ne sont pas rapidement identifiés et corrigés. Les méthodes de détection et isolation des défauts (FDI) sont essentielles pour la sécurité, l'efficacité opérationnelle élevée et la fiabilité du système de l'installation photovoltaïque. Ce travail fait partie de la détection et de l'identification des défauts capteurs et physiques dans les systèmes photovoltaïques (PV) par une technique moderne basée sur l'intelligence artificielle. Pour ce faire, dans la première étape, nous avons utilisé un réseau de neurones de type MLP (Multi Layer Perceptron) pour la génération de résidus, et dans la deuxième partie du travail, nous avons utilisé un autre réseau de type RNN (Recurrent Neural Network) pour identifier et classer les types de défauts dans les systèmes photovoltaïques. Les résultats obtenus montrent clairement la performance des réseaux développés pour la détection rapide de défauts avec l'estimation de leurs temps d'apparition ainsi que la décision robuste d'identifier le type de défauts dans le système PV.

Mots-clés : Isolation de Défaut, Détection de Défaut, Diagnostic, Système PV, Réseaux de Neurones.

Abstract: There exist two types of faults that can affect a photovoltaic system, faults related to the materials of the system and those produced by physical conditions. If not quickly identified and corrected, these faults are able to significantly reduce the efficiency, the energy yield, as well as the safety and the reliability of the entire photovoltaic facility. This work is part of the detection and identification of sensor and physical faults in photovoltaic (PV) systems by a modern technique based on artificial intelligence. In the first step of this, we used a neural network of the type MLP (Multi Layers Perceptron) for the generation of residuals, and in the second part of the work, we used another network of the type RNN (Recurrent Neural Network) to identify and classify types of faults in photovoltaic systems. The results obtained clearly show the performance of the networks developed for the rapid detection of the appearance of faults with the estimation of their times as well as the robust decision to identify the type of faults in the PV system.

keywords: Fault Isolation, Fault Detection, Diagnosis, PV System, Neural Networks.

ملخص: الأعطال الموجودة على مستوى أنظمة الطاقة الكهروضوئية هي عبارة عن أعطال متعلقة بالأجهزة ، أو أعطال ناتجة عن ظروف مناخية ، هي سبب في نقص الكفاءة وإنتاج الطاقة بشكل كبير، فضلاً عن سلامة وموثوقية التركيب الكهروضوئي بأكمله. لا يمكن تحديدها وتصحيحها بسرعة. تعد طرق إكتشاف الأعطال والعزل التشخيصي (FDI) ضرورية للسلامة وكفاءة التشغيل العالية وموثوقية النظام لتركيب الخلايا الكهروضوئية. هذا العمل هو جزء من الكشف والتعرف على أجهزة الاستشعار بالأعطال في أنظمة الطاقة الكهروضوئية (PV) بتقنية حديثة تعتمد على الذكاء الاصطناعي. في الخطوة الأولى ، استخدمنا شبكة عصبية من نوع MLP (MultiLayerPerceptron) لتوليد المخلفات، وفي الجزء الثاني ، استخدمنا شبكة أخرى من نوع RNN (الشبكة العصبية المتكررة) لتحديد وتصنيف أنواع الأعطال في الأنظمة الكهروضوئية. تظهر النتائج التي تم الحصول عليها بوضوح أداء الشبكات المطورة للكشف السريع عن ظهور الأعطال مع تقدير أوقاتها وكذلك القرار المناسب لتحديد نوع الأعطال في النظام الكهروضوئي.

الكلمات الرئيسية: عزل الأعطال، كشف الأعطال، التشخيص، نظام PV، الشبكات العصبية.

INTRODUCTION GENERALE

Introduction Générale

L'augmentation du coût des énergies d'une part et la limitation de ses ressources d'autre part a permis l'apparition d'autres formes d'énergies telle que l'énergie photovoltaïque comme une solution adéquate parmi les autres. La disponibilité de l'irradiation solaire au cours de l'année dans les quatre coins du globe terrestre encourage son développement.

L'énergie photovoltaïque (PV) est une énergie électrique produite à partir du rayonnement solaire grâce à des capteurs solaires ou à des centrales solaires photovoltaïques. Le soleil est considéré comme une source inépuisable. Il y a deux grands types de panneaux photovoltaïques, les panneaux solaires monocristallins et ceux poly cristallins. Citons que le panneau solaire monocristallin est le plus utilisé au monde vue sa puissance et sa garantie de produit et de rendement.

Au niveau des grandes installations, une station solaire PV peut contenir des milliers de panneaux photovoltaïques, dont la stabilité et la qualité de la puissance générée sont en connexion avec le fonctionnement de chaque cellule. La question posée, dans ce type d'installation, est comment surveiller le réseau illimité de cellules photovoltaïques afin de conserver le fonctionnement normal de la station ?

On constate généralement la fiabilité des générateurs PV en la comparant à d'autres systèmes. Néanmoins, un système photovoltaïque peut croiser divers pannes produisant l'anomalie au niveau de ce dernier, des études ont enregistré que la fiabilité des systèmes PV est solidement liée au matériel adopté pour la construction des panneaux PV, de la température, de l'humidité et de l'irradiation.

Plusieurs défauts peuvent subvenir au niveau du système PV parmi ces défauts, on peut citer les défauts de type : - fabrication des composants, - électrique, provoqués généralement par le climat. Par conséquent, le défaut d'ombrage partiel est habituellement le plus identifié dans un générateur PV, il est généralement causé par le passage des nuages, les arbres, les bâtis, etc.

Souvent, on rencontre l'ombrage partiel dans les zones habitantes, les cellules ayant moins d'irradiation doivent consommer l'excès de courant transmis par les cellules les plus éclairées, ce qui crée ainsi des échauffements en cas de faute de protection.

Des diodes de dérivation sont mises dans des boîtes de connexion pour que la cellule ne surchauffe pas. Ce qui permet de borner la tension opposée et la température de la cellule ombrée. Néanmoins, si l'ombrage partiel continue, et si la remise des diodes de dérivation n'est pas juste ou il y a un dysfonctionnement des diodes, la cellule ombrée peut surchauffer, allant jusqu'à la perte d'une partie du générateur PV.

D'autre part lorsque plusieurs défauts persistent sur les systèmes PV, ceci entraîne une baisse de performance qui réduit le rendement, et donc réduit l'avantage de l'installation, sans évoquer le coût de maintenance pour réparer le système.

Un diagnostic précis, une détection et une localisation de défauts dans un système PV, permettent de minimiser les coûts de maintenance et d'augmenter considérablement la production de l'énergie électrique.

Le travail abordé dans cette thèse concerne le diagnostic des systèmes complexes en utilisant des méthodes de l'intelligence artificielle, et en particulier les réseaux de neurones. Il est constitué de deux phases: la première est relative à la génération des résidus qui est basée sur l'écart entre le comportement réel du système et le comportement estimé; tandis que la deuxième contribue à la prise de décision, elle évalue les résidus afin de faire une classification des défauts détectés.

Organisation du manuscrit de la thèse

Le présent manuscrit est structuré comme suit :

Dans le premier chapitre nous présenterons un état de l'art sur les méthodes de diagnostic, nous donnerons quelques explications et termes relatifs à ce domaine, les étapes de diagnostic (détection, localisation, identification), ainsi que quelques définitions utilisées dans le diagnostic.

Dans le second chapitre, nous donnerons un résumé sur les réseaux de neurones, ainsi que quelques définitions, applications du réseau de neurone dans le domaine diagnostic.

Dans le troisième chapitre, nous aborderons en premier lieu sur les différents composants reliés au système PV, en deuxième lieu, nous définirons les différents types électriques équivalents d'une cellule PV et les différents types des défauts affectant les systèmes photovoltaïques.

Dans le dernier chapitre de la thèse, nous présenterons une étude numérique d'un système PV en vue de diagnostiquer les défauts physiques et les défauts capteurs. Cette étude est réalisée dans l'environnement MATLAB.

Finalement, le travail est achevé par une conclusion générale en suggérant quelques perspectives.

CHAPITRE I

I.1 Introduction

Le diagnostic des défauts dans les systèmes industriels a été un thème de recherche marquant, dès les débuts de l'automatique. On distingue habituellement deux étapes essentielles afin d'établir le diagnostic : la détection et la localisation, aussi l'identification.

Cette introduction est faite pour démontrer les techniques usuelles dans le domaine de diagnostic des défauts et ses différents types, aussi la terminologie de diagnostic. En littérature dans ce domaine on trouve plusieurs définitions quelques fois distinctes. C'est pourquoi on entame notre travail par des explications de mots qui sont essentiels pour une bonne compréhension.

I.2 Terminologie et définition

Dans un premier temps, on explique les termes essentiels utilisés dans le domaine de diagnostic[Ros,11].

I.2.1. Fonctionnement normal d'un système

Un fonctionnement est dit normal quand les caractéristiques du système physique restent à proximité de leurs valeurs nominales. Sinon on le nomme défaillant dans le cas contraire.

I.2.2. Dysfonctionnement

C'est l'anomalie irrégulière qui apparaît au niveau d'une fonction saturée par le système physique.

I.2.3. Défaut

La notion de défaut est importante au cours des faits de surveillance pour la conduite et la maintenance des procédés industriels. On dit défaut tout écart entre le comportement mesuré sur le dispositif et le comportement théorique. En l'absence de défaut cet écart est idéalement nul. Les défauts peuvent apparaître au niveau des capteurs, des actionneurs ou au niveau du processus lui-même.

I.2.4. Défaillance

Une défaillance est une anomalie du système physique, qui représente un fonctionnement inadmissible en vue des performances. Certainement, une défaillance implique l'apparition d'un défaut lors d'un écart entre les deux caractéristique mesurée et théorique. Cependant, un défaut n'engendre pas forcément une défaillance puisque le dispositif peut défendre sa fonction principale.

I.2.5. Panne

Une panne est l'incapacité d'un procédé à réaliser une fonction vitale. Une panne est le résultats d'une défaillance et donc d'un défaut :



Au sein de la maintenance protectrice conditionnelle, il est évident que le diagnostic permet la détection et la localisation d'un défaut avant que celui-ci ne mène à une panne qui provoquera l'arrêt du système.

I.2.6. Perturbation

Entrée du système physique qui n'est pas une commande. Autrement dit, c'est une entrée non contrôlée.

I.2.7. Résidu

Un indicateur de défauts basé sur l'écart entre les mesures et les estimées.

I.2.8. Symptôme analytique

Un changement de comportements dynamique du système physique provoqué par un défaut.

I.3 Types de défauts

Un défaut est la différence entre la valeur d'un système et sa valeur estimée. Comme l'illustre la figure (I.1), on distingue trois types de défauts : défauts capteurs, défauts actionneurs, et défauts procédés (ou défauts composants).

Chacun de ces défauts ainsi que leurs influences sur le processus sont décrits brièvement dans le paragraphe ci-dessous.

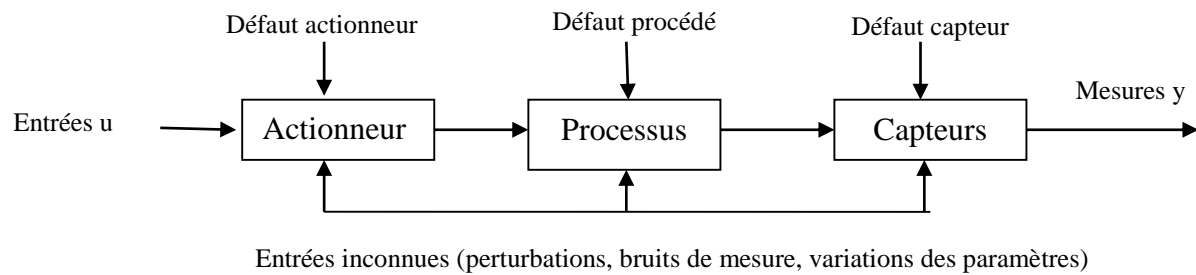


Figure I.1:Types de défauts d'un système physique

I.3.1 Défauts capteurs

Les capteurs concernent la sortie du système (mesuré) qui ne sont pas identique aux réponses du système.

On les représente mathématiquement comme suit [Sob,09]:

$$y_i(t) = \begin{cases} x_i(t) \forall t \geq t_0 \text{ sans défaut} & \text{(I.1)} \\ x_i(t) + b_i(t) |b_i(t)| = 0, b_i(t_f) \neq 0 & \text{biais} \\ x_i(t) + b_i(t) |b_i(t)| = c_i(t), 0 < c_i \ll 1 \quad \forall t \geq t_f, & \text{dérive} \\ x_i(t) + b_i(t) |b_i(t)| \leq \bar{b}_i, b_i(t) \in L^\infty \forall t \geq t_f \text{ pert d'efficacité} \\ x_i(t_f) \forall t \geq t_f \text{ blocage} \\ k_i(t) x_i \quad 0 < \bar{k}_i \leq k_i(t) \leq 1 \quad \forall t \geq t_f \text{ défaut de calibrage} \end{cases}$$

Avec:

t_{f_i} : temps d'apparition de défaut pour l' $i^{\text{ème}}$ capteur et b_i le détermine ou $b_i \in [-\bar{b}_i, \bar{b}_i]$ avec $\bar{b}_i > 0$. En plus, $k_i \in [\bar{k}_i, 1]$ avec $\bar{k}_i > 0$ indique l'efficacité du capteur.

I.3.2 Défauts actionneurs

Les défauts actionneurs affectent les entrées du système qui ne correspondent pas à la commande agissant sur le système.

Les expressions suivantes montrent les types de défauts actionneurs:

$$u_a^i(t) = \begin{cases} u_c^i(t) & \text{sans défaut} \\ k_i(t)u_c^i(t) & 0 < \varepsilon_i \leq k_i(t) < 1, \forall t \geq t_{f_i} & \text{pert d'efficacité} \\ 0 & \forall t \geq t_{f_i} & \text{oscillation} \\ u_c^i(t_{f_i}) \forall t \geq t_{f_i} & \text{blocage} \\ u_{i \min} \vee u_{i \max} \forall t \geq t_{f_i} & \text{saturation} \end{cases} \quad (I.2)$$

Avec :

$u_a^i(t)$: sortie de l'actionneur ; $u_c^i(t)$ la commande appliqué à l' $i^{\text{ème}}$ actionneur; t_{f_i} indique le temps d'apparition du défaut à l' $i^{\text{ème}}$ actionneur ; k_i est l'efficacité de l'actionneur, $\varepsilon_i > 0$ est l'efficacité minimale; $u_{i \max}$ et $u_{i \min}$ sont respectivement les limites de sortie de l' $i^{\text{ème}}$ actionneur.

I.3.3 Défauts composants

Ils affectent directement le système. Ces défauts interviennent quand les paramètres du système changent. Ils induisent une instabilité de système.

On peut classés les défauts selon leurs évolutions temporelles [Ise,02] :

- **Abrupt:** ce type de défaut est caractérisé par un comportement temporel discontinu. Cette évolution est due d'une panne brutale de l'élément lui-même: arrêt total ou partiel de connexion. Une représentation mathématique de ce défaut est donnée par:

$$f(t - t_{f_i}) = \begin{cases} \delta & t > t_{f_i} \\ 0 & t < t_{f_i} \end{cases} \quad (I.3)$$

Où : $f(t - t_{f_i})$ est le signal temporel du défaut et 0 est un seuil constant.

- **Intermittent:** Il apparait dans un intervalle distinct, représentant un des types de défaut abrupt.

- **Graduel**: il est caractérisé d'une dégradation. On ne peut pas facilement le détecter car il varie temporellement. La relation suivante montre son évolution temporelle :

$$(t - t_{f_i}) = \begin{cases} \delta (1 - e^{-\alpha(t-t_{f_i})}) & t \geq t_{f_i} \\ 0 & t < t_{f_i} \end{cases} \quad (I.4)$$

Où : δ et α sont deux constantes positives.

On classe les défauts sous deux types, additifs et multiplicatifs, selon leurs effets sur les comportements du système (Figure I.2). Les défauts additifs sont des signaux bruités qui s'accumulent en un point du schéma fonctionnel. On considère Les défauts capteurs et actionneurs comme des défauts additifs, cependant, les défauts composants sont spécifiés comme défauts multiplicatifs. Ainsi que des changements dans les caractéristiques de la dynamique de système.

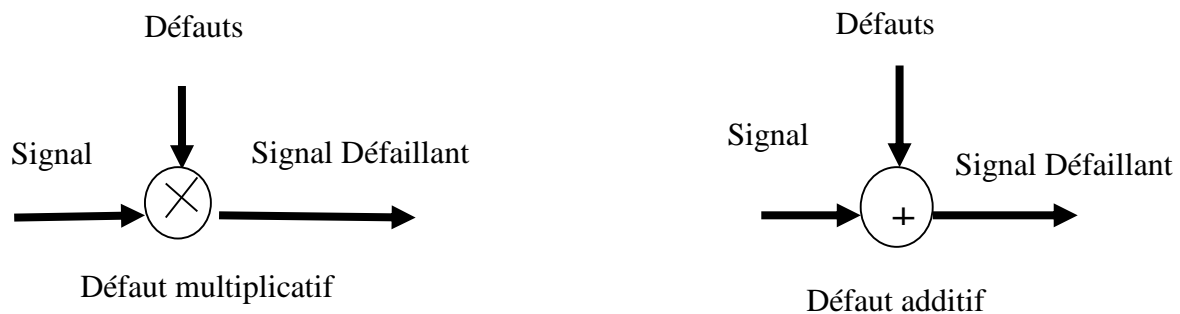


Figure I.2 : Classification des défauts : multiplicatifs et additifs.

I.4 Les méthodes de diagnostic

Il existe plusieurs procédés de diagnostic de défauts utilisés dans les différents espaces industriels. Ils consistent à évaluer les données relevées lors du fonctionnement réel du système avec son fonctionnement nominal ou de ses fonctionnements défaillants. Les méthodes de diagnostics sont conditionnées selon la forme, sous laquelle se présente la connaissance sur le système.

Les techniques de diagnostic sont connues sous le nom de FDI (Fault Detection and Isolation). L'application de cette approche dans le cas des systèmes linéaires a été très amplement étudiée.

La FDI pour les systèmes non linéaires est encore un champ de recherche important. Pour quelques systèmes non linéaires particuliers, des chercheurs [Sre, 93] ont employé la linéarisation autour des points de fonctionnement afin d'appliquer des méthodes linéaires de FDI. En général, cela n'est pas toujours réaliste, car il est dû aux fortes non linéarités (tel que les effets de saturation ou comportement non analytique) ou à l'inutilité de la linéarisation.

Par conséquent, plusieurs approches de FDI ont été améliorées afin de manipuler également des systèmes non linéaires plus généraux, on illustre l'approche basée sur les observateurs, l'approche de l'espace de parité et l'estimation paramétrique. Les observateurs flous et les réseaux de neurones artificiels ont été également considérés comme des outils pratiquement pertinents dans le cas des systèmes non linéaires. Récemment, de nouvelles approches ont été proposées pour la classe de systèmes non linéaires à entrée affine. Plus précisément une approche de FDI basée sur les observateurs pour les systèmes non linéaires a été étudiée et développée par [Åst, 00]; [Ise, 94]; [Ven, 03].

Au cours de notre recherche bibliographique, on a remarqué que la procédure de diagnostic des défaillances affectant les processus industriels s'assemble sous ces étapes (Figure I.3):

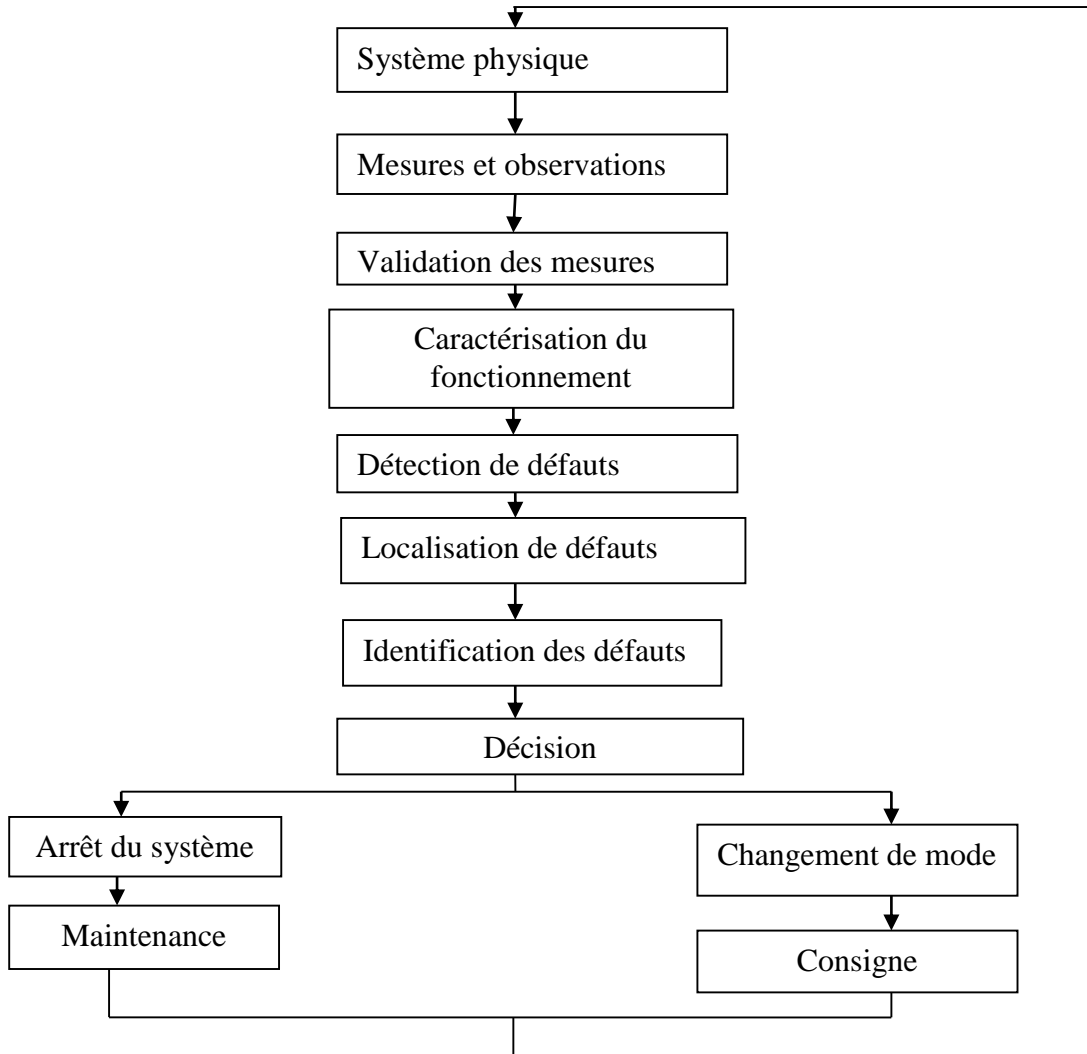


Figure I.3 : modules d'une procédure de surveillance

La classification des méthodes de diagnostic pour un système industriel donné se fait après une énumération de besoin des connaissances disponibles, de nombreuses approches ont été développées afin de collaborer au diagnostic des défauts (Figure I.4). Nous allons présenter ces différentes méthodes [Zwi, 95], en les rassemblant en trois classes: les méthodes de diagnostic de modélisation fonctionnelle et matérielle ou méthodes basées sur le mode de raisonnement, les méthodes de diagnostic de modélisation physique et enfin les méthodes de diagnostic d'analyse des signatures externes.

Les approches à base de modèles, s'appuient sur les principes physiques fondamentaux et sur des modèles quantitatifs ou qualitatifs insérant la structure du système et les liens entre composants [Pat, 89], [Ger, 91].

Les approches à base de connaissance, se fondent sur les connaissances et les raisonnements experts [Fra, 89], [Adj, 93], [Beb, 07].

Les approches à base de données réalisent une extraction des caractéristiques du système à partir de données sauvegardées [Din, 91].

L'étude se focalise autour de la construction directe des résidus sans construire de modèle de comportement du système étudié.

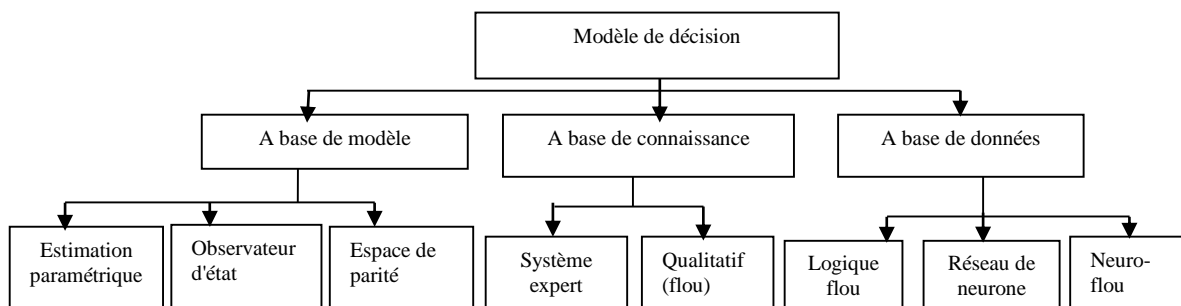


Figure I.4 : Les différentes méthodes de diagnostic

I.4.1 Les méthodes à base de modèle

Les méthodes de diagnostic à base de modèles occupent une place importante dans la littérature. Leur utilisation, notamment dans le cadre d'applications critiques (systèmes énergétiques, systèmes de transport, industrie lourde), s'est énormément développée. Le diagnostic à base de modèle a été développé dès les années soixante-dix. On illustre sur le plan méthodologique [Pat, 89], [Fra, 90], [Ise, 97a], [Maq, 97], [Che, 99], alors que [Ise, 96] a fait le point sur les applications industrielles de cette approche. Cette approche FDI, comme on l'a vu précédemment, contribue aux techniques de génération de résidus, de détection et de localisation des défauts. Cette approche est représentée sur la Figure I.5 [Ros, 11], [Kou, 12]:

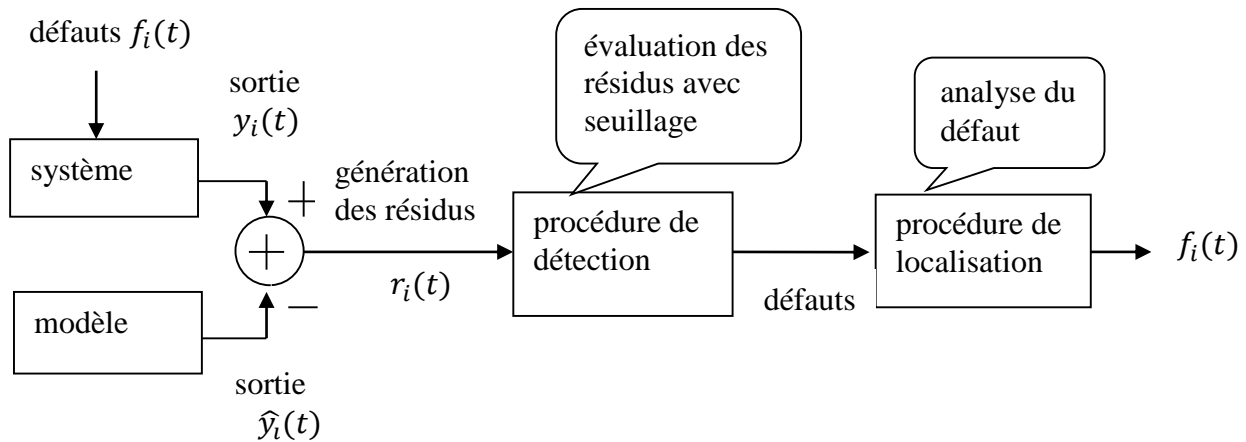


Figure I.5 : Procédure Détection et isolation de défaut (FDI)

La première phase de diagnostic d'un système à base de modèle est de générer des indicateurs de défauts contenant des informations sur les dysfonctionnements du système à surveiller. Le principe est de mesurer l'erreur entre les mesures des signaux du procédé, capteurs ou actionneurs, et la valeur théorique donnée par le modèle en cas de fonctionnement réel. La génération de résidus est un élément essentiel pour assurer les comportements d'un système de diagnostic. Par conséquent, la précision de la détection et la localisation dépendra de la performance du système de résidus donné.

a) Estimation paramétrique

Le modèle mathématique d'un système, qu'il soit de connaissance ou de représentation, fait intervenir un ensemble des paramètres dont les valeurs numériques sont généralement inconnues. Les techniques d'estimation paramétrique permettent, à partir d'un ensemble de mesure réalisées sur l'installation, de définir le vecteur des paramètres intervenant dans le modèle.

Le défaut apparaissant au sein du système entraîne une modification de ses caractéristiques physiques d'où résulte une évolution significative des paramètres par rapport à leurs valeurs nominales. Autrement dit, tout écart notable des paramètres par rapport aux valeurs nominales révèle un défaut.

De ce fait, la recherche d'un estimateur paramétrique pour diagnostiquer des systèmes industriels est captivante. Alors, l'estimation des paramètres du système, pourrait être comparée aux paramètres réelles correspondantes.

Le schéma de la figure I.6 représente la génération de résidus à partir d'une estimation des paramètres du système. $\hat{\theta}$ est le vecteur des paramètres estimée et θ_n le vecteur des paramètres réels correspondants [Ros,11].

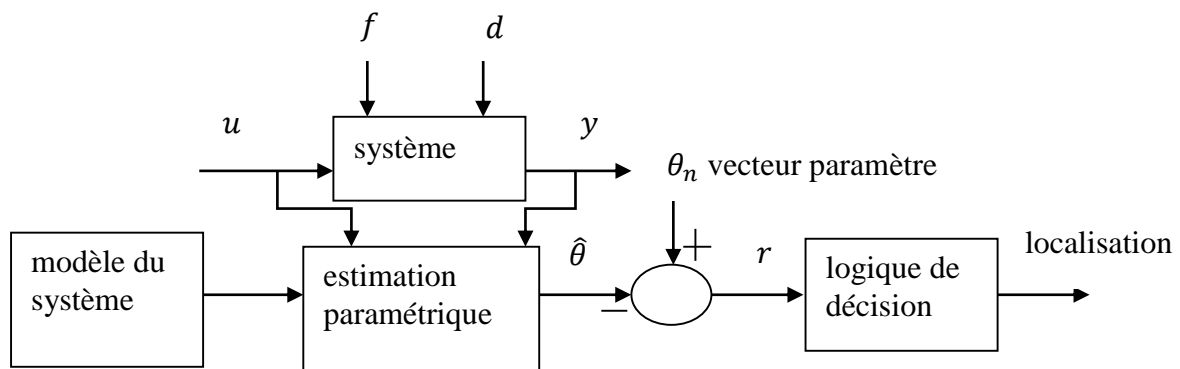


Figure I.6: Principe de la génération de résidus par estimation paramétrique

Le choix d'une structure de modèle de système est suffisant afin de générer un indicateur de défaut précis. Cependant, pour réaliser une analyse plus fine du défaut on utilise un modèle de connaissance en temps continu. Par conséquent, les paramètres d'un modèle de connaissance, ont une signification physique directe, par opposition au modèle de représentation. En effet, l'estimation de tels paramètres physiques va largement faciliter la détection et la localisation des défauts. Cependant, nous considérerons alors particulièrement le problème de l'identification des paramètres d'un modèle de connaissance.

b) Observation d'état

Le problème de l'estimation d'état d'un système est considérable que ce soit pour la mise en œuvre d'une loi de commande ou pour le diagnostic. La génération de résidus se base sur l'observateurs est l'estimation des sorties du système selon les grandeurs mesurables, autrement dit les entrées et les sorties. Le résidu est l'écart entre la sortie estimée et la sortie mesurée.

Un observateur d'état, appelé aussi estimateur, est un système dynamique ayant comme entrées, les entrées et les sorties du processus réel, et le vecteur des résidus représentant une étape du diagnostic.

La figure I.7 indique le principe général d'un observateur qui comporte notamment un modèle d'état du système bouclé par l'écart d'estimation[Ros,11].

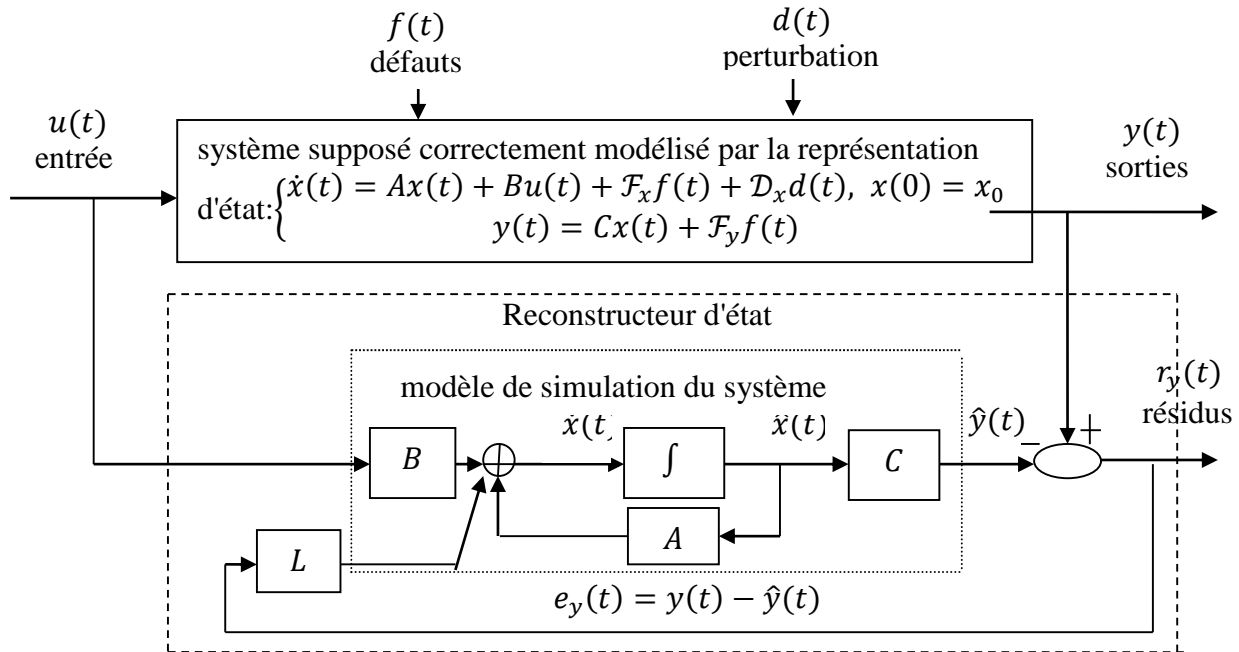


Figure I.7 : Principe de la génération du résidu à l'aide d'un observateur

Ou: $A \in R^{n \times n}$ est la matrice d'état ou d'évolution, $B \in R^{n \times m}$ est le vecteur d'entrée, $C \in R^{p \times n}$ est le vecteur de sortie ou d'observation, \mathcal{D}_x représente la d'action des perturbation $d(t)$, \mathcal{F}_x et \mathcal{F}_y sont les matrices d'action des défauts $f(t)$ à détecter, L la matrice du gain de l'observateur.

c) Espace de parité

Les équations du modèle sont projetées dans un espace particulier appelé espace de parité, qui permet d'éliminer les inconnues par des redondances. Les équations projetées ne font collaborer que des variables mesurables (les entrées et les sorties du système) sur une partie d'estimation. Ces équations s'appellent des relations de redondance analytique(RRA). L'idée est de tester la cohérence des mesures par rapport à leurs estimations données par le modèle, on parle alors de consistance des mesures, de leur parité (figure I.8) [Ros,11],[Kou,12]).

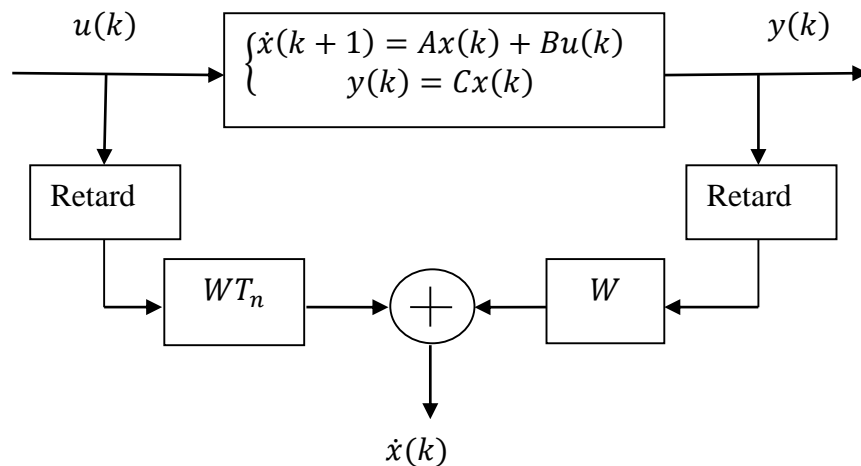


Figure I.8 : Diagnostic par espace de parité

Avec : \mathbf{W} est une de projection dans l'espace de parité.

I.4.2 Les méthodes à base de connaissances

On applique ces méthodes quand la modélisation des dispositifs qui relient les causes des défauts n'est pas techniquement réalisable. Elles sont basées sur le retour d'essai. On aperçoit entre ces méthodes la reconnaissance des formes, les réseaux de neurones, la logique floue et les systèmes experts ou à base de connaissances.

a) *Reconnaissance des formes*

Cette technique rassemble la composition des méthodes qui acquiesce le classement spontané d'une forme, selon sa ressemblance par rapport à une forme de référence.

En d'autres termes, il faut donc décider à quelle classe d'objets(formes) connus, l'objet observé, qu'on appelle une forme, doit être placé. On détermine une forme en utilisant q paramètres, appelés caractères, représentant les composantes d'un vecteur forme x qui est représentée par un point d'un espace à q dimension, appelé espace de représentation ($x \in R^q, x^T = [x_1 x_2 \dots x_q]$). Dans la suite, nous définirons C_1, C_2, \dots, C_l , les l mentionne les diverses classes, d'un problème de reconnaissance des formes. L'objectif est donc, selon une forme x , de décider si on l'affecte à la classe C_1 ou $C_2, \dots, ou C_l$. Chaque catégorie utilise une partie géométrique de l'espace R^q , le problème consiste alors, selon les différentes classes, à déterminer des limites entre classes[Ros,11].

Comme le montre la figure I.9, la connaissance des limites entre classe permet la désignation d'une nouvelle observation à l'une d'entre elles, c'est l'opération de discrimination.

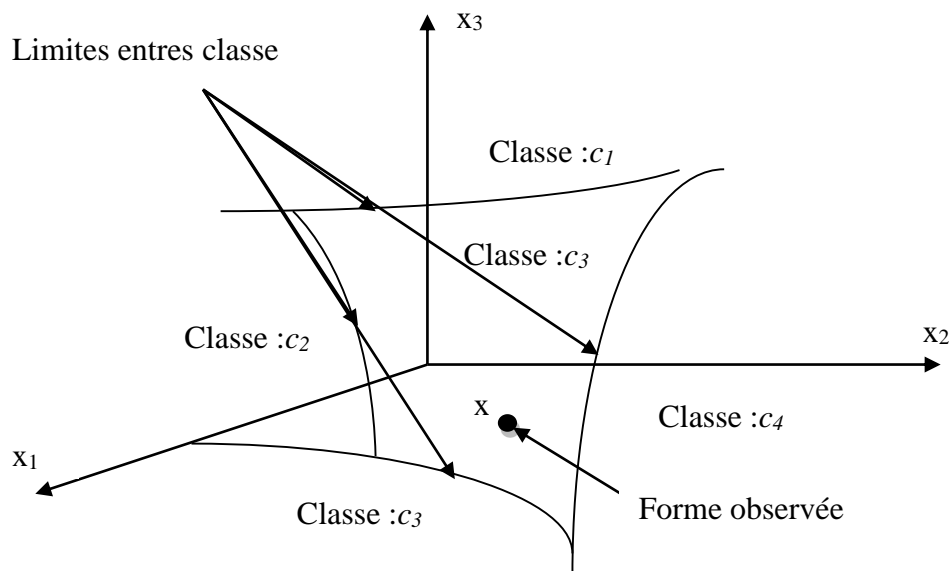


Figure I.9 : Les observation x_i est leurs classes \mathcal{C}_i

La figure I.10 schématise une combinaison abrégée d'un système de diagnostic par reconnaissance des formes. La fonction d'observation élabore le vecteur forme depuis mesures et observation effectuées sur l'installation. La forme ainsi générée est appliquée au mode de fonctionnement correspondant. Ceci n'est disponible que lorsqu'on a une base de connaissance permettant d'une part, de sélectionner les grandeurs à observer les plus utiles au diagnostic et d'autre part de structurer les modes variés de fonctionnement en classes[Ros,11].

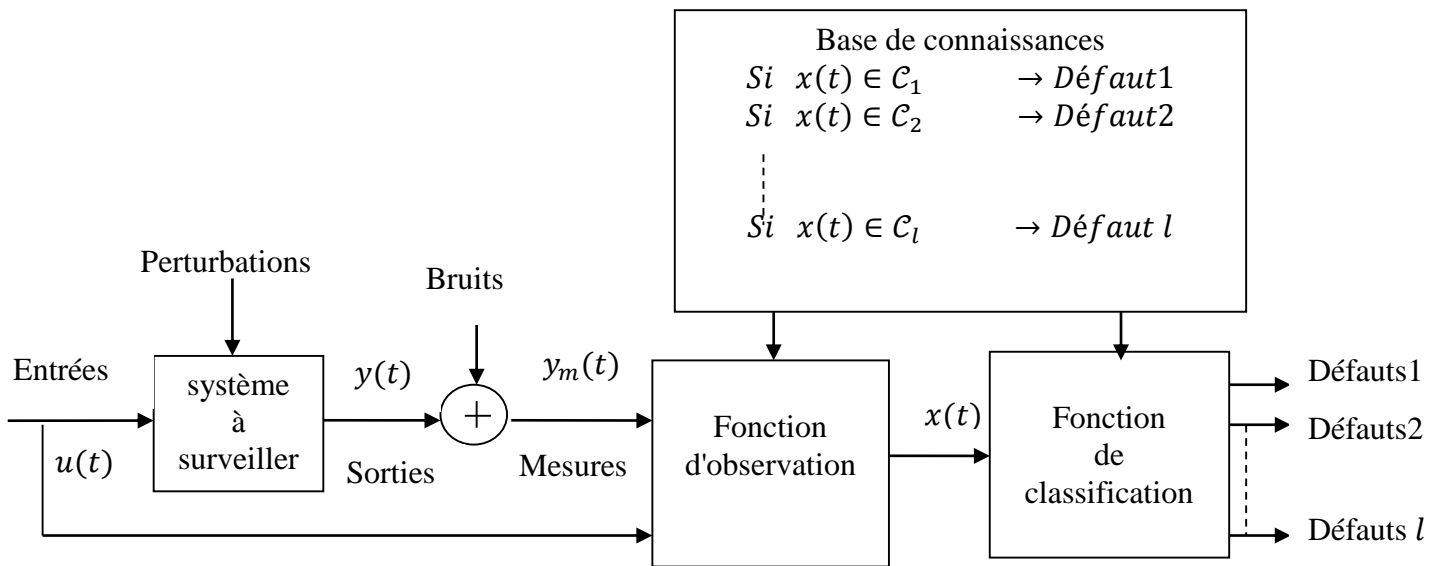


Figure I.10: Schéma de diagnostic d'un système par reconnaissance de formes

Le choix des grandeurs à observer peut-être issu directement du savoir et de l'expérience d'experts, mais aussi dérive d'une analyse fonctionnelle suivie d'une analyse dysfonctionnelle qui permet de déterminer quelles sont les grandeurs à surveiller pour une détection et une localisation des défauts les plus critiques. Cette double analyse fonctionnelle/ dysfonctionnelle nous permet également de déterminer les bases de règles reliant les grandeurs observables aux défauts. On pourra cependant utiliser cette base de règles pour résoudre le problème de classification. Notons que dans tous les cas cette double analyse est qualitative et repose sur le savoir et l'expérience d'opérateurs humains qui maîtrise l'installation.

On distingue trois étapes principales pour la composition d'une méthode de diagnostic par reconnaissance des formes:

- La création d'une base d'apprentissage.
- Le choix d'un classifieur et à son paramétrage.
- L'utilisation effective du classifieur en phase d'exploitation.

b) Système expert

Un système expert doit donner des réponses reliées à un état donné de plus la difficulté du domaine étudié interdit tous les aspects réalisables des conditions ; ainsi, un spécialiste de réparation réalise son diagnostic par une représentation partielle de la situation.

A partir de l'ensemble de signes dont il dispose, il démontre toutes les conclusions possibles, adapte de nouvelles suppositions et approfondie son diagnostic en donnant des nouvelles additionnelles liées sur le système à diagnostiquer [Zwi 95]. La figure I.11 illustre les composants fondamentaux d'un système expert.

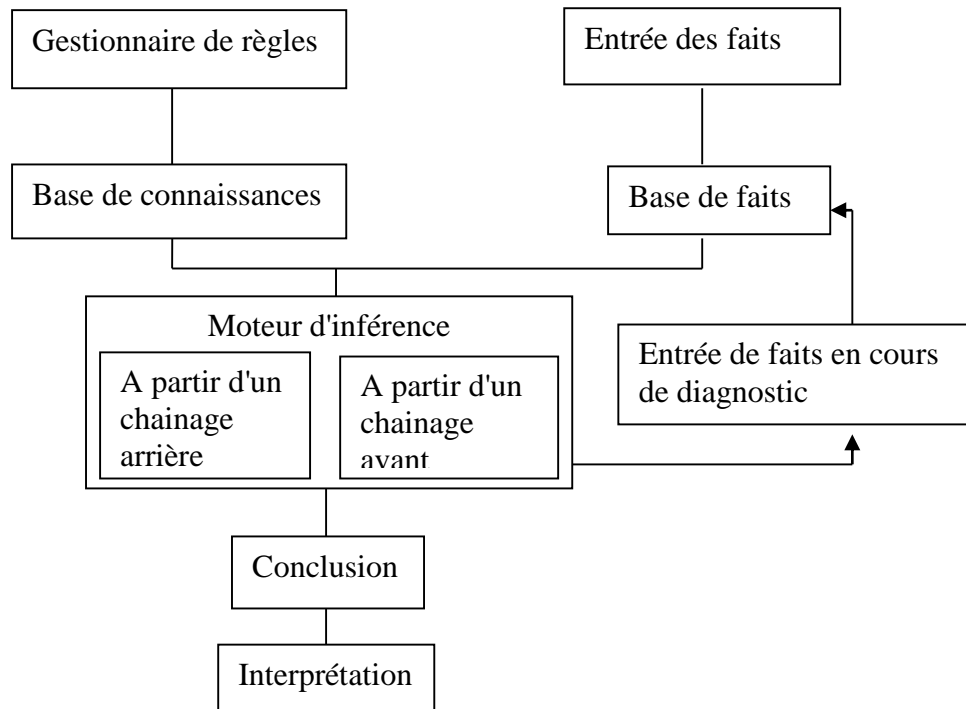


Figure I.11: Structure générale d'un système expert de diagnostic

- **La base de connaissances :** qui est composée d'une base de règles modélisant la connaissance du domaine considéré.
- **La base de faits :** Les faits qui contenant des informations à propos du cas que l'on est en train de traiter.
- **Le moteur d'inférence:** pouvant raisonner selon les informations possédées dans la base de connaissance, de faire des déductions ,etc.

I.5 Les étapes de diagnostic

On passe par trois étapes afin de diagnostiquer : la génération des résidus, la détection, la localisation et aussi l'identification [Kou,12],[Ros,11].

I.5.1 Génération des résidus

Afin de détecter et d'isoler les défauts il faut générer les résidus (figure I.12). Ce résidu est bien désigné et indique clairement son utilité.

Par conséquent, c'est un signe du dysfonctionnement du système. Il y'a diverse méthodes afin de gêner de résidus. Elle contient deux approches essentielles :

- **Approche quantitative** : On a adopté plusieurs techniques: observateur, filtre de Kalman, espace de parité, estimation paramétrique, etc.
- **Approche qualitative** : Cette étude emploi : Logique floue, réseaux de neurones, reconnaissance de forme, système expert, etc.

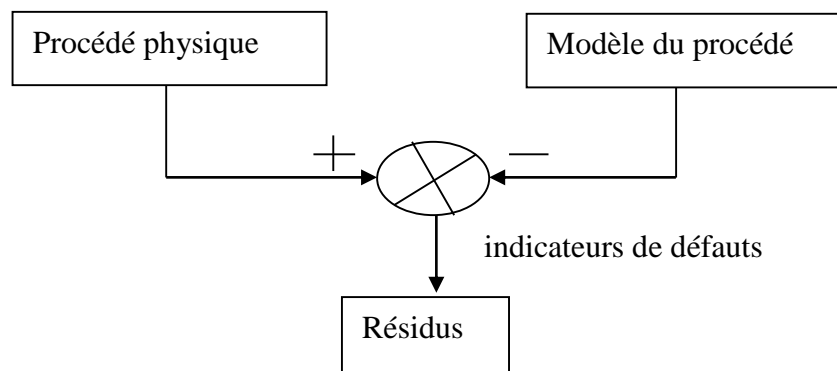


Figure I.12 : L'étape de génération de résidus

I.5.2 Détection de défauts

Cette étape permet l'état de fonctionnement normale du système. On décide de l'apparition d'un défaut lorsque le résidu n'est pas nul.

I.5.3 La localisation de défauts

L'étape de localisation doit permettre à partir des résidus détectés non nuls statistiquement, de localiser le défaut, c'est-à-dire de déterminer le ou les éléments défailants.

La signature d'un défaut représente l'effet de celui-ci sur un ou plusieurs résidus. Si l'on dispose de la signature de chacun des défauts à détecter, il est possible de remonter des effets (résidus non nuls) au causes (les éléments défailants).

I.5.4 Identification de défaut

L'objectif de cette phase est l'identification le type de paramètre en défaut et d'indiquer l'instant de l'apparition et la localisation d'un défaut. Aussi, l'identification peut contenir une procédure qui vise à décider la cause du défaut, autrement dit sa provenance.

I. 5 Conclusion

Dans ce chapitre, nous avons donné quelques définitions et terminologies usées dans ce domaine. Ensuite, nous avons expliqué les différentes méthodes de diagnostic, et les méthodes de diagnostic traitées qui sont composées de trois étapes principales, la détection, la localisation et l'identification.

Le chapitre suivant sera consacré à l'introduction de quelques techniques de l'intelligence artificielle, ainsi que leur utilisation dans le domaine du diagnostic de défauts. Nous nous intéresserons particulièrement aux réseaux de neurones qui seront par la suite utilisés dans notre contribution au diagnostic.

CHAPITRE II

II.1 Introduction

Un réseau de neurone artificiel définit implicitement une fonction non linéaire paramétrable, jouissant de la propriété d'approximateur universel. Cela signifie qu'il est capable d'approcher une fonction non linéaire, qu'on ne connaît que quelques points, qui forment la base d'exemples. On réalise le paramétrage du réseau à partir de la base d'exemples, au moyen d'un algorithme d'apprentissage, conçu pour minimiser un critère quadratique sur l'erreur d'approximation. Ceci explique l'utilité de ce type d'approche dans le domaine du diagnostic, où le problème à résoudre consiste, finalement, à approcher la relation inconnue reliant les symptômes aux défauts.

L'objectif principal dans ce chapitre est de présenter des développements concernant l'application des réseaux de neurone au diagnostic de défauts.

II.2 Neurone formel (Forme de neurone)

Bien que d'inspiration biologique, le terme de neurone formel doit être compris ici comme un opérateur mathématique, et n'a que peu de liens avec le fonctionnement d'une cellule nerveuse réelle [Ros, 11].

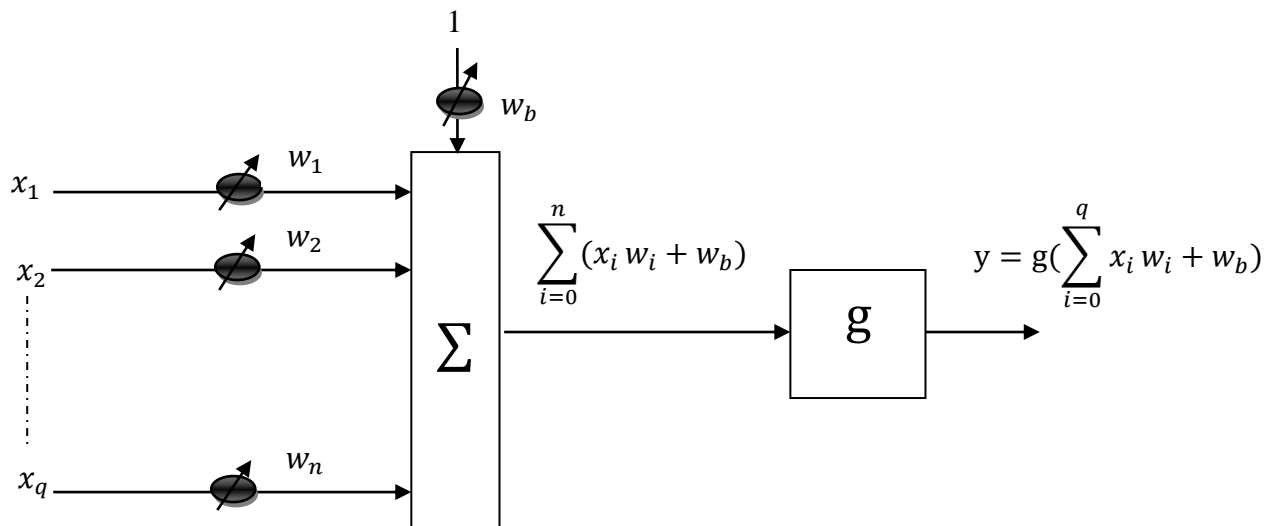


Figure II.1: Neurone formel

g : est une fonction non linéaire du neurone.

x_i ($i = 1, \dots, q$): entrée du neurone.

$$\begin{cases} y = f(w^T x) \\ w^T = [w_0 \dots w_i], \quad x^T = [1 \ x_1, \dots, x_q] \end{cases}$$

Avec:

w_i : poids ajustables du neurone.

w_b : biais du neurone.

- Fonction d'activation

Le réseau neurone à différents types de fonction d'activation, comme les fonctions linéaires, gaussienne ou des sigmoïdes par exemple (Figure II.2).

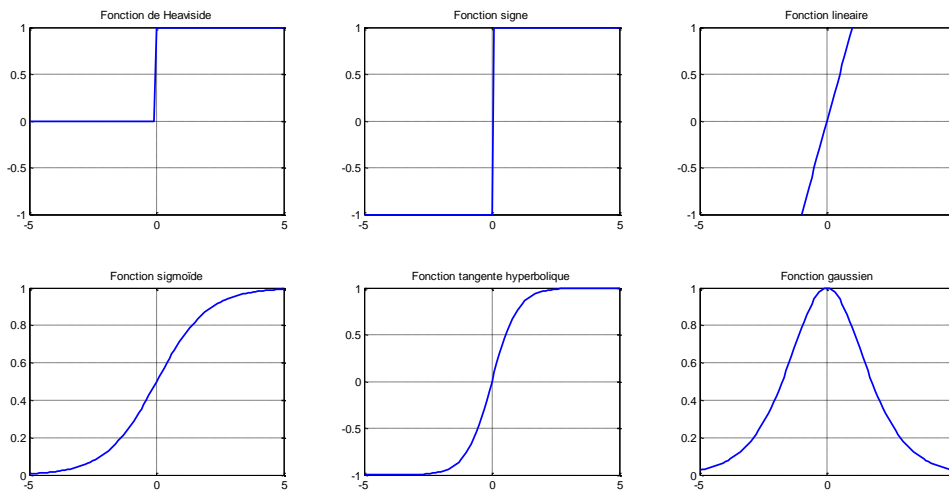


Figure II.2 : Fonction d'activation

II.3 Architecture de réseaux de neurones

On distingue deux types d'architecture: les réseaux non bouclés et les réseaux bouclés[Ros,11],[Kou,12].

I.3.1 Les réseaux de neurones non bouclés

Il définit les sorties du réseau à un instant t donné ne dépendent que des entrées appliquées au même instant. La relation mathématique d'un réseau de neurones statique peut alors être décrit par:

$$y(t) = g(x(t), W) \tag{II.1}$$

Où :

$x(t)$: Vecteur des entrées.

$y(t)$: Vecteur de sortie.

g : Fonction non linéaire des réseaux.

W : Matrice des poids des connexions.

Les réseaux non bouclés sont généralement utilisés pour la classification ou la modélisation de processus statique non linéaire.

II.3.2 Les réseaux de neurones bouclés

Un réseau de neurones bouclé définit les sorties du réseau à un instant donné dépendent non seulement des entrées appliquées au même instant mais aussi des entrées et des sorties passées.

II.4 Apprentissage des réseaux de neurones

L'apprentissage par réseau de neurone a comme base de minimiser l'écart entre le signal réel du réseau et les signaux désirées(cibles).

La détermination des poids et biais se fait à l'aide d'algorithmes d'apprentissage. Il existe deux modes d'apprentissage [Ros,11]:

- Le mode non supervisé.
- Le mode supervisé.

II.4.1 Le mode non supervise

Ce mode n'utilise pas une base d'apprentissage, il est souvent réalisé en ligne. Les poids et les biais sont ajustés à chaque itération en réponse des entrées seules du réseau [Par, 04].

La plupart des algorithmes utilisant ce type d'apprentissage réalisent des opérations de classification. Ils permettent de cataloguer les différentes entrées dans un certain nombre de classes fini.

II.4.2 Le mode supervise

Ce mode d'apprentissage, effectué hors ligne, est le plus souvent utilisé. Il consiste à évaluer les valeurs des poids synaptiques et biais qui minimisent une erreur sur une "base d'apprentissage" appelée le professeur. La base d'apprentissage comprend un ensemble d'observations entrées/sorties désirées (i.e. les cibles) [Par, 04].

Cette base d'apprentissage consiste à apprendre au réseau à donner des sorties qui s'approchent le mieux possible des cibles présentées dans la phase d'apprentissage.

Il existe plusieurs algorithmes dans ce mode d'apprentissage qui minimise l'erreur.

II.5 Algorithme d'apprentissage

II.5.1 La rétro-propagation du gradient de l'erreur

L'algorithme de rétro-propagation du gradient de l'erreur a été créé en généralisant les critères d'apprentissages de Widrow-Hoff aux réseaux multicouches à un système non linéaire. C'est un algorithme appliqué dans des réseaux de types feed-forward pour l'apprentissage de système, la reconnaissance de formes et la classification.

La rétro-propagation du gradient de l'erreur est utilisée afin de joindre les poids et les biais du réseau pour minimiser l'erreur quadratique entre la sortie du réseau et la sortie réelle.

Les étapes pour réaliser l'apprentissage par la méthode de rétro-propagation [Nor,00],[Nel,01]:

- 1) Initialisation des poids $W^{[q]}$ sont généralement de façon aléatoire.
- 2) Définition d'une entrée x_k et de la sortie désirée d_k .
- 3) Détermination de la sortie courante par propagation par les couches :

$$y_j^{[q]} = F\left(\sum w_{ji}^{[q]} \cdot y_i^{[q-1]}\right) \quad (\text{II.2})$$

Où: F est la fonction de transfert du neurone et [q] la q^{ième} couche du réseau.

- 4) Calcul d'erreur entre désirée et la sortie de réseau :

$$\varepsilon = \sum_k (d_k - y_k^{[s]})^2 \quad (\text{II.3})$$

Où: d_k est la sortie désirée, $y_k^{[s]}$ est la sortie obtenue sur la dernière couche.

ε : est l'erreur de prédiction en fonction de k.

- 5) Rétro-propagation du gradient de l'erreur (δ) de la dernière couche jusqu'à la première couche :

➤ Pour chaque cellule de sortie :

$$\delta_i^{[s]} = - (d_i - y_i^{[s]}) \cdot F'(p_i^{[s]}) \quad (\text{II.4})$$

➤ Pour chaque cellule cachée :

$$\delta_i^{[s]} = - \sum_k \delta_k^{[q+1]} \cdot W_{ki} \cdot F'(p_i^{[s]}) \quad (\text{II.5})$$

6) Mise à jour des poids selon la règle :

$$\Delta W_{ij}^{[q]} = \alpha \cdot (\delta_i^{[q]} \cdot x_j^{[q]}) \quad (\text{II.6})$$

Où: α est le coefficient d'apprentissage compris dans l'intervalle $[0, 1]$.

7) Retour à 2) tant qu'il y a des couples à présenter.

L'algorithme utilise la technique de recherche de gradient pour minimiser une fonction cout qui est égale à la moyenne de l'erreur quadratique entre la sortie désirée et la sortie actuelle du réseau. Le critère de minimisation d'erreur est le suivant :

$$\varepsilon = \sum_k (d_k - y_k^{[s]})^2 \quad (\text{II.7})$$

Ensuite les poids et les biais sont modifiés en ligne sur le réseau. On répète ces calculs jusqu'à l'obtention du critère d'arrêt.

II.5.2 Méthode de Levenberg-Marquardt

La direction de recherche obtenue par les méthodes de Newton ou de Gauss-Newton peut ne pas être optimale. En particulier, si le minimum de $L(i)$ (θ) est loin de l'itération courante. Pour y remédier on va chercher des minimaux locaux autour du voisinage de l'itération courante avec un rayon $\delta(i)$. Le problème de minimisation est formulé alors de la façon suivante [Nor,00],[Nel,01],[Nar,90]:

$$\theta(i+1) = \underset{\theta}{\operatorname{argmin}} L^{(i)}(\theta) \text{ Sous la contrainte } |\theta - \vartheta(i)| \leq \delta(i) \quad (\text{II.8})$$

La solution d'optimisation peut être de façon itérative par les équations suivantes :

$$\theta(i+1) = \theta(i) + f(i) \quad (\text{II.9})$$

Où:

$f(i)$: est la direction qui peut être calculée à partir de :

$$[R(\theta(i) + \lambda(i))]f(i) = -G(\theta(i)) \quad (\text{II.10})$$

La direction de recherche dépend du paramètre $\lambda(i)$ qui doit être initialisé à une faible valeur. Plusieurs méthodes existent pour déterminer le paramètre $\lambda(i)$ au cours de l'apprentissage.

Une manière de déterminer ce paramètre consiste à tester le critère au cours d'une itération. Tant que le critère ne diminue pas on multiplie $\lambda(i)$ par un coefficient supérieur à 1.

Au contraire, si le critère diminue on multiplie par un coefficient positif inférieur à 1 pour la prochaine itération.

Une autre manière d'évaluer ce paramètre consiste à calculer un indicateur $r(i)\lambda(i)$ pour déterminer l'évolution du paramètre $\lambda(i)$.

$$r(i) = \frac{V_N(\theta(i), Z^N) - V_N(\theta(i) + f(i), Z^N)}{V_N(\theta(i), Z^N) - L^{(i)}(\theta(i) + f(i))} \quad (\text{II.11})$$

Si cet indicateur donne une valeur supérieure à 0.75, on divise le paramètre $\lambda(i)$ par 2. Au contraire s'il est inférieur à 0.25 on multiplie $\lambda(i)$ par 2.

Avec:

$Z^N = \{[u(t), y(t)], T = 1 \dots \dots, N\}$: l'ensembles de donnée

V_N : Le critère à l'ième itération est donnée par:

$$V_N(\theta, Z^N) \approx L^{(i)}(\theta) = \frac{1}{2N} \sum_{t=1}^N \tilde{\varepsilon}^2(t, \theta) \quad (\text{II.12})$$

II.6 La classification par les réseaux de neurone

III.6.1 Classification linéaire

Il suffit d'avoir un Perceptron d'une seule couche afin d'accomplir cette tâche en cas de classe linéairement indépendante.

- **Utilisation d'un Perceptron** : A ce stade, la cellule de décision à l'aide d'une fonction de seuil joue le rôle un adaptateur linéaire, en séparant les exemples en deux classes CO1 et CO2 par le biais de la fonction linéaire : $g(x) = W^T x$

Avec:

$W = (W_{1j}, W_{2j}, \dots, W_{nj})^T$, vecteur des poids synaptique.

$x = (x_1, x_2, \dots, x_n, 1)^T$.

Cette fonction sépare l'ensemble des vecteurs x en deux classes CO_1 et CO_2 :

$x \in CO_1$ si $g(x) \geq 0$

$x \in CO_2$ si $g(x) < 0$

La figure II.3 illustre les précédentes explications graphiques de classification.




Figure II.3 : Séparation de deux classes avec adaptateur linéaire

D'après le schéma on observe que le perceptron linéaire a seuil a n entrées partage l'espace des entrées R en deux sous-espaces limites par un hyperplan. D'autre part, tout ensemble linéairement séparable peut être distinguer par un perceptron.

Sachant que l'équation d'un hyperplan dans un espace de dimension n est de la forme :

$$\alpha_1 \cdot x_1 + \alpha_2 \cdot x_2 \dots \dots \dots + \alpha_n \cdot x_n = \beta$$

Un Perceptron est donc un distinguant linéaire. On remarque clairement qu'un discret de l'espace R^n est divisé par un hyperplan, seulement si l'échantillon de R^{n+1} obtenu en ajoutant une entrée toujours égale à 1, est séparable par un hyperplan qui passe par l'origine.

III.6.2 Classification non linéaire

On utilise ces réseaux de neurones multicouches. Pour la classification non linéaire, et ils sont les plus répandus en diagnostic industriel.

L'apprentissage de ces réseaux s'effectue par un algorithme de rétropropagation de gradient dérivé de la règle de Windrow-Hoff, pour déterminer les poids concernant la couche cachée de neurone.

Pour établir un réseau multi-couche on adopte cette stratégie:

- **Détermination des caractéristiques du réseau**

1. L'ensemble des formes à classer représente l'entrée de la couche du réseau.
2. On utilise généralement la fonction d'activation des poids de la couche cachée du réseau de type sigmoïdes.
3. La couche de sortie du réseau est l'ensemble des sorties désirées.

La figure suivante montre l'architecture générale d'un réseau multicouches :




Figure II.4: Architecture d'un réseau à couches

- **Une base d'exemples**

1. x_k représente l'entrée du réseau, $w(x_k)$ représente le poids du réseau.
2. La sortie désirée du réseau prend la valeur 1 pour la cellule associée à la classe de x_k-1 pour toutes les autres.
3. Le réseau utilise deux phases l'ensemble d'apprentissage et de test.

- **Apprentissage**

1. On applique l'algorithme de rétropropagation du gradient.
2. En cas de confirmation, arrêt de l'apprentissage lorsque l'erreur est minimisée l'ensemble passe à la phase de validation(test).

II.7 Identification par réseau de neurone

On doit établir un modèle mathématique afin d'identifier des systèmes à partir de séries de mesures sur ces derniers. Selon les connaissances, à priori, le problème d'identification peut être approché de plusieurs manières différentes sur le système [Nel,01],[Nor,00],[Kou,12].

Si l'identification est basée exclusivement sur les données mesurées, en considérant qu'on ne connaît pas d'information sur la physique du système, le modèle recherché est appelé modèle de conduite. Le modèle de connaissance est utilisé suite à une connaissance physique du système.

II.7.1 Procédure d'identification

La procédure de base d'identification de système est schématisée ci-dessous [Nor,00],[Nel,01]:

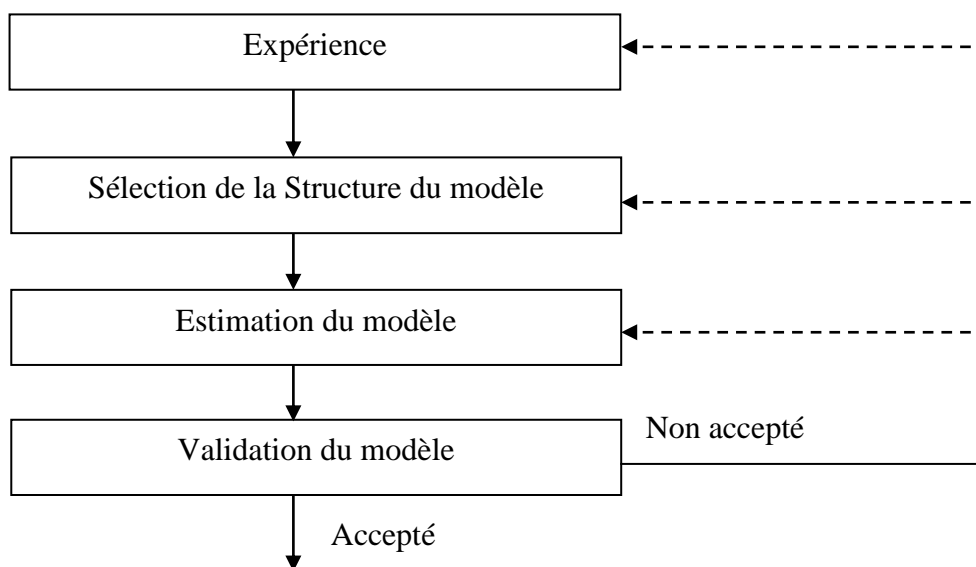


Figure II.5: La procédure de base d'identification du système

II.7.2 Structures de modèles non linéaires

Pour choisir la structure de modèle non linéaire pour l'identifier. Il suffit de faire le choix [Ben,11],[Nel,01],[Nor,00],[Nar,90]:

- Le nombre d'entrée du réseau.
- Le choix du nombre de couche cachées du réseau.

Les structures de modèle non linéaires ont le même principe de celle de la structure linéaire, car les entrées des modèles linéaires sont considérées comme architecture interne le réseau multicouche.

Nous concluons de cette technique plusieurs avantages :

- Une extension des structures communes de modèles linéaires.
- La possibilité d'augmenter le nombre de couche cachée cas d'identification des relations non linéaires.
- De bonnes décisions de la structure, demandées par l'utilisateur.
- Conforme pour la génération de commande de système.

Les structures de modèle non linéaires est définie par l'expression:

$$y(t) = g[\varphi(t, \theta), \theta] + e(t) \tag{II.12}$$

Où la relation de prédiction :

$$\hat{y}(t/\theta) = g[\varphi(t, \theta), \theta] + e(t) \tag{II.13}$$




Figure II.6: Les structures des modèles NNFIR (a) et NNARX (b)

Le prédicateur en fonction des signaux d'entrée et sorties précédent est défini par [Nor,00],[Ben,11]:

$$\varphi(t, \theta) = [y(t) \dots y(t - n), u(t - d) \dots u(t - d - m)]^T \tag{II.14}$$

Le choix de la structure NNARX est le mieux au niveau du système déterministe ou faiblement bruité afin de garantir la stabilité du système[Ben,11].

▪ **NNARMAX**

Malgré que la fonction g est représentée sur la figure (II.7) par un réseau de neurones en boucle ouverte, le prédicateur doit avoir une définition lorsque les régressions sont semblables à celles du modèle ARMAX.

$$\varphi(t, \theta) = [y(t) \dots y(t - n), u(t - d) \dots u(t - d - m), \varepsilon(t, \theta), \dots, \varepsilon(t - k, \theta)]^T \quad (II.15)$$

Les erreurs de prédiction est l'écart entre les sorties du modèle et les sorties du modèle estimée cependant elles placent une boucle de retour. Voir figure (II.7).

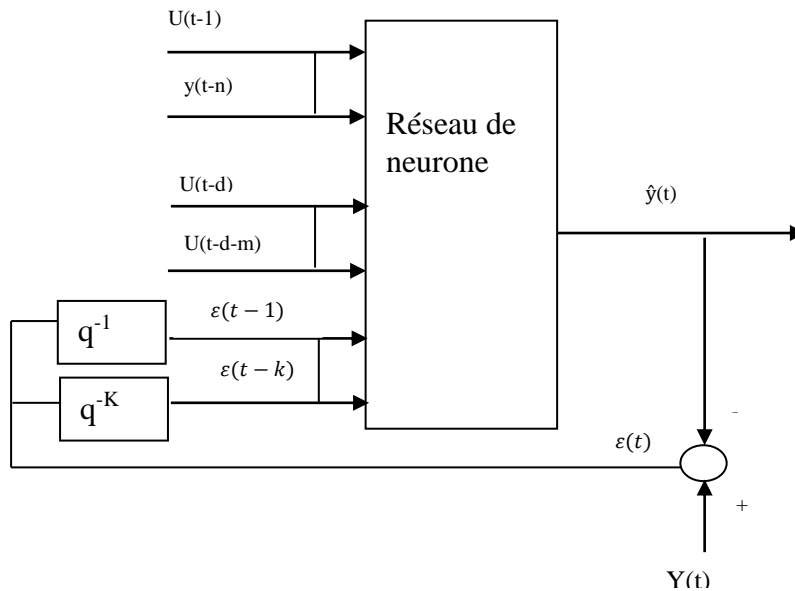


Figure II.7 :La structure du modèle NNARMAX.

On considère le schéma précédent comme réseau récurrent. Généralement on se base sur les racines du polynôme (ARMAX), on déduit donc que le prédicateur d'un modèle ARMAX est stable.

L'analyse des propriétés de stabilité est complexe pour les modèles NNARMAX . Afin de considérer la stabilité comme une propriété locale. Mais un modèle NNARMAX est stable dans des régimes et instable dans d'autres. Dans les deux cas, le problème va dépendre de la performance du système.

▪ NNOE

La sortie du prédicateur du modèle NNOE devint l'entrée du prédicateur en retard de réseau et il est confronté aux mêmes problèmes que la structure NNARMAX. Le modèle NNOE est représenté par la figure (II.8).

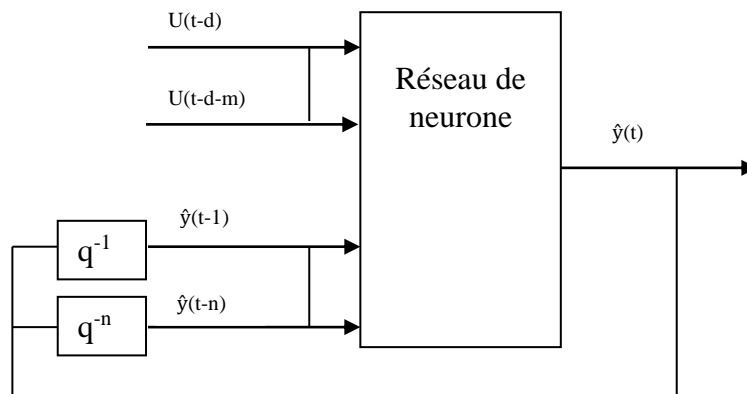


Figure II.8:La structure du modèle NNOE

II.8 Application des RDN dans le diagnostic

Le diagnostic du système par réseau neurone passe par deux phases [Ale,00],[Ben,11],[Che,02],[Chu,94],[Evs,94] :

- Identifier un modèle neuronal pour la génération des résidus.
- Evaluer ou classifier les types de défauts.

II.8.1 Génération de résidus a base de modèle neuronal

Afin d'établir la génération de résidus qui est identique à celui des modèles analytiques, Il suffit de comparer les sorties du système réel à leurs estimées (modèle neuronal)[Mok, 08], [Zha, 08],[Ale,00],[Ben,11],[Kou,10].

Le résidu $r(t)$ représente l'écart entre le signal de sortie réel du système $y(t)$ et le signal de sortie du modèle neuronal $\hat{y}(t)$ ceci est traduit par la relation mathématique qui suit:

$$r(t) = y(t) - \hat{y}(t) \quad (\text{II.16})$$

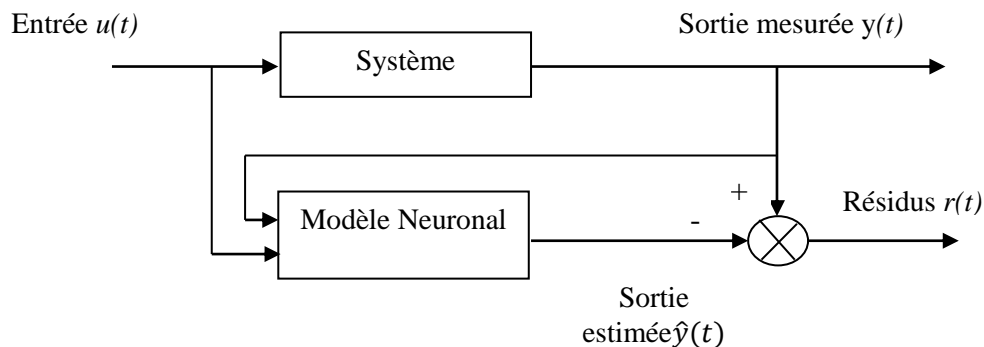


Figure II.9: Génération de résidu par le modèle neuronal

- **Création d'une base de données:** Une base de données doit être réalisée en hors ligne par une connaissance experte. Elle doit contenir les principales caractéristiques du processus (point de fonctionnement, stabilité, bruit...).

Cette base de données sera divisée en deux, une partie d'apprentissage, et l'autre de validation. Lorsque cette base est réalisée, la structure du réseau de neurone est adéquate.
- **Choix de la structure du réseau de neurones:** Généralement on opte pour la structure d'un réseau de neurones multicouches MLP (Multi- Layer Perceptron), qui est une structure conforme pour les modèles non linéaires.

L'utilisation d'un réseau de neurones à deux couches (une couche cachée et une couche de sortie) est suffisante afin d'identifier un système non linéaire multi-variable (MIMO). Selon une expérience la constitution de la couche cachée est selon le nombre de neurones choisi. Habituellement on choisit les fonctions de type sigmoïde pour ce genre de neurones. Alors que la fonction d'activation pour la sortie du réseau est de type linéaire.
- **Apprentissage:** on choisit les poids et les biais initialement de façon aléatoire, puis ajustés par un algorithme d'apprentissage, pour minimiser l'erreur quadratique. L'algorithme généralement utilisé comme dans le cadre de notre application est l'algorithme de Levenberg- Marquardt.
- **Validation:** Afin de vérifier la réaction du réseau il faut passé par une étape d'évaluation. On fait plusieurs essais sur le réseau. Si, le réseau n'est pas adéquat, on doit changer la construction du réseau concernant le nombre des sorties ou entrées, le nombre des neurones dans la couche cachée, ou amplifier le nombre d'itérations de la phase

d'apprentissage au cas où les paramètres du réseau sont divergés, aussi, réinitialisation des poids et des biais.

II.8.2 Classification

Lorsqu'on génère les résidus, on passe à la deuxième étape qui consiste à les évaluer pour classifier les défauts diagnostiqués. Nous entamons par des techniques de classification à base de réseaux de neurones[Ale,00],[Evs,94],[Che,02].

L'architecture du classifieur neuronal est de type MLP, On considère les résidus comme signaux d'entrée et les défauts comme signaux de sortie, après l'apprentissage il sera capable de localiser un défaut [Ale,00],[Ben,11].

L'utilisation des réseaux de neurones dans la classification donne une bonne décision entre les différentes classes, de plus présente une méthode pratique pour résoudre les problèmes complexes de classification.

II.9 Conclusion

Dans ce chapitre nous avons présentés un aperçu sur les réseaux de neurones. On a vu qu'à partir d'un modèle simple des neurones formule, on peut construire un modèle plus complexe, celui des perceptrons multi- couches. Ces outils permettent de calculer des fonctions complexes, adaptables à un ensemble d'exemples par le biais d'algorithmes d'optimisation utilisant la technique de la rétro-propagation. Aussi nous avons abordés les applications et les utilisations du réseau de neurone dans le domaine de diagnostic.

Dans le chapitre suivant on donnera une modélisation du système PV qui nous intéresse, aussi on a expliqué quelques types de défauts sur ce dernier.

CHAPITRE III

III.1 Introduction

Nous nous sommes intéressés dans ce chapitre, principalement, à la modélisation des cellules photovoltaïques (PV). Nous abordons par des principes sur l'énergie et les systèmes PV tout en exposant les différents composants des systèmes depuis des cellules jusqu'à l'injection au réseau. Également, nous montrons les divers modèles de la cellule photovoltaïque et certains types des défauts dans le système photovoltaïque.

III.2 Chaîne de conversion d'un système photovoltaïque

Nous nous intéressons uniquement au système PV. Le type de la chaîne de conversion d'énergie de ce système est schématisé dans la figure III.1.




Figure III.1 : Schéma de conversion d'énergie d'un système PV connecté au réseau

Elle est constituée de trois parties essentielles : La première partie est le générateur photovoltaïque qui converti l'énergie solaire en énergie électrique. La deuxième partie extrait la puissance maximale en continu du générateur PV et la transféré ensuite en puissance alternative avant de l'introduire dans le réseau qui représente la troisième partie [Khe,15].

III.3 Description d'un système photovoltaïque

Nous représentons le système PV selon ces différents composants connecté au réseau électrique[Ade,06]:

- Générateur PV : unité de production d'énergie électrique sous forme de courant continu.
- Convertisseur.
- Câblage et boîte de jonction.
- Système de protection : y compris la diode de by-pass, diode anti-retour et les autres dispositifs de sectionnement.

III.3.1 Générateur PV

Est la section qui produit l'énergie électrique. Les éléments de base de cette unité sont définis dans ce qui suit [Bun,11]:

▪ Cellule PV

Il y'a plusieurs technologies qui permettent la création de cellules PV mais beaucoup sont encore en période de recherche.

Les cellules les plus industrialisées, actuellement sont fabriquées à partir de silicium (environ 80% en 2010 pour le silicium cristallin « c-Si »).

On détermine une tension produite par une cellule PV selon la matière dont elle est originaire. Par exemple les cellules de type cristallin prennent la valeur de 0.6 V. Pour le courant, il est en fonction de la surface de la cellule et il dépend du rendement de la cellule pour une même surface. Comme illustration les cellules de type monocristallines ont un rendement de 15 à 22%, cependant celui des cellules multi cristallines est de valeur de 10 à 15% [Bun,11].

▪ Module PV

La puissance d'une cellule n'est pas adaptée aux applications courantes, il est donc nécessaire de l'associer. De plus, les cellules photovoltaïques sont sensibles à l'environnement extérieur, elles sont donc munies d'une protection mécanique (l'encapsulation). Pour cela, les cellules sont assemblées en modules photovoltaïques.

Généralement on connecte les cellules en série dans les modules courants commercialisés c'est à dire que le courant reste identique tandis que la tension est multipliée par le nombre de cellules en série ce qui augmente la puissance. Généralement, dans un module PV « classique » on trouve 36 ou 72 cellules. Mais ce nombre de cellules peut changer selon les modules dans les applications spécifiques. On peut remarquer des modules de 40, 54, 60 ou même 92 cellules en série. La figure III.2 représente un module de 36 cellules reliées en série.




Figure III.2 : Des cellules PV dans le module mise en série

Chaque groupe de cellules est connecté en antiparallèle avec une diode, appelée diode de by-pass ou diode de dérivation, qui sert à protéger les cellules contre leur fonctionnement dans le régime inverse.

Généralement chaque 18 cellules représente en parallèle une diode de by-pass. cependant, ce nombre peut changer d'après les différents fabricants des modules. Néanmoins, pour une bonne protection des cellules, On propose une connexion de chaque cellule individuelle à une diode de by-pass[Sur,86].

- **String PV**

Aussi appelé chaîne photovoltaïque, est la composition de modules assemblés en série afin de créer la tension de sortie définie.

- **Champ PV**

Sous une tension adéquate, on rassemble les modules en série et en parallèle. Formant ainsi un champ photovoltaïque.

III.3.2 Convertisseur

A comme tâche de prendre et de convertir la puissance maximale du système PV en puissance alternative avant de l'introduire dans le réseau. C'est pourquoi, le convertisseur est constitué d'un hacheur en série avec l'onduleur comme le montre la figure III.3 [Khe,15].




Figure III.3 : Différents phases de convertisseurs

Le hacheur extrait la puissance maximale du générateur PV. Car il est doté d'un algorithme de recherche de type MPPT (Maximum Power Point Tracker), puis il transforme la puissance maximale en puissance alternative active par l'onduleur.

- **Principe de fonctionnement du MPPT**

Un champ PV est calculé par le courant par rapport à la tension, appelée caractéristique I-V qui est montré dans la Figure (III.4).

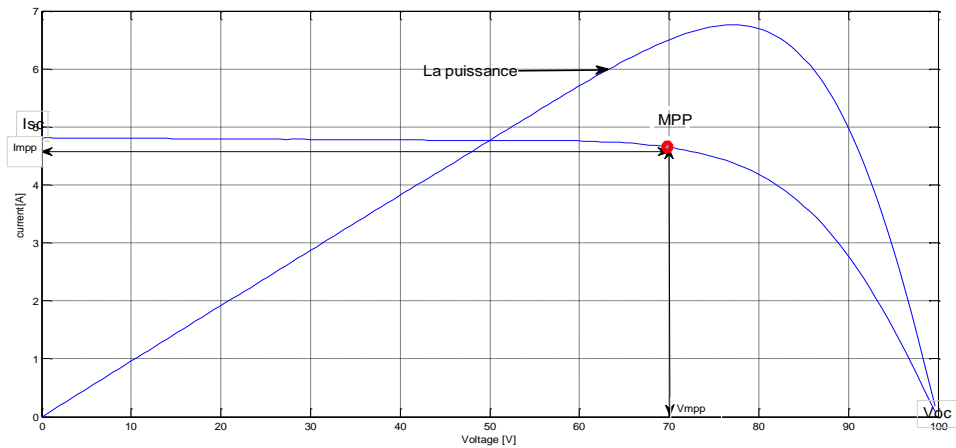


Figure III.4 : Courbe I-V d'un champ PV en fonctionnement normal

D'après la précédente figure on détermine la valeur de tension de circuit ouvert (V_{oc}) et la valeur de courant de court-circuit (I_{sc}). Au moment de l'opération, le fonctionnement normal du générateur PV à ce point de la puissance maximal (MPP).

III.3.3 Câblage et boîte de jonction

Pour composer un string par des câbles on doit effectuer une mise en série plusieurs modules. Pour réduire les défauts à la terre ou de court-circuit après l'installation on recommande fortement d'utiliser des câbles à simple conducteur avec double isolation [Pvp,98].

En vue de simplifier la procédure d'installation on peut utiliser des connecteurs débrochables. Ces derniers protègent contre les risques de choc électrique.

Une boîte de jonction permet de mettre en parallèle de divers strings dans un système PV. La boîte de jonction peut contenir des éléments de protection tels que des fusibles, des interrupteurs et des sectionneurs.

III.3.4 Système de protection

Il existe plusieurs sortes de protection pour une installation photovoltaïque : protection des intervenants, protection contre la foudre, protection du générateur PV [Bun,11],[Khe,15].

▪ Diode de by-pass

La diode de by-pass est connectée en antiparallèle avec un groupe de cellules afin de protéger les cellules les plus faibles contre la polarisation inverse.

▪ Diode anti-retour

L'utilisation de la diode anti-retour introduit une perte dans la production du fait de la chute de tension provoquée par cette diode pendant le fonctionnement normal du champ PV. De plus, ces diodes peuvent être en défaut et par conséquent demandent un contrôle régulier.

III.4 Les différents types des systèmes photovoltaïques

Il existe plusieurs types de systèmes PV expliquer ci-dessous [Khe,15],[Zou,16]:

III.4.1 Système PV autonome

Aussi appelée stand-alone, l'énergie au niveau du générateur PV est insuffisante afin d'effectuer la demande de charge. C'est pourquoi, un système de stockage d'énergie assure son autonomie (figure III.5). Ces installations se compose de quatre points :

- Modules PV.
- Le système de régulation.
- Une batterie.
- Un onduleur.

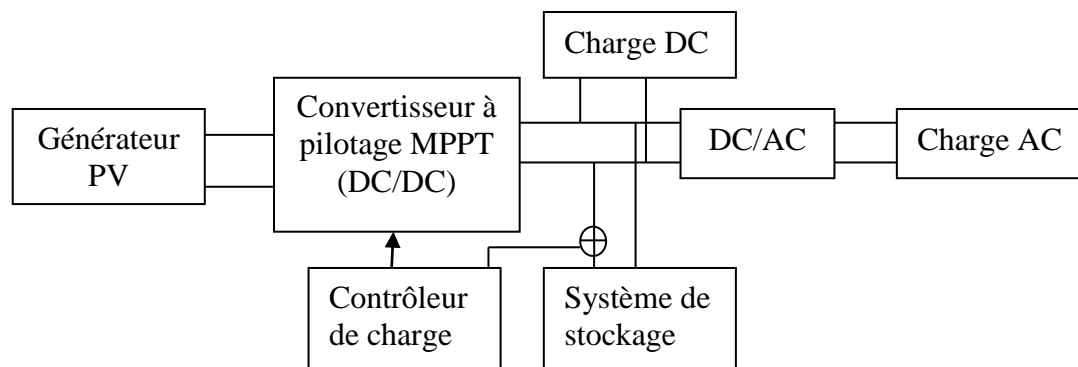


Figure III.5 : Schéma d'installation photovoltaïque autonome

III.4.2 Système PV en connexion directe avec le réseau

Les systèmes PV joints à un réseau permettent la délocalisation de la production sur ce réseau électrique comme illustré dans la figure III.6. L'énergie se fait à proximité des lieux de consommation.

Au fil du temps, les systèmes PV connectés à un réseau diminueront le besoin d'augmenter la capacité des lignes de transmission et de distribution en nécessitant d'acheminer uniquement son excédent d'énergie vers les zones en manque de production.

Cette mise en commun des productions permet aussi un sous-dimensionnement des équipements de production complémentaire. Ces transferts éliminent la nécessité d'acheter et d'entretenir une batterie d'accumulateurs. Il est toujours possible d'utiliser ceux-ci pour servir d'alimentation d'appoint lorsque survient une panne de réseau.

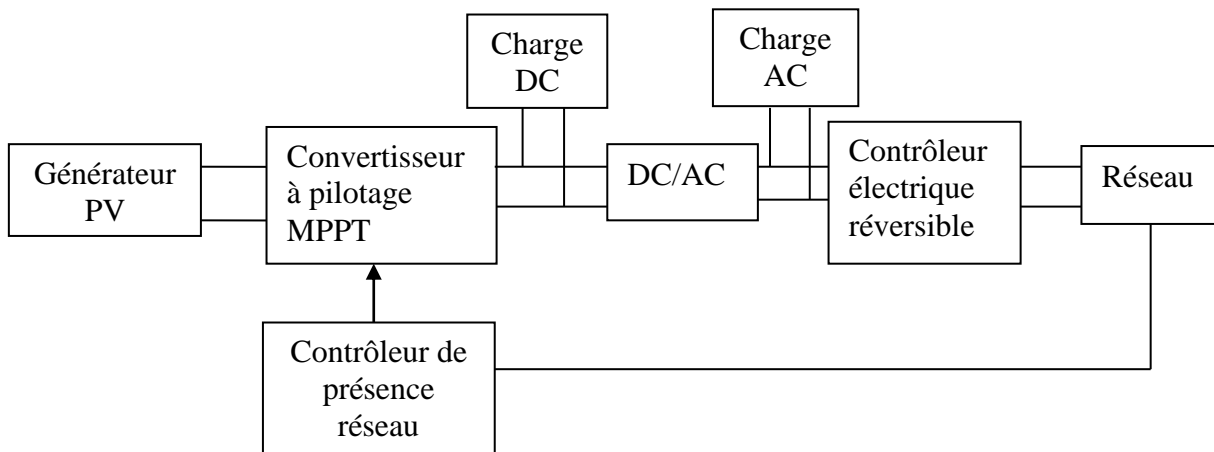


Figure III.6 : Installation photovoltaïque couplée au réseau

III.4.3 Système PV hybride

Ce type est fréquent, il conçoit à associer d'autres générateurs avec le GPV, voir figure III.7. Le générateur intégré peut être renouvelable tels qu'une turbine éolienne, turbine conventionnel, générateur diesel alimenté par des biocarburants, ou non renouvelable comme un moteur diesel ou le réseau de distribution électrique. Il est aussi possible d'y intégrer un système thermique pour chauffer l'eau domestique ou de faire la climatisation en exploitant la chaleur dissipée par le GPV.

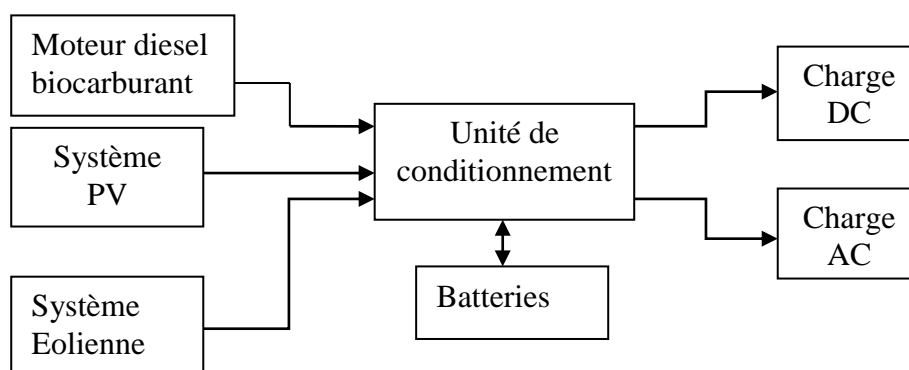


Figure III.7 : Système PV hybride(PV, Eolienne et Moteur diesel biocarburant).

III.5 Modélisation électrique d'une cellule photovoltaïque

On constate divers circuits électriques définissant le fonctionnement de la cellule PV. On classe trois différents modèles selon la modélisation des comportements physiques de la cellule.

III.5.1 Modèle à une diode

Ce modèle a été beaucoup utilisé, vu sa facilité et sa précision adéquats pour plusieurs applications citons: le rapport de performance d'une installation photovoltaïque [Des,06],[Kau,03], le dimensionnement d'un système PV [Li,09], l'analyse de performance de l'algorithme de MMPT [Fem,05], [Kim,06], l'étude de l'équilibre de la jonction au réseau [Zue,06]. La figure III.8 schématise ce modèle.




Figure III.8 : Montage à une diode d'une cellule PV

Ce montage est composé de source de courant I_{ph} représentant l'irradiation G et la température T obtenu par la cellule et une diode pour modéliser la cellule de type jonction PN. La résistance série R_s et la résistance shunt R_{sh} étalent l'état non idéal de la cellule, et le courant I_d passe à travers la diode et le courant de shunt I_{sh} passe par la résistance shunt [Mey,04]. [Bun,11],[Khe,15].

D'après la loi de Nœuds on déduit l'expression du courant de ce modèle:

$$I = I_{ph} - I_d - I_{sh}$$

$$I = I_{ph} - I_0 \times \left(\exp\left(\frac{V - I \times R_s}{V_t}\right) - 1 \right) - \frac{V - I \times R_s}{R_{sh}} \quad (\text{III.1})$$

Avec:

T : La température [$^{\circ}\text{C}$].

G : Irradiation de solaire [W/m^2].

I : Courant fourni par la cellule [A].

V : Tension à la borne de la cellule [V].

I_{ph} : Courant équivalent proportionnel à l'ensoleillement reçu par la cellule [A].

I_0 : Courant de saturation inverse de la diode [A].

$V_t = ak_b T_c / q$: Tension thermique de la diode. Elle dépend de température de la cellule T_c . Tandis que, a, k_0 et q et sont respectivement le facteur d'idéalité de diode (1 à 2), la constante de Boltzmann ($1.38 \cdot 10^{-23}$ J/°K) et la charge de l'électron ($1.602 \cdot 10^{-19}$ C).

R_s : Résistance série de la cellule [Ω].

R_{sh} : Résistance shunt de la cellule [Ω].

III.5.2 Modèle à deux diodes

Le modèle électrique le plus proche d'une cellule photovoltaïque est celui à deux diodes (double exponentiel), où la cellule est présentée comme un générateur de courant électrique dont le comportement est conforme à une source de courant avec deux diodes en parallèle. Afin de tenir compte des phénomènes physiques au niveau de la cellule, ce modèle est complété par les deux résistances série R_s et parallèle R_{sh} selon le schéma électrique équivalent de la figure III.9 [Tsa,08], [Ser,09],[Ish,11],[Bou,15],[Ali,17].

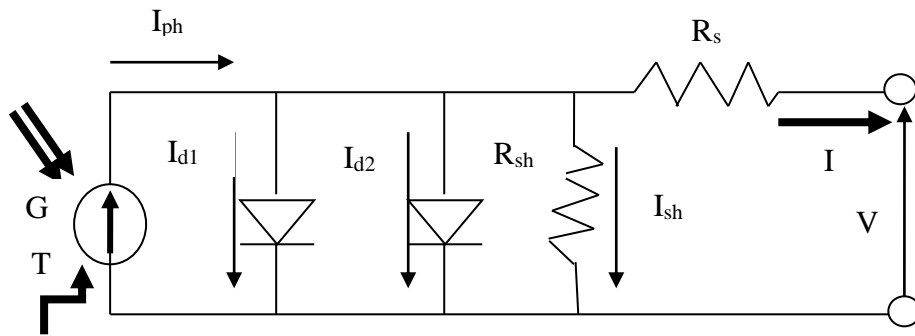


Figure (III.9): Montage à deux diodes d'une cellule PV

Le modèle montre un courant ressemblant au courant d'une cellule PV avec quelques complexités de calcul de relation analytique comme suit:

$$I = I_{ph} - I_{d1} - I_{d2} - I_{sh} \text{ (En appliquant la loi de Nœuds).}$$

Donc :

$$I = I_{ph} - I_{01} \times \left(\exp \left(\frac{V - I \times R_s}{a_1 \cdot V_{t1}} \right) - 1 \right) - I_{02} \times \left(\exp \left(\frac{V - I \times R_s}{a_2 \cdot V_{t2}} \right) - 1 \right) - \frac{V - I \times R_s}{R_{sh}} \quad \text{(III.2)}$$

Avec :

a_1 et a_2 : Coefficient respective des diodes D1 et D2.

I_{01} et I_{02} : Courants de saturation respective des diodes D1 et D2.

III.5.3 Modèle de Bishop

C'est un modèle qui ressemble le modèle à une diode, sauf que le Bishop à un multiplicateur non linéaire $M(V_1)$ en série avec la résistance shunt comme dans la figure III.10 .La relation entre le courant (I) et la tension (V) d'une cellule PV est identique à celle du modèle à une diode sauf qu'il 'a en plus un multiplicateur non linéaire comme suit dans l'équation (III.3) [Bun,11],[Bis,88].

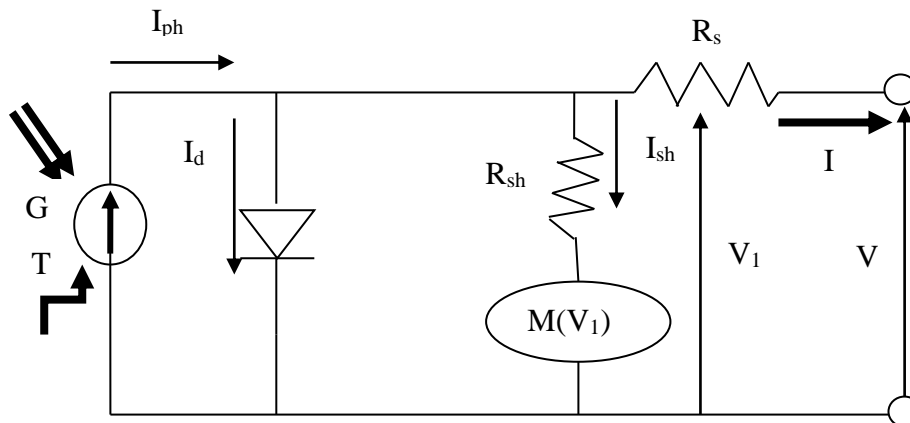


Figure (III.10):Modèle de Bishop

$$I = I_{ph} - I_0 \times \left(\exp \left(\frac{V - I \times R_s}{V_t} \right) - 1 \right) - \frac{V - I \times R_s}{R_{sh}} \left[1 + k \left(1 - \frac{V + R_s I}{V_b} \right)^{-n} \right] \quad (III.3)$$

Avec :

$$M(V_1) = k \left(1 - \frac{V + R_s I}{V_b} \right)^{-n}$$

III.6 Les défauts des panneaux photovoltaïques

A ce niveau nous exposant plusieurs défauts rencontré dans la partie DC d'un système photovoltaïque.

Ces défauts apparaissent à cause des défauts de fabrication ou des conditions climatiques.

Il existe quatre types de pertes de catégories différentes dans un système photovoltaïque[Fir,10],[Khe,15].

- **Défauts étendus avec rendement nul** : Lors d'un défaut physique, système débranché (longue durée).
- **Défauts courts avec rendement nul** :se produit lors d'une déconnexion momentanée de l'onduleur, système débranché (courte durée).
- **Défauts d'ombrage**: se fait lors d'un passage d'ombre (câbles, bâtis, arbre, nuage, etc.).

- **Défauts avec rendement en absence d'ombrage:** Quand l'erreur de MPPT, et d'autres défauts se produisent.

III.6.1 L'augmentation de la résistance série (R_s)

Généralement, l'augmentation de la résistance série est causée par la corrosion de la connectique entre deux modules PV, une vis de connexion mal serrée, la corrosion de point de soudure entre cellules, etc. En fonctionnement normal, cette résistance de connectique est quasi nulle. La valeur de cette résistance peut être augmentée dans plusieurs cas anormaux [Baz,11],[Hac,16].



Figure III.11 :Défaut d'augmentation de la résistance R_s

L'augmentation de la résistance série cause pour une limite donnée une perte en tension qui peut être suffisamment grande pour rendre la tension du groupe négative et faire basculer la diode de by-pass en mode passant donnant des points d'inflexion dans la courbe $I(V)$ [Che,18],[Bel,18],[Khe,15].

III.6.2 Défaut d'ombrage

Il existe deux défauts d'ombrage : l'ombrage total et l'ombrage partiel. L'ombrage total couvre tout le rayonnement d'arriver au cellules PV, cependant l'ombrage partiel ne laisse pas le rayonnement d'atteindre une partie de la cellule photovoltaïque (Passage de nuages , feuilles d'arbre, câbles...) [Che,17],[Bou,17],[Khe,15].

III.6.2.1 L'ombrage partiel

Souvent, en milieu urbain, on ne peut pas éviter l'ombrage partiel puisque dans certaines états, il est impossible de confirmer un ensoleillement homogène au niveau du système PV comme par exemple les ombres partielles sur le générateur PV, les oiseaux, nuages, des ombres sur l'ensemble des cellules [Pet,09]. Il est généralement considéré comme un défaut

aperçu dans un panneau photovoltaïque, cette panne diminue la puissance, cette dernière est donnée par le générateur indique plusieurs maximums [Kad,12], [Roy,10]. En particulier, cela se provoque quand les diodes de protections (diodes by-pass) des cellules PV guident.

Ainsi, un comportement instable surgit pour le générateur PV lorsqu'une ou plusieurs cellules de celui-ci ont un éclairage différent par rapport à ses voisines, les cellules ayant moins d'énergie doivent dissiper le supplément de courant remis par les cellules les plus éclairées, ce qui produit des échauffements dans le cas où le module n'est pas protégé. Et pour éviter la surchauffe de la cellule, des boîtes de connexion sont équipées par des diodes de dérivation, afin de limiter la tension opposée de la cellule ombrée, et la température. Toutefois, lorsque le fonctionnement des diodes de dérivation n'est pas correct, la cellule ombrée peut surchauffer, allant jusqu'à la perte d'une partie du générateur PV si le défaut persiste [Ali,17],[Ril,12]. Ces phénomènes ont une conséquence directe sur la production d'énergie livrée par le générateur peut alors diminuer par rapport à la puissance produite sous un éclairage cohérent. On conclut, pour ne pas endommager le générateur PV on doit éviter ce défaut c'est pourquoi des diodes de protection sont posées sur les générateurs PV de forte puissance (diode by-pass). Cependant, ces protections sont coûteuses[Hac,16],[Spa,15],[Khe,15].



Figure III .12 :Schéma de défaut d'ombrage partiel

III.6.3 Défauts de la diode de by-pass de diode anti-retour

On utilise la diode de by-pass pour défendre les cellules de l'ombrage partiel. En général, cette diode est unie en parallèle avec une branche d'un nombre de cellules. On constate divers défauts de fabrication de cette dernière. Ainsi dans un panneau PV on peut repérer une diode déconnectée, une diode équivalente à une impédance quelconque, une diode court-circuitée et une diode inversée[Cro,12]. De manière semblable que pour la diode de by-pass, la diode anti retour affronte les mêmes types de défauts aperçus pour la diode anti-retour : court-circuit, impédance quelconque, circuit ouvert et diode inversée...[Chi,16],[Me1,13].




Figure III.13 : Montage de défaut de la diode de by-pass.

III.6.4 Défaut de module

Le défaut de module s'affecte à tous les défauts électriques associés à la connexion d'un module dans un string PV. Ces défauts électriques sont : module court-circuité, module connecté en parallèle avec une impédance et inversion de la polarité du module [Sko,09],[Hac,16].

La figure III.14 représente le défaut affecté à tous les défauts électriques reliée à la connexion d'un module PV.




Figure III.14: Montage de défaut module

III.6.5 Défaut de connectique

Il est lié au problème d'augmentation de la résistance de connectique entre deux modules PV. En état normal, cette résistance de connectique est quasi nulle. sa valeur peut être augmentée dans plusieurs cas anormaux (corrosion de la connectique, vis mal serrée etc.). En cas extrême, on peut utiliser une résistance infinie pour représenter un module qui est déconnecté du string PV [Chi,15],[Cho,10],[Ali,17].

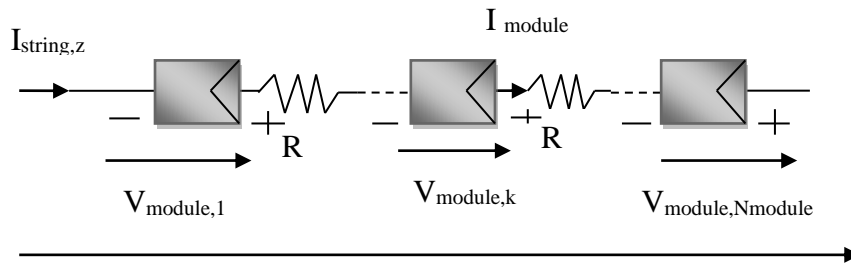


Figure III.15 : Montage d'un string PV avec la résistance de connectique non nulle

III.6.6 Défaut de diode anti-retour

De la même manière que pour la diode de by-pass, on distingue 4 types de défauts pour la diode anti-retour : court-circuit, impédance quelconque, circuit ouvert et inversée [Dav,13],[Hac,16].

La figure III.16 présente un schéma d'un champ PV dans lequel la diode anti-retour est remplacée par un élément qui peut, à chaque fois, montrer un des états défectueux de la diode.

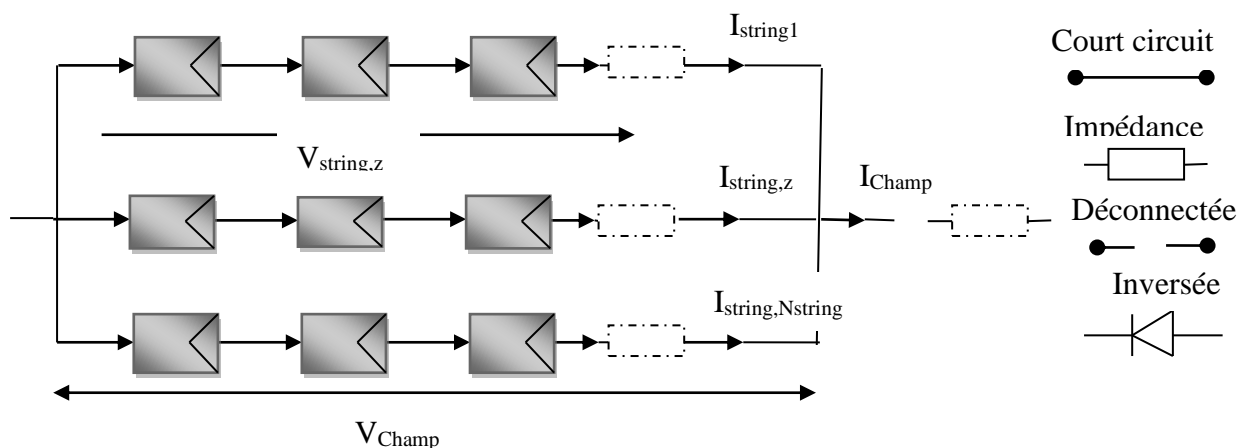


Figure III.16 : Montage d'un champ PV avec la diode anti-retour défectueuse

III.7 Classification des défauts d'un générateur photovoltaïque

Précédemment nous avons mentionné quatre types de défauts selon leurs rendements : les défauts étendus avec un rendement nul, les défauts courts avec un rendement nuls, les défauts d'ombrage et les défauts sans ombrage avec un rendement non nul. Dans cette partie on va classer des défauts selon leur catégorie [Fir,10],[Khe,15].

Tableau III .1 : La classification des défauts selon leurs catégories.

Défauts	Description	Catégorie
- Défaut du composant. - Système déconnecté (longue durée).	- En cas de pannes au niveau des composants la production de l'électricité est nulle. - Lors d'une isolation (déconnection) du système PV.la production s'arrête.	Défaut étendus avec un rendement nul.
- déconnection temporaire de l'onduleur. - Système déconnecté (courte durée).	- En présence d'une déconnection entre le string PV et l'onduleur la production de l'électricité est nulle. - Lorsqu'il ya une isolation (déconnection) du système PV la production est arrêtée.	Défaut court avec un rendement nul.
Défauts d'ombrage.	Le rayonnement solaire est bloqué par des objets d'ombrage externe (bâtiments, arbres, etc.).	Défaut d'ombrage.
Erreurs MPPT.	La variation des caractéristiques (I-V) varie la caractéristique de la courbe de puissance.	Défaut avec un rendement non nul (pas d'ombrage).

III.8 Conclusion

Ce chapitre, représente des explications et des principes de base de conversion de l'énergie solaire en énergie électrique. Aussi, nous avons défini les divers composants reliés au système PV. Ainsi, nous avons montré les différents modèles électriques équivalents d'une cellule PV et les différents types des défauts affectant les systèmes photovoltaïques.

CHAPITRE IV

IV.1 Introduction

Le but de ce chapitre est d'étudier une méthode de diagnostic de défauts d'un système énergétique (système PV) qui doit effectuer ces trois tâches principales :

- La détection des défauts, permet de décider l'état du système.
- La localisation des défauts, son rôle est de définir le lieu où apparait le défaut.
- L'identification des types de défauts, qui détermine la nature de la panne.

Le travail développé dans ce chapitre se base sur l'intelligences artificielle pour détecter et identifier les défauts des capteurs et physiques dans les systèmes PV.

On a divisé notre recherche en deux parties, premièrement on a commencé par décrire les composants du système et étudier son comportement avec l'influence de température et l'irradiation par plusieurs essais (courbe caractéristique I-V).Deuxièmement on a diagnostiqué le système par les réseaux de neurones, cette étape se compose de deux phases : la première est la génération des résidus par réseau de neurone (MLP), quant à la deuxième, elle consiste à évaluer ou/et identifier les défauts (capteurs et physiques) par réseau de neurone de type récurrent(RNN).

Les résultats numériques qui sont présentés dans ce chapitre sont issus d'une simulation réalisée en Matlab.

IV.2 Description du système PV

Dans un premier temps de cette partie de description de système utilisé, nous avons étudié deux types de défauts dans un système PV. Le système PV mise en étude est un champ photovoltaïque qui comporte trois strings en parallèle, chaque string contient trois modules en série, chacune contient soixante cellules de type poly-cristallines. Une base de données exprimant les différents modes de fonctionnement du système PV a été construite. Le premier scénario exprime l'état de fonctionnement du système sain avec un nombre d'essai de 1529. Le deuxième scénario représente le fonctionnement avec la présence de phénomène d'ombrage avec 657 expériences, et le dernier scénario représente le mode de fonctionnement avec la présence de défauts de résistance avec 124 expériences [Hac,16]. Le tableau suivant illustre une description de la base de données utilisée dans cette étude.

Table IV.1 :Description de la base de données du système PV

Etats du PV	Nombre d'expérience	Causes et effets
Etats Normale	1529	Fonctionnement optimal du system PV
Défaut ombrage	657	Provoque une faible tension générée et une faible puissance,
Défaut résistif	124	La dégradation des interconnexions fissuration corrosion des liaisons inter-cellules, est liée au problème d'augmentation de la résistance de la connexion entre deux modules PV
Total	2310	

IV.2.1 Les caractéristiques électriques du module photovoltaïque

On a choisi le module PV de type CLS220P (panel China Light Solar)[Ali,17] pour la simulation de notre système, afin de diagnostiquer, détecter, localiser et identifier quelques défauts fréquents et importants. Le tableau IV.2 illustre les caractéristiques électriques du module PV.

Table IV.2: Caractéristique électriques du module CLS220P

Le module CLS220P	Caractéristiques électriques
La puissance nominal P_{MAX} [W]	220
La tension maximum V_{MPP} [V]	28.9
Le courant maximum I_{MPP} [A]	7.61
La tension de circuit ouvert V_{OC} [V]	36.8
Le courant de court-circuit I_{SC} [A]	8.24
La puissance garantie minimum P_{MIN} [W]	220
Efficacité du panneau [%]	13.5
La tension maximum du système [V_{DC}]	1000
Coefficient de température P_N [%/ °C]	-0.0044
Coefficient de température I_{SC} [mA/ °C]	0.0004
Coefficient de température V_{OC} [mA/ °C]	-0.0032

Dans la deuxième partie, du travail nous avons présenté une étude sur la détection et l'identification de défauts de capteurs simples et combinés dans le système photovoltaïque définis précédemment avec des instants et des amplitudes différentes.

Les tableaux ci-dessous (IV.3 - IV.4) montrent l'apparition des défauts capteurs et physique et leurs influences sur les strings avec différents instants.

IV.2.2 Description de défauts de capteurs et leurs influences dans le système PV

Le tableau IV.3 montre les différents types de défauts qui apparaissent sur les capteurs avec l'instant d'apparition et leurs amplitudes.

Table IV.3 :Description de défauts capteur et leurs influences sur les strings

Scenario	N° du capteur	Type de défaut			Instant du défaut (k)	Amplitude du défaut
		Biais	intermittent	Dérivée		
1 ^{er}	Capteur1	+			50	0.001
2 ^{ème}	Capteur2		+		[50,100]	0.001
3 ^{ème}	Capteur3			+	[30,100]	0.009
4 ^{ème}	Capteur1	+			50	0.001
	Capteur2		+		[50,100]	
5 ^{ème}	Capteur2		+		[50,100]	0.001
	Capteur3			+	50	0.009
6 ^{ème}	Capteur1	+			50	0.001
	Capteur2		+		[50,100]	0.001
	Capteur3			+	[30,90]	0.009

IV.2.3 Description de défauts physique et leurs influences sur les strings dans le système PV

Dans le tableau suivant nous monterons l'apparition des défauts physique et leurs influences sur les strings avec différents instants et différentes amplitudes.

Table IV.4:Description de défauts physique et leurs influences sur les strings

Scenario	N° du string	Type de défaut		Instant du défaut (k)
		Shading (ombrage)	Shunt (résistif)	
1 ^{er}	String1		+	100
2 ^{ième}	String2	+		100
3 ^{ième}	String3	+		100
4 ^{ième}	String1		+	[30,100]
5 ^{ième}	String1	+		100
	String2	+		100
6 ^{ième}	String1		+	100
	String2	+		100
7 ^{ième}	String1		+	[30,100]
	String2	+		100

IV.3 Modélisation de système PV

La figure IV.1, montre un champ photovoltaïque utilisé en étude. Ce champ comporte trois strings en parallèle, chaque string contient trois modules en série. Ce dernier composé de soixante (60) cellules de type poly-cristallines.

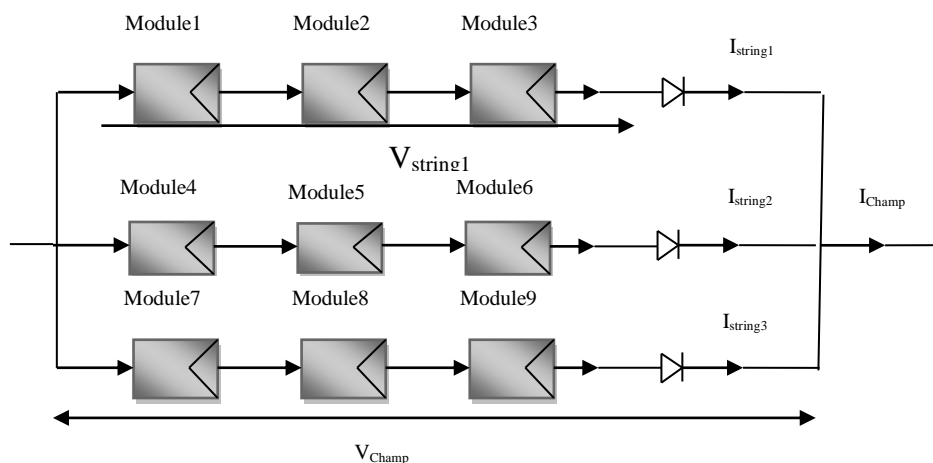



Figure IV.1 :La configuration du string de PV étudié

Pour éclaircir le schéma précédent, nous avons défini les composants de la configuration du champ ci-dessous :

Groupe de cellules:



Module:




Figure IV.2 : La configuration retenue pour la modélisation.

Le modèle PVG à une diode sera adopté, le circuit électrique équivalent est montré dans le chapitre III (voir paragraphe III.5.1).

IV.4 Influence de la variation de la température et de l'ensoleillement sur le point maximal de puissance (PPM)

Les figures IV.3 et IV.4 représentent l'influence de la température et l'irradiation par rapport au point maximal de puissance des caractéristiques (I-V) et(P-V) du système PV.




Figure IV.3 : Influence de la température sur le courant de court-circuit (I_{cc}).

La température représente un bon facteur pour les systèmes PV, ce qui est constaté sur la figure précédente (figure IV.3). Le courant de court-circuit augmente au fur et à mesure que la température augmente, ce qui entraîne par la suite le changement de l'emplacement du PPM.




Figure IV.4 : Influence de l'irradiation sur le point de puissance maximal (PPM).

Selon la figure IV.4, on constate que le PPM varie avec la variation de l'irradiation, provoquant ainsi un changement du courant au niveau du système PV.

IV.5 Influence du phénomène d'ombrage sur la température et de l'ensoleillement du système PV

Les deux figures suivantes représentent respectivement la température et l'ensoleillement (irradiation) du système photovoltaïque étudié dans le cas sain et avec le phénomène d'ombrage.




Figure IV.5 : Température et irradiation dans le cas sain et avec phénomène d'ombrage

D'après les deux courbes précédentes on constate que le phénomène d'ombrage est bien clair sur l'évolution de la température et l'ensoleillement en fonction de temps par rapport à l'évolution des deux caractéristiques dans le cas d'absence d'ombrage.

IV.6 L'évolution de courant du système PV dans le mode défaillant

Les figures suivantes représentent l'évolution des courants de sortie de système photovoltaïques dans les cas sain, ombrage et avec un défaut de résistance.




Figure IV.6 : Courant en fonction de temps cas sain, ombrage et défaut de résistance

D'après la première courbe de la figure précédente, on constate que l'évolution de courant généré par le système dans le cas ombré a diminué jusqu'à la valeur inférieure de 2A par contre le courant dans le cas sain varie autour de 5A ce qui montre l'effet de phénomène d'ombrage sur le courant généré par le système PV et par conséquent sur la puissance fournie par le système. A l'inverse l'évolution de la tension dans les deux cas est presque identique.

IV.7 L'évolution des caractéristiques I-V et P-V dans le mode défaillant

Les deux figures suivantes montrent les caractéristiques I-V et P-V du système PV étudiées dans les trois modes de fonctionnement cas sain, ombré et avec la présence de défaut de court circuit.




Figure IV.7: Caractéristiques I-V & P-V de système PV avec les trois modes de fonctionnement

D'après les caractéristiques I-V et P-V du système PV, on constate que, le point de fonctionnement maximale dans le cas ombré est différent à celui du cas sain par contre le cas de défauts résistance légèrement différente, ce qui montre que le phénomène d'ombrage est plus sensible par rapport au défaut de résistance.

IV.8 Détection et identification de défauts par réseaux de neurones

A ce stade d'étude nous avons présenté la procédure de détection et identification de défauts dans le système PV, comme l'illustre la figure suivante:

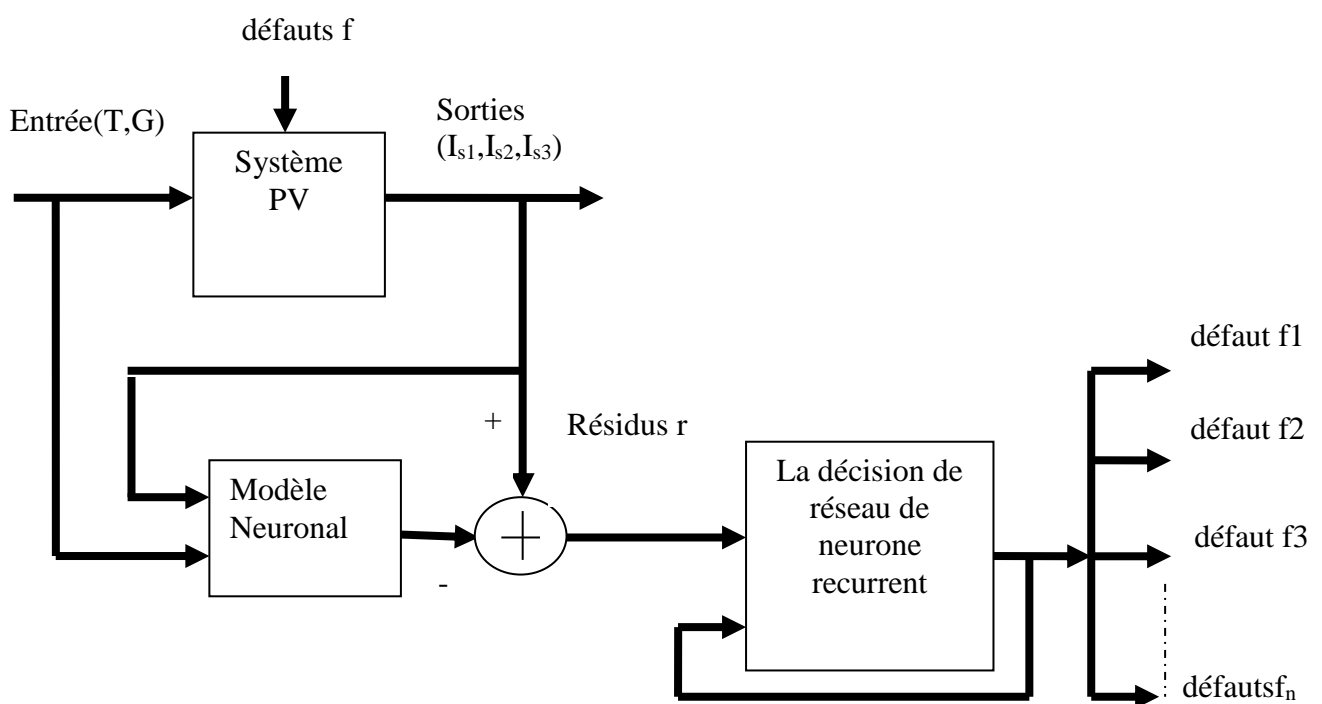


Figure IV.8: Principe d'isolation et de classification de défauts

IV.8.1 Génération des résidus

IV.8.1.1 Identification par réseau de neurones

Premièrement, nous avons développé une étape de génération des résidus source d'une comparaison de la sortie du système PV et celle estimés d'un modèle neuronal de type NNARX par la méthode d'apprentissage de Levenberg- Marquadt.

Le principe de base de ce modèle neuronal est présenté par la figure suivante:

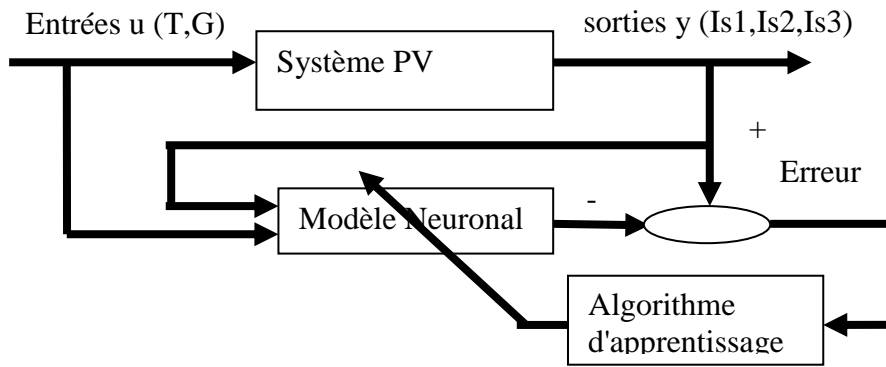


Figure IV.9 : Schéma bloc d'identification par réseau de neurones

Dans ce cas le schéma de la procédure de création du modèle est présenté dans l'organigramme suivant.

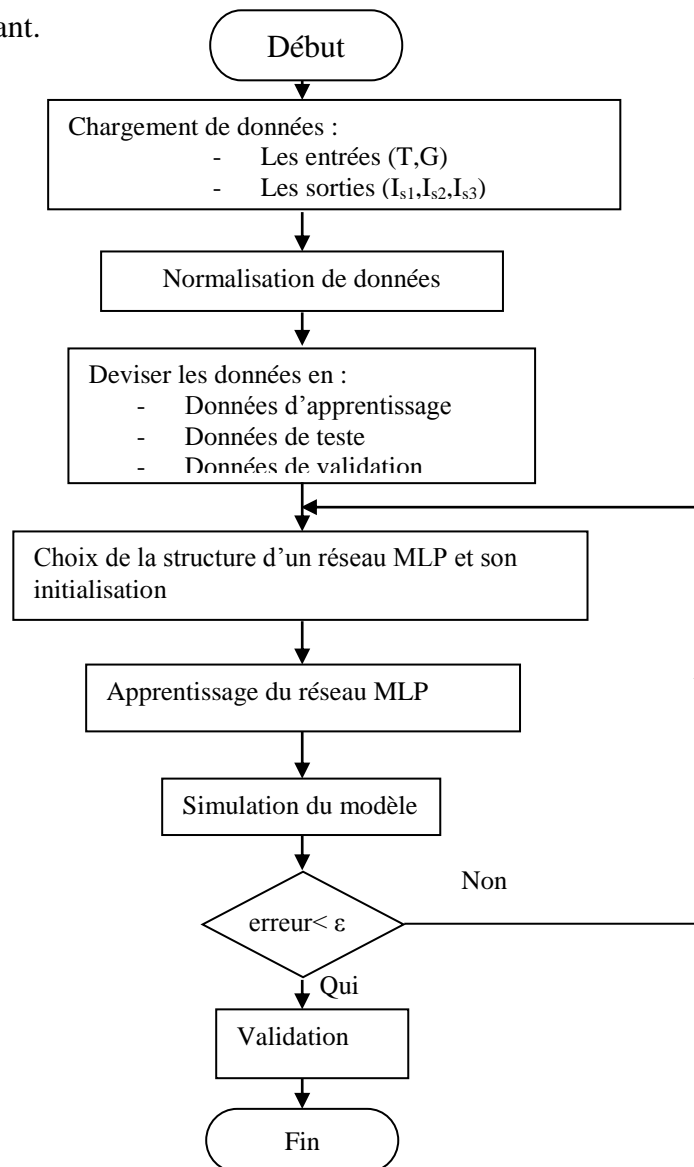


Figure IV.10: L'organigramme d'élaboration d'un modèle neuronale.

A. Architecture du réseau de neurones

On a adopté l'architecture du réseau suivant, après certaines expériences :

- **Treize** neurones au niveau de la couche cachée.
- **trois** neurones au niveau de la couche de sortie.
- **Treize** neurones au niveau de la couche d'entrée.
- La fonction d'activation de neurones de la couche cachée est de type **tanh**.

La figure suivante montre l'architecture de ce réseau:




Figure IV.11: Architecture du réseau de neurone

Les sorties $\hat{I}_{(1,...,3)}$ du réseau sont établit dans la relation suivante:

$$\hat{I}_i = \Psi_i(Z_i \cdot h + b_i) \quad i = 1 \dots 3 \quad (\text{IV.2})$$

Avec:

$$h = \varphi(w_1 I_{s1}(k-1) + w_2 I_{s2}(k-1) + w_3 I_{s3}(k-1) + w_4 T(k-1) + w_5 G(k-1))$$

Où :

w_i : Poids raccordant la couche cachée à la couche d'entrée.

z_i : Poids raccordant la couche cachée à la couche de sortie.

Ψ : Fonction d'activation de type linéaire et φ une fonction d'activation de type tangent.

b : Le biais du réseau.

a_i et b_i avec $i = 1:3$: Indice décalage du structure du modèle.

B. Apprentissage du réseau

L'algorithme de Levenberg- Marquadt a été utilisé pour adapter les poids du réseau, après divers essais l'erreur quadratique est égale à 10^{-5} au bout de 1417 itérations, la figure IV.12 illustre le précédemment dit:




Figure IV.12 : L'erreur quadratique d'apprentissage du modèle neuronal

Les figures suivantes présentent les trois courants réels et estimés avec leurs erreurs de prédiction de string étudié.




Figure IV.13: Courant de string1 réel est estimée et l'erreur de prédiction




Figure IV.14: Courant de string2 réel est estimée et l'erreur de prédiction




Figure IV.15: Courant de string3 réel est estimée et l'erreur de prédiction

Les résultats de calcul obtenus montrent que l'erreur quadratique des trois courants de string utilisé se stabilise à la valeur 10^{-4} au niveau 1417 itérations, cette valeur est considérée comme bonne estimation de précision et temps de réponse.

IV.8.1.2 Génération des résidus du système PV par les réseaux de neurones

Le modèle neuronal conçu, reproduit les comportements sains du système PV. On peut maintenant introduire la deuxième étape qui consiste à générer les résidus pour la détection de défauts et qui est représenté par la figure IV.16.

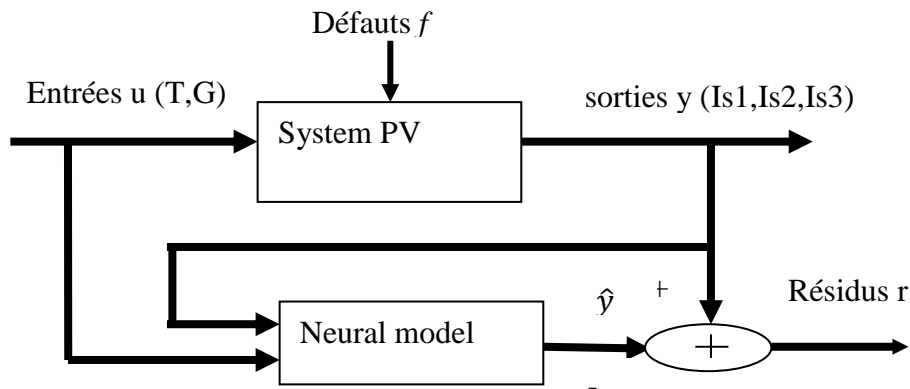


Figure IV.16: Génération des résidus par les réseaux de neurones.

D'après la figure IV.16 on déduit que les résidus du système PV nous mènent à ces résultats.




Figure IV.17 : Les résidus du système PV en absence de défaut

La figure IV.17 présente les trois résidus des strings du système PV qui sont de l'ordre de 10^{-4} .

On a utilisé cet organigramme pour la classification des défauts comme l'illustre la figure IV.18.

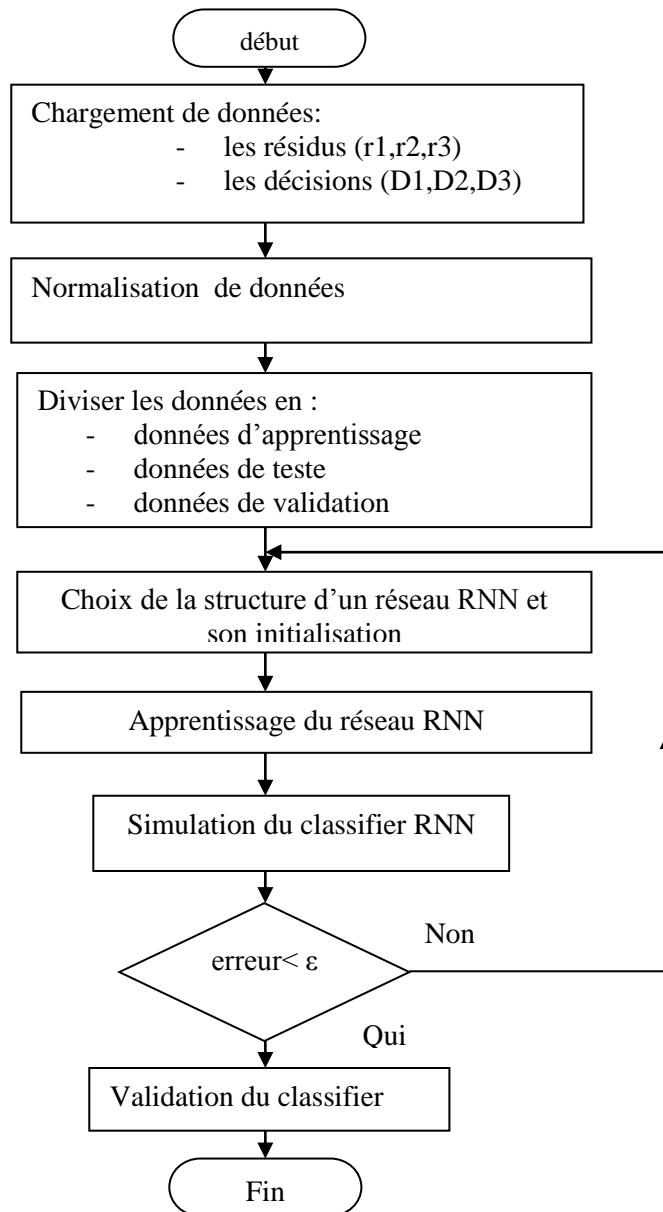


Figure IV. 18 : Procédure générale pour la classification et l'identification des défauts

IV.9 Détection et classification des défauts

Nous allons étudier au niveau de cette étape les résidus extraits précédemment par un réseau de neurones récurrent de type MLP.

On met à l'entrée du réseau les résidus, et les décisions précédentes [de l'instant (k-1)] et en sortie les décisions, ces derniers sont reliés par la boucle de retour pour établir un effet mémoire sur la décision.

A. Structure du réseau :

L'architecture de ce réseau est composé de : six neurones au niveau de la couche d'entrée qui représentent les entrées des différents résidus à un instant (k) et les décisions $D(c_i)$ avec $i=1,2,3$ à un instant (k-1), six neurones au niveau de la couche cachée et trois neurones au niveau de la couche de sortie (Figure IV.19).




Figure VI. 19 : Evaluation du résidus par le réseau RNN

$D(c_i)$: est la fonction non linéaire de la sortie du réseau extrait de la relation suivante :

$$D(c_i) = \varphi_i(Z * h_i + z_0) \quad (IV.3)$$

Où:

$$h_i = \varphi (W * x_i + w_0)$$

Avec :

$D(c_i)$: fonction de décision $i^{\text{ème}}$

Z : poids assemblant les neurones de la couche cachée à celles de la couche de sortie

z_0, w_0 : les poids initiaux

φ : la fonction d'activation de type sigmoïde passant de l'intervalle $[-\infty, +\infty]$ à $[0,1]$

h_i : la sortie de la couche cachée $i^{\text{ème}}$

W : poids assemblant les neurones de la couche cachée à celles de la couche d'entrée

x_i : les résidus et les décisions précédentes

B. Apprentissage du réseau :

On a adopté des poids par l'algorithme de la retro-propagation. Selon plusieurs essais donnant l'erreur quadratique égale à 10^{-6} jusqu'à 300 itérations, indiquant le résultat dans la figure IV.20.




Figure IV.20: L'erreur quadratique d'apprentissage du réseaux

VI.9.1 Cas du system sain

Les figures suivantes montrent les résidus d'identifications des trois strings sans défauts. On constate que les résidus des trois strings avec une amplitude de 2×10^{-4} pour les deux premier String et le troisième string Avec une amplitude de 1×10^{-4} et la décision de réseau de neurone utilisé tends vers zéro le cas des strings sans défauts.

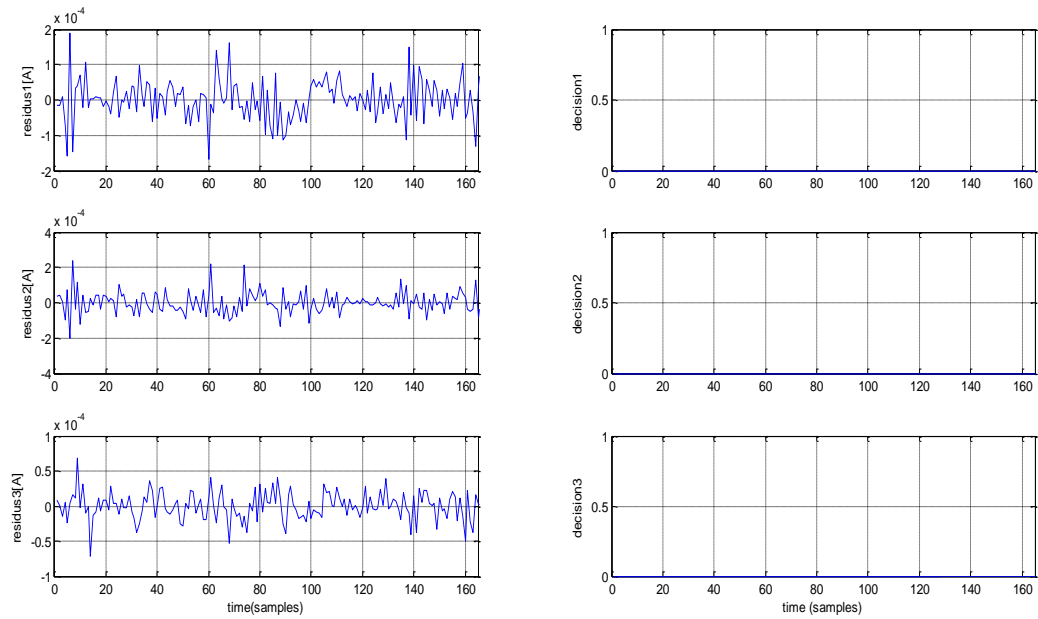


Figure IV.21: Résidus et décision du réseau en absence de défauts

VI.9.2 Localisation et identification des défauts du système PV dans le cas des défauts capteurs

Dans cette étape nous avons utilisé plusieurs types de défauts avec ces différents instants d'apparition en plus de l'amplitude du défaut (voir tableau IV.3).

Dans le premier scénario, nous avons injecté un défaut additif abrupts (biais) simple sur le premier capteur du système PV à l'instant 50 échantillon d'amplitude 0.001. Ce qui est représenté dans la figure IV.22.

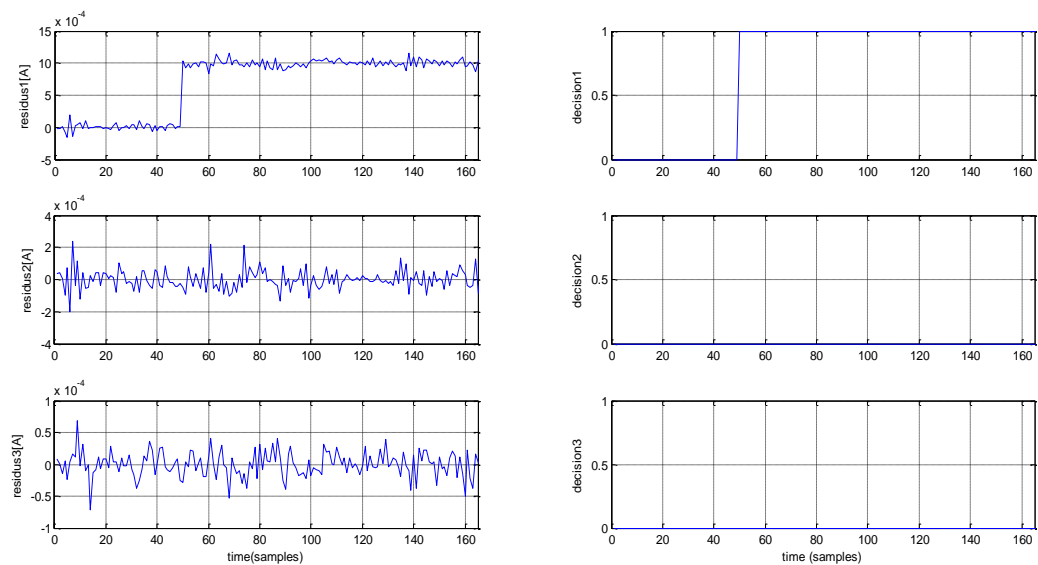


Figure IV.22: Résidus et décisions du réseau en présence de défauts sur le capteur1

La figure IV.22 représente les trois résidus avec leurs décisions du réseau. On remarque l'apparition du défaut dans le premier résidu à l'instant 50 échantillon, le réseau a indiqué 1 au même instant, cependant les autres ont donnés zéros.

Le deuxième scénario présente un défaut sur le deuxième capteur de type intermittent à l'instant [50,100] d'amplitude 0.001.

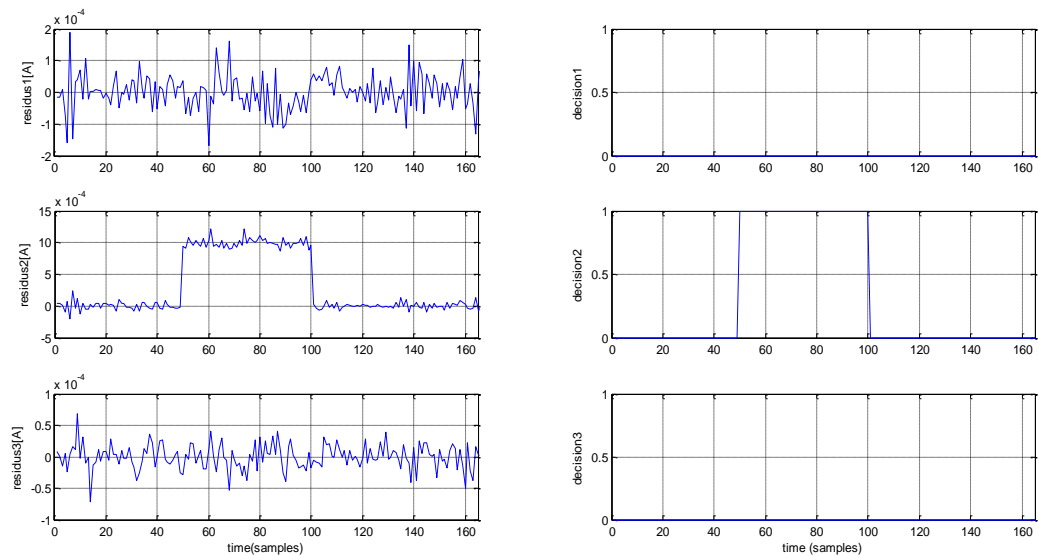


Figure IV.23: Résidus et décisions du réseau en présence de défauts sur le capteur2

La figure IV.23 présente les trois résidus et aussi les décisions en apparition de défauts sur le deuxième résidu détectant un défaut à l'instant [50,100] ce qui déduit la décision du réseau RNN et les autres résidus indique zéro.

Dans le troisième scénario, nous avons injecté un défaut de type dérivée à l'instant [30,100] d'une amplitude de 0.001 sur le troisième capteur.

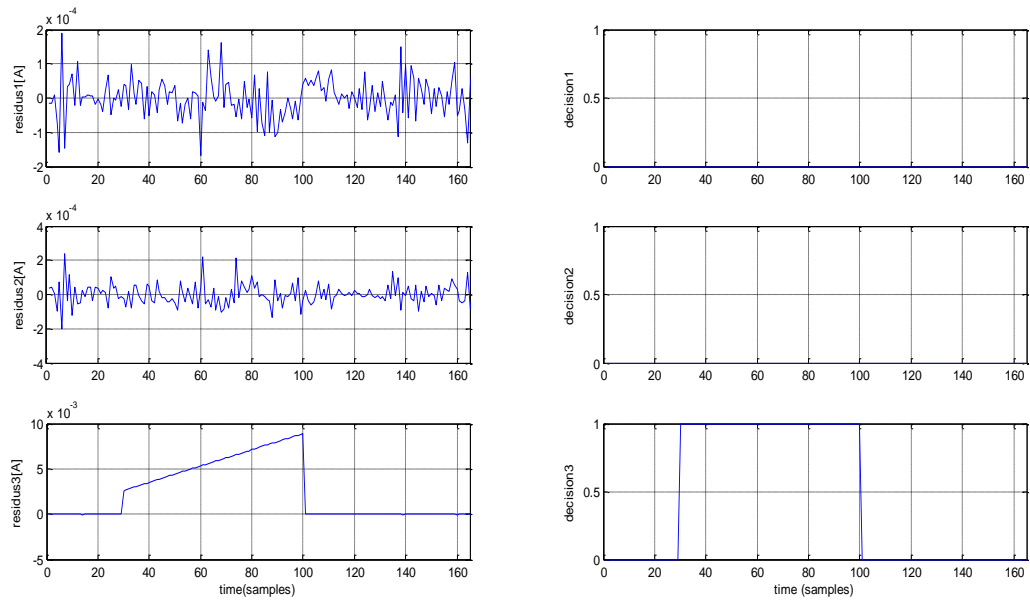


Figure IV.24: Résidus et décisions du réseau en présence de défauts sur le capteur3

La figure IV.24 montre les résidus et les décisions en existence de défauts sur le troisième capteur. On conclut que le troisième résidu détecte un défaut à l'instant [30,100] d'une amplitude de 0.001, ce qui confirme la décision du réseau au même instant (indication 1) et les autres résidus indiquent 0.

Le quatrième scénario présente deux types de défauts différents à des instants de défaut différents de même amplitude. Le premier capteur a injecté un défaut additif de type biais à l'instant 50 échantillon, alors qu'au deuxième capteur un défaut de type intermittent à l'instant [50,100], les deux capteurs ont une amplitude de 0.001.

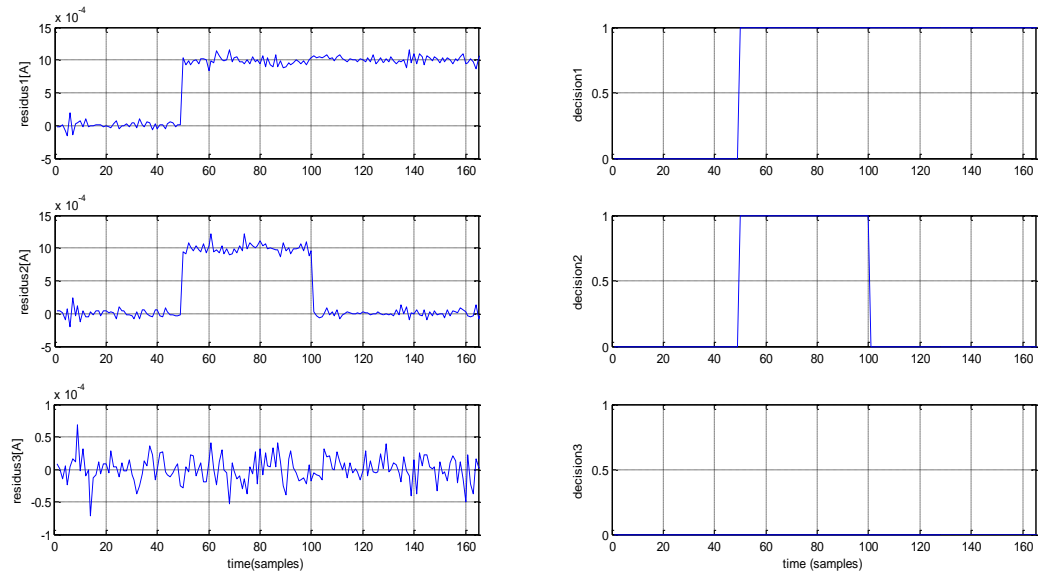


Figure IV.25: Résidus et décisions du réseau en présence des défauts sur le capteur1 et capteur2

On remarque dans le deuxième scénario les deux résidus détecte des défauts d'amplitudes identiques (0.001) cependant le premier résidu apparait au moment 50 échantillon alors qu'au deuxième au moment [50,100],ce qui confirme notre décision de réseau (indication 1).

Le cinquième scénario présente deux types de défauts différents, le premier défaut injecté sur le deuxième capteur de type intermittent à l'instant [50,100] d'amplitude de 0.001 alors qu'au troisième capteur et de type dérivé à l'instant 50 échantillon d'amplitude de 0.009.

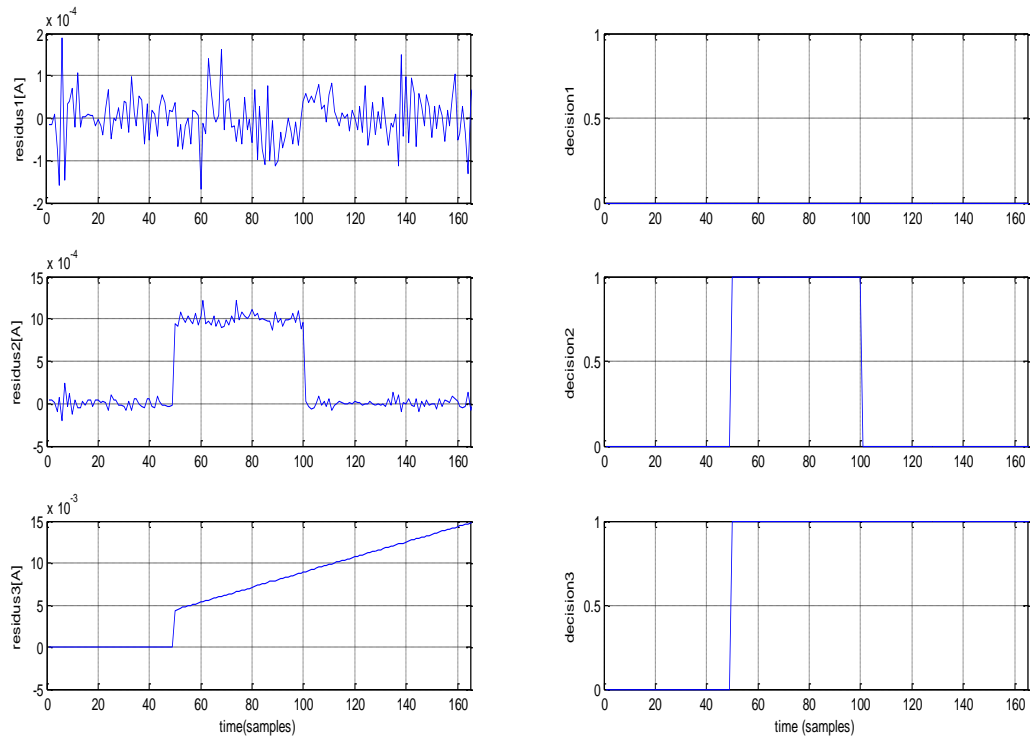


Figure IV.26: Résidus et décisions du réseau en présence des défauts sur les capteur2 et3

La figure IV.26 illustre les résidus et décisions en existence de défauts sur le capteur2 et capteur3. On remarque que les deux résidus 2 et 3 détectent un défaut. Le deuxième résidu détecte l'apparition de défauts à l'instant [50,100] d'amplitude de 0.001, tandis que le troisième détecte le défaut à l'instant 50 échantillon d'une amplitude de 0.009. Le réseau classifie les deux capteurs ayant un défaut au même instant.

Le sixième scénario représente les trois capteurs injectant trois types de défauts différents. Le premier capteur est de type biais à un instant 50 échantillon, le deuxième capteur est de type intermittent à l'instant [50,100] d'une amplitude identique à celle du premier (0.001), et le troisième capteur est de type dérivé à l'instant [30,90] d'une amplitude de 0.009.

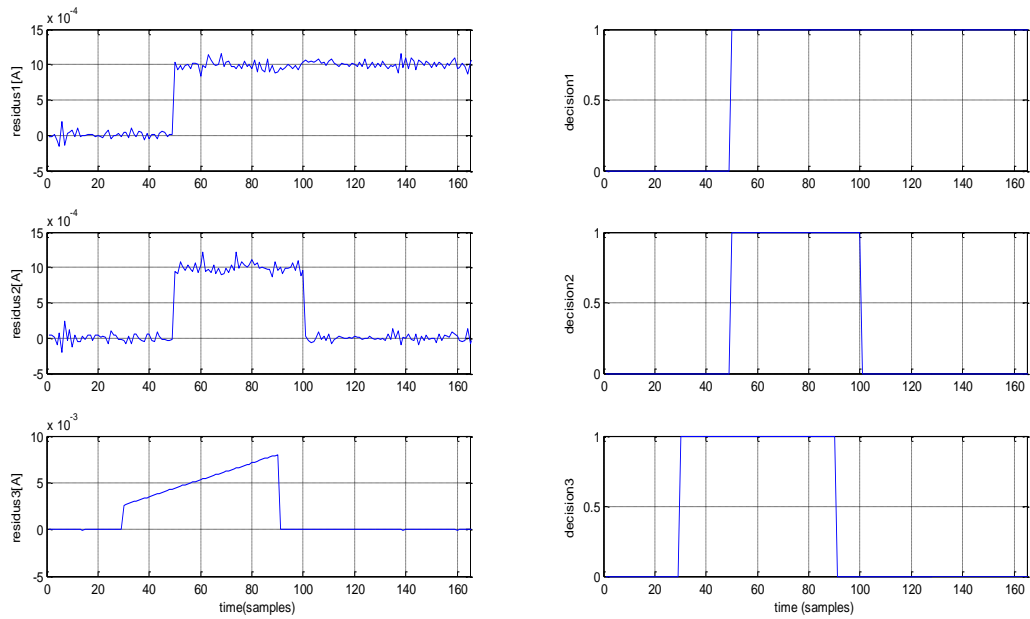


Figure IV.27: Résidus et décisions du réseau en présence des défauts sur les trois capteurs

La figure IV.27 illustre les résidus et décisions en apparence des défauts sur les trois capteurs. On constate que les trois résidus détectent trois différents types de défauts avec de différents instants, ce qui définit la décision du réseau (indication 1).

En vue de valoriser notre technique concernant la sensibilité et la rapidité du réseau RNN nous avons injectés les types des défauts suivants :

- Dans le premier type, nous avons introduit un défaut de type bruit de mesure sur le premier capteur à l'instant [50,100] échantillon d'amplitude de 20%(voir figure IV.28)

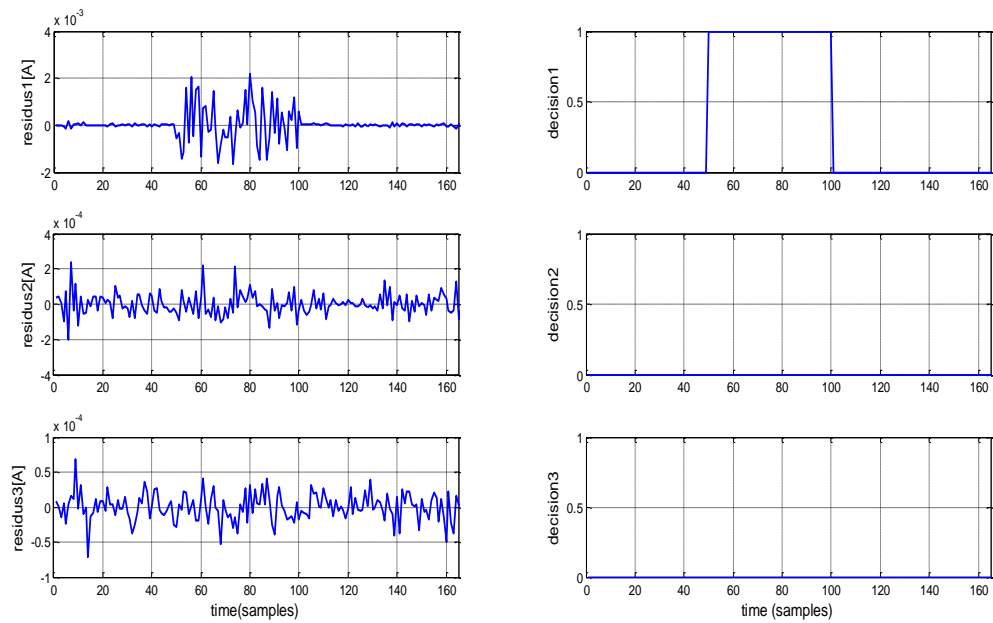


Figure IV.28: Résidus et décisions du réseau en présence de défauts de bruit de mesure sur le capteur1

On remarque que le premier résidu a détecté les défauts en même instant cité précédemment. Ce que déduit le réseau qui indique 1 tandis qu'aux autres donne la valeur de zéro.

- Dans le deuxième type, nous avons indiqué un défaut de type abrupte simple sur le deuxième capteur d'une amplitude de 20% à l'instant 50 échantillon.

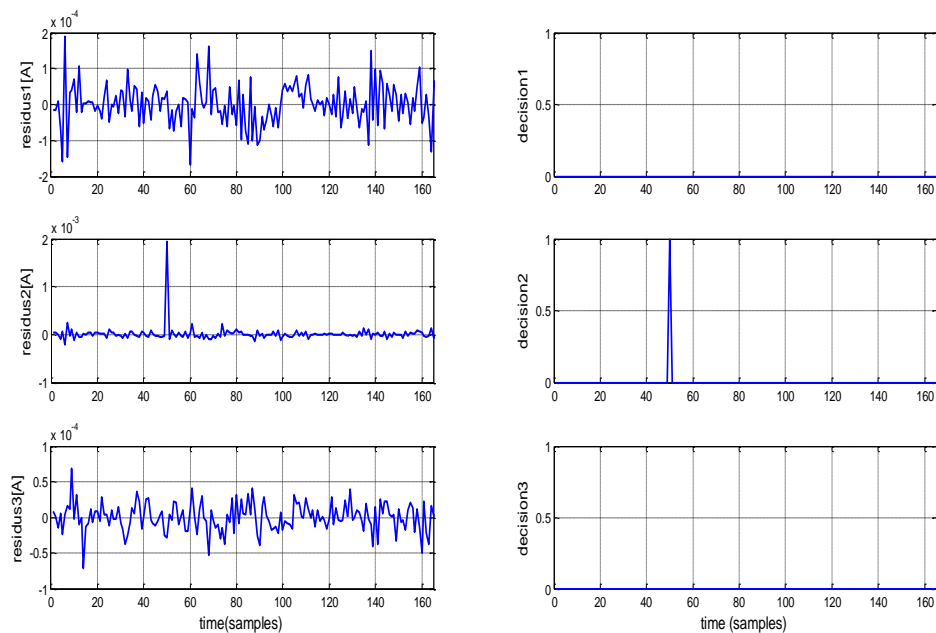


Figure IV.29: Résidus et décisions du réseau en présence de défaut sur le capteur2

On observe que le deuxième résidus a détecté un défaut au même instant précédemment donné ce que a indiqué le réseau RNN la valeur de 1 et les autres zéro.

- Dans le troisième type, nous avons ajouté un type de défaut progressif sur le deuxième capteur au moment de 90 jusqu'à 110 échantillonné avec une amplitude de 0,02.

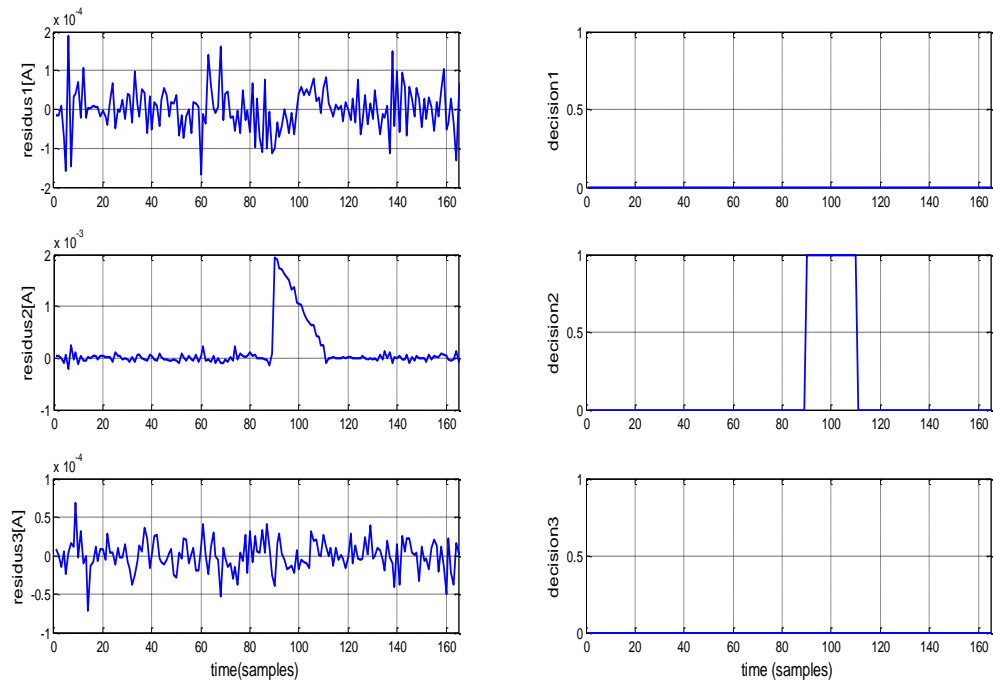


Figure IV.30: Résidus et décisions du réseau en présence de défaut sur le capteur2.

Suivant la figure IV.30 on remarque l'apparissance de défaut sur le deuxième résidus au même instant donné .En parallèle un défaut a été identifié par le réseau traduisant la valeur 1 tandis qu'au autre 0.

- Dans le quatrième type, nous avons introduit un défaut irrégulier c'est à dire le défaut augmente à un instant ensuite il se stabilise en même temps. Nous allons appliquer ce type de défaut sur le troisième capteur à l'instant [30,90], le défaut augmente alors qu'à l'instant [90,120] il reste stable.

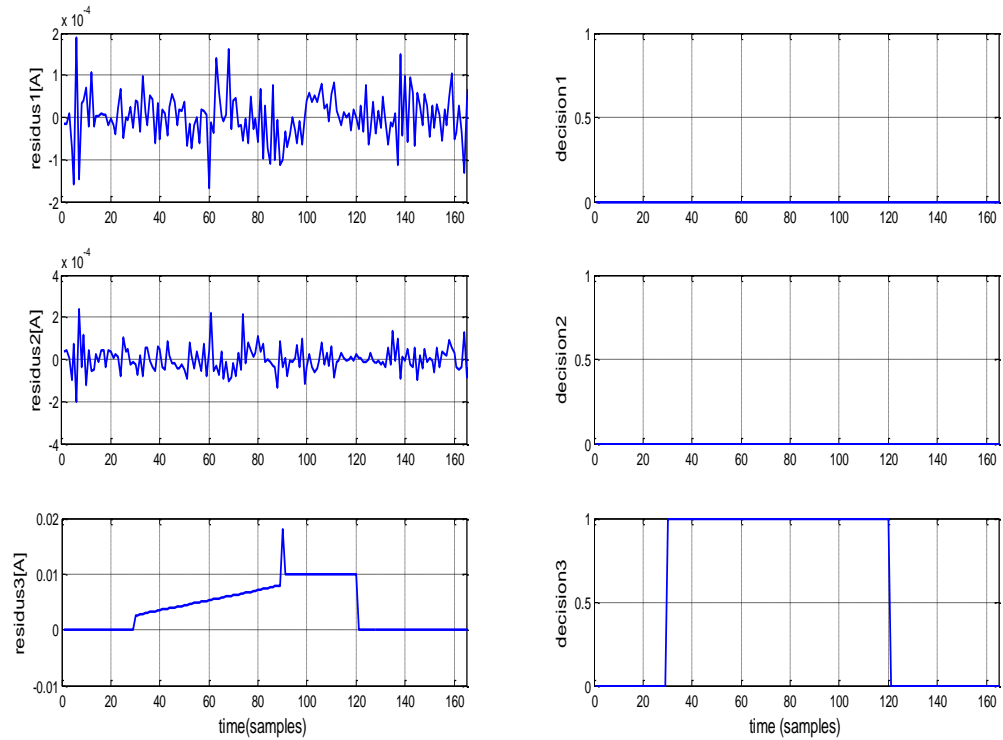


Figure IV.31: Résidus et décisions du réseau en présence de défaut sur le capteur3

On déduit selon la figure IV.31 que dans le troisième résidus un défaut apparait au même instant précédemment défini le réseau alors identifie un défaut à l'instant [30,120] échantillon qui la traduit en valeur 1.

- Dans le cinquième type, nous avons ajouté un défaut combiné, c'est à dire composé de trois types de défauts en série (dérivé, abrupt, intermittent) affectant le premier capteur à l'instant [30,60], le défaut augmente d'une amplitude de 0.01 de [60,100], il se stabilise de même valeur de [100,150]. Le défaut augmente jusqu'à la valeur de 0.02 après le défaut rechute à 0.

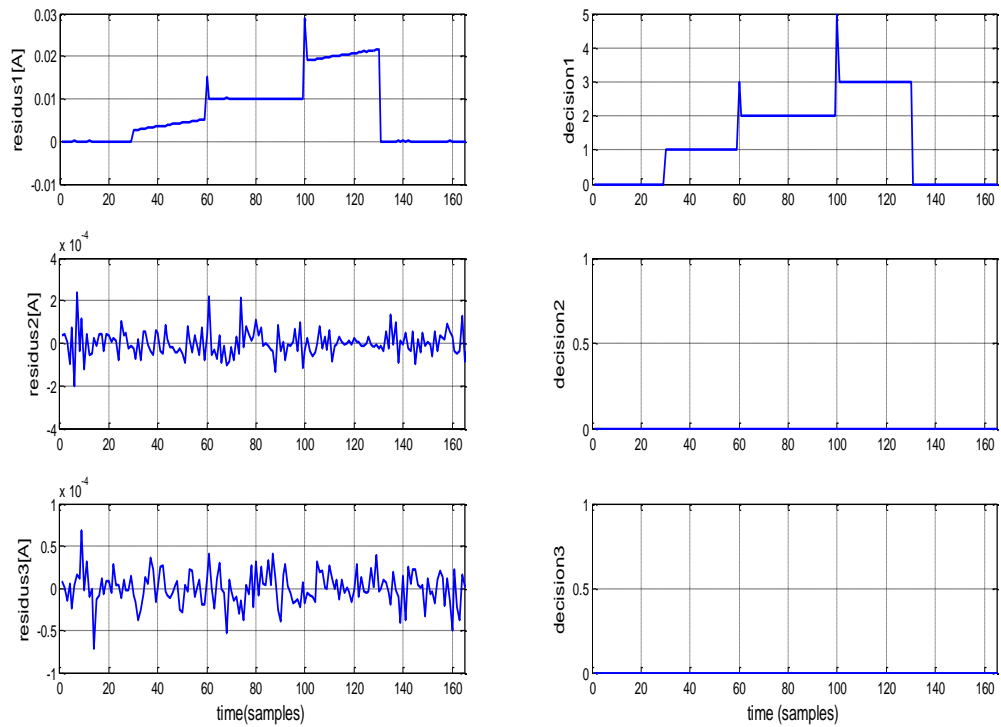


Figure IV.32: Résidus et décisions du réseau en présence de défaut sur le capteur1

Les résultats selon la figure IV.32 expliquent ce qu'on a cité précédemment car le défaut apparaît dans le premier résidu au même instant. Le réseau identifie et classifie trois niveaux de défaut avec de différents instants, tandis qu'aux autres résidus 1 et 2 indique la valeur de zéro.

- Dans le sixième type, c'est à peu près le même défauts que celui du cinquième essai sauf qu'à la fin le défaut diminue progressivement entre l'intervalle [90,110] affectant le premier capteur.

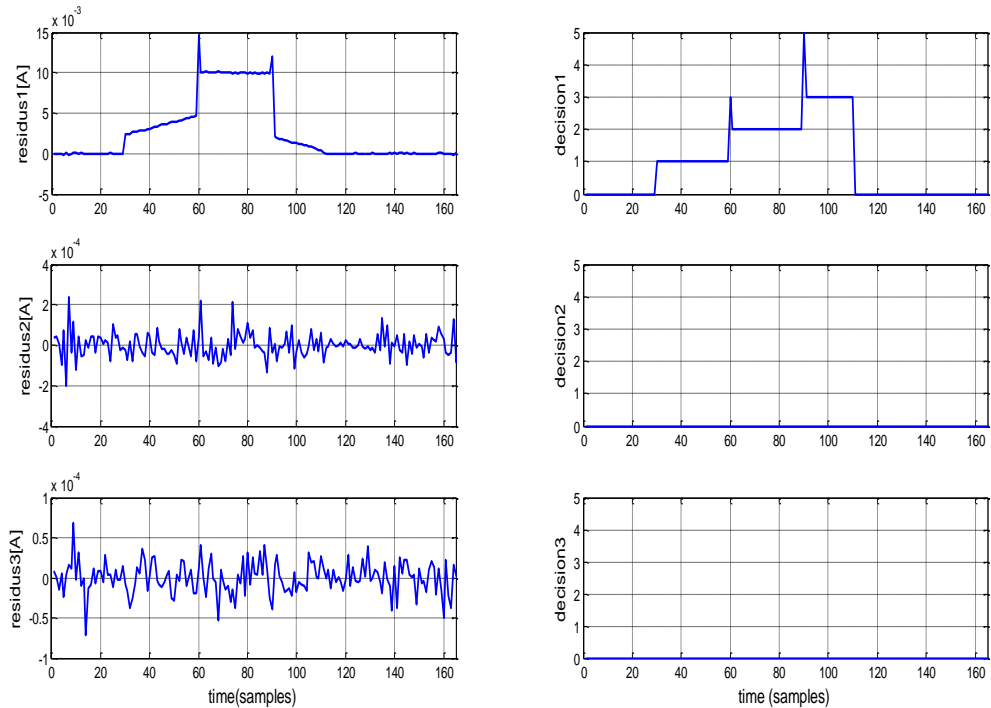


Figure IV.33: Résidus et décisions du réseau en présence de défaut sur le capteur1.

Selon la figure IV.33 on constate l'apparition de défaut au niveau du résidus 1 de [30,110] échantillon avec différentes amplitudes et instants, c'est que donne le réseau RNN qui classifie et identifie les niveaux de défauts en plusieurs instants qui affectent le capteur 1. Alors que les deux derniers capteurs la décision du réseau indique zéro.

L'analyse de ce réseau permet de construire la table des signatures des défauts, sont $f_1, f_2, f_3, f_4, f_5, f_6$. Les défauts respectivement sur les trois capteurs, on a:

Table IV.5: Table de signatures des défauts capteurs

Décisions				
Défaut		<i>D1</i>	<i>D2</i>	<i>D3</i>
<i>Normal</i>		0	0	0
<i>f₁</i>		1	0	0
<i>f₂</i>		0	1	0
<i>f₃</i>		0	0	1
<i>f₄</i>		1	1	0
<i>f₅</i>		0	1	1
<i>f₆</i>		1	1	1

Avec:

- f_1 : défaut abrupt sur capteur 1.
- f_2 : défaut intermittent sur capteur 2.
- f_3 : défaut graduel (dérivée) sur capteur 3.
- f_4 : défaut combine sur capteur 1 et 2.
- f_5 : défaut combine sur capteur 2 et 3.
- f_6 : défaut combine sur les capteurs (1,2,3).

Notons que ce réseau permet cette fois de localiser l'ensemble des défauts considérés, la figure IV.34 présente différents défauts de type capteur, l'évolution du réseau RNN.

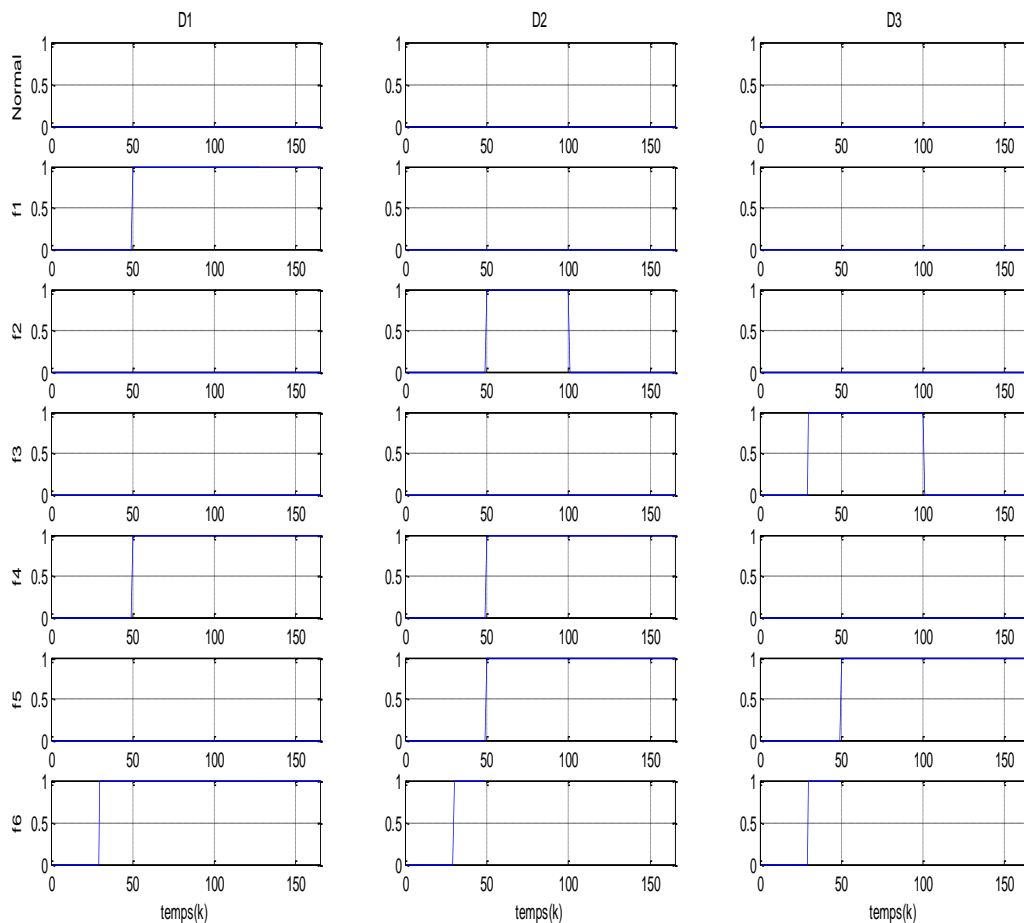


Figure IV.34: Evolution du RNN en fonction des défauts capteurs

Selon la figure IV.34 le RNN donne les dysfonctionnements du système PV par un 1, sa décision est plus rapide.

VI.9.3 Détection et identification des défauts du système PV dans le cas de défauts physiques

VI.9.3.1. Cas de défaut simple

Dans cette première partie, nous avons présenté le cas de défauts physique simple (Phénomène d'ombrage ou défaut shunt) au niveau de string de système PV.

▪ Shunt (résistif)

Les résultats obtenus dans la figure IV.35, montrent les résidus d'identification avec la décision de réseau de neurone RNN en présence de défauts shunt dans le système PV au niveau de string 1 au de l'instant 100.

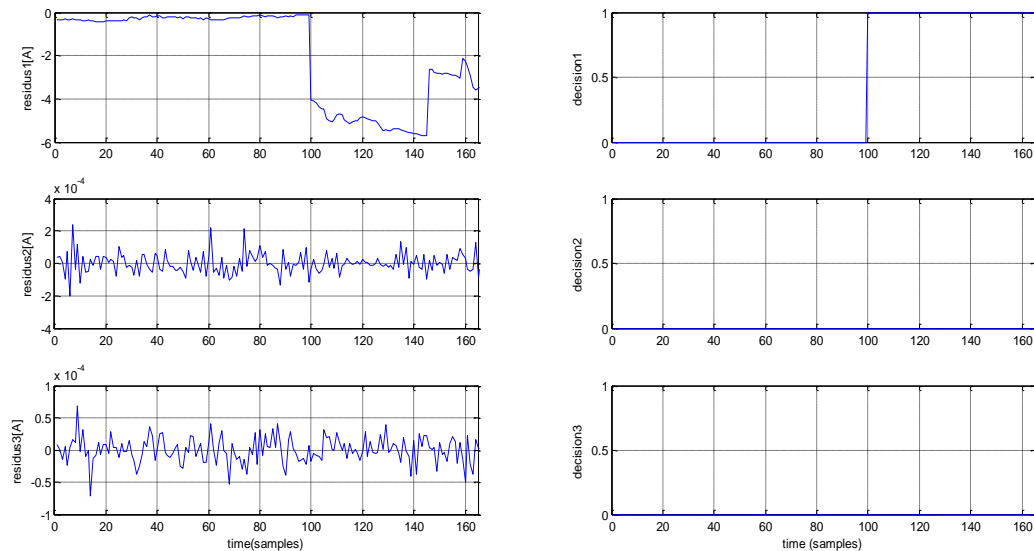


Figure IV.35:Résidus d'identification et la décision du réseau : cas défaut shunt

Les résidus d'identification obtenus dans ce cas, montrent que le premier résidu correspond au string I du système PV. Ce dernier indique la présence d'un défaut d'amplitude absolue de 4A au de la 100 échantillon, cette présence de défaut est confirmée par la décision du réseau de neurone avec une réponse logique d'un (1) dans le string I au de la 100 échantillons et zéro dans les deux autres string 2 et 3.

▪ Cas de phénomène d'ombrage

Les résultats obtenus dans la figure IV.35, montrent les résidus d'identification avec la décision de réseau de neurone RNN en présence du phénomène d'ombrage dans le système PV au niveau du deuxième string à partir de l'instant 100.

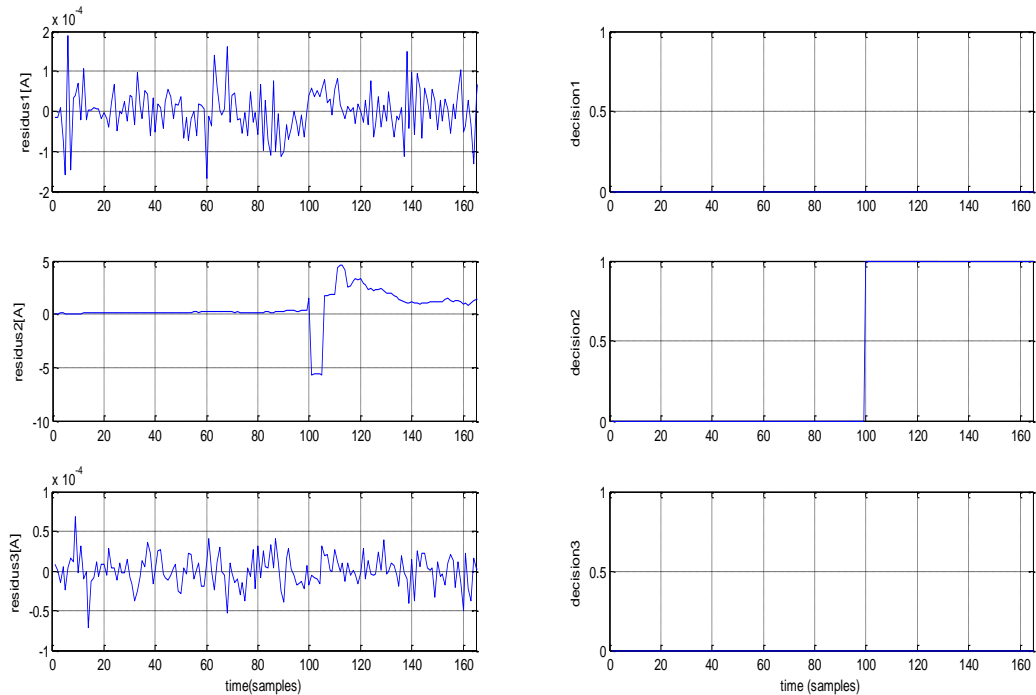


Figure IV.36: Résidus d'identification et la décision du réseau : cas de phénomène d'ombrage

Les résidus d'identification obtenus dans ce cas, montrent que le deuxième résidu correspond au string II du système PV. Ce dernier indique la présence d'un défaut à partir de 100 échantillons (k). Ce défaut avec un résidu d'amplitude au début atteint 5.2 A, et à partir 160 échantillons se stabilise autour de 1.5 A. La décision de réseau RNN est utilisé pour confirmer la présence d'un défaut à partir de l'échantillon 100 la décision logique est égal 1 au niveau de string II, et tends vers 0 dans les autres string I et III.

▪ Cas de phénomène d'ombrage au niveau string III

La figure IV.37 présente les résidus d'identification au niveau des trois strings avec la présence de phénomène d'ombrage dans le string III à partir de l'échantillons 100.

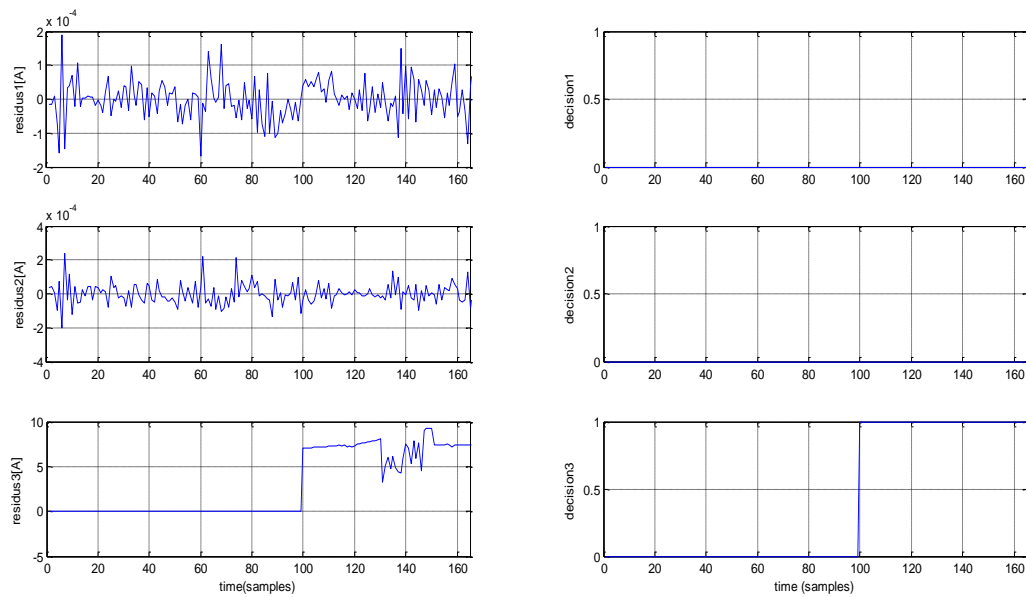


Figure IV.37: Résidus d'identification et la décision du réseau : cas de phénomène d'ombrage

Les résidus d'identifications obtenus montrent l'effet de la présence de phénomène d'ombrage sur le résidu de string III avec une amplitude presque 9A, ce changement correspond à une réponse logique de réseau RNN est égale à 1 et zéro dans les autres.

▪ **Cas de phénomène shunt (résistif) intermittent au niveau string I**

La figure IV.38 représente un défaut shunt (résistif) intermittent entre l'intervalle [30,100] échantillon au niveau du string I.

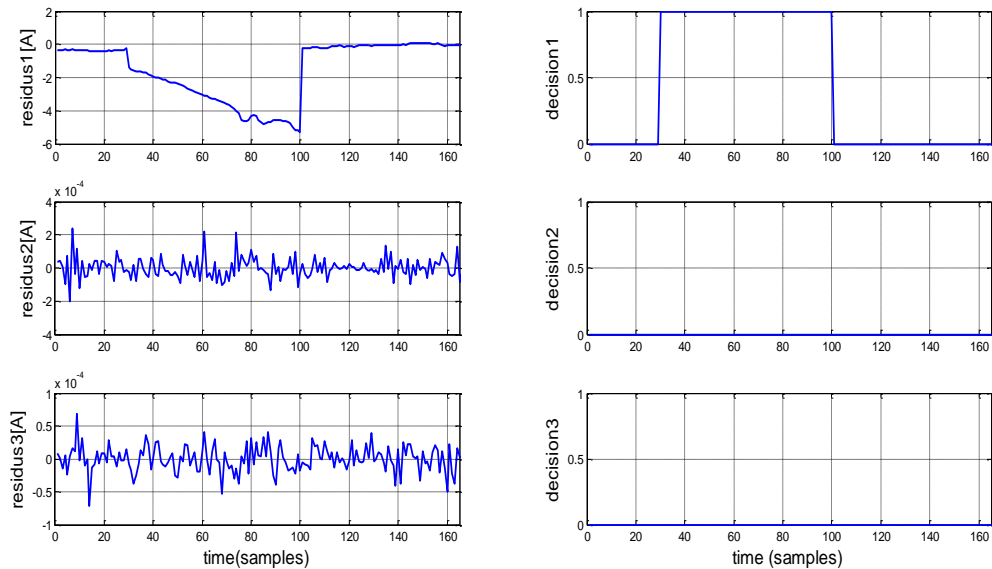


Figure IV.38: Résidus d'identification et la décision du réseau : cas défaut shunt de type intermittent

Les résidus détectent la présence de défaut shunt de type intermittent entre [30,100] sur le résidu de string I avec une amplitude d'environ 5A, la décision du réseau RNN est égale à 1 et zéro dans les autres.

VI.9.3.2 Cas de défauts combinés

Dans cette partie et pour montrer la sensibilité et la bonne décision de notre méthode d'identification, nous avons introduit des défauts combinés (ombrage et shunt) au niveau des strings de système PV étudié dans des différentes périodes.

▪ Cas de défaut d'ombrage combiné

La figure IV.39 présente les résidus d'identifications dans les strings avec la présence de défauts d'ombrage au niveau string I et II.

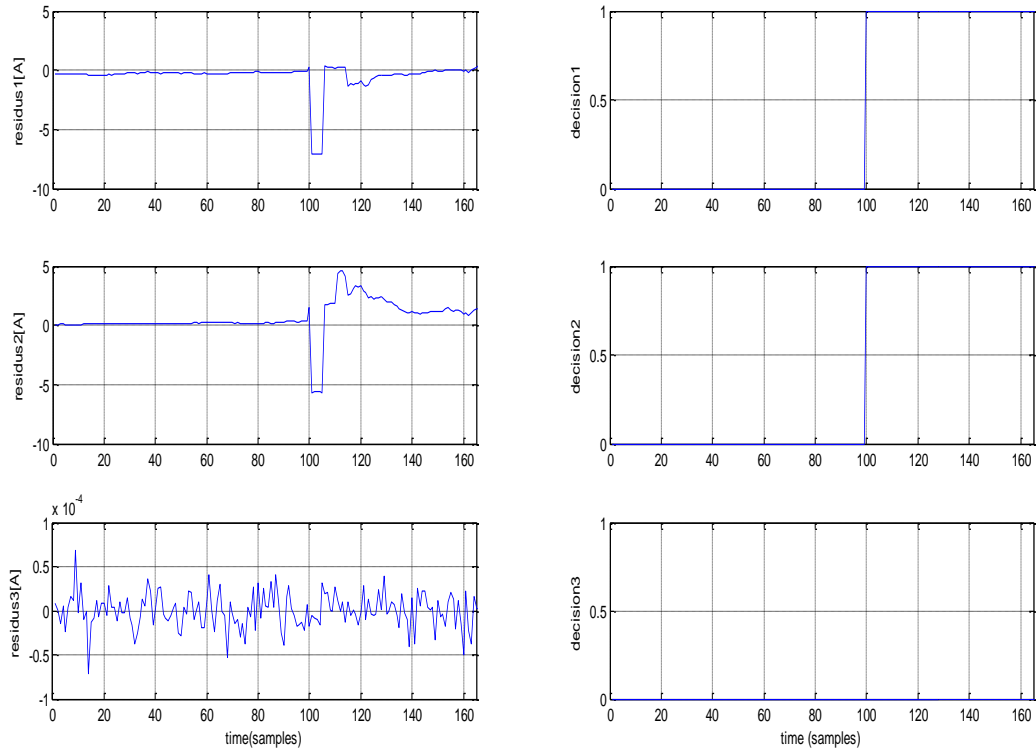


Figure IV.39: Résidus d'identification et la décision du réseau : cas de défaut d'ombrage combiné

Les résidus d'identification obtenus montrent l'effet du phénomène d'ombrage au niveau de deux string I & II, d'après les résidus on constate que, l'évolution des résidus en présence de phénomène d'ombrage dans les deux String est presque identique, ce qui montre la robustesse de notre méthode d'identification.

▪ Cas de défaut shunt et ombrage

La figure IV.40 présente les résidus d'identifications des trois strings de système PV étudié en présence de défaut shunt au niveau string I et le phénomène d'ombrage au niveau de string II.

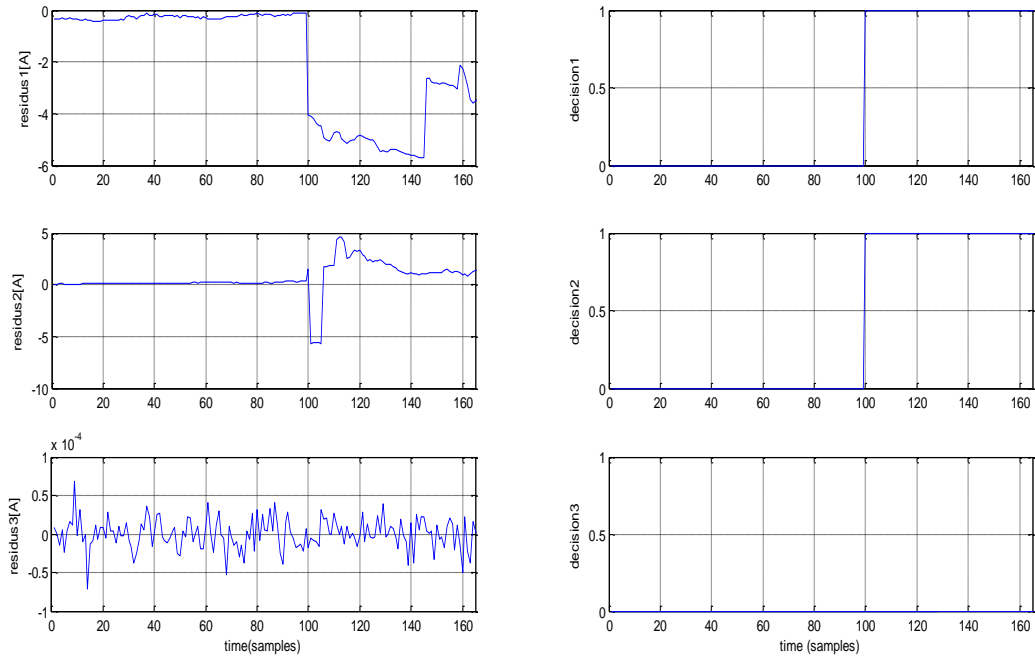


Figure IV.40: Résidus d'identification et la décision du réseau : cas de défaut shunt et d'ombrage combiné

Les résultats obtenus représentent les effets des défauts sur les résidus d'identifications. D'après les deux résidus, on constate que le résidu de string I enregistré par le capteur I atteint jusqu'à une amplitude d'une valeur absolue de 5.7A, et par la suite se stabilise avec une valeur absolue de 4A. de la même manière, le résidu enregistré par le capteur I au niveau de string II atteint une valeur d'amplitude 4A et se stabilise autour d'une valeur faible.

▪ Cas de défaut shunt de type intermittent et ombrage

Dans ce cas la figure IV.41 représente un défaut combinée entre deux types : Un défaut shunt de type intermittent entre l'intervalle [30,100] échantillon au niveau du string I et un défaut ombrage à l'instant 100 échantillon au niveau du string II.




Figure IV.41: Résidus d'identification et la décision du réseau : cas de défaut shunt de type intermittent et d'ombrage combiné

On observe que les deux premiers résidus montrent un défaut. Le premier résidu indique un défaut intermittent de type shunt d'amplitude d'environ 5A, et le deuxième indique un défaut à l'instant 100 échantillon d'amplitude 5A, et cela explique que le réseau donne la même décision de résidus et indique 1.

Dans le deuxième essai, nous avons introduit un défaut combiné intermittent (shunt et ombrage). C'est à dire on a injecté les deux phénomènes en série. Tandis que le premier indique un défaut shunt de [30,100], le deuxième défaut donne [100,120] affectant le niveau du string I.

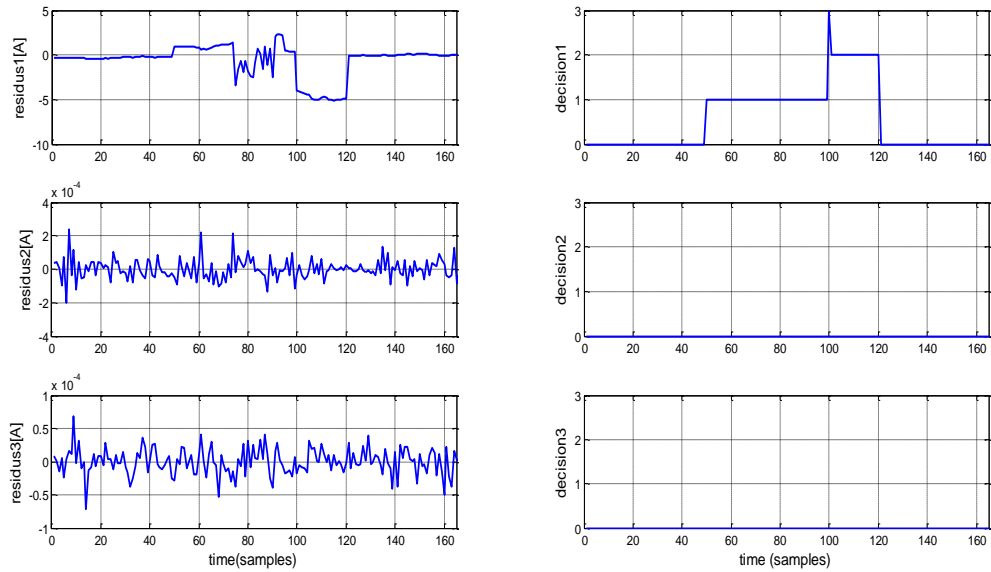


Figure IV.42:Résidus d’identification et la classification du réseau : cas de défaut shunt de type intermittent et d'ombrage combiné.

On constate d'après la figure IV.42 que deux défauts apparaissent dans le premier résidus, ce que traduit que le réseau RNN identifie et classe le défaut à deux niveaux ; au niveau des deux derniers strings le réseau indique zéro. Les résultats d'identification illustrent différents défauts. Ils sont montrés dans le tableau IV.6.

Table IV.6: Identification de défaut physique du système PV

<i>Décisions</i> <i>Etats</i>	<i>D1</i>	<i>D2</i>	<i>D3</i>
<i>Normal</i>	0	0	0
<i>f₁</i>	1	0	0
<i>f₂</i>	0	1	0
<i>f₃</i>	0	0	1
<i>f₄</i>	1	1	0
<i>f₅</i>	1	1	0

Avec:

f₁ :défaut shunt au niveau string I.

f₂: phénomène ombrage au niveau string II.

f₃: phénomène ombrage string III.

f₄: défaut combinés d'ombrage au niveau de string I & II.

f₅: défaut combinés shunt & ombrage au niveau de string I & II.

Notons que ce réseau RNN permet, cette fois de localiser l'ensemble des défauts considérés. La figure IV.43 présente les différents défauts physique du système PV, et l'évolution du réseau.

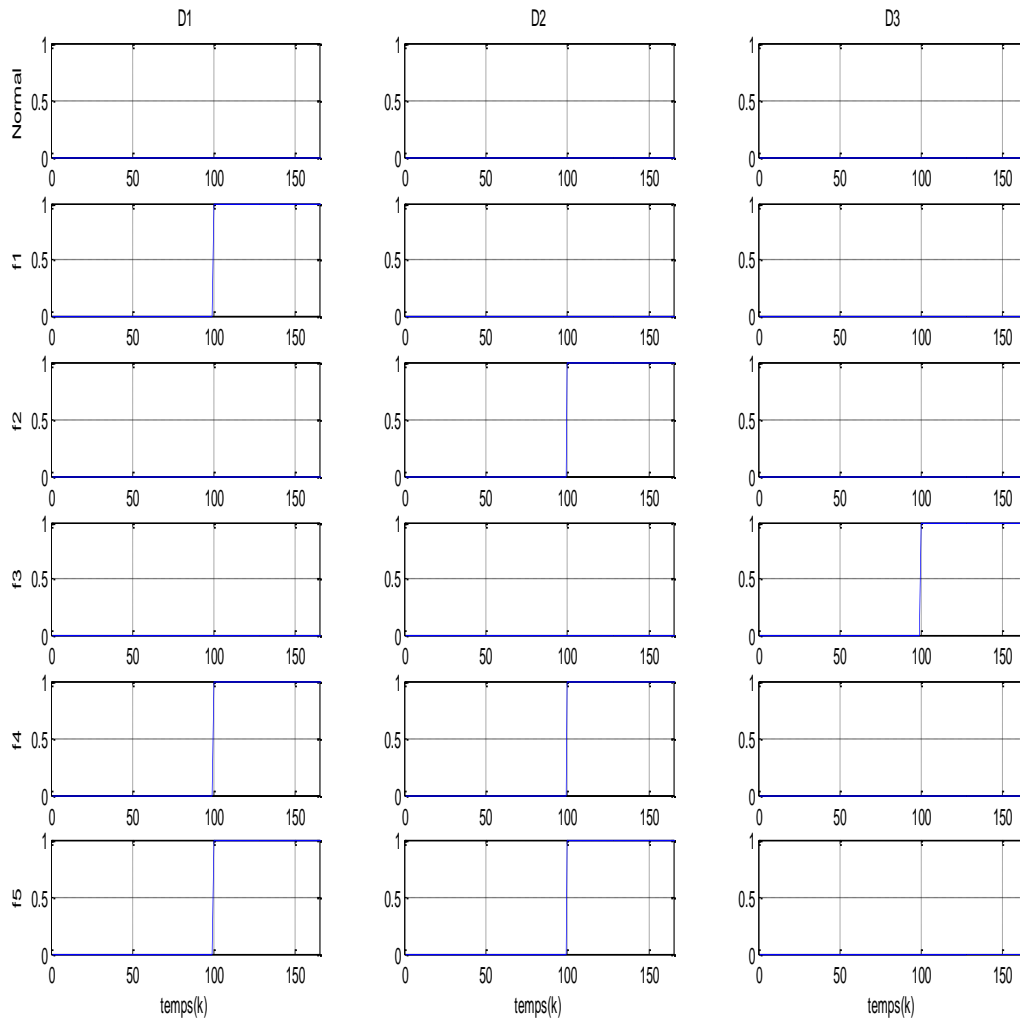


Figure IV.43: Evolution du RNN en fonction des défauts physiques

D'après la figure IV.43, le RNN détecte et classe les défauts physiques du système PV et fait apparaître les décisions du réseau d'une manière plus précise.

VI.10 Conclusion

Dans ce chapitre on a étudié l'influence des températures et l'irradiation par rapport au système PV. A cet effet, on a déduit que la variation de PPM en fonction du changement de l'ensoleillement et la température, provoque la variation du courant du panneau photovoltaïque.

Notre objectif dans ce chapitre est de présenter les résultats d'identification de défaut obtenus. On conclut que le réseau RNN montrent la précision et la rapidité de la détection et l'identification ou classification de différents types de défauts physique et capteurs affectant le système PV.

CONCLUSION GENERALE

Conclusion Générale

Le travail présenté dans cette thèse s'inscrit dans le cadre de détection et diagnostic de défauts dans les systèmes énergétiques par des méthodes de l'intelligence artificielle.

La méthodologie du travail consiste à utiliser des techniques modernes de détection et de diagnostic basées sur l'intelligence artificielle pour surveiller, détecter et diagnostiquer les défauts dans les systèmes énergétiques: cas d'un système photovoltaïque.

Dans la littérature, les réseaux de neurones largement utilisés en vue de diagnostic de défauts dans différent domaine à cause, constituent un bon outil de modélisation et de diagnostic des systèmes non linéaires. En dépit des problèmes croisés dans le choix d'une architecture optimale en fonction des entrées, le nombre de couches, le nombre de neurones dans chaque couche, les poids, les biais initiaux, ainsi que le choix d'un algorithme doit être précis ; Dans le travail de cette thèse nous avons développé un algorithme neuronal permettant de :

- ✓ Générer des résidus de détection des défauts,
- ✓ Créer des modèles enregistrés pour l'identification des défauts.

Dans un premier lieu, nous avons pu développer un algorithme neuronal de type MLP utilisé pour générer les résidus afin de détecter des défauts physiques (shunt, ombrage) et des défauts capteurs (abrupt, intermittent et dérivée). Dans le deuxième lieu, l'identification de défauts a été effectuée grâce à un autre algorithme de type RNN développé pour créer des modèles enregistrés.

Les résultats obtenus montrent clairement la précision et la rapidité des algorithmes neuronal développés en vue de la détection et l'identification des défauts physiques et des défauts capteurs dans les systèmes photovoltaïques.

Dans les futurs travaux scientifiques, nous nous intéresserons au développement des algorithmes intelligents de classification et de prédiction de défauts dans les systèmes énergétiques multi-sources.

BIBLIOGRAPHIE

Bibliographie:

[Åst, 00] K.J. Åström, P. Albertos, M. Blanke, A. Isidori, R. Santz & W. Schaufelberger, (2000) "*Control of Complex Systems*", Springer Verlag.

[Adj, 93] K.H. Adjallah, (1993) "Contribution au diagnostic de systèmes par observateurs d'état", Thèse de doctorat de l'Institut National Polytechnique de Lorraine, France.

[Ade, 06] ADEME, (2006) "Guide de spécifications techniques relatives à la protection des personnes et biens - Générateurs photovoltaïques raccordés au réseau," ADEME,.

[Ali,17] M. H. Ali, A. Rabhi, A. E. Hajjaji, and G. M. Tina, (2017) "Real time fault detection in photovoltaic systems," *Energy Procedia*, vol. 111, pp. 914–923, Mar. 2017, doi: 10.1016/j.egypro.2017.03.254.

[Ale, 00] M. Alexandru, C. Combastel, and S. Gentil, (2000) "Diagnostic decision using recurrent neural networks," *IFAC Proceedings Volumes*, vol. 33, no. 11, pp. 405–410, Jun. 2000, doi: 10.1016/S1474-6670(17)37392-5.

[Ben, 11] M. L. Benloucif, (2011) "Neuro-fuzzy sensor fault diagnosis of an induction motor," *Journal of Engineering Research*, vol. 8, no. 1, pp. 53–60, 2011, doi: 10.24200/tjer.vol8iss1pp53-60.

[Bou, 15] A. Bouraiou, M. Hamouda, A. Chaker, M. Sadok, M. Mostefaoui, and S. Lachtar, (2015) "Modeling and simulation of photovoltaic module and array based on one and two diode model using matlab/simulink," *Energy Procedia*, vol. 74, pp. 864–877, Aug. 2015, doi: 10.1016/j.egypro.2015.07.822.

[Beb, 07] A. Bebiolles, (2007) "Diagnostic de systèmes complexes à base de modèle interne, reconnaissance des formes et fusion d'informations", thèse de doctorat ; Université de Technologie de Compiègne.

[Bun,11] L. Bun, (2011) "Détection et Localisation de Défauts pour un Système PV.(2011)" Thèse de Doctorat, Spécialité en Génie Electrique. Université de Grenoble, France, 2011.

[Bis,88] J. W. Bishop, (1988) "Computer simulation of the effects of electrical mismatches in photovoltaic cell interconnection circuits," *Sol. cells*, vol. 25, no. 1, pp. 73–89.

[Baz,11] A. M. Bazzi, K. A. Kim, B. B. Johnson, P. T. Krein, and A. Dominguez-Garc, (2011) "Fault impacts on solar power unit reliability," in *Conference Proceedings - IEEE Applied Power Electronics Conference and Exposition - APEC*, pp. 1223–1231.

[Bou, 17] L. Bouselham, M. Hajji, B. Hajji, and H. Bouali, (2017) "A new MPPT-based ANN for photovoltaic system under partial shading conditions," *Energy Procedia*, vol. 111, pp. 924–933, Mar. 2017, doi: 10.1016/j.egypro.2017.03.255.

- [Bel, 18]A. Belaout, F. Krim, A. Mellit, B. Talbi, and A. Arabi, (2018) “Multiclass adaptive neuro-fuzzy classifier and feature selection techniques for photovoltaic array fault detection and classification,” *Renewable Energy*, vol. 127, pp. 548–558, Nov. 2018, doi: 10.1016/j.renene.2018.05.008.
- [Che, 99] J. Chen & R. Patton, (1999) "*Robust Model-Based Fault Diagnosis for Dynamic Systems*". London : Kluwer Academic Publishers.
- [Cro,12] J. L. Crozier, (2012)“Characterization of Cell Mismatch in Photovoltaic Modules Using Electroluminescence and Associated Electro-optic Techniques.” Nelson Mandela Metropolitan University.
- [Che, 17]Z. Chen, L. Wu, S. Cheng, P. Lin, Y. Wu, and W. Lin,(2017) “Intelligent fault diagnosis of photovoltaic arrays based on optimized kernel extreme learning machine and I-V characteristics,” *Applied Energy*, vol. 204, pp. 912–931, Oct. 2017, doi: 10.1016/j.apenergy.2017.05.034.
- [Che, 18]G. Chen, P. Lin, Y. Lai, Z. Chen, L. Wu, and S. Cheng, (2018)“Location for fault string of photovoltaic array based on current time series change detection,” *Energy Procedia*, vol. 145, pp. 406–412, Jul. 2018, doi: 10.1016/j.egypro.2018.04.067.
- [Che,02]Y. M. Chen and M. L. Lee, (2002)“Neural networks-based scheme for system failure detection and diagnosis,” *Mathematics and Computers in Simulation*, vol. 58, no. 2, pp. 101–109, Jan. 2002, doi: 10.1016/S0378-4754(01)00330-5.
- [Chi, 16]W. Chine, A. Mellit, V. Lughi, A. Malek, G. Sulligoi, and A. M. Pavan, (2016)“A novel fault diagnosis technique for photovoltaic systems based on artificial neural networks,” *Renewable Energy*, vol. 90, pp. 501–512, May 2016, doi: 10.1016/j.renene.2016.01.036.
- [Chi, 15]V. J. Chin, Z. Salam, and K. Ishaque, (2015)“Cell modelling and model parameters estimation techniques for photovoltaic simulator application: A review,” *Applied Energy*, vol. 154, pp. 500–519, Sep. 2015, doi: 10.1016/j.apenergy.2015.05.035.
- [Chu,94]Ah Chung Tsoi and A. D. Back,(1994) "Locally recurrent globally feedforward networks: a critical review of architectures," in *IEEE Transactions on Neural Networks*, vol. 5, no. 2, pp. 229-239, March 1994, doi: 10.1109/72.279187.
- [Cho,10]A. Chouder and S. Silvestre, (2010)“Automatic supervision and fault detection of PV systems based on power losses analysis,” *Energy Conversion and Management*, vol. 51, no. 10, pp. 1929–1937, Oct. 2010, doi: 10.1016/j.enconman.2010.02.025.
- [Dav, 13]M. Davarifar, A. Rabhi, A. E. Hajjaji, and M. Dahmane, (2013)“New method for fault detection of PV panels in domestic applications,” in *3rd International Conference on Systems and Control*, Oct. 2013, pp. 727–732, doi: 10.1109/ICoSC.2013.6750940.
- [Des,06] W. De Soto, S. A. Klein and W. A. Beckman, (2006)"Improvement and validation of a model for photovoltaic array performance," *Solar Energy*, vol. 80, pp. 78-88.

[Din, 91] X, Ding & P.M, Frank (1991) "Frequency domain approach and threshold selector for robust model-base fault detection and isolation", Proc. of IFAC Symp. SAFEPROCESS'91, Baden, Germany, vol. 1, pp.307-312.

[Evs,94]A.Evsukoff,., C. Combastel ,and S. Gentil.(1994) " Qualitative Reasoning and Neural Network Decision Procedures for Fault Detection and Isolation", *Proceedings of the 14th IFAC WorldCongress*, vol. 32, no. 2, pp. 7635-7640, 1994, doi:10.1016/S1474 6670(17)57303-6.

[Fem,05] N. Femia, G. Petrone, G. Spagnuolo and M. Vitelli,(2005) "Optimization of perturb and observe maximum power point tracking method," *Power Electronics, IEEE Transactions on*, vol. 20, pp. 963-973.

[Fir,10] S. K. Firth, K. J. Lomas, and S. J. Rees, (2010)"A simple model of PV system performance and its use in fault detection," *Sol. Energy*, vol. 84, no. 4, pp. 624–635.

[Fra, 90] P.M ,Frank , (1990) "Fault diagnosis in dynamic systems using analytical and knowledgebased redundancy : A survey and some new results". *Automatica* 26 (3), pp. 459–474.

[Fra, 96] P. M ,Frank., (1996) "Analytical and Qualitative Model-based Fault Diagnosis - A Survey and Some New Results", *European Journal of Control*, 2(1), pp. 6–28.

[Fra, 00] P. M , Frank.E, Alcorta Garcia. & B, Koppen-Seliger, (2000) "Modelling for fault detection and isolation versus modelling for control". *Mathematics and Computers in Simulation*, 53(4-6):259–271.

[Fra, 89] P.M ,Frank. & J, Wünnenberg, (1989) "*Robust diagnosis using unknown input observer schemes, for Fault diagnosis in dynamic systems: theory and application*", Patton R.J, Frank P.M., Clark R.N., Prentice Hall, Englewood, Cliffs, pp. 47-98.

[Ger, 91] J,Gertler, (1991) "Analytical Redundancy Methods in Failure Detection and Isolation". SAFEPROCESS 91, Baden-Baden (Germany), pp. 9–21.

[Hac, 16]O. Hachana, G. M. Tina, and K. E. Hemsas, (2016)"PV array fault diagnostic technique for BIPV systems," *Energy and Buildings*, vol. 126, pp. 263–274, Aug. 2016, doi: 10.1016/j.enbuild.2016.05.031.

[Ise ,02] R,Isermann,R. Schwarz, and S, Stolzl .(2002)" Fault-tolerant drive-by-wire systems, *IEEE Control Systems Magazine*", 22(5), pp. 64-81, 2002.

[Ise, 94] R, Isermann,(1994) "On the applicability of Model-based fault detection for technical processes", *Control Engineering Practice*, 2, pp. 439-450.

[Ise, 97a] R, Isermann,(1997) "Supervision, fault-detection and fault-diagnosis methods – Advanced methods and applications". Proc. Of the *IMEKO* word congress, New Measurements – Challenges and Visions, Tampere, Finland, vol. 1 pp 1-28.

[Ise, 96] R. Isermann & P. Ballé, (1996) "Trends in the application of model-based fault detection and diagnosis of technical processes". Proc. Of the IFAC, 13th Triennial World Congress, San Francisco, USA, vol. 7, pp. 1-12.

[Ish, 11] K. Ishaque, Z. Salam, and H. Taheri, (2011) "Simple, fast and accurate two-diode model for photovoltaic modules," *Solar Energy Materials and Solar Cells*, vol. 95, no. 2, pp. 586–594, Feb. 2011, doi: 10.1016/j.solmat.2010.09.023.

[Kau,03] N. D. Kaushika and N. K. Gautam, (2003) "Energy yield simulations of interconnected solar PV arrays," *Energy Conversion, IEEE Transactions on*, vol. 18, pp. 127-134.

[Kim,06] I.S. Kim, M.-B. Kim and M.-J. Youn, (2006) "New Maximum Power Point Tracker Using Sliding-Mode Observer for Estimation of Solar Array Current in the Grid-Connected Photovoltaic System," *Industrial Electronics, IEEE Transactions on*, vol. 53, pp. 1027-1035.

[Kad,12] R. Kadri, H. Andrei, J.-P. Gaubert, T. Ivanovici, G. Champenois, and P. Andrei, (2011) "Modeling of the photovoltaic cell circuit parameters for optimum connection model and real-time emulator with partial shadow conditions," *Energy*, vol. 42, no. 1, pp. 57–67.

[Kou, 10] Y. Kourd, N. Guersi, and D. Lefebvre, (2010) "Neuro-fuzzy approach for default diagnosis: Application to the DAMADICS," 2010, doi: 1109/DEST.2010.5610663.

[Kou,12] Y. Koud (2012), "Génération des résidus par les outils de l'intelligence artificielle pour le diagnostic des systèmes complexes", Thèse de Doctorat en science en Électronique option Automatique, Université de badj Mokhtar ,Annaba, Algérie ,2011-2012.

[Khe ,15] R. Khenfer (2015), "Détection et isolation de défauts combinant des méthodes à base de données appliquées aux systèmes électro-énergétique ", Thèse Doctorat en Science option Automatique, Université de Ferhat Abbas, Setif1, Algérie ,2015.

[Li,09] C.-H. Li, X.-J. Zhu, G.-Y. Cao, S. Sui and M.-R. Hu, (2009) "Dynamic modeling and sizing optimization of stand-alone photovoltaic power systems using hybrid energy storage technology," *Renewable Energy*, vol. 34, pp. 815-826.

[Maq, 97] D. Maquin ,V. Cocquempot ,J.P. Cassar, M. Staroswiecki. & J. Ragot , (1997) "Generation of analytical redundancy relations for FDI purposes", *IEE Int. Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives, SDEMPED'97*, Carry-le Rouet, France, pp. 270-276, September 1-3rd.

[Mok, 08] H. T. Mok & C. W. Chan., (2008) "Online fault detection and isolation of nonlinear systems based on neurofuzzy networks", *Engineering Applications of Artificial Intelligence*, vol. 21, no. 2, pp. 171–181.

[Mey,04] E. L. Meyer and E. E. v. Dyk, (2004) "Assessing the Reliability and Degradation of Photovoltaic Module Performance Parameters," *IEEE TRANSACTIONS ON RELIABILITY*, vol. 53, pp. 83-92.

[Mel, 13] A. Mellit, S. Sağlam, and S. A. Kalogirou, (2013) “Artificial neural network-based model for estimating the produced power of a photovoltaic module,” *Renewable Energy*, vol. 60, pp. 71–78, Dec. 2013, doi: 10.1016/j.renene.2013.04.011.

[Nor, 00] M. Norgaard, O. Rav, N. K. Poulsen, and L. K. Hansen, (2000) “Neural networks for modelling and control of dynamic systems,” in *A Practitioner’s Handbook*, London: Springer, 2000, p. 246.

[Nel, 01] O. Nelles, “Nonlinear Dynamic System Identification, (2001)” in *Nonlinear System Identification*, Berlin, Heidelberg: Springer Berlin Heidelberg, 2001, pp. 547–577.

[Nar, 90] K. S. Narendra and K. Parthasarathy, (1990) “Identification and control of dynamical systems using neural networks,” *IEEE Transactions on Neural Networks*, vol. 1, no. 1, pp. 4–27, Mar. 1990, doi: 10.1109/72.80202.

[Pat, 89] R.J. Patton, P.M. Frank & R.N. Clark. (1989) "*Fault diagnosis in dynamic systems: theory and application*". International Series in Systems and Control Engineering. Prentice Hall, Englewood Cliffs. New Jersey, USA.

[Par, 04] M. Parizeau, (2004) "*Réseaux de Neurones GIF-21140 et GIF-64326*", Université de Laval.

[Pvp,98] PVPS, (1998) "Utility aspects of grid connected photovoltaic power systems," Report IEA PVPS T5-01.

[Pet,09] S. Petibon, (2009) “Nouvelles architectures distribuées de gestion et conversion de l’énergie pour les applications photovoltaïques.” These Doctorat. Université Paul Sabatier-Toulouse III.

[Roy,10] S. Roy Chowdhury and H. Saha, (2010) “Maximum power point tracking of partially shaded solar photovoltaic arrays,” *Sol. Energy Mater. Sol. Cells*, vol. 94, no. 9, pp. 1441–1447, Sep. 2010.

[Ril, 12] D. Riley and J. Johnson, (2012) “Photovoltaic prognostics and health management using learning algorithms,” in 2012 38th IEEE Photovoltaic Specialists Conference, Jun. 2012, pp. 001535–001539, doi: 10.1109/PVSC.2012.6317887.

[Ros,11] R. Toscano (2011), "Commande et diagnostic des systèmes dynamique", *Automatique*, Technosup, Ellipses, pp 189-278, 2011.

[Sob,09] S. Sobhani-Tehrani, K. Khorasani. (2009) "*Fault Diagnosis of Nonlinear Systems Using a Hybrid Approach*". Lecture Notes in Control and Information Sciences 383, Springer, 2009.

[Sre, 93] F. Sreedhar, B. Fernandez. & Masada G. Y. (1993) "Robust Fault Detection in Nonlinear Systems Using Sliding Mode Observers", *IEEE Conference on Control Applications*, September 13-16, Vancouver, Canada.

[Sur,86] H. E. Suryanto, S. R. Wenham, and M. A. Green, (1986.) "Shadow tolerance of modules incorporating integral bypass diode solar cells," *Solar Cells*, vol. 19, pp. 109-122.

[Ser,09] D. Sera,(2009) “Real-time modelling, diagnostics and optimised MPPT for residential PV systems.” These Doctorat .Aalborg University.

[Spa, 15] S. Spataru, D. Sera, T. Kerekes, and R. Teodorescu,(2015) “Diagnostic method for photovoltaic systems based on light I–V measurements,” *Solar Energy*, vol. 119, pp. 29–44, Sep. 2015, doi: 10.1016/j.solener.2015.06.020.

[Sko,09] E. Skoplaki and J. A. Palyvos,(2009) “On the temperature dependence of photovoltaic module electrical performance: a review of efficiency/power correlations,” *Solar Energy*, vol. 83, no. 5, pp. 614–624, May 2009, doi: 10.1016/j.solener.2008.10.008.

[Tsa,08] H.L. Tsai, C.-S. Tu, and Y.-J. Su,(2008) “Development of generalized photovoltaic model using MATLAB/SIMULINK,” in *Proceedings of the world congress on Engineering and computer science*, vol. 2008, pp. 1–6.

[Ven, 03] V, Venkatasubramanian , R, Rengaswamy , K, Yin . & S,N ,Kavuri, (2003) "A review of process fault detection and diagnosis Part I: Quantitative model-based methods", *Computers and Chemical Engineering*, 27, pp. 293-311.

[Zwi, 95] G, Zwingelstein, (1995) "Diagnostic des Défaillances Théorie et Pratique pour les Systèmes Industriels", Editions Hermès.

[Zwi, 95] G, Zwingelstein, (1995) "Diagnostic des Défaillances Théorie et Pratique pour les Systèmes Industriels", Editions Hermès.

[Zha, 08] J, Zhao , J, Huang , & W, Sun , (2008) "On-line early fault detection and diagnosis of municipal solid waste incinerators", *Waste Management*, vol. 28, no. 11, pp. 2406–2414.

[Zue,06] A. O. Zue and A. Chandra, (2006)"Simulation and stability analysis of a 100 kW grid connected LCL photovoltaic inverter for industry," in *Power Engineering Society General Meeting*, 2006. IEE, p. 6 pp.

[Zou,16] F, Zaoui (2016),"Utilisation des énergies renouvelables influence de la température sur les performances du module PV", Thèse de Doctorat LMD, option gestion de l'énergie , Université Mohamed khider Biskra , Algérie ,2016.