



HAL
open science

Aide à la décision pour le diagnostic des défauts pour une maintenance proactive dans un générateur photovoltaïque

Wendpuiре Ousmane Compaore

► To cite this version:

Wendpuiре Ousmane Compaore. Aide à la décision pour le diagnostic des défauts pour une maintenance proactive dans un générateur photovoltaïque. Automatique / Robotique. Normandie Université; Université Joseph Ki-Zerbo (Ouagadougou, Burkina Faso), 2023. Français. NNT : 2023NORMR095 . tel-04471783

HAL Id: tel-04471783

<https://theses.hal.science/tel-04471783>

Submitted on 21 Feb 2024

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

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



Normandie Université



THÈSE

Pour obtenir le diplôme de doctorat

Spécialité **AUTOMATIQUE, SIGNAL, PRODUCTIQUE, ROBOTIQUE**

Préparée au sein de l'**Université de Rouen Normandie**

En cotutelle internationale avec l'**Université Joseph Ki-Zerbo, BURKINA FASO**

Aide à la décision pour le diagnostic des défauts pour une maintenance proactive dans un générateur photovoltaïque

Présentée et soutenue par
WENDPUIRE OUSMANE COMPAORE

Thèse soutenue le 19/12/2023

devant le jury composé de :

MME MIHAELA BARREAU	Maître de Conférences HDR - UNIVERSITE ANGERS	Rapporteur du jury
M. MOHAND DJEZIRI	Maître de Conférences HDR - Aix-Marseille université	Rapporteur du jury
M. MAAN EL BADAOUI EL NAJJAR	Professeur des Universités - UNIVERSITE LILLE 1 SCIENCES ET TECHNOLOGIE	Membre du jury
M. FRANÇOIS ZOUGMORE	Professeur des Universités - Université Joseph Ki-Zerbo	Président du jury
M. GHALEB HOBLOS	Maître de Conférences HDR - ESIGELEC ROUEN	Directeur de thèse
M. ZACHARIE KOALAGA	Professeur des Universités - Université Joseph Ki-Zerbo	Co-directeur de thèse

Thèse dirigée par **GHALEB HOBLOS** (INSTITUT DE RECHERCHE EN SYSTEMES ELECTRONIQUES EMBARQUES) et **ZACHARIE KOALAGA** (Université Joseph Ki-Zerbo)

COTUTELLE DE THÈSE

Pour obtenir le diplôme de doctorat

Spécialité : AUTOMATIQUE, SIGNAL, PRODUCTIQUE, ROBOTIQUE

Préparée au sein de Normandie Université et Université Joseph KI-ZERBO

Aide à la décision pour le diagnostic des défauts pour une maintenance proactive dans un Générateur Photovoltaïque

Présentée et soutenue par

Wendpuiré Ousmane COMPAORÉ

Thèse soutenue publiquement à Rouen le 19/12/2023

devant le jury composé de

M. MOHAND DJEZIRI	IM2NP, Aix-Marseille Université	Rapporteur
Mme MIHAELA BARREAU	LARIS, Polytech'Angers, Angers	Rapporteur
M. FRANÇOIS ZOUGMORE	LAME, UJKZ, Ouagadougou	Président
M. MAAN EL BADAOUI EL NAJJAR	CRYStAL, Université de Lille	Examineur
M. GHALEB HOBLOS	IRSEEM, Normandie Université	Co-Directeur
M. ZACHARIE KOALAGA	LAME, UJKZ, Ouagadougou	Co-Directeur

Thèse dirigée par GHALEB HOBLOS et ZACHARIE KOALAGA, IRSEEM Rouen et LAME Ouagadougou

UNIVERSITÉ JOSEPH KI-ZERBO

École Doctorale Sciences et Technologies



Laboratoire de Matériaux et Environnement
(LAME)

N° d'ordre : ...

THÈSE

Présentée par **Wendpuiré Ousmane COMPAORE**

Pour obtenir le grade de

DOCTEUR DE L'UNIVERSITÉ JOSEPH KI-ZERBO

Mention : **Physique Appliquées**

Spécialité : **Automatique, Signal et Informatique Industrielle**

TITRE DE LA THÈSE

«Aide à la décision pour le diagnostic des défauts pour une maintenance proactive dans un Générateur Photovoltaïque»

Soutenu publiquement le 19 décembre 2023 devant le jury composé de :

Nom et Prénom	Titre/Institution	Rôle
-Pr François ZOUGMORE	Professeur Titulaire, UJKZ Burkina Faso	Président
-Pr Mohand DJEZIRI	Professeur Habilité, Université Aix-Marseille, France	Rapporteur
-Pr Mihaela BARREAU	Professeur Habilité, Université d'Angers, France	Rapporteur
-Pr Maan EL BADAOUI EL NAJJAR	Professeur Titulaire, Université de Lille, France	Examineur
-Pr Ghaleb HOBLOS	Professeur Habilité, Université de Rouen en France	Co-Directeur de thèse
-Pr Zacharie KOALAGA	Professeur Titulaire, UJKZ Burkina Faso	Co-Directeur de thèse

Dédicace

A ma mère,
A ma tendre épouse,
A mes rayons de soleil.

Remerciements

C'est avec un grand plaisir que je réserve ces quelques lignes en signe de gratitude et de profonde reconnaissance à toutes celles et à tous ceux qui, de près ou de loin, ont contribué à la réussite de mes travaux de thèse en Cotutelle, effectués en collaboration entre le Laboratoire Matériaux et Environnements (LAME) de l'Université Joseph Ki-Zerbo de Ouagadougou au Burkina Faso et l'Institut de Recherche en Systèmes Electroniques Embarqués (IRSEEM) de l'ESIGELEC à Rouen en France.

Je tiens à exprimer ma très vive reconnaissance à l'endroit des professeurs Ghaleb HOBLOS, Enseignant-Chercheur, HDR et Chef du département Génie Electrique et Energie au sein d'ESIGELEC et Zacharie KOALAGA, Enseignant-Chercheur, Professeur Titulaire et directeur du Laboratoire Matériaux et Environnement (LAME) au sein de l'Université Joseph KI-ZERBO (UJKZ), mes deux directeurs de thèse, pour leurs qualités pédagogiques et scientifiques d'une part, mais surtout pour leurs encouragements incessants. Je les remercie surtout pour leur confiance sans cesse renouvelée durant ces cinq années de thèse. Vos conseils, suggestions et aides multiformes ont été les plus utiles pour l'aboutissement de ce travail.

J'exprime aussi ma gratitude à l'ensemble des présidents, vices présidents ainsi que tous mes directeurs et chefs de département, pour leur flexibilité, face à mes multiples absences ou les heures non effectuées durant les périodes les plus difficiles, mais surtout pour leur confiance accordée durant ces cinq années de thèse.

J'adresse toute ma reconnaissance à Madame Mihaela BARREAU, Professeure au laboratoire LARIS à Polytech'Angers de l'Université d'Angers, Monsieur Mohand DJEZIRI, Professeur au laboratoire IM2NP à l'Université d'Aix-Marseille et Monsieur Oumarou SIE, Professeur au Laboratoire de Mathématique et Informatique (LAMI) de l'UJKZ, d'avoir accepté d'être rapporteurs de cette thèse. Je les remercie vivement de leur lecture approfondie du manuscrit de thèse, de leurs remarques constructives et fort enrichissantes.

Je remercie profondément Monsieur Maan EL BADAoui EL NAJJAR, Professeur au laboratoire CRYStAL de l'Université de Lille d'avoir promptement accepté de participer à ce jury en tant qu'examineur de cette thèse.

J'exprime mes sincères remerciements à Monsieur François ZOUGMORE, Professeur Titulaire au laboratoire LAME de l'Université Joseph KI-ZERBO, d'avoir accepté de présider ce jury de thèse.

Mes remerciements vont également à tous les membres du LAME, de l'IRSEEM, plus particulièrement au pôle Automatique et Signal, et au service support d'ESIGELEC.

Je suis reconnaissant envers les amis, collègues et simples anonymes des deux Laboratoires pour qui j'ai beaucoup d'amitié. Je les remercie particulièrement pour la sympathie dont ils m'ont constamment témoignée. Je leur exprime ici toute ma gratitude.

Enfin, j'exprime ma profonde gratitude à ma famille et à toutes ces personnes sans l'aide desquelles, je ne me serais pas si bien intégré en Normandie. En attendant des jours meilleurs sur le plan sécuritaire, je vous donne rendez-vous dès que possible, au Burkina pour découvrir quelques pans de la culture, du tourisme mais surtout de la légendaire tradition d'hospitalité de ce beau pays.

- a : le coefficient d'idéalité de la diode ;
 a_i : le coefficient directeur ;
 AM : le nombre d'air-masse ;
 b_0 : le biais du neurone artificiel ;
 b_i : la pente ;
 C_0, C_1, C_2, C_3 : les coefficients déterminés expérimentalement ;
 e : l'erreur finale de sortie du PMC ;
 E_g : 1,12 eV pour le silicium cristallin est le gap du matériau utilisé ;
 f_1 : la fonction du nombre d'air-masse ;
 f_2 : la fonction de l'angle d'incidence du rayonnement sur le module PV ;
 f_j^i : la fonction d'activation du neurone j de la couche cachée i ;
 $f_{\theta_a^i}$ et $f_{\theta_b^j}$: les estimés de la première et de la seconde fenêtre ;
 G : l'ensoleillement actuel ;
 G_n : l'ensoleillement nominal à 1000 W/m^2 ;
 $g(t)$: la fonction de détection de l'instant de changement ;
 h : le seuil de détection à définir ;
 I : l'intensité qui traverse le capteur de courant [A] ;
 $I = I_c$: le courant fourni par la cellule PV ;
 I_G : le courant du générateur ou champ PV ;
 \hat{I}_G : la mesure du capteur de courant ;
 I_{MP_r} : le courant du point de puissance maximale de référence [A] ;
 I_{phn} : le courant nominal de la cellule PV, donné dans les conditions nominales $T = 25^\circ\text{C}$ et $G = 1000 \text{ W/m}^2$;
 I_{scn} : le courant de court-circuit nominal aux conditions de test standard 25°C et 1000 W/m^2 ;
 I_{scr} : le courant de court-circuit de référence [A] ;
 I_{stgi} : le courant du string i ;
 \hat{I}_{stgi} : la mesure du courant du string i par un capteur ;
 k_b : la constante de Boltzmann ;
 K_i : le coefficient courant/température de court-circuit ;
 K_v : le coefficient de tension/température de circuit ouvert ;

N_c : le paramètre d'ajustement, est égal à 36 cellules en série par exemple pour un module PV parfait ;
 N_{Cell} : le nombre de cellules raccordées en sérié ;
 N_p : le nombre de string raccordés en parallèle ;
 N_s : le nombre de Modules raccordés en sérié ;
 P_{cd} : la probabilité de détection correcte ;
 $Perf$: la performance en pourcentage ;
 P_{fa} : la probabilité de fausse alarme ;
 P_G : la puissance du générateur PV ;
 P_m : la puissance du module ;
 $P_r(h)$: la précision de la détection ;
 P_{stg} : la puissance du string ;
 $P_1, P_2, P_3, \text{ et } P_4$: les paramètres à déterminer expérimentalement ;
 q : la charge de l'élection ;
 R_s : la résistance série de la cellule qui dépend des matériaux utilisés pour construire la cellule et dont l'effet est plus grand dans la région de fonctionnement en source de tension ;
 R_{sh} : La résistance shunt dont l'effet est plus grand dans la région de fonctionnement en source de courant ;
 $S_e(h)$: le taux de bonnes détections ;
 S_h : la sortie du PMC ;
 $S_p(h)$: le taux de bonnes non détections ;
 T : la température actuelle ;
 T_n : la température nominale à $25^\circ C$;
 T_c : respectivement la température de la cellule en [K] ;
 T_r : la température de référence en [K] ;
 T_j : la température de jonction du capteur PV [K] ;
 T_{ref} : la température de référence [K] ;
 V : la tension aux bornes du capteur de tension [V] ;
 V_c : la tension aux bornes de la cellule PV ;
 V_G : la tension aux bornes du générateur ou champ PV ;
 \hat{V}_G : la mesure du capteur de tension ;
 V_m : la tension aux bornes du module PV ;
 V_{M_jstgi} : la tension du module M_j du string i ;
 V_{stgi} : la tension du string i ;
 V_{MPr} : la tension du point de puissance maximale de référence [V] ;
 V_{ocn} : la tension de circuit ouvert nominal ;
 V_{ocr} : la tension de circuit-ouvert de référence [V] ;
 w_i : le poids du neurone i ;
 $w_{j,m}^i$: le poids de la connexion entre les neurones j de la couche i et m de la couche cachée ($i - 1$) ;
 β : l'angle d'incidence entre le rayonnement direct du soleil et la normale au plan du module PV ;
 ϵ_{I_G} : le bruit de mesure du capteur de courant ;

$\epsilon_{I_{stgi}}$: le bruit de mesure du courant du string i ;

ϵ_{V_G} : le bruit de mesure du capteur de tension ;

μ_{IMP} : le coefficient de dépendance en température du courant de puissance maximale [A/K] ;

$\mu_{I_{sc}}$: le coefficient de dépendance en température du courant de court-circuit [A/K] ;

$\mu_{V_{MP}}$: le coefficient de dépendance en température de la tension de puissance maximale [V/K] ;

$\mu_{V_{oc}}$: le coefficient de dépendance en température de la tension de circuit-ouvert [V/K] ;

η : le taux d'apprentissage du PMC.

Abréviations et sigles

Ordre	Sigle	Désignations
A	AC	Alternative Current
	ACP	Analyse en Composante Principale
	Adaline	ADApive LINear Element
	AdD	Arbres de Défaillances
	AdE	Arbre d'Evènements
	AI	Artificial Intelligence
	AMDE	Analyse des Modes de Défaillance et de leurs Effets
	AMDEC	Analyse des Modes de Défaillance et de leurs Effets et de leurs Criticités
	ANN	Artificial Neuronal Network
	API	Application Programming Interface
	ARR	Analytic Redundancy Relation
	ART	Adaptive Resonance Theory
	ARTMap	Adaptive Resonance Theory Map
B	ASC	Aire Sous la Courbe
	BG	Bond Graphs
	BLE	Bluetooth LowEnergy
C	BP	Back Propagation
	CAOK	Cartes Auto-Organisatrices de Kohonen
	CISCO	Computer Information System Company
	CoAP	Constrained Application Protocol
	COR	Caractéristiques Opérationnelles de Réception
	CPU	Central Processing Unit
D	CSV	Comma Separated Values
	DC	Direct Current
F	DCS	Dynamic Cumulative Sum
	FDI	Fault Detection and Identification
G	GHz	Giga Hertz
	GPIO	General Purpose Input/Output

Ordre	Sigle	Désignations
	GPV	Générateur PhotoVoltaïque
	GSM	Global System for Mobile Communications
H	HAZOP	HAZard and OPerability
	HTTP	HyperText Transfer Protocol
I	I2C	Inter-Integrated Circuit
	IA	Intelligence Artificielle
	IDE	Integrated Development Environment
	IdO	Internet Des Objets
	IEEE	Institute of Electrical and Electronics Engineers
	IIoT	Industrial Internet of Things
I	IoT	Internet of Things
	IP	Internet Protocol
	IPV4	Internet Protocol version 4
	IPV6	Internet Protocol version 6
	ITU	International Telecommunication Union
J	JTAG	Joint Test Action Group
	LCD	Liquid Crystal Display
L	LM	Levenberg-Marquardt
	LVQ	Learning Vector Quantization
M	MAC	Media Access Control
	MLP	Multi-Layer Perceptron
	MSE	Mean Square Error
N	NFC	Near Field Communication
P	PIN	Personal Identification Number
	PID	Potential Induced Degradation
	PMC	Perceptron Multi Couches
	PWM	Pulse Wilde Modulation
Q	QTA	Qualitative Tendance Analysis
R	RAM	Random Acces Memory
	RCSF	Réseau de Capteurs Sans Fil
	RdP	Réseau de Pétri
	RFID	Radio Frequency Identification
	RNA	Réseaux de Neurones Artificiel
	ROM	Read Only Memory
	RRA	Relations de Redondance Analytique
	RTOS	Real Time Operating System
S	SED	Systèmes à Evènements Discrets
	SD	Card Secure Digital Card
	SDK	Software Development Kit
	SDG	Signed Directed Graph
	SIM	Subscriber Identity Module

Ordre	Sigle	Désignations
	SMS	Short Message System
	SOM	Self-Organizing Map
	SSL	Secure Sockets Layer
T	TCP	Transmission Control Protocol
	TCP/IP	Transmission Control Protocol/ Internet Protocol
	TIC	Technologie de l'Information et de Communication
	TLS	Trasport Layer Security
U	UID	Unique IDentifier
	USB C	USB type C
	USB	Universal Serial Bus
V	VPN	Virtual Private Network
	VQ	Vector Quantization
W	WIFI	Wireless Fidelity

Dédicace	i
Remerciements	ii
Notations	iv
Abréviations et Sigles.	vii
Sommaire	x
Liste des figures	xvii
Liste des tableaux	xviii
Résumé	xix
Abstract	xx
Introduction générale	1
1 Etat de l’art sur le diagnostic	4
1.1 Introduction	4
1.2 Position par rapport au diagnostic des GPV	5
1.3 Définitions	6
1.3.1 Défaut	6
1.3.2 Défaillance	6
1.3.3 Panne	7
1.3.4 Symptôme	7
1.3.5 Résidu	7
1.3.6 Signature	7
1.3.7 Mode de fonctionnement	7
1.3.8 Diagnostic	8
1.4 Surveillance, Supervision et Diagnostic	8

1.5	Critères de performance d'un système de diagnostic	9
1.6	Classification des méthodes de diagnostic	10
1.6.1	Méthodes sans modèles	10
1.6.2	Méthodes basées sur les modèles quantitatifs	12
1.6.3	Méthodes basées sur les modèles qualitatifs	14
1.7	Choix d'une méthode de diagnostic	15
1.8	Conclusion	16
2	Modélisation du générateur photovoltaïque	18
2.1	Introduction	18
2.2	Production photovoltaïque	19
2.2.1	Cellules photovoltaïques	19
2.2.2	Effet photovoltaïque	19
2.2.3	Caractéristique électrique d'une cellule photovoltaïque	20
2.3	Modélisation électrique d'une cellule photovoltaïque	21
2.3.1	Modèle standard	22
2.3.2	Modèle à une diode	23
2.3.3	Modèle à deux diodes	23
2.3.4	Modèle de Bishop	24
2.4	Modélisation mathématique du GPV	25
2.4.1	Modèle de Sandia	25
2.4.2	Modèle du Cenerg	26
2.4.3	Modèle de Madison.	27
2.5	Choix du modèle de la cellule PV	27
2.6	Synoptique d'un système photovoltaïque	28
2.6.1	Générateur PV	28
2.6.2	De la cellule au Module PV	28
2.6.3	Du module aux strings de module PV	31
2.6.4	Du string au générateur PV	32
2.6.5	Fonctionnement au point MPPT	33
2.7	Interconnexion et jonction	34
2.8	Système de protection	34
2.8.1	Diode de bypass	34
2.8.2	Diode anti retour	34
2.9	Défauts dans le système photovoltaïque	35
2.9.1	Chaîne fonctionnelle d'un SPV	36
2.9.2	Classification des défauts et d'anomalies d'un champ PV	38
2.9.3	Impact des différents défauts sur la courbe de la caractéristique	38
2.10	Modes de dégradation des modules PV	44
2.10.1	Corrosion	44
2.10.2	Délamination	45
2.10.3	Décoloration	45
2.10.4	Fissures et les bris de verre	45
2.10.5	Points chauds ou hotspot	45

2.10.6	Bulles	46
2.10.7	PID ou Potential Induced Degradation	46
2.10.8	Modèle de dégradation des modules PV	46
2.11	Conclusion	47
3	Diagnostic de défauts capteurs par relation de redondance analytique	48
3.1	Introduction	48
3.2	Définitions	49
3.3	Caractérisation de défauts	50
3.4	Différents types de défauts	51
3.5	Diagnostic par analyse des relations de redondance	52
3.5.1	Synoptique de génération de résidus	54
3.5.2	Localisation des défauts	54
3.5.3	Prise de décision : évaluation des résidus	55
3.5.4	Méthode de l'espace de parité	56
3.6	Déteçtabilité par la DCS	58
3.7	Analyse de la performance par la méthode de la courbe COR	60
3.7.1	Sensibilité	61
3.7.2	Spécificité	61
3.7.3	Précision	61
3.7.4	Courbe COR	61
3.7.5	Mesure de performance	63
3.8	Application au cas du GPV	63
3.8.1	Modélisation	63
3.8.2	Génération de résidus	64
3.8.3	Détection et localisation	66
3.9	Résultats et interprétation	67
3.9.1	Cas d'un défaut de 2 A	67
3.9.2	Cas d'un défaut de 10 A	68
3.10	Conclusion	68
4	Diagnostic par intelligence artificielle	73
4.1	Introduction	73
4.2	Du neurone au réseau de neurone	74
4.3	Modèle et Topologie	78
4.3.1	Réseaux de neurones non bouclés « Feed Forward »	78
4.3.2	Réseaux de neurones bouclés « Feed-Back »	79
4.4	Mode d'apprentissage	79
4.4.1	Algorithme d'apprentissage supervisé	79
4.4.2	Apprentissage non supervisé	79
4.4.3	Apprentissage semi-supervisé	79
4.5	Configuration du RNA pour le GPV	80
4.5.1	Classification pour la détection	81
4.5.2	Classification pour le diagnostic	93

4.6	Conclusion	105
5	Prototype d'IIoT d'acquisition temps réel pour un GPV	112
5.1	Introduction	112
5.2	Conception du système d'acquisition temps réel sur la base d'un IIoT	113
5.3	Différents composants du système d'IIoT	115
5.4	Assemblage du premier prototype à base d'une Arduino	118
5.5	Assemblage du second prototype à base d'un ESP 32 Wrover	120
5.6	Application au diagnostic par la méthode de l'espace de parité	123
5.6.1	Pour une largeur de fenmax = 20	124
5.6.2	Pour une largeur de fenmax = 50	125
5.6.3	Synthèse de l'application de la méthode de l'espace de parité	126
5.7	Application au diagnostic par la méthode des RNA	126
5.7.1	Classification pour la détection avec les données d'acquisition	126
5.7.2	Classification pour le diagnostic avec les données d'acquisition	128
5.7.3	Synthèse de l'application de la méthode des RNA	130
5.8	Conclusion	131
	Conclusion générale et perspectives	135
	Production scientifique	137
	Bibliographie	138

Table des figures

1.1	Différents types de défauts d'un processus physique.	6
1.2	Interaction entre Surveillance, Diagnostic et Supervision [Hernandez 2007].	8
1.3	Structure d'un système de diagnostic à base de modèle [Maquin et al. 2000].	9
1.4	Classification des méthodes de diagnostic [Haithem 2009].	11
1.5	Structure générale d'un système expert [Chebira 2021].	12
1.6	Principe de diagnostic basé sur la génération des résidus.	13
2.1	Demande d'énergie du type PV en fonction des années [Hemetsberger 2023].	18
2.2	Schéma d'une jonction PN sous l'effet des photons.	20
2.3	Caractéristique I-V complète d'une cellule PV.	21
2.4	Circuit électrique équivalent d'une cellule PV standard.	22
2.5	Circuit électrique équivalent d'une cellule PV à une diode.	23
2.6	Circuit électrique équivalent d'une cellule PV à deux diodes.	23
2.7	Circuit électrique équivalent du modèle de Bishop d'une cellule PV.	24
2.8	Synoptique électrique d'un système PV.	29
2.9	Cellules regroupées dans un module, protégées par une diode de bypass.	29
2.10	Caractéristiques de 9, 18 et 36 cellules mis en série.	30
2.11	Mise en série de 36 cellules protégées par deux diodes de bypass.	30
2.12	Module PV avec deux diodes de bypass en overlap.	31
2.13	Caractéristiques de modules placés en série.	31
2.14	GPV de plusieurs strings avec des modules PV organisé en 36 cellules.	32
2.15	GPV matérialisé au point MPPT.	33
2.16	Protection d'un générateur par diode de bypass et diode anti retour.	35
2.17	Chaîne fonctionnelle d'un système PV.	37
2.18	GPV avec des modules de 36 cellules avec variation de R_s	40
2.19	GPV avec des modules de 36 cellules avec variation de R_{sh}	41
2.20	GPV avec des modules de 36 cellules avec variation de T	41
2.21	GPV avec des modules de 36 cellules avec variation de G	42
2.22	Défaut de la diode de bypass.	43
2.23	Défaut du module.	43

2.24	Défaut de connectique.	43
2.25	Défaut de diode anti retour.	44
3.1	Classification en (a, b, c) et modélisation en (d, e) des défauts.	51
3.2	Différents types de défauts.	51
3.3	Principe de diagnostic.	53
3.4	Logique de diagnostic.	54
3.5	Synoptique de diagnostic par la méthode de l'espace de Parité.	54
3.6	Principe de détection basé sur deux fenêtres glissantes [Mustapha et al. 2008] . .	59
3.7	Courbe COR.	62
3.8	Synoptique d'instrumentation des capteurs pour le GPV.	63
3.9	Position du MPPT du PGV par rapport aux caractéristiques I-V et P-V.	64
3.10	Synoptique de la méthode de l'espace de parité du GPV.	65
3.11	Traitement des 5 résidus pour un défaut d'amplitude 2A.	70
3.12	Localisation et courbe COR pour un défaut d'amplitude 2A.	71
3.13	Localisation et courbe COR pour un défaut d'amplitude 10A.	71
3.14	Traitement des 5 résidus pour un défaut d'amplitude 10A.	72
4.1	Neurone biologique.	75
4.2	Modèle du neurone artificiel.	76
4.3	Différents types de fonctions de transfert pour le neurone artificiel.	76
4.4	Exemple d'un PMC.	77
4.5	Configuration des RNA pour la détection.	82
4.6	Conséquence de la variation de T sur les données P, V et I pour la détection. . .	83
4.7	Performances du RNA de défaut T avec des données liées à P.	84
4.8	Performances du RNA de défaut T avec des données liées à V.	84
4.9	Performances du RNA de défaut T avec des données liées à I.	85
4.10	Conséquence de la variation de G sur les données P, V et I pour la détection. . .	86
4.11	Performances du RNA de défaut G avec des données liées à P.	86
4.12	Performances du RNA de défaut G avec des données liées à V.	87
4.13	Performances du RNA de défaut G avec des données liées à I.	87
4.14	Conséquence de la variation de R_s sur les données P, V et I pour la détection. . .	88
4.15	Performances du RNA de défaut R_s avec des données liées à P.	89
4.16	Performances du RNA de défaut R_s avec des données liées à V.	89
4.17	Performances du RNA de défaut R_s avec des données liées à I.	90
4.18	Conséquence de la variation de R_{sh} sur les données P, V et I pour la détection. .	91
4.19	Performances du RNA de défaut R_{sh} avec des données liées à P.	91
4.20	Performances du RNA de défaut R_{sh} avec des données liées à V.	92
4.21	Performances du RNA de défaut R_{sh} avec des données liées à I.	92
4.22	Caractéristique I-V en mode sain (noire) et mode dégradé (rouges).	95
4.23	Configuration RNA pour le diagnostic en fonction du nombre de couches cachées. .	98
4.24	Conséquence de la variation de T sur les données P, V et I pour le diagnostic. . .	99
4.25	Performances du RNA de 2 couches cachées pour un défaut de température. . . .	100
4.26	Performances du RNA de 5 couches cachées pour un défaut de température. . . .	100

4.27 Performances du RNA de 10 couches cachées pour un défaut de température. . .	101
4.28 Performances du RNA de 20 couches cachées pour un défaut de température. . .	101
4.29 Conséquence de la variation de G sur les données P, V et I pour le diagnostic. . .	102
4.30 Performances du RNA de 2 couches cachées pour un défaut d'ensoleillement. . .	103
4.31 Performances du RNA de 5 couches cachées pour un défaut d'ensoleillement. . .	104
4.32 Performances du RNA de 10 couches cachées pour un défaut d'ensoleillement. . .	105
4.33 Performances du RNA de 20 couches cachées pour un défaut d'ensoleillement. . .	106
4.34 Conséquence de la variation de R_s sur les données P, V et I pour le diagnostic. . .	106
4.35 Performances du RNA de 2 couches cachées d'un défaut de résistance série. . . .	107
4.36 Performances du RNA de 5 couches cachées d'un défaut de résistance série. . . .	107
4.37 Performances du RNA de 10 couches cachées d'un défaut de résistance série. . .	108
4.38 Performances du RNA de 20 couches cachées d'un défaut de résistance série. . .	108
4.39 Conséquence de la variation de R_{sh} sur les données P, V et I pour le diagnostic. .	109
4.40 Performances du RNA de 2 couches cachées d'un défaut de résistance shunt. . . .	109
4.41 Performances du RNA de 5 couches cachées d'un défaut de résistance shunt. . . .	110
4.42 Performances du RNA de 10 couches cachées d'un défaut de résistance shunt. . .	110
4.43 Performances du RNA de 20 couches cachées d'un défaut de résistance shunt. . .	111
5.1 Dimensions de l'IoT.	113
5.2 Synoptique d'acquisition temps réel du prototype 1.	114
5.3 Synoptique d'acquisition temps réel du prototype 2.	114
5.4 Capteur de courant ACS70331.	115
5.5 Capteur de courant ACS725.	115
5.6 Capteur de tension Phidgets P/N 1135.	116
5.7 Capteur de température AHT10.	116
5.8 Capteur de luminosité VEML7700.	116
5.9 Module RTC Clock.	117
5.10 Module d'affichage LCD 4*20 caractères.	117
5.11 Module carte SD.	117
5.12 Module solaire WBL 1.6.	118
5.13 Exemple de carte à microcontrôleur.	118
5.14 Schéma électronique avec la carte Arduino Uno.	119
5.15 Assemblage électronique du premier prototype.	119
5.16 Capture d'écran du contenu de la carte SD.	120
5.17 Schéma électronique avec la carte ESP32 Wrover.	120
5.18 Assemblage électronique avec la carte ESP32 Wrover.	121
5.19 Capture d'écran de la transmission sur le Server web 192.168.15.153.	122
5.20 Données au format CSV.	122
5.21 Données au format .mat exploitées sous Matlab.	122
5.22 Traitement des résidus avec fenmax = 20.	124
5.23 Traitement des résidus avec fenmax = 50.	125
5.24 Performances du RNA pour la détection avec les données d'acquisition de P. . . .	127
5.25 Performances du RNA pour la détection avec les données d'acquisition de V. . .	128
5.26 Performances du RNA pour la détection avec les données d'acquisition de I. . . .	128

5.27	Configuration RNA en fonction des couches cachées pour des données réelles. . .	130
5.28	Performances du RNA de 2 couches cachées pour des données réelles.	131
5.29	Performances du RNA de 5 couches cachées pour des données réelles.	132
5.30	Performances du RNA de 10 couches cachées pour des données réelles.	133
5.31	Performances du RNA de 20 couches cachées pour des données réelles.	134

Liste des tableaux

2.1	Défauts et anomalies d'un générateur PV.	36
2.2	Comparaison des méthodes de diagnostic.	37
2.3	Relation entre anomalies et défauts d'un générateur PV.	39
2.4	Relations entre défaut et paramètres du générateur PV.	40
2.5	Conséquence d'un défaut de diode de bypass.	43
2.6	Conséquence d'un défaut de de module.	43
2.7	Conséquence d'un défaut de diode anti retour.	44
3.1	Matrice d'occurrence pour le cas de défauts multiples.	56
3.2	Matrice d'occurrence d'un générateur PV.	66
4.1	Analogie entre le neurone artificiel et le neurone biologique.	75
4.2	Différents types d'apprentissages en mode supervisé.	80
4.3	Différents types d'apprentissages en mode non supervisé.	81
4.4	Performance de la classification avec un défaut T.	85
4.5	Performance de la classification avec un défaut G.	88
4.6	Performance de la classification avec un défaut R_s	90
4.7	Performance de la classification avec un défaut R_{sh}	93
4.8	Croisement des défauts et des zones.	96
4.9	Matrice de sortie.	97
4.10	Performance du RNA pour un défaut du type T.	98
4.11	Performance du RNA pour un défaut du type G.	102
4.12	Performance du RNA pour un défaut du type R_s	103
4.13	Performance du RNA pour un défaut du type R_{sh}	104
5.1	Caractéristiques des cartes utilisées.	119
5.2	Paramètres du module PV utilisé.	123
5.3	Matrice d'occurrence de la simulation.	124
5.4	Performances du RNA pour la détection avec les données d'acquisition.	129
5.5	Synthèse de la performance du RNA pour un défaut système.	129

La perte de puissance d'un générateur photovoltaïque (GPV) est sans conteste due à l'apparition d'un certain nombre d'anomalies liées à la fabrication, à la production ou à l'environnement, engendrant des défaillances dans son bon fonctionnement. A partir d'un modèle réaliste, assez proche du fonctionnement réel et capable de prendre en compte l'effet d'avalanche d'une jonction PN transmise à l'ensemble du GPV, nous avons montré à suffisance, la perte de performances d'un générateur PV et la nécessité d'avoir une méthode de diagnostic pour l'aide à la maintenance afin de ne pas subir les effets des défauts.

Deux méthodes de diagnostic ont été appliquées à ce GPV, l'une portant sur la détection et la localisation des défauts capteurs, et l'autre sur la détection et la localisation des défauts systèmes. Le choix particulier de ces deux techniques de diagnostic, qui ne ciblent pas les mêmes types de défauts, réside dans la nature complexe du modèle du processus industriel soumis à l'étude. Les performances obtenues avec la méthode des relations de redondance analytique (RRA) basée sur le principe de l'espace de parité appliqué au point de fonctionnement maximal, sont très pertinentes. Par la méthode de l'intelligence artificielle (IA) basée sur le principe des réseaux de neurones artificiels (RNA), nous avons expérimenté deux méthodes de classification pour la détection et le diagnostic des défauts systèmes. Si la détectabilité est prouvée avec nos différentes configurations sans possibilité de situer l'origine et la cause dans la première partie de la classification, nous arrivons grâce à un faisceau d'indices à situer l'origine ou la cause grâce à la classification pour le diagnostic.

La réalisation de deux prototypes d'acquisition temps réel est faite sur le principe de l'Internet industriel des objets (IIoT). Le premier permet uniquement l'acquisition et la sauvegarde des données sur une carte SD. Le second prototype plus évolué, permet la transmission en temps réel par Wifi à un serveur web et vise la réalisation à long terme d'une plateforme de surveillance en temps réel. Les deux prototypes produisent des données qui sont utilisées pour alimenter les deux méthodes de diagnostic. Les résultats obtenus avec des données réelles sont compatibles avec ceux obtenus en phase de simulation. Les conclusions de ce diagnostic permettront une meilleure efficacité dans les opérations de maintenance proactive.

Mots clés : générateur photovoltaïque, diagnostic, défaut capteur, défaut système, relations de redondance analytique, espace de parité, somme dynamique cumulée, réseau de neurones artificiels, temps réel, Internet industriel des objets.

Abstract

The loss of power of a photovoltaic generator (PVG) is undoubtedly due to the appearance of a certain number of anomalies linked to manufacturing, production or the environment and causing failures in its proper functioning. From a realistic model, quite close to real operation and able to take into account the avalanche effect of a PN junction transmitted to the entire PVG, we have sufficiently shown the loss of performance of a PV generator and the need to have a diagnostic method for maintenance assistance in order not to suffer the effects of faults.

Two diagnostic methods were applied to this PVG, one relating to the detection and localization of sensor faults, and the other to the detection and localization of system faults. The particular choice of these two diagnostic techniques, which do not target the same types of faults, lies in the complex nature of the model of the industrial process subjected to study. The performances obtained with the analytical redundancy relations (ARR), method based on the principle of parity space applied to the maximum operating point are very relevant. Using the artificial intelligence (AI), method based on the principle of artificial neural networks (ANN), we experimented with two classification methods for the detection and diagnosis of system faults. If detectability is proven with our different configurations without the possibility of locating the origin and the cause in the first part of the classification, we arrive thanks to a bundle of clues to locate the origin or the cause thanks to the classification for the diagnostic.

The production of two real-time acquisition prototypes is based on the principle of the Industrial Internet of Things (IIoT). The first only allows the acquisition and saving of data on an SD card. The second, and more advanced prototype, allows real-time transmission via WiFi to a web server and aims to create a real-time monitoring platform in the long term. Both prototypes produce data that is used to power both diagnostic methods. The results obtained with real data are compatible with those obtained in the simulation phase. The conclusions of this diagnosis will enable greater efficiency in proactive maintenance operations.

Key words : photovoltaic generator, diagnosis, sensor fault, system fault, analytical redundancy relations, parity space, dynamic cumulative sum, artificial neural network, real time, industrial Internet of Things.

Introduction générale

Tant en solutions pour les zones éloignées ou isolées que raccordées au réseau comme complément, les sources d'énergie solaire photovoltaïque, s'imposent aujourd'hui comme une vraie alternative aux énergies primaires et non renouvelables pour faire face à la croissance de la demande, au déclin des gisements et au problème de pollution dû aux gaz générés et autres déchets associés à l'extraction et exploitation des énergies fossiles et fissiles. Le soleil en tant que source gratuite et inépuisable d'énergie a accru l'intérêt à développer des techniques nouvelles pour en tirer profit et rendre cette forme d'énergie accessible et facile à maîtriser. Le changement météorologique du cycle jour / nuit, reste un handicap majeur pour la disponibilité de cette forme d'énergie. Cette contrainte impose que, le système de production s'encombre de plusieurs périphériques pour stocker et transformer l'énergie produite [Boukhers 2017, Compaoré et al. 2021 a., Jamil 2023].

Grâce aux fruits de la recherche, de nombreux matériaux ont été développés avec succès, favorisant la maîtrise de la technologie du stockage et l'accessibilité des modules photovoltaïques pour des utilisations diversifiées notamment en zones isolées. Une bonne politique de pénétration a fini par faire le reste quant à la bonne acceptation et vulgarisation des installations à base de modules photovoltaïques.

Cependant, les fabricants des modules photovoltaïques donnent des paramètres de références qui évoluent avec les facteurs extérieurs du site d'implantation notamment la température et l'exposition au soleil [Koester et al. 2022, Malik et al. 2022]. Alors que le changement de ces paramètres étant une réalité en fonction des conditions réelles de fonctionnement des panneaux, il était de bon ton d'identifier la modélisation de la cellule photovoltaïque capable de traduire le comportement réel suivant les anomalies subies par un générateur photovoltaïque [Compaoré et al. 2021 a., Haque et al. 2019, Bishop 1988].

Le générateur photovoltaïque est aussi source de problèmes s'il ne fonctionne pas au point de fonctionnement nominal et optimal. D'origines fort diverses, les anomalies de fonctionnement peuvent être liées à la fabrication, à l'utilisation ou à l'environnement des modules photovoltaïques [Azizi 2018]. On peut citer entre autres :

- la température : la forte augmentation de la température ambiante, engendre de la chaleur source de défaut pour le GPV ;
- la perte de modules PV : la perte de module du champ PV entraîne une modification significative des paramètres du modèle, donc, des performances ;

- la mauvaise connexion : les circuits ouverts ou les courts circuits, entraînent d'énormes pertes de performances dans le GPV ;
- l'ombrage partiel : le mauvais éclairage, les pollutions atmosphérique, industrielle ou chimique sous forme de dépôt constituent de sérieux freins pour l'obtention des performances.

Le peu d'intérêt actuel des outils de l'automatique pour ce système industriel complexe doublé d'un manque d'instrumentation consensuelle freine la progression de la mise en place de modules de surveillance ou de monitoring dans les systèmes photovoltaïques [Mendil 2018] et [Dilmi 2022]. Un bon nombre de capteurs de mesures disponibles, qui servent à instrumenter se révèle souvent imprécis. L'impossibilité d'avoir une base de données fiable, pose le problème des contraintes techniques face aux nouveaux progrès technologiques pour la conception de systèmes d'acquisition temps réels pour mesurer les variables tant électriques que physiques (courant, tension, ensoleillement, température) et de les transmettre instantanément au système de diagnostic ou de surveillance. A ce jour, beaucoup de systèmes d'instrumentations temps réel, en ligne ou hors ligne, voient le jour, sur la base des aspects suivants [Bun 2011 a., Ribot 2009, Migon-Dubois et al. 2019, Guillerm 2011, Belaout 2018, Ghimire et al. 2013] :

- faible complexité ;
- aptitude à fournir des mesures de ces variables ;
- coût réduit (maintenance, installation) ;
- robustesse vis-à-vis des conditions d'utilisation et de fonctionnement.

Aussi, nous estimons nécessaire de rechercher une méthode de diagnostic éprouvée pour un système de surveillance économiquement abordable et particulièrement non intrusive en capteurs mais tournée vers l'Internet industriel des objets connectés (IIoT). Cela devra permettre la prise en compte diligente des actions de maintenance corrective ou prédictive, afin de remettre le générateur photovoltaïque dans un bon état de fonctionnement. Cet ensemble d'actions, permettra un meilleur retour sur investissement acceptable.

Bien entendu, le premier objectif de cette thèse s'appuie sur le choix d'un bon modèle tant électrique que mathématique, capable de s'adapter à l'ensemble des problèmes physiques, environnementaux, d'exploitation et de fabrication du générateur photovoltaïque. En outre ce modèle devra être capable de prendre en compte toutes défaillances engendrant une dégradation de l'état des performances en temps réel du générateur photovoltaïque.

Le second objectif de cette thèse est de mettre au point une approche de diagnostic innovante et fiable, capable de réduire ou de minimiser les pertes énergétiques dans un générateur photovoltaïque, pouvant améliorer la disponibilité globale de la source d'énergie de sorte à accroître la durée de vie de telles installations.

Le troisième objectif de cette thèse s'inscrit dans une vision de développement propre et durable, où les solutions envisagées seront basées sur l'exploitation de sources d'énergie renouvelables, grâce à une maintenance préventive et prédictive à travers une instrumentation peu coûteuse et non invasive. Aussi, les technologies seront simples à mettre en œuvre pour favoriser leur appropriation par les potentiels utilisateurs.

Les technologies proposées visent la satisfaction des besoins fondamentaux (accès à l'eau, à l'alimentation et accroissement des revenus grâce à l'énergie disponible) pour une meilleure rentabilité des installations photovoltaïques en passant nécessairement par une maîtrise de la

maintenance et de la disponibilité de la fourniture d'énergie grâce au prototype IIoT d'acquisition en temps réel avec des données propres.

Compte tenu des objectifs visés et des différentes articulations, le mémoire est organisé de la façon suivante.

Le chapitre 1 traite de l'état de l'art du diagnostic. Il débute par une présentation générale de la problématique du diagnostic suivi de la définition de certains concepts. Une revue bibliographique sur l'utilisation des méthodes de diagnostic est ensuite faite [Hoblos 2008, Chebira 2021]. Enfin, nous présentons les caractéristiques nécessaires de ces méthodes, afin d'en choisir deux qui soient bien adaptées au type de systèmes industriels complexes de notre étude.

Le chapitre 2 commence par quelques généralités sur la production d'énergie photovoltaïque débouchant naturellement sur la modélisation tant électrique que mathématique de la cellule photovoltaïque jusqu'au générateur PV [Bun 2011 a., Azizi 2018]. Après avoir montré le comportement sain, nous regardons le cas particulier de certaines anomalies impactant le GPV, leurs liens avec certains paramètres du modèle retenu, mais aussi leurs impacts sur les performances du système.

Le chapitre 3 déroule la méthode de diagnostic basée sur l'espace de parité. Il débute par quelques définitions, pour nous permettre d'exposer la méthode de diagnostic basée sur les relations de redondance analytique [Dhimish 2018, Bradley 1997]. L'une de ces techniques est notamment mise en avant à travers l'application de la technique de l'espace de parité au point de fonctionnement maximal du GPV. Après avoir structuré les résidus, nous appliquons l'algorithme de détection de la somme cumulée (DCS) pour bien localiser les instants de changements brusques. Grâce aux caractéristiques opérationnelles de réception (courbes COR), nous analysons la performance de l'algorithme de détection, utilisé dans cette méthode de diagnostic.

Le chapitre 4 déroule la méthode de diagnostic basé sur l'intelligence artificielle. Il commence avec quelques analogies permettant de situer le comportement du neurone artificiel vis-à-vis du neurone biologique [Mansouri 2021, Zhang et al. 2005]. Ensuite, nous analysons la mise en réseau des neurones artificiels à travers la topologie et surtout les modes d'entraînement avant de proposer deux architectures l'une pour la détection et la classification des défauts et l'autre pour le diagnostic des défauts systèmes. Les résultats de simulation montrent une certaine satisfaction de cette technique de diagnostic basée sur l'apprentissage peu profond par rapport à la méthode de l'espace de parité.

Le chapitre 5, est dédié à la réalisation du prototype d'IIoT. Il commence par la définition d'un certain nombre de concepts liés à l'organisation et l'architecture des IoT [Dilmi 2022, Oztemel 2020]. Nous présentons aussi les résultats d'instrumentations et d'exécutions de deux architectures IIoT expérimentées dans le cadre de cette thèse pour faciliter l'acquisition en temps réel des données devant alimenter l'une ou l'autre des deux méthodes de diagnostic exposées dans les deux chapitres précédents. Grâce à la base de données acquise, nous procédons à l'application des deux méthodes de diagnostic, pour marquer la concrétisation de la mise en place d'un système de surveillance en ligne ou hors ligne sur le GPV.

Nous terminons bien entendu la rédaction de ce manuscrit de thèse par une conclusion générale avec quelques pistes de perspectives.

Etat de l'art sur le diagnostic

1.1 Introduction

En raison de la complexité des phénomènes électriques, biologiques, physiques, chimiques, pétrochimiques, aérospatiaux, etc. mis en jeu dans les procédés impliqués dans les unités industrielles, il est souvent très difficile de quantifier les interactions et les relations qui existent entre les entrées et les sorties de ces procédés. Il faut les surveiller en permanence pour détecter les pannes éventuelles et maintenir une bonne qualité de service. Les modèles des procédés, lorsqu'ils existent, sont souvent spécifiques pour certaines de leurs variations. Ces considérations d'optimisation, de commande et d'estimation des paramètres ont motivé d'importants efforts dans le développement de méthodes de diagnostic pour les systèmes industriels [Bun et al. 2011 b., Chebira 2021, Rezgui et al 2014 a., Ribot 2009].

Les générateurs photovoltaïques ont un fonctionnement complexe qui ne peut pas être mesuré, modélisé et interprété que d'une façon partielle liée à la complexité des phénomènes, anomalies et changements mis en jeu mais aussi par leur nature non stationnaire et aléatoire : ils peuvent donc avoir des fonctionnements différents d'un état à l'autre, pour les mêmes conditions expérimentales d'ensoleillement et de température.

Généralement, un niveau supérieur comme la supervision, est superposé à la boucle de commande afin d'assurer des conditions d'opération pour lesquelles les algorithmes d'estimation et commande sont efficaces. Parmi les tâches spécifiques de la supervision se trouvent la détection des défaillances, le diagnostic, le changement des consignes et la reconfiguration de la loi de commande. Ces tâches sont réalisées typiquement par des opérateurs humains qui prennent des décisions après avoir évalué la situation du procédé à partir des variables observées, en utilisant leur connaissance d'expert, leur habilité naturelle pour résoudre des situations complexes et probablement aussi quelques règles heuristiques.

La gestion des divers problèmes de fonctionnement, qu'il s'agisse de dysfonctionnements ou de pannes des différents capteurs ou systèmes ou actionneurs (vannes, pompes, agitateurs ...) d'un processus industriel, se pose avec acuité. Le diagnostic de défaut dans le processus, consiste à détecter l'apparition d'un défaut, à le localiser, à en identifier la cause, puis à adopter la marche

à suivre afin d'assurer la sûreté de fonctionnement du système pour ne pas subir les effets d'une éventuelle dégradation.

Le diagnostic de systèmes technologiques élément essentiel d'un système de production, a suscité et continue de susciter un grand intérêt de la part du monde industriel : savoir détecter un mode de fonctionnement anormal suffisamment tôt permettrait de produire une commande susceptible de revenir à un mode de fonctionnement plus adapté à la mission pour laquelle ce système a été conçu.

Automatiser peut avoir des objectifs divers, augmenter les performances du système de production, garantir la qualité du produit, diminuer les coûts de production et d'améliorer la sécurité de l'installation industrielle et de son environnement [Zwingelstein 1995].

Dans la première partie de ce chapitre, nous introduisons quelques définitions utiles dans le domaine de la supervision et du diagnostic, puis nous donnons quelques aspects fondamentaux de la supervision de procédés et des méthodes de diagnostic.

Ensuite, nous présentons une approche pour la surveillance à base de méthodes de classification. Finalement, un léger clin d'œil est fait à la fonction maintenance qui connaît une forte mutation depuis qu'elle est considérée comme un des facteurs majeurs dans la maîtrise de l'outil de production et qui a désormais un rôle préventif dans le maintien de l'état de fonctionnement des systèmes de production.

1.2 Position par rapport au diagnostic des GPV

De nos jours, la surveillance de l'état de santé associant un système de monitoring de l'installation à des techniques de diagnostic des défauts est largement décrit comme l'approche la plus efficace pour lutter contre la diminution des performances des systèmes PV.

Malgré l'engouement sans cesse accrue de la communauté scientifique sur ces problématiques, rien qu'à apprécier le très grand nombre de publications associées aux mots clés "**Fault detection**" et "**diagnosis**" et "**photovoltaics**", force est de reconnaître qu'il n'existe pas pour l'instant, une piste claire permettant de dire que telle technique de diagnostic de détection de défaut peut être considérée comme l'une des plus efficaces pour la surveillance des systèmes PV.

En 2017, une analyse de 163 articles des méthodes de classification a été effectuée, sur la base de critères spécifiques [Migan-Dubois et al. 2019]. Il ressort de celle-ci, que 58 décrivent ou illustrent des techniques de diagnostic de défaut, 32 présentent des systèmes de monitoring pour le diagnostic de défaut et 73 se concentrent sur un défaut PV particulier, mais sur des générateurs PV avec convertisseur DC/AC.

L'utilisation de techniques issues du domaine de l'intelligence artificielle apparaît comme la principale alternative pour aborder ces problèmes lorsqu'il est nécessaire de prendre en compte le retour d'expérience des experts du domaine ou de traiter de l'information de nature qualitative.

Nous n'occultons pas non plus les différentes solutions algorithmiques ou logicielle informatique tentant de redonner un nouveau visage aux systèmes PV ayant ou subissant des avaries de fonctionnement.

Aussi la particularité des travaux menés tout au long de cette thèse vise la recherche d'un meilleur outil de diagnostic qui puisse convenir uniquement à la partie générateur du système photovoltaïque.

1.3 Définitions

Vu la diversité (pluralité, variété, abondance) des définitions trouvées dans la littérature sur le diagnostic, nous avons jugé nécessaire d'établir un lexique clair et précis sur les termes qui seront utiles pour la compréhension de la suite de cette thèse. En effet, les définitions, peuvent être réorientées en fonction de l'angle d'étude du système envisagé. Certaines de ces définitions ont été extraites à partir des références suivantes : [Guillerm 2011, Frini et al. 2019, Haithem 2009, Aggab 2016, Zwingelstein 1995, Kortbi et al. 2019, Hu et al. 2020, Chebira 2021, Charaf et al. 2019, Hatem et al. 2019, Md Nor et al. 2020].

1.3.1 Défaut

Un défaut se définit comme une anomalie du comportement d'un système sans forcément remettre en cause sa fonction. Tout comme une défaillance ou une panne, un défaut peut connaître une accentuation dans la progression de sa sévérité : mineur, majeur, critique et catastrophique. Le défaut peut être une perturbation du type bruit aléatoire, variations des paramètres ou erreur de modèle.

Lorsqu'un défaut mineur ou majeur se produit, le système de production fonctionne mais dans un mode dégradé.

Les défauts sont classés en plusieurs types comme l'indique la Figure 1.1, selon leur origine.




FIGURE 1.1 – Différents types de défauts d'un processus physique.

- défauts de capteurs qui se caractérisent par un écart entre la valeur réelle de la grandeur et sa mesure. On classe ces défauts en fonction de leur type en : biais, dérive, modification du gain de mesure, valeurs aberrantes, blocage du capteur à une valeur atteinte ou à une coupure électrique du capteur ;
- défauts d'actionneurs qui se traduisent par une incohérence entre les commandes et la sortie de l'actionneur ;
- défauts du processus physique qui sont dus à des modifications de la structure ou des paramètres du modèle.

1.3.2 Défaillance

Une défaillance est causée par une anomalie et marque l'altération ou la cessation de l'aptitude d'un système à accomplir sa ou ses fonctions autour des valeurs nominales. Les défaillances peuvent aussi être définies selon leur degré de sévérité par :

- défaillance mineure qui nuit au bon fonctionnement du processus en engendrant des dommages négligeables ;

- défaillance majeure ou significative qui nécessite une attention de traitement, quand bien ses conséquences ne sont pas aussi dommageables ;
- défaillance critique qui requiert une intervention d'urgence car susceptible de causer des blessures aux personnes ou des dégâts importants aux matériels ;
- défaillance catastrophique qui entraîne la perte d'une ou de plusieurs fonctions essentielles causant des dommages importants soit du système, soit à l'environnement. Dans ce cas de figure, le système doit être réparé.

1.3.3 Panne

La panne est l'incapacité d'un dispositif (composant, sous-système, système) à accomplir une fonction requise. Une panne résulte toujours d'une défaillance et donc d'un défaut selon le cheminement : $Defaut \rightarrow Défaillance \rightarrow Panne$

1.3.4 Symptôme

Un symptôme est un événement au travers duquel le système de détection marque l'entrée du procédé dans un état de fonctionnement anormal. C'est le seul élément dont a connaissance le système de surveillance au moment de la détection d'une anomalie.

1.3.5 Résidu

Un résidu est un signal temporel, associé à une différence résultant de la comparaison de mesures de capteurs à des valeurs calculées analytiquement d'une variable considérée dans le système modélisé. Certains sont dits affectés, si différents de zéros, et d'autres pas.

1.3.6 Signature

La signature d'un défaut est caractérisée par son impact sur le comportement de tous les résidus. L'analyse de cette signature permettra de localiser l'origine du défaut.

1.3.7 Mode de fonctionnement

Un système est en « état de fonctionnement normal » lorsque les variables le caractérisant (variables d'état, variables de sortie, variables d'entrée, paramètres du système) demeurent au voisinage de leurs valeurs nominales. En outre on peut distinguer plusieurs types de modes de fonctionnement, parmi lesquels :

- le mode de fonctionnement nominal qui est le mode de fonctionnement requis et attendu par le constructeur, avec les exigences attendues de l'exploitant ;
- le mode de fonctionnement dégradé qui correspond soit à l'accomplissement partiel de la mission, soit à l'accomplissement de celle-ci avec des performances moindres suite à l'apparition d'une dégradation non défaillante dans l'équipement ou le système ;
- le mode de défaillance qui correspond à des mauvais fonctionnements du système défaillant suite : soit à une dégradation soit à une défaillance brusque. Un mode de défaillance est caractérisé par les effets causés par cette défaillance. Les effets sont toutes les modifications qui découlent directement de l'apparition d'un événement. Ces effets

peuvent être mesurables ou qualifiables. Le rôle d'un expert dans cette situation consiste à faire une analyse des causes à effets des défaillances, tout en associant le mode de défaillance.

1.3.8 Diagnostic

Le diagnostic à base de modèle consiste à établir un lien de cause à effet entre le symptôme observé et la défaillance qui est survenue, ses causes et ses conséquences. Cette fonction se décompose en trois fonctions élémentaires :

- *la détection* d'un défaut qui consiste à classer des situations observables comme étant normales ou anormales ;
- *la localisation* d'un défaut qui consiste à déterminer le sous-système fonctionnel à l'origine de la défaillance et progressivement affiner cette détermination pour designer l'organe ou dispositif élémentaire défectueux ;
- *l'identification* des causes qui consiste à déterminer les causes qui ont mené à une situation anormale. Ces causes peuvent être internes (sous-ensembles défaillants faisant partie de l'équipement), ou bien externes à l'équipement.

1.4 Surveillance, Supervision et Diagnostic

La surveillance et la supervision constituent un complément du diagnostic et peuvent se décliner suivant les interactions de la Figure 1.2 :

- la surveillance est une opération passive, informationnelle qui analyse l'état du système et fournit des indicateurs ;
- quant à la supervision, elle consiste à gérer et à surveiller l'exécution d'une opération ou d'un travail accompli par l'homme ou une machine, puis à proposer des actions correctives en cas de besoin dès l'apparition de défauts.

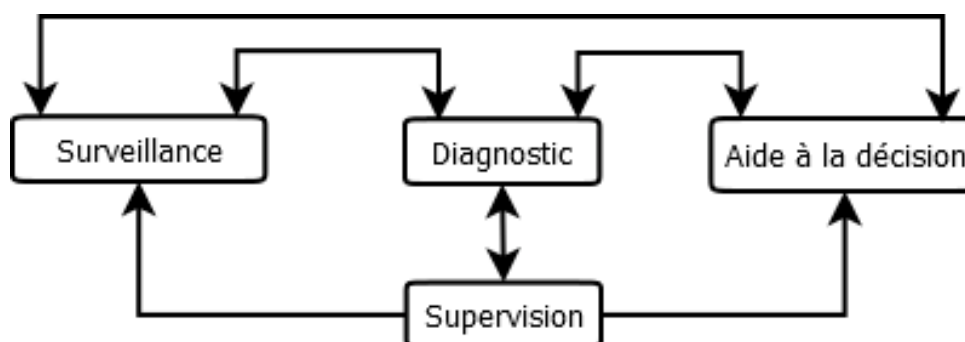


FIGURE 1.2 – Interaction entre Surveillance, Diagnostic et Supervision [Hernandez 2007].

L'ensemble de ces tâches vise à assurer le maintien des performances optimales de fonctionnement du système, en termes de disponibilité, fiabilité et maintenabilité. La surveillance de l'évolution d'un système industriel nécessite la conception d'un système de diagnostic capable de faire la détection précoce de faibles écarts par rapport à une caractérisation du système en fonctionnement nominal, afin de prévenir un dysfonctionnement avant qu'il n'arrive. Toute méthode de diagnostic repose sur l'analyse d'un certain nombre d'indicateurs ou de symptômes qui permettent de caractériser l'état de fonctionnement du système. Ces symptômes doivent

être générés et interprétés correctement afin de déterminer l'origine du défaut et par conséquent l'élément présentant un fonctionnement anormal afin de prendre une décision pour un retour à un fonctionnement normal de l'installation tel qu'illustré à la Figure 1.3.

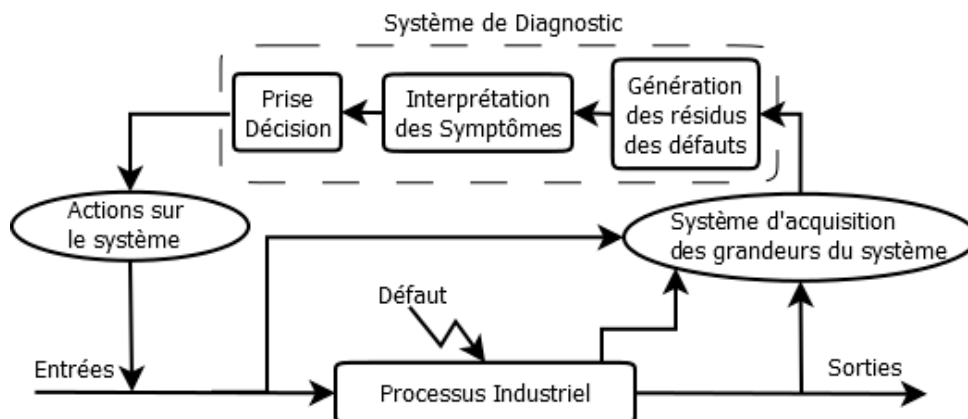


FIGURE 1.3 – Structure d'un système de diagnostic à base de modèle [Maquin et al. 2000].

La conception d'un système de diagnostic nécessite l'utilisation de l'ensemble des connaissances disponibles sur le processus surveillé ainsi que d'autres informations qui peuvent être obtenues à partir des méthodes d'analyse telles que HAZOP, AMDE, AMDEC, Arbre de Défaillance ou des graphes fonctionnels et/ou de composantes [Tahiri 2020].

1.5 Critères de performance d'un système de diagnostic

La définition de certains critères de performance pour lesquels on peut évaluer n'importe quelle stratégie de surveillance est nécessaire. Il existe un ensemble commun de critères d'évaluation pour toute approche de surveillance et de diagnostic de défauts. Ces critères incluent les erreurs de détection, le temps de détection, et les exigences de calcul.

Pour ce qui est du premier critère de l'erreur de détection, dans toute procédure de modélisation, un modèle parfaitement précis et exact d'un système physique est difficilement atteignable, soit à cause de la variation des paramètres du système dans le temps, soit à cause de la méconnaissance de la nature des bruits. Par conséquent, en cas de défaut, il y a toujours un décalage entre le comportement observé sur le processus réel et son comportement prédit par le modèle construit. Ce qui peut causer à la fois soit de fausses alarmes ou soit des alarmes manquées. D'une manière générale, une réduction de la sensibilité aux incertitudes de modélisation influe sur les résidus, conduit donc à une baisse de la sensibilité et par conséquent à la détection de défauts [Gao et al. 2015, Gandhi et al. 2020]. En fait, la formulation la plus significative de ce problème est d'augmenter l'insensibilité aux incertitudes de modélisation afin de fournir plus de sensibilité aux défauts.

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

Enfin, réduire les exigences de stockage et de calcul joue également un rôle important dans l'évaluation des performances d'une méthode de surveillance et de diagnostic, et spécialement dans le cas de la surveillance des processus en temps réel. Surveiller en temps réel s'avère donc

indispensable, parce que cela reste un compromis raisonnable entre les exigences de calcul par rapport aux obligations de stockage de données. D'une manière générale, nous pouvons regrouper les différents critères de performance du système de diagnostic de la manière suivante [Ding 2008, Gertler 1998, Chakour et al. 2016] : détectabilité, isolabilité, sensibilité et robustesse.

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

1.6 Classification des méthodes de diagnostic

Les méthodes de diagnostic des défauts utilisées dans le milieu industriel sont très variées à cause des facteurs tels que la nature des processus, des systèmes, des composants, des modèles établis, des données disponibles... en d'autres termes, du système à surveiller dont il faut tenir compte des technologies employées.

Le principe général des méthodes de diagnostic repose sur une comparaison entre les données observées au cours du fonctionnement du système et les connaissances acquises sur son comportement normal et ses comportements de défaillance [Haithem 2009]. De par la littérature, nous présentons sur la Figure 1.4, une classification des principales méthodes de diagnostic rencontrées. Cette classification s'appuie sur plusieurs critères tels que la nature de l'information disponible (quantitative ou qualitative) ou la dynamique du système (continu, discret ou hybride). Dans la suite, nous proposons une classification non exhaustive des méthodes de diagnostic selon deux approches : sans modèles et à base de modèles [Zwingelstein 1995]. Nous référons le lecteur aux travaux suivants pour avoir plus de détails : [Tidiri et al. 2016, Hu et al. 2020, Kortbi et al. 2019, Da Silva et al. 2018, Bessam 2016].

Le fait d'utiliser une méthode plutôt qu'une autre est plus dicté par le type de connaissances dont on dispose pour l'accomplissement de telle ou telle étape du diagnostic, qu'à un choix délibéré de la part du concepteur. Nous précisons que notre objectif est uniquement de fournir quelques outils pour la mise en œuvre d'un système de surveillance, destiné à la détection et la localisation des défauts d'un système industriel.

1.6.1 Méthodes sans modèles

Dans certaines applications industrielles, il est difficile, voire impossible d'obtenir le modèle du système. Cette difficulté est justifiée par la complexité accrue ou par de nombreuses reconfigurations intervenants durant le processus de production. En effet, seules les méthodes

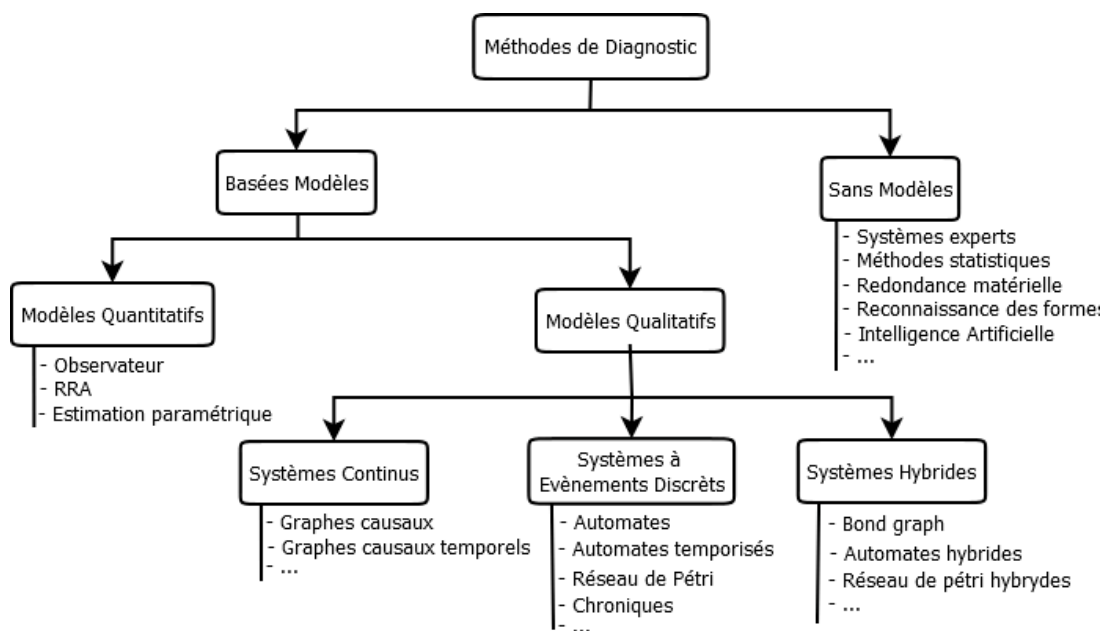


FIGURE 1.4 – Classification des méthodes de diagnostic [Haithem 2009].

de surveillance sans modèles sont opérationnelles pour ce type d'application industrielle. Ces méthodes de diagnostic se basent sur des informations issues d'une expérience préalable, sur des règles heuristiques ou encore sur des exemples de résolution. Dans cette famille de méthodes, on trouve :

- Méthode du seuil : Les signaux fournis par les capteurs sont comparés à une valeur limite constante ou adaptative qui évolue autour du point de fonctionnement [Karoui 2011]. Le premier niveau indique qu'il peut y avoir un défaut, tandis que le second niveau peut caractériser sa gravité. Franchir le seuil indique l'existence d'une anomalie.
- Méthodes statistiques : ces méthodes supposent que les signaux fournis par les capteurs ont certaines propriétés statistiques et s'établissent sur la base des tests de seuil [Kortbi et al. 2019, Bessam 2016]. En effet, l'étude de l'évolution de la moyenne ou de la variance du signal (plus largement les tests statistiques) peut être bénéfique pour mettre en évidence des anomalies.
- Reconnaissance des formes : Ces méthodes sont basées sur l'utilisation d'algorithmes de classification de formes et de mesures (continues ou discrètes). Un système de diagnostic par reconnaissance de formes fonctionne en trois phases [Hotait 2020, Idriguen et al. 2018] :
 - La phase d'analyse, qui consiste à identifier et à réduire l'espace de représentation des données et à définir l'espace de décision, de sorte qu'un ensemble de classes possibles puisse être spécifié ;
 - Dans l'étape de choix d'une méthode de prise de décision, des règles de décision peuvent être définies, dont la fonction est de classer les nouvelles observations de différentes catégories dans l'ensemble d'apprentissage ;
 - Lors de la phase de développement, le mode de fonctionnement du système est déterminé en fonction de chaque nouvelle observation collectée au cours du processus en appliquant des règles de décision.
- Systèmes experts : dans ce type de systèmes, des informations heuristiques sont utili-

sées pour associer des symptômes aux défauts [Seguy 2008]. Ce sont des systèmes basés sur des règles qui établissent des associations empiriques entre les effets et les causes [Zwingelstein 1995].

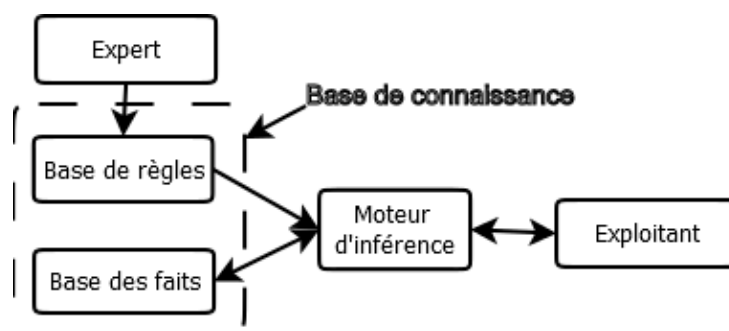


FIGURE 1.5 – Structure générale d'un système expert [Chebira 2021].

Ces associations sont généralement basées sur l'expérience d'experts plutôt que sur la connaissance de la structure et/ou du comportement du système et illustrées sur la Figure 1.5. Leur fonction est de parcourir les règles par raisonnement inductif, soit en avant soit en arrière, pour trouver les causes des observations.

- Réseaux de neurones artificiels (RNA) : Ce sont des modèles mathématiques (fonctions, algorithmes d'optimisation...) qui imitent la structure du cerveau humain [Kortbi et al. 2019]. Les "neurones" sont connectés dans une structure hiérarchique complexe, permettant au modèle d'approximer des fonctions non linéaires complexes avec des neurones d'entrée, de sortie et cachés [Bessam 2016]. Il existe différentes techniques d'apprentissage, dont la plupart nécessitent un grand nombre d'exemples et beaucoup de temps de calcul. L'une de ces techniques est l'apprentissage supervisé, dans lequel le réseau s'adapte en comparant ce qu'il calcule à partir de l'entrée qui lui est fournie avec la réponse attendue à la sortie [Patan 2008].

1.6.2 Méthodes basées sur les modèles quantitatifs

Le principe de ces méthodes de diagnostic repose sur la comparaison du comportement en mode sain par rapport au mode dégradé du modèle qualitatif et/ou quantitatif établi du système. Tout écart est alors synonyme d'une défaillance, comme indiqué dans le schéma de la Figure 1.6.

A ce moment, un résidu sera généré. Les décisions de détection 0 ou 1 , seront comparés aux signatures des défauts connues, afin d'isoler et d'identifier la défaillance. Parmi les différentes méthodes de détection et de diagnostic utilisant des modèles mathématiques, nous trouvons principalement les relations de redondance analytique (RRA), les observateurs et l'estimation paramétrique.

Une procédure de détection et de localisation de défauts à base de modèles peut être décomposée en deux étapes principales désignées sous le nom de "génération des résidus" et "*prise de décision*", comme illustré sur la Figure 1.6. Lorsque le modèle mathématique du système est disponible, ces méthodes à base de modèles quantitatifs sont très performantes. Elles sont généralement intitulées FDI (Fault Detection and Isolation). Si pour la notion de détection de défauts toutes les communautés scientifiques partagent la même définition, beaucoup de divergences apparaissent dès lors qu'il s'agit du diagnostic [Tidriri et al 2018]. La localisation de défaut est

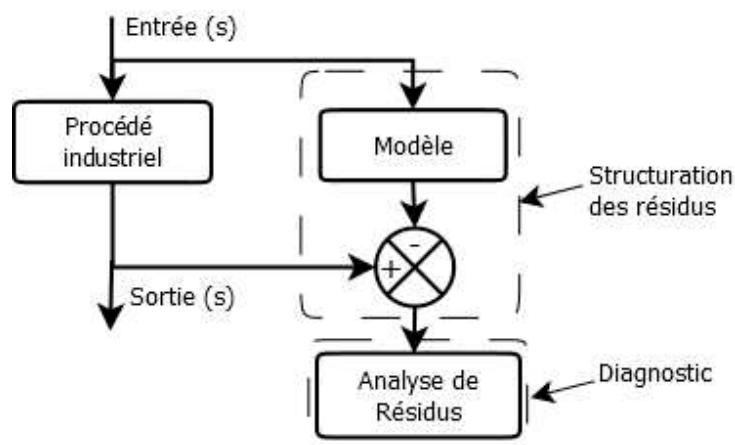


FIGURE 1.6 – Principe de diagnostic basé sur la génération des résidus.

définie comme étant la détermination du lieu exact du défaut afin de déterminer l'origine exacte du composant défectueux.

Estimation de paramètres

L'estimation des paramètres du système à l'aide d'une procédure d'identification permet de mesurer l'impact des défauts sur les paramètres structurels du modèle. Les résidus proviennent de la différence entre les paramètres nominaux et estimés du modèle [Tidriri et al 2018, Ceban 2012, Abdelghani 2017, Hatem et al. 2019]. La très grande variation d'un paramètre indique un défaut.

Dans ce cas, l'écart des résidus par rapport à zéro est le résultat des variations de paramètres. Ces écarts sont ensuite analysés par la théorie de décision [Hu et al. 2020]. Cette méthode est bien adaptée aux types de défauts multiplicatifs qui affectent les paramètres du système et peut obtenir des informations sur l'ampleur de l'écart. Cependant, elle est difficile à appliquer aux systèmes complexes en raison des nombreuses variables impliquées, et les étapes de localisation des défauts sont difficiles.

Observateurs

Cette méthode s'appuie sur une bonne connaissance du modèle et de ses paramètres pour la reconstruction de la sortie du processus à l'aide d'observateurs, afin de la comparer avec la sortie mesurée.

Un vecteur résiduel est l'écart résultant entre les sorties mesurées et celles estimées. Le diagnostic basé sur les observateurs est une technique très populaire et très utilisée. Plusieurs travaux ont été développés dans ce sens [Patan 2008, Park et al. 2020, Kumar et al. 2022, Chebira 2021, Ghorbanian et al. 2015, Zhonghai et al. 2018].

Relation de Redondance Analytique

Une relation de redondance analytique (RRA) est une équation dans laquelle toutes les variables sont connues [Chebira 2021]. La génération de telles relations entre les paramètres du modèle et les mesures issues de capteurs permet d'engendrer des résidus [Tidriri et al. 2016] sensibles aux défauts et insensibles aux perturbations. Pour la détection des défauts basée sur l'utilisation de modèles, un résidu est un signal temporel, fonction des entrées et des sorties du

processus, indépendant du point de fonctionnement de celui-ci [Maquin et al. 2000]. En l'absence de défauts, ce résidu est statistiquement nul. Lors de l'apparition d'un défaut, son amplitude évolue de manière significative [Kaplan et al. 2017].

D'autres travaux ont permis à cette méthode de passer par la redondance parallèle avant d'être généralisée aux systèmes dynamiques à travers la redondance temporelle entre les sorties et les entrées du système dans le but de générer des résidus. Le diagnostic par l'espace de parité, une méthode parmi tant d'autres issue des RRA aussi connue sous l'appellation Analytical Redundancy Relations (ARR), a été utilisée avec succès dans plusieurs applications industrielles [Jahn et al. 2020, Hafifa et al. 2015, Zhong et al. 2015, Han et al. 2018, Cui et al. 2019]. La méthode de l'espace de parité a été une des premières méthodes employées à des fins de détection et localisation de défauts.

1.6.3 Méthodes basées sur les modèles qualitatifs

Les modèles qualitatifs permettent d'abstraire le comportement du procédé avec un certain degré d'abstraction à travers des modèles non plus mathématiques mais des modèles de type symbolique [Soleimani et al. 2021]. Ces modèles décrivent d'une manière qualitative l'espace d'état continu du système. Contrairement aux modèles de type numérique, les modèles qualitatifs ne représentent pas la physique du système, mais ils le décrivent en terme de mode de fonctionnement. Les méthodes à base de modèles qualitatifs peuvent être classifiées selon le niveau d'abstraction considéré du système à diagnostiquer, pour les systèmes continus, pour les systèmes à événements discrets (SED) ou pour les systèmes hybrides dynamiques.

Systèmes continus

Pour les systèmes continus, les approches ont été développées en s'appuyant sur la forme de raisonnement des relations de cause à effet régissant le processus. En définitive, ils sont basés sur les graphes causaux [Batteux 2011], tels les graphes signés orientés (SGD ou Signed Directed Graph), les arbres de défaillance et les méthodes d'analyse des modes de marche, de défaillance de leur effet (AMDE) et de leur criticité (AMDEC) ; ou les graphes causaux temporels [Tidriri et al. 2016] tels les Réseaux de Pétri ou les réseaux de Pétri temporels.

Systèmes à événements discrets

Le diagnostic des SED est basé sur l'utilisation de modèles discrets tels que les Réseaux de Pétri (RdP) et les automates d'états finis,... Un exemple contextuel de diagnostic proposé dans [Gao et al. 2015], est devenu une référence dans la littérature a consisté à modéliser un système par des automates à états finis, puis à construire son système de diagnostic.

Systèmes hybrides

Pour les systèmes hybrides, des méthodes reposant sur des modèles hybrides tels que les automates hybrides à temps discret dans [Da Silva et al. 2018], les Bond Graphs (BG) dans [Sallami et al. 2016, Aziz et al. 2018], ou les Réseaux de Pétri hybrides dans [Peng et al. 2018]. Pour certaines de ces méthodes, une grande limitation réside parfois dans la génération d'un grand nombre d'hypothèses pouvant conduire à une mauvaise formulation du problème ou à une

solution très incertaine. Ceci est dû en partie aux ambiguïtés ou aux mauvaises interprétations du comportement du système, de nature qualitative qui y sont posées.

1.7 Choix d'une méthode de diagnostic

Le développement d'une stratégie de surveillance et de diagnostic avec une méthode choisie reste relativement une tâche importante et difficile. Le choix, d'une méthode de diagnostic, dépend de plusieurs critères comme :

- le type de diagnostic en ligne/hors ligne ;
- la modélisation discrète, continue ou hybride ;
- le comportement du système (régime stationnaire / régime non stationnaire) ;
- la nature de l'information (quantitative / qualitative) ;
- l'existence des connaissances à priori disponibles sur le système ;
- la présence ou non d'un modèle mathématique des processus à diagnostiquer ;
- les types de défauts à détecter ;
- la présence ou non d'entrées inconnues (bruits, incertitudes) ;
- etc . . .

Pour les systèmes mécaniques, électriques et mécatroniques, il est souvent possible de concevoir un modèle mathématique, le choix des méthodes de diagnostic à base d'un modèle sera donc préféré. Par contre, pour certaines applications industrielles, la conception d'un modèle mathématique est difficile, voire impossible à obtenir, à cause des nombreuses reconfigurations intervenant dans le processus de production ou de la complexité des phénomènes mis en jeu (par exemple, les processus industriels chimiques). Dans ce cas, les méthodes de détection de défauts sans modèle de référence peuvent être appliquées.

L'objectif majeur étant de déterminer la ou les méthodes les plus appropriées pour la résolution du problème de diagnostic posé, il convient d'avoir toujours à l'esprit, les points forts de chacune des principales méthodes précédemment citées.

Les méthodes de diagnostic des défauts basées sur les modèles présentent les avantages suivants : elles fournissent les estimateurs ou les observateurs les plus précis lorsqu'elles sont bien mises en œuvres, des modèles détaillés peuvent modéliser les opérations normales et défectueuses du système considérés, le bruit du système et les erreurs de modélisation peuvent être modélisés et incorporés dans la stratégie de diagnostic des défauts. Elles possèdent quand même les faiblesses suivantes : complexes et avec des calculs intensifs ; être influencés par les erreurs de modélisation impactant significativement les résultats finaux. Les types de modèles que les approches analytiques peuvent gérer sont limités à des modèles linéaires et dans certains cas, à des modèles non linéaires très spécifiques. Pour un modèle non linéaire général, les approximations linéaires peuvent s'avérer médiocres et par conséquent l'efficacité de ces méthodes pourrait être considérablement réduite.

L'un des avantages des méthodes qualitatives fondées sur une connaissance approfondie est qu'elles peuvent fournir une explication du chemin de propagation d'un défaut. C'est indispensable en matière d'aide à la décision pour les opérateurs. Cependant, ils souffrent des problèmes de résolution résultant de l'ambiguïté du raisonnement qualitatif. Lorsque l'information quantitative est disponible en partie, on pourrait l'utiliser pour améliorer la résolution de méthodes

purement qualitatives.

Les méthodes de diagnostic des défauts sans modèles présentent les avantages suivants : bien adaptées aux systèmes hautement non linéaires et ne nécessitent pas de compréhension de la physique du système modélisé. Ils présentent également les faiblesses suivantes : les modèles ne peuvent pas être utilisés au-delà de la plage de données d'apprentissage, les modèles sont spécifiques au système modélisé et les données d'apprentissage sont requises pour les opérations normales et défectueuses. Alors, afin d'"optimiser" le diagnostic, il est souhaitable de combiner les avantages de chaque méthode. En effet, cette fusion permet d'accueillir le maximum possible d'informations sur le comportement du système.

La détection rapide, la localisabilité et la robustesse au bruit sont des propriétés des réseaux de neurones qui ont été démontrées grâce à l'utilisation de nombreuses études de cas par différents chercheurs. Étant donné que les réseaux de neurones fonctionnent principalement avec des données d'historiques de processus, les exigences de modélisation sont minimales. En outre, une fois qu'un réseau neuronal est formé, les calculs en ligne sont de simples évaluations de fonctions et par conséquent, la complexité des calculs en ligne est minime. Enfin, en ce qui concerne la propriété d'identification de multiples défauts systèmes, si la structure des données d'entrée est favorable, un diagnostic de défauts systèmes multiples est possible. Cependant, la procédure de développement de réseau de neurones en elle-même ne prend pas explicitement en compte l'idée de l'identification des défauts systèmes multiples. Cela peut être comparé à une approche basée sur l'observateur où l'on pourrait explicitement inclure l'identification de défauts systèmes multiples dans la procédure de conception.

En l'absence de modèle, les réseaux de neurones semblent donner les meilleurs résultats même si leur phase d'apprentissage reste délicate. Mais là encore, les approches de reconnaissance des formes par réseaux de neurones [Bishop 1995] et par la logique floue [Nguyen et al. 2019] par exemple, sont utilisées pour classer le système dans un certain mode de fonctionnement et notamment de défaut, ce qui suppose la connaissance du comportement du système.

Pour conclure, la plupart des approches portent sur un système spécifique, connu, et cherchent à détecter et à localiser des défaillances également connues sur le système. Finalement, l'approche à employer dépend de la connaissance ou non du modèle, de sa précision, de la connaissance des défauts sur le système ou encore de la possibilité d'effectuer la phase d'apprentissage.

Pour notre part, pour l'implémentation nous retenons deux méthodes de diagnostic dont l'une est basée sur le principe de la RRA à travers la technique de l'espace de parité et l'autre qui est basé sur le principe d'un apprentissage peu profond à travers la configuration de deux réseaux de neurones artificiels. Ces deux méthodes s'adaptent mieux au modèle de notre processus industriel complexe, le GPV, dont le modèle non linéaire est difficilement approchable par une représentation d'état.

1.8 Conclusion

Un système de diagnostic doit être en mesure de réaliser trois fonctions principales pour un retour à la normale, à savoir : la détection, la localisation et l'identification. La détection de défauts consiste à signaler toute situation autre qu'une situation nominale. En d'autres termes, tout ce qui n'est pas normal doit être classé comme anormal. C'est alors que la fonction diagnostic

doit localiser l'organe défaillant et identifier les causes ayant provoqué ces situations anormales et enfin, prendre en compte les mesures nécessaires à travers l'étape de prise de décision, pour un retour à un fonctionnement normal du système.

L'objectif de ce chapitre a été de donner un aperçu des techniques habituellement utilisées pour faire du diagnostic des défauts. Le chapitre a démarré avec la définition de certaines terminologies et concepts majeurs en diagnostic. Un ensemble de critères d'évaluation de performances et leur impact sur les principales fonctions de la surveillance et du diagnostic ont été discutés. A travers une revue bibliographique générale sur les méthodes de diagnostic de défauts, deux catégories de méthodes ont été présentées : les méthodes basées sur des modèles et les méthodes sans modèles des processus. Les techniques les plus populaires de chaque catégorie ont été présentées, à savoir : l'espace de parité, les observateurs, les modèles causaux, les systèmes experts, et les RNA.

Le choix d'une de ces méthodes dépend essentiellement des connaissances disponibles sur le procédé, sans oublier les considérations techniques et économiques.

La question de l'adéquation de l'une des méthodes de diagnostic de défaut ci-dessus est principalement une question de la qualité du modèle mathématique disponible du système, de la connaissance du système et de la structure du système. De plus, la qualité atteignable de la localisation des défauts dépend de manière décisive du nombre de mesures disponibles à travers une instrumentation non invasive et économique. Les systèmes de diagnostic sans modèles du processus peuvent donc représenter d'excellents systèmes d'aide à la décision pour peu que la connaissance du modèle soit totale et irréprochable. Dans ce sens, le chapitre suivant sera consacré à la présentation du modèle du système industriel, qu'est le GPV, sur lequel sera appliqué les deux méthodes de diagnostic envisagées que sont : la RRA à travers la méthode de l'espace de parité et un apprentissage peu profond à travers la configuration de deux réseaux de neurones artificiels.

Modélisation du générateur photovoltaïque

2.1 Introduction

Depuis une décennie, le marché du photovoltaïque a connu une croissance très remarquable comme illustrée sur la Figure 2.1, surtout ces dernières années grâce, aux différents facteurs stimulants : réduction des coûts de production et politiques de soutien. Ces facteurs stimulants rendent le retour sur l’investissement d’une installation photovoltaïque de plus en plus intéressant [Hemetsberger 2023]. Or, comme tous les autres processus industriels, un système photovoltaïque peut être soumis, au cours de son fonctionnement, à différents défauts et anomalies, conduisant à une baisse de la performance du système, voire à l’indisponibilité totale du système. Toutes ces conséquences défavorables vont évidemment réduire la productivité de l’installation, et partant le rendement de l’installation, sans compter le coût de remise en état de bon fonctionnement grâce à une bonne politique de maintenance.




FIGURE 2.1 – Demande d’énergie du type PV en fonction des années [Hemetsberger 2023].

À l’heure actuelle, il existe des systèmes de monitoring qui permettent de calculer la puissance fournie par les modules et l’énergie associée par l’intermédiaire de capteurs de tension et

de courant. Il existe même des services qui permettent de faire la corrélation entre la production d'une installation et les conditions météorologiques. Un satellite mesure l'ensoleillement émis sur le site et compare avec la productivité du champ. Les informations sont mensuelles et lorsqu'un écart important apparaît, l'utilisateur est informé. Ce genre de service est une première étape intéressante vers une supervision précise de l'installation mais montre des limites car il ne permet pas de détecter et localiser assez rapidement l'apparition d'un défaut quelconque [Sebbane et al. 2022].

L'étude bibliographique montre que de nombreuses études ont porté sur l'évaluation de l'impact des différents défauts par l'analyse de la caractéristique I-V (caractéristique statique) résultante. Par contre, l'utilisation d'une telle caractéristique pour remonter à la nature des défauts n'est pas largement répandue. Deux raisons principales peuvent être citées comme barrière à l'application d'une telle méthode pour faire le diagnostic : la difficulté d'obtention de la caractéristique complète I-V et le manque d'une base des données pertinente sur les causes entre défauts et modifications de la caractéristique I-V [Hadji 2018].

Cette partie du travail de la thèse consiste à établir de façon pertinente, un modèle tant mathématique qu'électrique et objectivement représentatif d'un générateur photovoltaïque qui puisse mettre en évidence, les principaux défauts considérés sur la caractéristique I-V résultante en mode sain comme en mode dégradé.

Nous nous étalerons sur la modélisation et la simulation d'un champ photovoltaïque pour obtenir la caractéristique I-V. La mise en évidence des défauts pour une configuration quelconque du système PV (module, string ou champ) sera faite en rapport avec les paramètres intrinsèques du modèle de simulation retenu. La modélisation et la simulation sont faites tant en fonctionnement sain qu'en fonctionnement défaillant du champ PV.

2.2 Production photovoltaïque

L'énergie photovoltaïque est l'un des enjeux de la politique énergétique de notre siècle. Elle résulte de la transformation directe de la lumière du soleil en énergie électrique, au moyen d'une photopile. Cette dernière qu'on appelle aussi, cellule solaire ou cellule photovoltaïque, est fabriquée à l'aide de matériaux semi-conducteurs, comme les transistors ou les puces dans un ordinateur. Les cellules photovoltaïques sont fabriquées généralement à base de "silicium cristallin", qui reste la filière la plus avancée sur le plan technologique et industriel, pour la raison que le silicium est l'un des éléments les plus abondants sur la terre, sous forme de silice non toxique.

2.2.1 Cellules photovoltaïques

Les cellules photovoltaïques convertissent directement l'énergie lumineuse en électricité sous la forme de courant continu. Comme l'énergie lumineuse vient du soleil, on parle alors des cellules solaires [Bey et al. 2019].

2.2.2 Effet photovoltaïque

L'effet photovoltaïque (PV), composé du mot de grec ancien « photos » ou lumière et du nom de famille du physicien italien (Alessandro Volta), est un phénomène physique, qui convertit

la lumière du soleil (photons) en électricité à travers les capacités de certains matériaux tels que les semi-conducteurs qui possèdent des propriétés électroniques particulières. La cellule photovoltaïque issue du matériau semi-conducteur, est constituée d'une jonction avec une couche comportant un excès d'électrons (zone dopée N) et une couche comportant un déficit d'électrons (zone dopée P), comme illustré sur la Figure 2.2. La jonction PN ainsi constituée, exposée au rayonnement solaire, va créer un excès de charges électriques dans les deux couches, et la mise en contact de ses deux bornes à travers une charge externe, va provoquer une circulation d'un courant électrique.




FIGURE 2.2 – Schéma d'une jonction PN sous l'effet des photons.

2.2.3 Caractéristique électrique d'une cellule photovoltaïque

En rappel, la cellule PV est un dispositif semi-conducteur construit à partir d'une jonction PN. Lorsque cette jonction PN est illuminée, le déséquilibre de la charge électrique dans les deux couches (P et N) provoque un mouvement de charges à travers la jonction produisant ainsi de l'électricité [Tahmi et al. 2022].

La cellule PV est normalement conçue pour fonctionner comme un générateur en fournissant l'énergie électrique convertie de l'énergie solaire à une charge. Par contre, il se peut que cette même cellule, lorsqu'elle est inter-connectée avec d'autres cellules, fonctionne comme un récepteur en absorbant de l'énergie débitée par les autres cellules [Vieira et al. 2020]. La caractéristique électrique d'une cellule PV montrant ses différents régimes de fonctionnement est illustrée dans la Figure 2.3. Dans cette figure, on peut remarquer deux points de fonctionnement importants : le courant de court-circuit (I_{sc}) et la tension de circuit ouvert (V_{oc}) qui encadrent subtilement ses trois zones :

- comme son nom indique, le courant de court-circuit correspond au courant quand la cellule est court-circuitée. Ce courant de court-circuit est proportionnel à la surface de la cellule qui capture la lumière, et pour une surface donnée, ce courant de court-circuit dépend de l'intensité de lumière absorbée par la cellule.
- la tension de circuit ouvert est la tension aux bornes de la cellule quand il n'y a pas de courant. Sa valeur est de l'ordre de 0,6 V pour la cellule de type cristallin. Ces deux points (I_{sc} et V_{oc}) délimitent le fonctionnement de la cellule en trois zones différentes.
- la zone I de la Figure 2.3 correspond au fonctionnement en générateur de la cellule avec $0 \leq I \leq I_{sc}$ et $0 \leq V \leq V_{oc}$. C'est le fonctionnement dit normal de la cellule dans lequel elle débite l'énergie électrique produite à la charge.
- la zone II correspond au fonctionnement en récepteur de la cellule avec $I > I_{sc}$ et $V < 0$. Quand le courant traversant la cellule est forcé par un circuit extérieur à dépasser son courant de court-circuit, la cellule produit une tension négative à ses bornes. La croissance en courant endommage la cellule si la tension à ses bornes atteint une limite : la tension

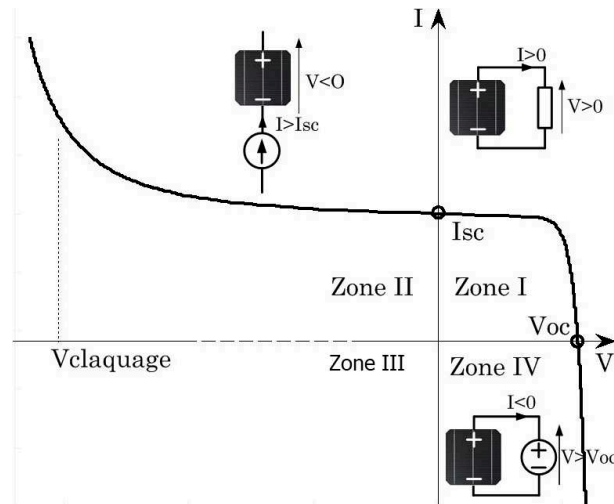


FIGURE 2.3 – Caractéristique I-V complète d'une cellule PV.

de claquage ($V_{claquage}$). L'étude expérimentale sur différentes cellules de type cristallin a montré que la valeur de la tension de claquage varie entre 10 V et 30 V [Sharaf et al. 2015].

- la zone IV correspond de nouveau au fonctionnement en récepteur de la cellule, mais avec cette fois ci $I < 0$ et $V > V_{oc}$. Quand la tension aux bornes de la cellule est amenée à dépasser sa tension de circuit ouvert, un courant inverse circule dans la cellule. Si ce courant inverse dépasse une limite, la cellule sera irrémédiablement endommagée. Cette limite n'est pas facile à définir car elle dépend de la technologie, des phénomènes internes à la circulation du courant dans la cellule en défaut.

Il est à noter que la zone III sur la Figure 2.3, correspond à une zone interdite de fonctionnement pour un semi-conducteur.

2.3 Modélisation électrique d'une cellule photovoltaïque

La démarche de modélisation d'un champ PV proposée ici, repose principalement sur la caractéristique d'une cellule photovoltaïque. A partir d'une connaissance du principe de fonctionnement de la cellule photovoltaïque, pour les différents régimes de fonctionnement, nous étendons le comportement à la configuration d'un champ de PV. Nous présentons ensuite les quelques modèles électriques comme mathématiques rencontrés dans la littérature pour représenter une cellule .

Plusieurs modèles électriques ont été proposés dans la littérature afin de simuler les cellules PV opérant sous diverses conditions. La complexité des modèles dépend du nombre de paramètres (R_s, R_{sh}, \dots) à identifier [Baouche et al. 2022]. Chaque modèle est essentiellement une amélioration du modèle idéal qui contient une source de courant représentant la puissance solaire incidente et une diode qui représente la jonction PN. Des éléments supplémentaires peuvent être ajoutés pour mieux rendre compte de la description du comportement de la cellule PV dans certains quadrants de fonctionnement de la Figure 2.3 [Dhass et al. 2022]. Les modèles les plus courants selon le nombre de leurs paramètres sont présentés et comparés ci-dessous :

- le modèle standard ;
- le modèle à une diode ;

- le modèle à deux diodes ;
- le modèle de Bishop.

Enfin, nous énumérerons quelques modèles mathématiques des cellules qui ont suscité quelque temps de l'espoir, avant de décrire la méthode de résolution du modèle retenu pour générer la caractéristique I-V.

2.3.1 Modèle standard

Ce modèle de la cellule PV est illustré à la Figure 2.4. Son principal avantage est le nombre très réduit de paramètres. En supposant sa résistance shunt R_{sh} infinie, on obtient très rapidement le courant de la caractéristique du circuit électrique par la relation (2.1) ci-dessous.




FIGURE 2.4 – Circuit électrique équivalent d'une cellule PV standard.

$$I = I_{ph} - I_0 \times \left[\exp\left(\frac{V + R_s I}{V_t}\right) - 1 \right] \quad (2.1)$$

avec les paramètres et constantes suivantes :

- le courant dans la cellule ;

$$I_{ph} = (I_{phn} + K_i \Delta_T) \frac{G}{G_n} \quad (2.2)$$

où $\Delta_T = T - T_n$

- le courant de saturation de la diode ;

$$I_0 = \frac{I_{scn} + K_i \Delta_T}{\exp\left(\frac{V_{ocn} + K_v \Delta_T}{V_t}\right)} - 1 \quad (2.3)$$

- la tension thermique de la diode.

$$V_t = \frac{ak_b T}{q} \quad (2.4)$$

avec

I_{phn} : le courant nominal de la cellule PV, donné dans les conditions nominales $T = 25^\circ C$ et $G = 1000 W/m^2$;

K_i : le coefficient courant/température de court-circuit ;

K_v : le coefficient de tension/température de circuit ouvert ;

T et T_n : les températures actuelle et nominale à $25^\circ C$;

G et G_n : respectivement l'éclairement actuel et nominal à $1000 W/m^2$;

I_{scn} : le courant de court-circuit nominal aux conditions de test standard $25^\circ C$ et $1000 W/m^2$;

V_{ocn} : la tension de circuit ouvert nominal ;

a : le coefficient d'idéalité de la diode ;

k_b : la constante de Boltzmann ;

q : la charge de l'électron ;

R_s : la résistance série de la cellule qui dépend des matériaux utilisés pour construire la cellule ;

R_{sh} : La résistance parallèle dont l'effet est plus grand dans la région de fonctionnement en sources de courant ;

2.3.2 Modèle à une diode

Le modèle à une diode est le modèle le plus couramment utilisé dans la littérature. Il est utilisé pour les cellules PV et les modules PV en raison de sa simplicité et sa bonne précision dans la zone II de production d'énergie par rapport au modèle standard. Le modèle électrique à une diode de la cellule PV est donné par la Figure 2.5 et son modèle mathématique par la relation (2.5).




FIGURE 2.5 – Circuit électrique équivalent d'une cellule PV à une diode.

$$I = I_{ph} - I_0 \times \left[\exp\left(\frac{V + R_s I}{V_t}\right) - 1 \right] - \left[\frac{V + R_s I}{R_{sh}} \right] \quad (2.5)$$

2.3.3 Modèle à deux diodes

Le modèle à deux diodes permet d'améliorer le modèle à une diode du fait qu'il prend en compte les pertes résistives et les mécanismes de recombinaison dans les différents composants électriques du circuit [Telidjane 2017].

Dans ce modèle, il y a une diode pour représenter les phénomènes de polarisation de la jonction PN. La seconde diode représente la recombinaison des porteurs minoritaires, d'une part en surface du matériau et d'autre part dans le volume du matériau [Belaout 2018]. Le schéma électrique du générateur photovoltaïque devient comme présenté dans la Figure 2.6 et se résumera mathématiquement dans la relation (2.6).




FIGURE 2.6 – Circuit électrique équivalent d'une cellule PV à deux diodes.

$$I = I_{ph} - I_{01} \times \left[\exp\left(\frac{V + R_s I}{V_t}\right) - 1 \right] - I_{02} \times \left[\exp\left(\frac{V + R_s I}{2V_t}\right) - 1 \right] + \left[\frac{V + R_s I}{R_{sh}} \right] \quad (2.6)$$

avec

I_{01} : le courant de saturation de la première diode ;

I_{02} : le courant de saturation de la seconde diode.

2.3.4 Modèle de Bishop

Lorsque la cellule PV est occultée, elle fonctionne dans le régime inverse (dans la région négative) [Bishop 1988], alors que les deux premiers modèles représentent uniquement chacun, deux cellules en fonctionnement normal de la zone I de la caractéristique de fonctionnement de la Figure 2.3. Ce qui ne prend pas en compte l'effet d'avalanche de la cellule. Ce fonctionnement qui s'explique uniquement en mode défaillant de la cellule ou du champ exige un modèle qui peut décrire la totalité de la caractéristique de la cellule dans ses quatre zones à savoir :

- zone I : fonctionnement normal ;
- zone II : fonctionnement en mode récepteur ;
- zone III : aucun fonctionnement autorisé ;
- zone IV : fonctionnement en régime inversé, car la cellule est occultée.

L'effet d'avalanche de la cellule n'est pris en compte que dans le modèle de Bishop et s'opère à travers le passage simultané de la cellule dans les trois zones ci-dessus citées. Sur le plan du modèle mathématique de la relation (2.7), il est amélioré en ajoutant un facteur multiplicatif $M(V1)$ représentant l'effet d'avalanche en série avec la résistance shunt (R_{sh}) [Bishop 1988, Kazem et al. 2020, Luo et al. 2017] et illustré sur la Figure 2.7




FIGURE 2.7 – Circuit électrique équivalent du modèle de Bishop d'une cellule PV.

$$I = I_{ph} - I_0 \times \left[\exp\left(\frac{V + R_s I}{V_t}\right) - 1 \right] - \left[\frac{V + R_s I}{R_{sh}} \right] \times M(V1) \quad (2.7)$$

avec l'effet d'avalanche représenté par la relation (2.8) :

$$M(V1) = 1 + k \left(1 - \frac{V + R_s I}{V_b} \right)^{-n} \quad (2.8)$$

avec :

- k : le coefficient de réglage de Bishop ($3, 4 \leq k \leq 4$) ;
- n : le coefficient de réglage de Bishop ($n \cong 0, 1$) ;

- V_b : la tension de claquage de la cellule ($-30 \leq V_b \leq -10$).

2.4 Modélisation mathématique du GPV

A travers la littérature, nous apprenons l'existence de trois modèles mathématiques, pour modéliser un générateur PV. Deux de ces modèles plutôt statistiques sont obtenus en faisant des relevés de mesures sur le générateur PV une fois installé. C'est le cas des modèles "Sandia" et "Cenerg". Le troisième modèle quant à lui, dit de "Madison", est obtenu de façon expérimentale en se basant sur les données fournies par les constructeurs.

2.4.1 Modèle de Sandia

Le modèle de module PV élaboré par le Sandia National Laboratory en Albuquerque aux USA, a permis à la fois de tester des modules, ainsi que d'estimer leur productivité [Kim et al. 2021, Pantic et al. 2016, Aghaei et al. 2022].

Les principaux avantages du modèle sont les suivants [Aghaei et al. 2022, Zarmai et al. 2015] :

- il prend en charge, la variation du spectre solaire en fonction de la position du soleil dans le ciel, et son influence sur le rendement photovoltaïque ;
- le modèle prend aussi en compte l'angle d'incidence du rayonnement direct sur le module PV. La face avant du module PV étant en général composée d'une vitre, celle-ci ne laisse pas passer le rayonnement de la même manière suivant l'angle d'incidence du rayonnement. Ce phénomène apparaît dès que l'angle d'incidence (par rapport à la normale au module PV) dépasse 60° [Aghaei et al. 2022].
- le modèle peut s'appliquer à la caractérisation d'un string PV constitué de plusieurs modules.

Les équations déterminantes se résument dans les relations (2.9) , (2.10) , (2.11) et (2.12) suivantes [Aghaei et al. 2022] :

$$I_{sc} = \frac{G}{G_n} \times f_1(AM).f_2(\beta).(I_{scr} + \mu_{Isc} \times (T_c - T_r)) \quad (2.9)$$

$$I_{MP} = C_0 + \frac{I_{sc}}{I_{scr}} \times (I_{MPr} + \mu_{IMP} \times (T_c - T_r)) \quad (2.10)$$

$$V_{oc} = V_{ocr} + C_1 \times \ln \frac{I_{sc}}{I_{scr}} + \mu_{Voc} \times (T_c - T_r) \quad (2.11)$$

$$V_{MP} = V_{MPr} + C_2 \times \ln \left(\frac{I_{sc}}{I_{scr}} \right) + C_3 \times \left[\ln \left(\frac{I_{sc}}{I_{scr}} \right) \right]^2 + \mu_{VMP} \times (T_c - T_r) \quad (2.12)$$

avec

T_c et T_r : respectivement la température de la cellule et la température de référence en [K] ;

AM : le nombre d'air-masse ;

β : l'angle d'incidence entre le rayonnement direct du soleil et la normale au plan du module PV ;

f_1 : la fonction du nombre d'air-masse ;

f_2 : la fonction de l'angle d'incidence du rayonnement sur le module PV ;

I_{scr} : le courant de court-circuit de référence [A];
 V_{ocr} : la tension de circuit-ouvert de référence [V];
 V_{MP_r} : la tension du point de puissance maximale de référence [V];
 I_{MP_r} : le courant du point de puissance maximale de référence [A];
 μ_{Isc} : le coefficient de dépendance en température du courant de court-circuit [A/K];
 μ_{Voc} : le coefficient de dépendance en température de la tension de circuit-ouvert [V/K];
 μ_{VMP} : le coefficient de dépendance en température de la tension de puissance maximale [V/K];
 μ_{IMP} : le coefficient de dépendance en température du courant de puissance maximale [A/K];
 C_0, C_1, C_2, C_3 : les coefficients déterminés expérimentalement.

2.4.2 Modèle du Cenerg

Le modèle développé par le Centre Energétique (Cenerg) se base sur le modèle à une diode. Un bilan électrique sur ce schéma permet d'établir une expression donnant le courant I en fonction de la tension V disponible aux bornes du générateur PV à travers la relation (2.13)

$$I = P_1 G [1 + P_2 (G - G_n) + P_3 (T_j - T_{ref})] - \left[P_4 T_j^3 \exp\left(\frac{-E_g}{kT_j}\right) \right] \left[\exp\frac{q(V + R_s I)}{a N_c k T_j} - 1 \right] - \frac{V + R_s I}{R_{sh}} \quad (2.13)$$

avec

I : l'intensité qui traverse le capteur de courant [A];
 V : la tension aux bornes du capteur de tension [V];
 T_j : la température de jonction du capteur PV [K];
 T_{ref} : la température de référence [K];
 $P_1, P_2, P_3, et P_4$: les paramètres à déterminer expérimentalement;
 N_c : le paramètre d'ajustement, est égal au nombre de cellules en série (36 par exemple) pour un module PV parfait;
 E_g : 1.12 eV pour le silicium cristallin est le gap du matériau utilisé;

Les coefficients $P_1, P_2, P_3, P_4, R_s, et R_{sh}$ sont déterminés expérimentalement. Le calcul de la puissance électrique P fournie aux bornes des capteurs d'instrumentation se fait en multipliant la tension V par le courant I calculé dans la relation (2.13).

Ce modèle a été validé expérimentalement par le Centre d'Energétique à Sophia Antipolis [Joshi et al. 2017]. Dans tous les cas, la différence entre calculs et résultats expérimentaux pour la productivité électrique est inférieure à 5% [Belaout 2018].

Lors de la caractérisation du champ de modules, et donc de la mesure des différents coefficients, il est noté que ces coefficients intègrent les pertes électriques dues aux "*Pertes de Mismatch*" (dissymétrie entre modules) ainsi que les pertes dans les connexions. La puissance électrique perdue est estimée à environ 3%.

Avec ce modèle, la problématique reste la même que dans le cas du modèle Sandia, à savoir que les paramètres expérimentaux permettent une caractérisation plus fiable du système PV, mais cela nécessite une phase de mesures relativement lourde [Belaout 2018, Dhoke et al. 2018].

2.4.3 Modèle de Madison.

A l'image de son prédécesseur, ce modèle est aussi basé sur le modèle électrique des cellules à une diode. Il a été développé par l'Université de Madison, pour la programmation d'un module PV appelé PHANTASM [Fouad et al. 2017] en parallèle au programme de simulation thermique de bâtiment TRNSYS [Kim et al. 2021, Ringkjøb et al. 2018]. Par contre, le modèle développé propose une méthode qui permet de calculer les performances du module PV à partir des données fournies par les constructeurs. L'équation qui donne l'intensité I en fonction de la tension V aux bornes du module est donnée par la relation (2.14) :

$$I = I_{ph} - I_0 \times \left[\exp\left(\frac{V + R_s I}{V_t}\right) - 1 \right] - \left[\frac{V + R_s I}{R_{sh}} \right] \quad (2.14)$$

La relation (2.14) du modèle de Madison fait apparaître trois termes équivalents aux trois termes de la relation (2.13) du modèle du Cenerg. Il existe quelques différences à noter entre les deux modèles [Belaout 2018] :

- le premier terme de l'équation du modèle du Cenerg (équivalent au photo courant I_{ph} du modèle "Madison") $P_1 G [1 + P_2 (G - G_n) + P_3 (T_j - T_{ref})]$ est fonction de la température de jonction T_j , et dépend d'un terme en G^2 , ce qui n'est pas le cas pour l'expression du photo courant du modèle de Madison. Pour ce calcul, le modèle de Madison utilise une hypothèse simplificatrice qui fait que le photo courant est proportionnel au rayonnement incident G de la relation (2.2), et qu'il ne dépend pas de la température T_j ;
- le second terme du modèle du Cenerg ou de Madison, représente le courant traversant une diode, dans le cas du modèle standard ;
- le calcul du troisième terme du modèle de Madison $\left[\frac{V + R_s I}{R_{sh}} \right]$, à savoir le courant traversant la résistance shunt (R_{sh}), fait intervenir la tension aux bornes de la résistance série (R_s). Cette résistance série n'intervient pas dans l'équation du modèle du Cenerg, car dans ce modèle pour calculer l'intensité traversant la résistance shunt (R_{sh}), la tension aux bornes de la résistance série est négligée.

2.5 Choix du modèle de la cellule PV

En rappel parmi les modèles utilisés pour décrire le circuit électrique équivalent de la cellule PV [Fadhel et al. 2016], nous pouvons retenir entre autre le :

- le modèle empirique ;
- le modèle à une seule diode ;
- le modèle à deux diodes ;
- le modèle de Bishop.

Le modèle le plus utilisé par certains chercheurs, est le modèle à une seule diode avec ses cinq paramètres, représentant le comportement électrique de la jonction P-N. Le modèle à deux diodes avec ses sept paramètres, donne plus de détails sur le processus de recombinaison des porteurs de charge de surface et de volume. Le modèle empirique avec ses trois paramètres est le plus adapté sur la caractéristique I-V mesurée, et en plus il a moins de paramètres que les autres modèles. Les modèles mathématiques se révèlent plus contraignants à cause de la lourdeur d'instrumentation et de calcul qu'ils nécessitent.

Enfin, le modèle de Bishop avec ses huit paramètres, reste le seul capable de prendre en compte l'effet de la tension de claquage, mais aussi et surtout l'effet de la cellule travaillant dans le régime inverse de fonctionnement. Ce subtil passage entre les trois zones de la caractéristique I-V d'une cellule, est plus connu sous le nom d'effet d'avalanche.

Le modèle simple, peut simuler le comportement de la cellule PV uniquement dans la zone I c'est-à-dire en fonctionnement sans défaut, parce que là on n'a besoin que de la caractéristique directe de la cellule PV, alors que le modèle de Bishop peut être utilisé afin de décrire la cellule en fonctionnement dans le régime inverse, un nouveau terme ajouté par Bishop qui rend le modèle de la cellule PV plus proche de sa réalité, c'est l'effet d'avalanche. La présence d'un défaut dans une cellule PV parmi d'autres pousse cette dernière à fonctionner dans le régime inverse [Compaoré et al. 2021 a., Sebbane et al. 2022, Fernández-Solas et al. 2021, Fadhel et al. 2016].

Notre choix sur le modèle de Bishop tient compte prioritairement de l'objectif d'approcher le comportement réel du générateur PV à travers la cellule PV. Cette prise en compte de l'environnement réel de travail de la cellule PV se traduit surtout par sa capacité à prendre en compte, une quelconque variation de l'un de ses paramètres de modélisation sur les états de fonctionnement du GPV.

2.6 Synoptique d'un système photovoltaïque

Un système PV isolé ou connecté au réseau peut être représenté par le synoptique électrique de la Figure 2.8. On peut distinguer les composantes suivantes :

- un générateur PV : unité de production d'énergie électrique sous forme de tension continue ;
- un ensemble de câblage et boîte de jonction, comportant les diodes anti-retour ;
- un convertisseur ;
- un compteur d'énergie, avant la distribution sur site isolé ou raccordé à un réseau.

2.6.1 Générateur PV

Le générateur photovoltaïque est l'unité de production d'énergie électrique sous forme de tension continue. L'élément de base de cette unité qui convertit l'énergie solaire en l'énergie électrique est la cellule photovoltaïque suivant le modèle de Bishop. Le module est composé de rangées de 36 cellules protégées par une diode de bypass. Le string est obtenu par la mise en série de modules, et le champ est obtenu par la mise en parallèle d'un certain nombre de strings.

2.6.2 De la cellule au Module PV

La tension et le courant, donc la puissance, d'une cellule ne sont pas adaptées aux applications courantes, il est donc nécessaire de les associer. De plus, les cellules photovoltaïques sont fragiles et sensibles à l'environnement extérieur, elles sont donc munies d'une protection mécanique (l'encapsulation). Pour toutes ces raisons, les cellules sont assemblées en module photovoltaïque comme illustré sur la Figure 2.9.

En mettant des cellules identiques en série, le courant de la branche reste le même, mais la tension augmente proportionnellement au nombre des cellules en série, pour obtenir la tension

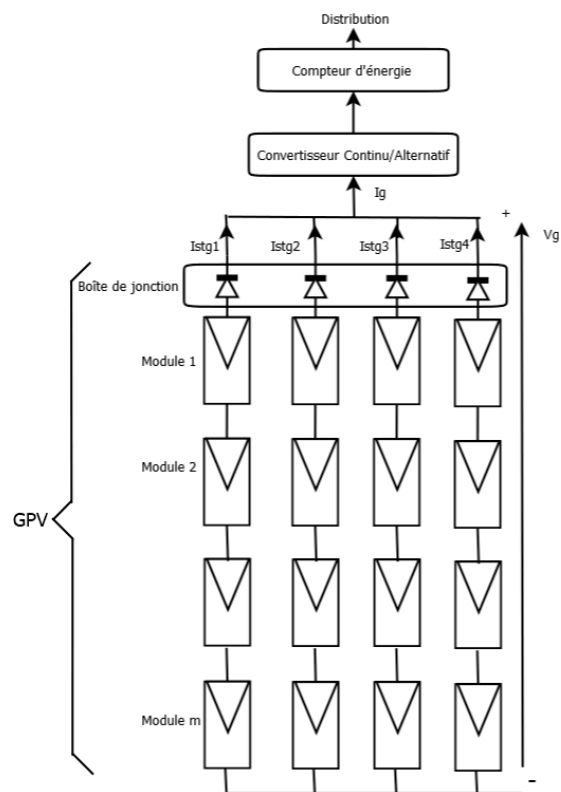


FIGURE 2.8 – Synoptique électrique d'un système PV.




FIGURE 2.9 – Cellules regroupées dans un module, protégées par une diode de by-pass.

de sortie du module comme illustrée sur la figure 2.10a. La puissance quant à elle sur la Figure 2.10b, augmente à cause de l'augmentation de la tension.

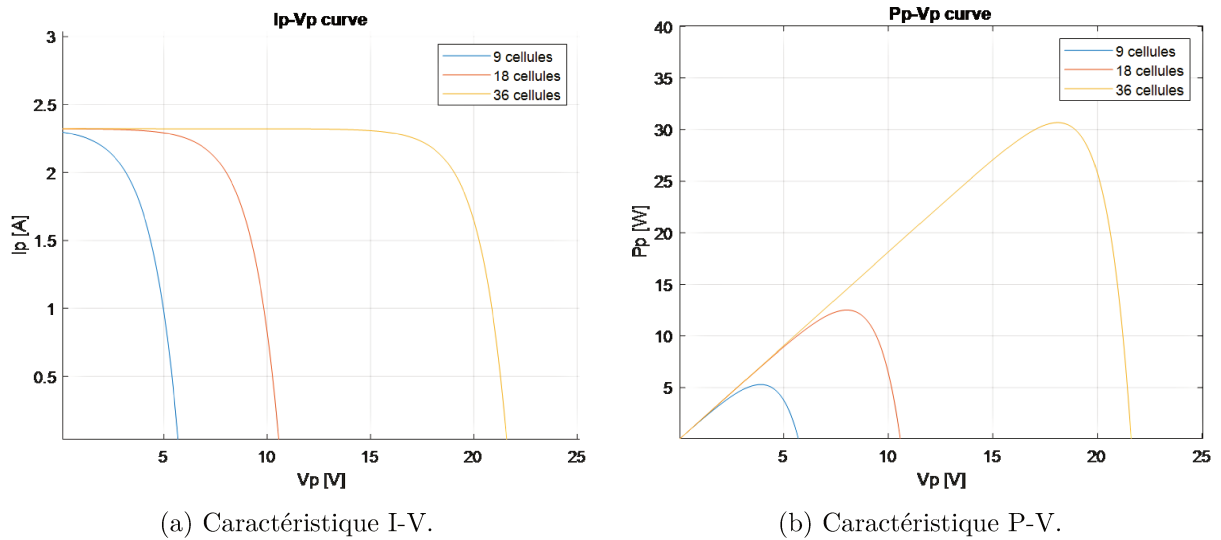


FIGURE 2.10 – Caractéristiques de 9, 18 et 36 cellules mis en série.

On tire alors l'ensemble des relations (2.15) suivantes :

$$\begin{cases} I_c = I \\ V_m = V_c \times N_{Cell} \\ P_m = V_c \times I \times N_{Cell} \end{cases} \quad (2.15)$$

avec

$I = I_c$: le courant fourni par la cellule PV ;

V_c : la tension aux bornes de la cellule PV ;

V_m : la tension aux bornes du module PV ;

P_m : la puissance du module ;

N_{Cell} : le nombre de cellule en série dans le module PV ;

Un module PV « classique » contient 36 à 72 cellules. Mais ce nombre de cellules peut varier selon les modules servant aux applications spécifiques. On peut trouver des modules de 40, 54, 60 ou même 92 cellules en série [Zarmai et al. 2015, Dhoke et al. 2018, Akhsassi et al. 2016, Zerdoudi et al. 2015]. La Figure 2.11 montre un module contenant 36 cellules interconnectées en série.




FIGURE 2.11 – Mise en série de 36 cellules protégées par deux diodes de bypass.

Les cellules dans un module sont associées en plusieurs groupes. Chaque groupe est ensuite

connecté en antiparallèle avec une diode, appelée diode de bypass. Cette diode sert à protéger les cellules contre leur fonctionnement dans le régime inverse.

On compte généralement 18 cellules protégées par une diode de bypass. Par contre, ce nombre peut varier selon les différents fabricants des modules. Par ailleurs, pour mieux protéger les cellules, la connexion de chaque cellule individuelle à une diode de bypass a été également proposée. Il existe d'autres architectures de connexion des diodes de bypass par module, largement étayées dans la littérature [Pachauri et al. 2020, Vieira et al. 2020, Quaschnig 2016], et qui sont rarement appliquées du fait de la difficulté de fabrication, comme sur la Figure 2.12.

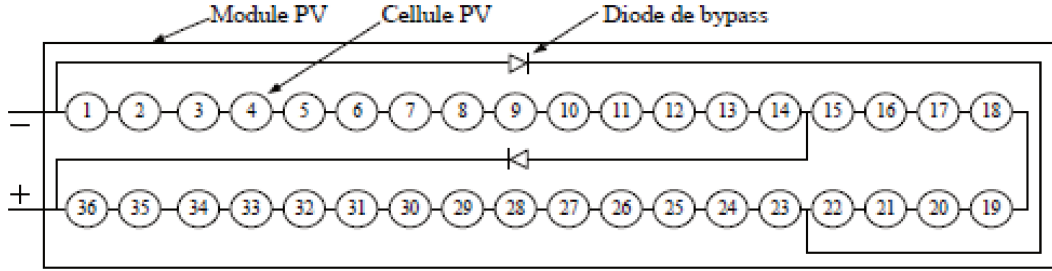


FIGURE 2.12 – Module PV avec deux diodes de bypass en overlap.

2.6.3 Du module aux strings de module PV

La mise en série des modules pour constituer des strings, augmente la tension générale de sortie du GPV mais pas le courant comme illustré sur la Figure 2.13a. La puissance quant à elle sur la Figure 2.13b augmente dans ce cas, à cause de l'augmentation de la tension.

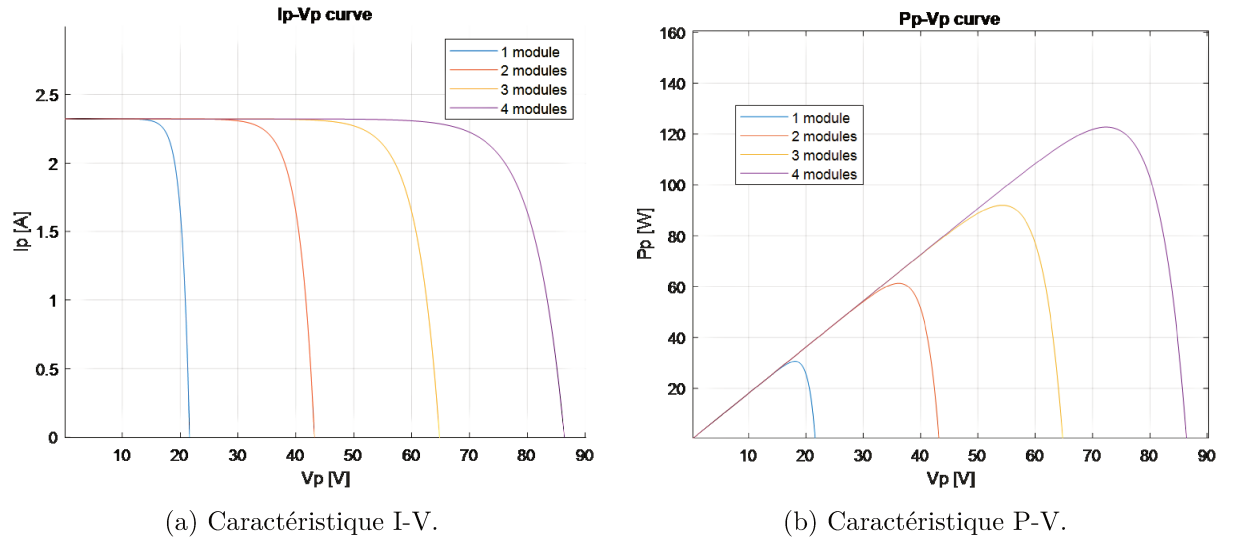


FIGURE 2.13 – Caractéristiques de modules placés en série.

On a déduit l'ensemble des relations (2.16) suivantes :

$$\begin{cases} I_{stg} = I \\ V_{stg} = V_m \times N_s \\ P_{stg} = V_m \times N_s \times I \end{cases} \quad (2.16)$$

avec

I_{stg} : le courant du string ;

V_{stg} : la tension aux bornes du string ;

P_{stg} : la puissance du string ;

N_s : le nombre de module en série ;

2.6.4 Du string au générateur PV

Un générateur PV est la résultante de l'association hybride (série et parallèle), tant des cellules que des modules. Il est généralement constitué de plusieurs strings mis en parallèle. Il permet ainsi d'augmenter de façon substantielle le courant, la tension et la puissance générale du générateur ainsi créé, comme illustré sur la Figure 2.14 et résumé dans les relations (2.17).

Les résultats de la simulation ci-dessous, ont été obtenus par la mise en série de 2, 3 et 4 modules, pour augmenter la tension de sortie, suivie de la mise en parallèle avec 2, 3 et 4 strings pour mieux apprécier l'augmentation du courant général de sortie sur la Figure 2.14a. L'augmentation de la puissance du GPV, s'observe sur la Figure 2.14b en fonction des configurations.

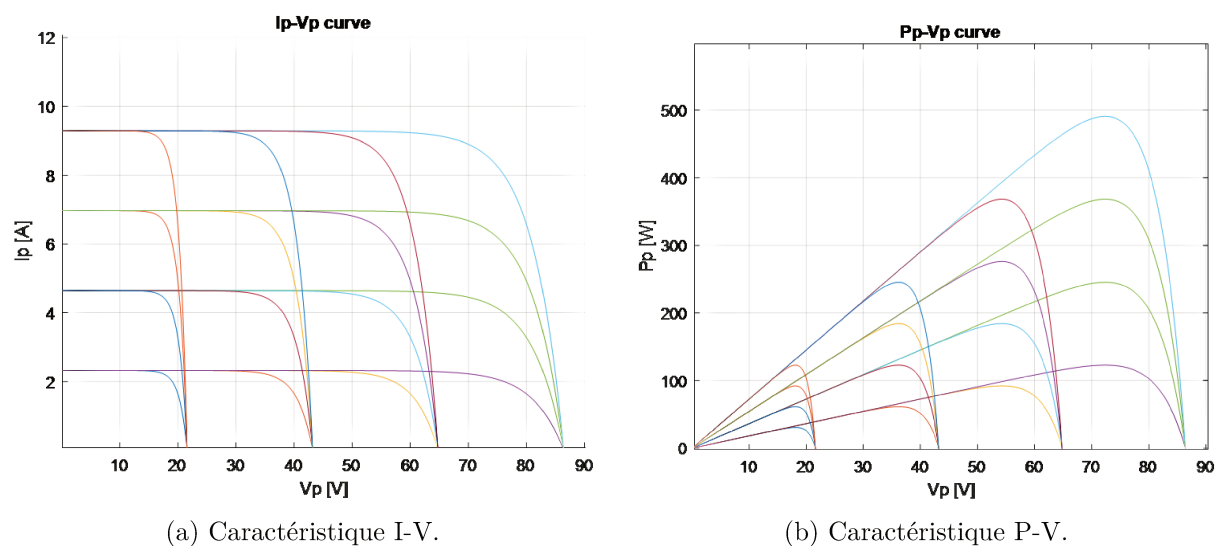


FIGURE 2.14 – GPV de plusieurs strings avec des modules PV organisé en 36 cellules.

On a déduit l'ensemble des relations (2.17) suivantes :

$$\begin{cases} I_G = I \times N_p \\ V_G = V_c \times N_{Cell} \times N_s \\ P_G = V_G \times I_G \end{cases} \quad (2.17)$$

avec

I_G : le courant général du générateur PV ;

V_G : la tension aux bornes du générateur ou champ PV ;

P_G : la puissance générale du GPV ;

2.6.5 Fonctionnement au point MPPT

Un champ photovoltaïque peut être caractérisé par ses caractéristiques statiques I-V, ou P-V. De telles caractéristiques d'un champ PV en fonctionnement normal sont illustrées dans la Figure 2.15. Cette caractéristique s'étend du point de tension de circuit ouvert (V_{oc}) au

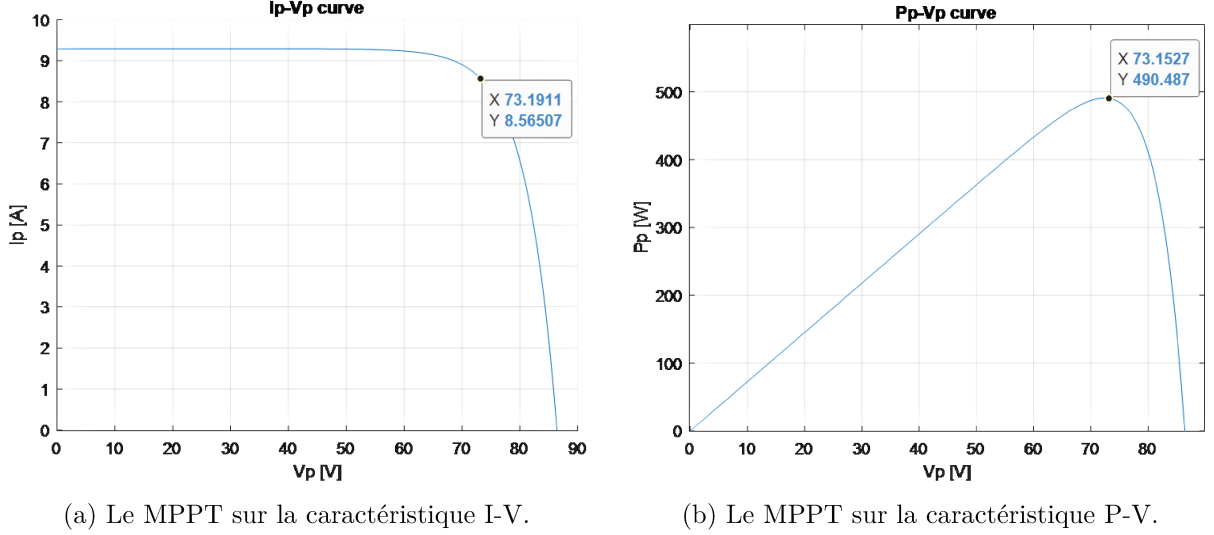


FIGURE 2.15 – GPV matérialisé au point MPPT.

point de courant de court-circuit (I_{sc}). Pour récupérer le maximum de puissance, le champ PV fonctionne normalement au point de la puissance maximale (MPP). Le rôle du MPPT est de faire fonctionner le générateur PV à ce point MPP.

De nombreux algorithmes de MPPT ont été proposés dans la littérature pour la recherche du point MPP [Singh et al. 2015]. Ces algorithmes diffèrent les uns des autres en termes de :

- vitesse de convergence vers le point de MPPT ;
- capacité de trouver le vrai point de MPP ;
- grandeurs mesurées ;
- implémentation.

Par souci d'efficacité, nous imposons à notre modèle de fonctionner au point de MPPT. Aussi nous définissons ce point MPPT comme deux droites tangentes aux points pouvant être placés sur les caractéristiques de la Figure 2.15.

Pour élaborer la caractéristique I-V de la cellule, il faut résoudre l'équation du courant général de sortie du générateur de la relation (2.18) du modèle de Bishop [Bishop 1988], qui ne peut pas être résolue analytiquement, mais mise sous la forme $f(V, I) = 0$. Pour cela nous utilisons la méthode classique de Newton-Raphson [Sebbane et al. 2022], sous Matlab. Elle consiste alors à calculer la valeur de l'une des inconnues (V ou I) en fonction de l'autre, en supposant que les autres paramètres de l'équation sont connus. Les cellules étant mises en série, il est préférable de calculer I à partir de V de la relation (2.18) [Rezgui et al 2014 a.].

$$I_G - N_p \times [I_{ph} - I_0 \left[\exp\left(\frac{V + R_s I}{V_t}\right) - 1 \right]] - \frac{V + R_s I}{R_{sh}} \times \left[1 + k \left(1 - \frac{V + R_s I}{V_b} \right)^{-n} \right] = 0 \quad (2.18)$$

Pour chaque tension donnée $V(k)$, on essaie de calculer le courant correspondant $I(k)$ par

itérations avec la relation (2.19)

$$I(k) = I(k) - \frac{f(I(k))}{f'(I(k))} \quad (2.19)$$

En utilisant les relations (2.7), (2.8), (2.18) et (2.19) de la modélisation GPV, pour tenir compte de son caractère non linéaire, nous générons les caractéristiques courant-tension ($I-V$), et puissance-tension ($P-V$). Les simulations permettent alors de mieux jauger le comportement sain puis dégradé du GPV recherché, car la modification de certains paramètres tels que : R_s , R_{sh} , T , G et N_{cell} dégradent les performances.

2.7 Interconnexion et jonction

Grâce à un câblage, la mise en série de plusieurs modules est effectuée pour constituer un string. Afin de minimiser les risques de défaut à la terre ou de court-circuit après l'installation, l'utilisation de câbles à simple conducteur avec double isolation est fortement recommandée [Zeb et al. 2018].

Des connecteurs débroschables peuvent être utilisés pour simplifier la procédure d'installation tout en renforçant la protection contre les risques de choc électrique.

Si le système PV est constitué de plusieurs strings, une boîte de jonction permet leur mise en parallèle.

2.8 Système de protection

Plusieurs sortes de protection peuvent être utilisées sur une installation photovoltaïque, à l'image des autres installations électriques : protection des intervenants, protection contre la foudre, protection du générateur PV. Etant amené à parler des défauts ou des anomalies conduisant à une baisse de production, nous ne nous intéressons donc qu'aux composants servant à la protection du générateur PV.

2.8.1 Diode de bypass

Comme dit plus haut précédemment, la diode de bypass est connectée en antiparallèle avec un groupe de cellules pour protéger les cellules les plus faibles contre la polarisation inverse (confère Figure 2.16). Nous aborderons ce rôle de protection dans la partie liée aux défauts.

2.8.2 Diode anti retour

La tension produite par chaque string peut être différente. Lors de la mise en parallèle de ces strings pour former un champ, le string avec la tension la plus faible peut absorber un courant inverse provenant des autres strings. Cela conduit donc à une baisse de production et les modules du string traversés par le courant inverse pourraient être également susceptibles de défaillance. Pour éviter ces courants inverses, une diode anti retour est placée au bout de chaque string comme sur la Figure 2.16.

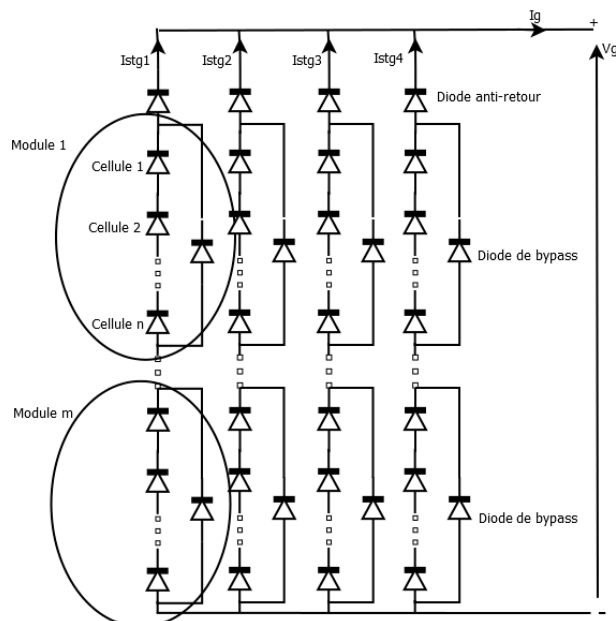


FIGURE 2.16 – Protection d'un générateur par diode de bypass et diode anti retour.

L'utilisation de la diode anti retour introduit pourtant une perte dans la production du fait de la chute de tension causée par cette diode pendant le fonctionnement normal du générateur PV. De plus, ces diodes peuvent tomber en panne. Aussi un contrôle régulier s'impose.

Par contre, l'utilisation du fusible en lieu et place de la diode anti retour, ne protège pas le string contre le courant inverse. Le fusible doit être dimensionné afin que les composants du string (module, câble, connecteur) puissent supporter l'intensité du courant inverse lorsque ce dernier existe [Sebbane et al. 2022].

Le choix de l'un des deux composants réside donc sur la tolérance entre la perte en fonctionnement normal (pour le cas d'utilisation de la diode anti retour) et la perte causée par le courant inverse (lors de l'utilisation du fusible).

2.9 Défauts dans le système photovoltaïque

La productivité d'un SPV se juge à travers sa disponibilité et à sa performance. Les pertes liées à la capacité de production d'un SPV peuvent être liées à la température ou à l'ensoleillement ou au champ PV lui-même, et qui peuvent surtout se situer dans :

- la captation qui est non optimisée ;
- la dispersion entre les modules du générateur ;
- l'extraction non optimale de la puissance ;
- le vieillissement des panneaux ;
- les pertes joules dues aux câblages.

À ces pertes normales peuvent s'ajouter les défauts et défaillances des composants de la chaîne de conversion, affectant du coup la performance de la chaîne de production PV de la Figure 2.16, dont l'indice de performance est de l'ordre de 0,6 à 0,8 quand le champ PV fonctionne bien [Kim et al. 2021, Munoz et al. 2011].

2.9.1 Chaîne fonctionnelle d'un SPV

Les principaux défauts et anomalies dans un SPV sont au nombre de 50, mais grâce au retour d'expérience des industriels, une liste restreinte a pu être confirmée par [Bosman et al. 2020, Gorjian et al. 2021] et validée dans une brève sélection par [Parizad et al. 2018], et dont la criticité et la force d'occurrence les plus élevées étaient les critères mis en avant.

Le critère de sélection de ces défauts repose sur le produit entre la criticité et l'occurrence. Suite au retour d'expérience de Trans énergie, les défauts avec un score supérieur ou égal à 3 ont été retenus et sont listés dans le Tableau (2.1). C'est pour le moment une simple liste de défauts issue du critère que nous avons retenu. Nous n'allons pas chercher à discriminer complètement ces défauts. Nous tenterons également de faire autant que possible le lien entre ces défauts et les paramètres de notre modèle.

TABLE 2.1 – Défauts et anomalies d'un générateur PV.

Parties du générateur PV	Origines de défauts et d'anomalies
Générateur PV	<ul style="list-style-type: none"> - Feuilles d'arbre, déjections, pollution, sable, neige etc ; - Détérioration des cellules, fissures ; - Echauffement des cellules ; - Pénétration de l'humidité, corrosion des liaisons entre les cellules ; - Dégradation des interconnexions ; - Modules de performances différentes ; - Module arraché ou cassé ; - Modules court-circuités, modules inversés.
Boîte de jonction	<ul style="list-style-type: none"> - Rupture du circuit électrique ; - Court-circuit du circuit électrique ; - Destruction de la liaison ; - Corrosion des connexions.
Câblage et connecteur	<ul style="list-style-type: none"> - Circuit ouvert ; - Court-circuit ; - Mauvais câblage (module inversé) ; - Corrosion des contacts ; - Rupture du circuit électrique.
Diode de protection (diode de bypass et diode anti-retour)	<ul style="list-style-type: none"> - Destruction des diodes ; - Absence ou non fonctionnement de diodes ; - Inversion de la polarité des diodes au montage ; - Diode mal connectée.

Nous pouvons alors déduire la chaîne fonctionnelle suivant le diagramme d'Ishikawa de la Figure 2.17, qui permet de voir l'impact de la bonne santé d'un GPV en fonction des différents aléas pouvant intervenir durant son cycle de vie.

Le diagnostic peut se faire à deux niveaux par des méthodes :

- non électriques du type :
 - destructifs ;
 - non destructifs ;
- électriques du type :
 - courant, I ;
 - tension, V ;
 - résistance, R_s .

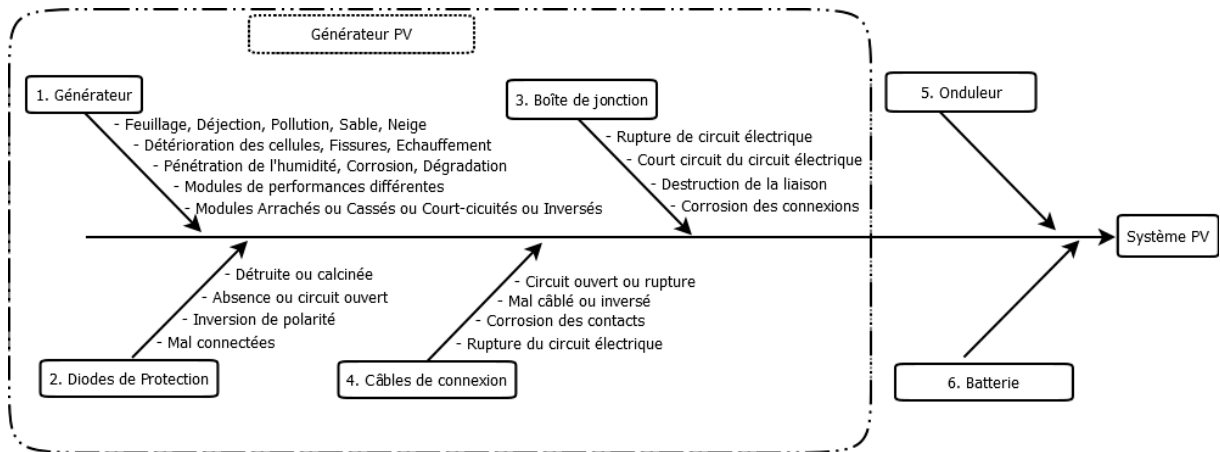


FIGURE 2.17 – Chaîne fonctionnelle d'un système PV.

Le Tableau (2.2) propose une synthèse des différentes méthodes de diagnostic permettant de mettre à jour ce qui se fait de mieux pour le diagnostic des système PV.

TABLE 2.2 – Comparaison des méthodes de diagnostic.

Défaut	Mesures	Méthode	Capacité de détection / localisation	En ligne ou hors ligne	Finesse du diagnostic
<ul style="list-style-type: none"> - Courant de fuite ; - Augmentation de la résistance de connectique ; - Echauffement anormal des cellules ou des modules ; - dysfonctionnement des diodes de bypass ou anti retour. ; 	Image	Imagerie infrarouge	localisation	Hors ligne	cellules
<ul style="list-style-type: none"> - Circuit ouvert - Court circuit - Augmentation de l'impédance de la connectique 	Signal réfléchi	Méthode de réflectométrie	localisation	Hors ligne	Strings

Défaut	Mesures	Méthode	Capacité de détection / localisation	En ligne ou hors ligne	Finesse du diagnostic
Famille de défauts non discriminable t	I, V, G, T	Analyse de la puissance et de l'énergie	DéTECTABLE, localisable	En ligne	Champ
- Modules défectueux - Strings défectueux - Fausses alertes - Court circuit	I, V, G, T	Analyse du MPPT	DéTECTABLE, localisable	En ligne	Champ
- Courant	IV et PV	Analyse de la caractéristique I-V	DéTECTABLE, localisable	Hors ligne	Modules, Strings, Champ.

L'analyse critique de toutes les méthodes de diagnostic [Sebbane et al. 2022], met plus l'accent sur l'analyse de la Puissance. Malheureusement force est de constater qu'on peut incriminer uniquement une famille de défauts mais pas la localiser individuellement.

Quant à l'analyse s'appuyant sur la caractéristique I-V, il existe 2 freins majeurs : le manque d'une base de données pertinente sur la causalité des défauts et surtout la difficulté d'obtenir en ligne la fameuse caractéristique I-V.

Une piste s'offre alors ici, pour le choix et l'implémentation d'une méthode de diagnostic à base de modèle.

2.9.2 Classification des défauts et d'anomalies d'un champ PV

A travers ce paragraphe, nous confortons comme tant d'autres auteurs [Sebbane et al. 2022, Compaoré et al. 2021 a., Martín-Chivelet et al. 2022], à travers le Tableau (2.3), la relation qui s'établit explicitement entre certaines anomalies et le comportement du GPV suite à une dégradation de certains paramètres du modèle du générateur.

2.9.3 Impact des différents défauts sur la courbe de la caractéristique

La dégradation de l'état de l'un des paramètres du GPV peut conduire à une défaillance des performances du générateur. C'est essentiellement le cas pour une variation de l'un des paramètres tels que la résistance série, la résistance shunt, la température, l'ensoleillement, l'inclusion d'un ou plusieurs modules dont le nombre de cellules utilisées est différente de celui de la configuration des autres modules.

Les différents scénarii de simulation ci-dessous, reflet des manifestations réelles des défauts et leurs impacts sur la caractéristique I-V allant de la cellule aux champs, sont organisés sur le principe de la variation de l'un des paramètres du modèle.

TABLE 2.3 – Relation entre anomalies et défauts d'un générateur PV.

Composant du champ	Nature des défauts	Dénomination de défaut
1. Cellules	<ul style="list-style-type: none"> - Module arraché ou cassé ; - Pylône, cheminée, sable, neige etc ; - Dégradation des connexions ; - Fissure, bris de verre ; - Corrosion des liaisons entre cellules ; - Modules de performances différentes ; - Détérioration des cellules ; - Pénétration de l'humidité ; - Echauffement. 	Défaut de mismatch ou d'ombrage
2. Groupe de cellules	<ul style="list-style-type: none"> - Destruction des diodes ; - Absence de diodes ; - Inversion de la polarité des diodes ; - Diodes mal connectées ; - Diodes court-circuitées . 	Défauts de diode de bypass
3. Module	<ul style="list-style-type: none"> - Modules court-circuités ; - Inversion de polarité du module ; - Module shuntés ; - Délamination, décoloration. 	Défaut de module
4. String	<ul style="list-style-type: none"> - Rupture du circuit électrique ; - Destruction de la liaison ; - Corrosion des connexions ; - Corrosion des contacts ; - Court-circuit du circuit électrique ; - Module déconnecté ; - PID, terre ; 	Défaut de connectique
5. Champ	<ul style="list-style-type: none"> - Destruction des diodes ; - Absence de diodes ; - Inversion de la polarité des diodes ; - Diodes mal connectées ; - Diodes court-circuitées ; - Diodes en circuit ouvert ; - Haute impédances . 	Champ

2.9.3.1 Défaut de Mismatch ou d'ombrage

Le défaut de Mismatch ou d'ombrage, affecte essentiellement les paramètres du modèle du GPV et est observable sur la caractéristique I-V. Il est recensé dans le Tableau (2.4).

L'ensemble des simulations de chaque scénario, se fait sur un générateur configuré en 4 strings avec 4 modules de 36 cellules en série par string. Chacune des caractéristiques I-V et P-V du GPV, représente un défaut probable en lien avec l'un des quatre scénarii ci-dessous : variation de R_s ; variation de R_{sh} ; variation de T ; variation de G .


Variation de R_s

Les caractéristiques I-V et P-V de la Figure 2.18, sont la résultante de la variation de la résistance série R_s de $0,015 \Omega$ à 2Ω puis à 4Ω . Elles montrent le déplacement du MPPT, qui engendre une perte de puissance sur la Figure 2.18b due à la baisse de la tension sortie du

TABLE 2.4 – Relations entre défaut et paramètres du générateur PV.

Nature des défauts	Paramètres affectés
- Module arraché ou cassé ; - Ombrage : feuille d'arbre, neige, déjection, sable, pollution.	Variation de I_{ph}
- Echauffement des cellules ; - Délamination ; - Décoloration .	Variation de T ou G
- Dégradation des interconnexions ; - Fissure, bris de verre ; - Corrosion des liaisons entre cellules ;	Variation de R_s
- Module de performances différentes ; - Détérioration des cellules ; - Pénétration de l'humidité ;	Variation des paramètres des cellules, mais en particulier de R_{sh}

générateur sur la Figure 2.18a suite à une forte augmentation de la résistance série.

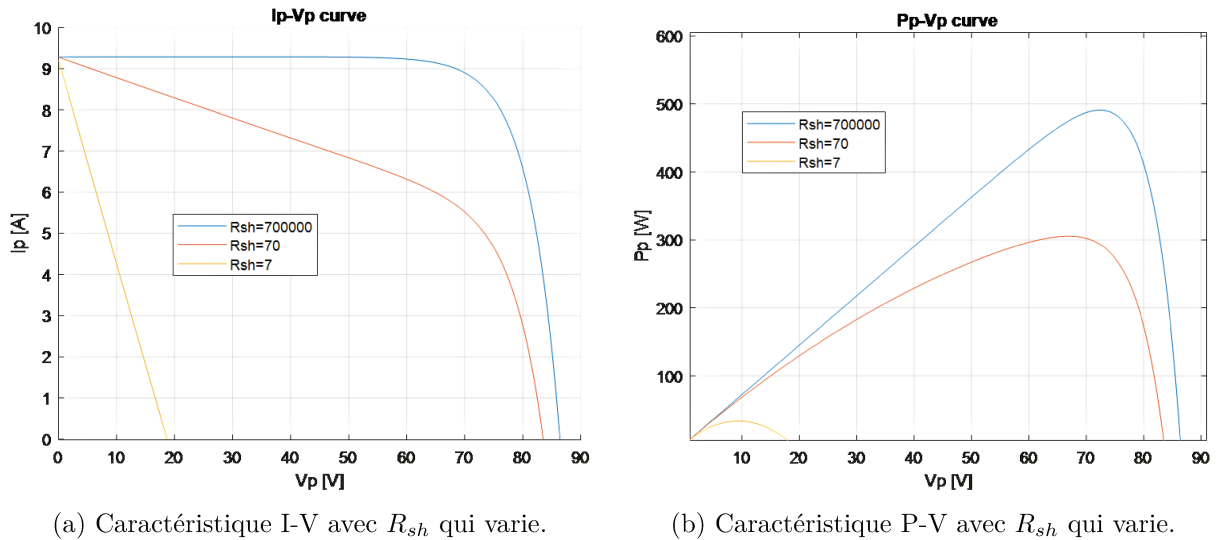
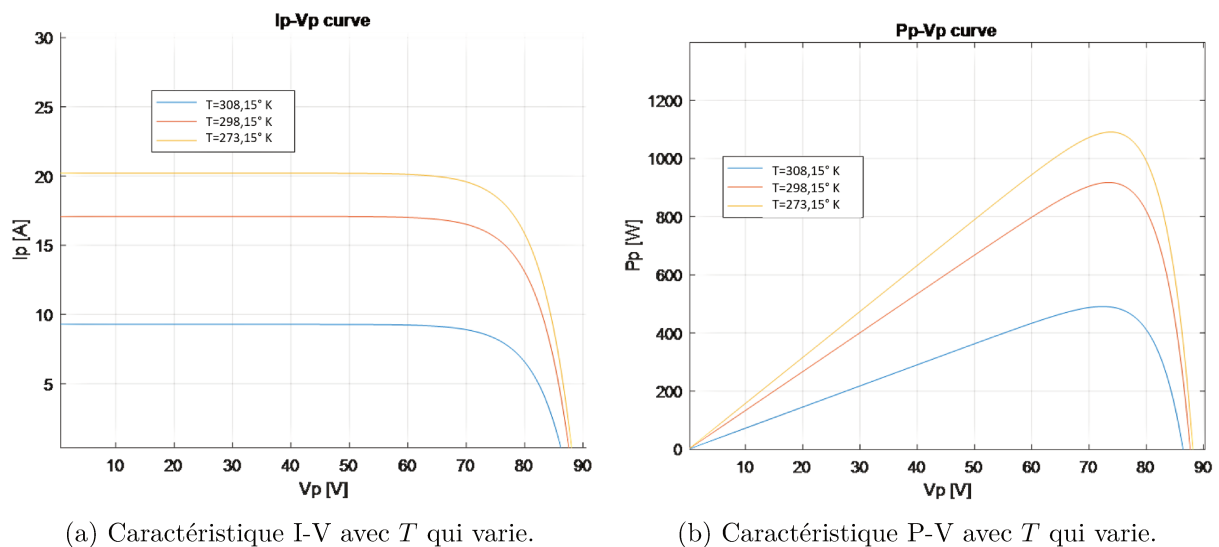
(a) Caractéristique I-V avec R_s qui varie.(b) Caractéristique P-V avec R_s qui varie.FIGURE 2.18 – GPV avec des modules de 36 cellules avec variation de R_s .

Variation de R_{sh}

La Figure 2.19a de la caractéristiques I-V et la Figure 2.19b de la caractéristique P-V, sont la résultante de la variation de la résistance shunt R_{sh} de 700 000 Ω à 70 Ω puis à 7 Ω . Elles montrent le déplacement du MPPT, qui engendre une perte de puissance due à la fois à la baisse de la tension et au courant de sortie du générateur, suite à une forte diminution de la résistance shunt.

Variation de T

Les caractéristiques I-V et P-V des Figures 2.20a et 2.20b sont la résultante de la variation de la température de 35° à 25° puis à 0°C. Elles montrent le déplacement du MPPT, qui engendre une perte de puissance due à la fois à la baisse de la tension et au courant de sortie du générateur suite à l'augmentation de la température incidente sur le générateur.

FIGURE 2.19 – GPV avec des modules de 36 cellules avec variation de R_{sh} .FIGURE 2.20 – GPV avec des modules de 36 cellules avec variation de T .

Variation de G

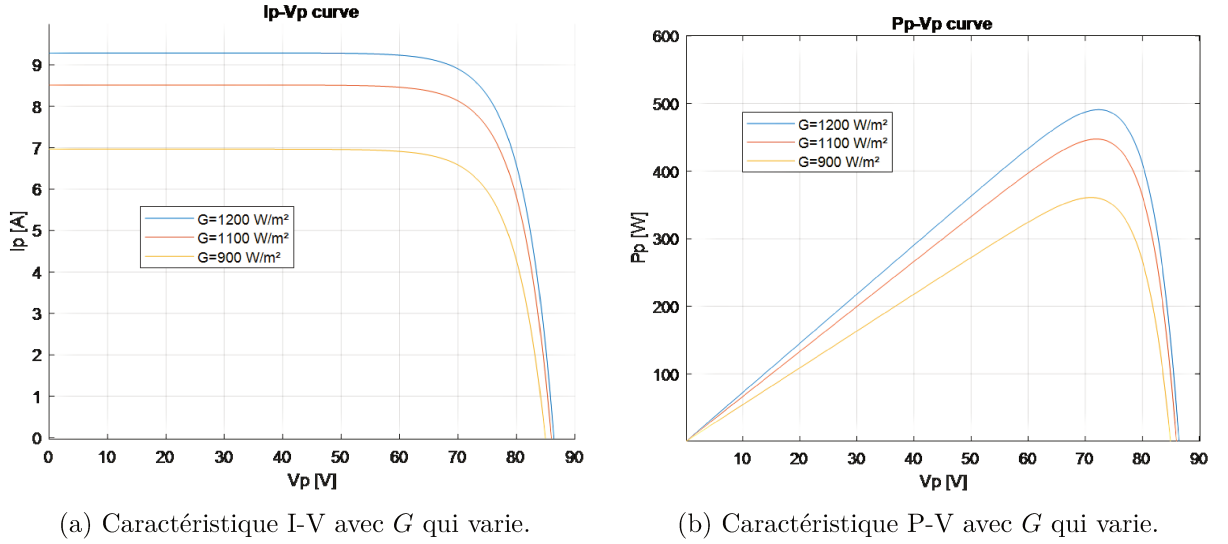
Les caractéristiques I-V et P-V des Figures 2.21a et 2.21a, sont la résultante de la variation de l'ensoleillement de 1200 à 1100 puis à 900 W/m^2 . Elles montrent le déplacement du MPPT, qui engendre une perte de puissance due à la baisse du courant de sortie du générateur suite à la diminution niveau d'ensoleillement sur le générateur.

2.9.3.2 Défaut de diodes de bypass

Ce type de défaut de diode de bypass, résulte de la perte de la fonction de la diode de protection. Il peut être synthétisé par le schéma de la Figure 2.22.

En termes de modélisation, les différents cas pouvant être représentés se résument dans le Tableau (2.5) ci-dessous.

En tenant compte du fait que la diode de bypass peut annuler la tension d'un module, on peut conclure que son comportement peut être confondu à celui dû à un ombrage partiel affectant

FIGURE 2.21 – GPV avec des modules de 36 cellules avec variation de G .

un module. Ce qui est désagréable, c'est que cela peut prêter à confusion quant à la localisation dudit défaut, à moins d'y voir de plus près.

2.9.3.3 Défaut de module

Comme illustré sur la Figure 2.23, ce défaut se manifeste soit comme un module en court-circuit, soit comme un module en inversion de polarisation enfin soit comme un module shunté. En termes de modélisation les différents cas pouvant être représentés, se résument dans le Tableau (2.6).

L'annulation de la tension d'un module, réduit la tension de sortie du générateur, ce qui déplace donc le MPPT vers l'intérieur de la caractéristique I-V. On peut conclure que son comportement peut être confondu à celui dû à un ombrage partiel affectant un module. Le plus désagréable, c'est que cela peut aussi prêter à confusion pour la localisation dudit défaut. Il faudra alors examiner de plus près toutes les hypothèses.

2.9.3.4 Défaut de connectique

Ce type de défaut résulte d'une augmentation de la résistance de la connectique, entre deux modules qui devrait être logiquement nulle en temps normal, et ce pour plusieurs raisons. Très schématiquement il peut être vu comme ci-dessous sur la Figure 2.24. Ce comportement se résume par de légères baisses de la tension de sortie générale du GPV, donc une perte de puissance.

$$\begin{cases} I_{stg\ i} = I_{Module\ i} \text{ si } \sum_{i=1}^{N_{Cell}} V_{Cell\ i} < 0 \\ V_{stg\ i} = \sum_{i=1}^{N_{Cell}} V_{m, k} - R \times I_{stg\ i} \end{cases}$$

Ce défaut peut facilement se confondre avec un défaut du type ensoleillement ou de température. Toujours est il qu'il faut rester vigilant en cas de diagnostic.




FIGURE 2.22 – Défaut de la diode de bypass.

TABLE 2.5 – Conséquence d’un défaut de diode de bypass.

	Le courant	La tension
En court-circuit	$I_{stg} = I_{Bypass} + I_{Cell}$	$V_m = 0$
En circuit ouvert	$I_{stg} = I_{Cell}$	$V_m = \sum_{i=1}^{N_{Cell}} V_{Cell\ i}$
Inversion de polarité de la diode de Bypass	$I_{stg} = I_{Bypass} + I_{Cell}$	$\begin{cases} V_m = \sum_{i=1}^{N_{Cell}} V_{Cell\ i} \text{ si } \sum_{i=1}^{N_{Cell}} V_{Cell\ i} < 0 \\ V_m = 0 \text{ si } \sum_{i=1}^{N_{Cell}} V_{Cell\ i} > 0 \end{cases}$
Impédance Z quelconque	$I_{stg} = I_{Cell} + \frac{V_m}{Z}$	$V_m = \sum_{i=1}^{N_{Cell}} V_{Cell\ i}$




FIGURE 2.23 – Défaut du module.

TABLE 2.6 – Conséquence d’un défaut de de module.

	Le courant	La tension
En court-circuit	$I_{Module} = I_{stg} + I_{shunt}$	$V_m = 0$
En circuit ouvert	$I_{Module} = I_{stg} = 0$	$V_m = 0$
Inversion de polarité du module	$I_{Module} = -I_{stg\ i}$	$V_m = \sum_{i=1}^{N_{Cell}} V_{Cell\ i}$
Module Shunté	$I_{Module} = I_{Cell} + \frac{V_{m,k}}{Z}$	$V_m = \sum_{i=1}^{N_{Cell}} V_{Cell\ i}$




FIGURE 2.24 – Défaut de connectique.

2.9.3.5 Défaut de diode anti retour

Ce type de défaut résulte de la perte de fonction d'une diode sensée protégée un string. Il peut être schématisé par la Figure 2.25 ci-dessous :

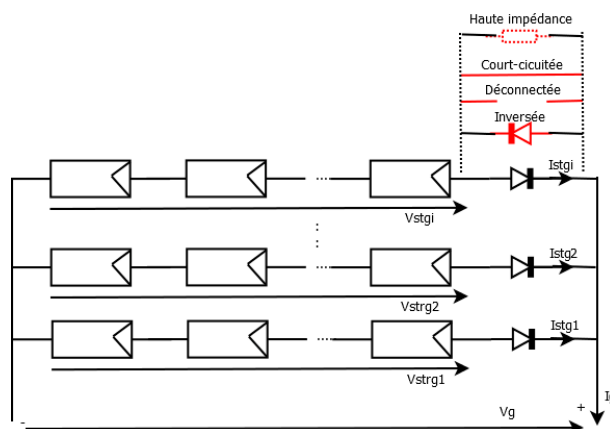


FIGURE 2.25 – Défaut de diode anti retour.

En termes de modélisation, les différents cas pouvant être représentés, se résument dans le Tableau (2.7).

TABLE 2.7 – Conséquence d'un défaut de diode anti retour.

	Le courant	La tension
En court-circuit	$I_G = \sum_{i=1}^{N_p} I_{stg\ i}$	$V_G = V_{Imposee}$
En circuit ouvert	$I_G = \sum_{i=1}^{N_p} I_{stg\ i}$; $I_{stg\ i} = 0$ si la diode est deconnectee	$V_G = V_{Imposee}$
Inversion de polarité de la diode Anti retour	$I_G = \sum_{i=1}^{N_p} I_{stg\ i}$; avec $I_{stg\ i} = 0$ si $V_{stg\ i} > V_G$	$V_G = V_{Imposee}$
Module Shunté	$I_{Module} = I_{Cell} + \frac{V_{m,k}}{Z}$	$V_G = V_{Imposee}$

2.10 Modes de dégradation des modules PV

De nos jours, on note toujours un déficit d'information sur les différents modes de dégradation des modules photovoltaïques en termes de fréquence, de vitesse d'évolution, du degré d'impact sur la durée de vie ou la durée de vie restante et la fiabilité des modules PV. Ces dernières années, les recherches sur les modules photovoltaïques se sont plutôt focalisées sur la course au développement de nouvelles technologies sans avoir fourni suffisamment de retour d'expériences sur celles qui sont déjà opérationnelles.

Les principaux modes de dégradations des modules PV recensés sont présentés en même temps que les facteurs et les moyens de détection des dégradations des modules [Djeziri et al. 2022].

2.10.1 Corrosion

L'humidité entraine la corrosion et la décoloration dans les modules PV, ce qui entraine des courants de fuite, donc des pertes de performances [Atsu et al. 2020]. La constitution du

panneau même poserait problème [Kazem et al. 2020], car le sodium contenu dans le vitrage constituerait la source de réaction avec l'humidité. Aussi, l'humidité et l'oxygène dans les modules PV au silicium, constitue la première réaction à l'origine de la corrosion [Kim et al. 2021]. Pour [Aghaei et al. 2022], l'humidité est la première source de dégradation des panneaux dans les zones géographiques chaudes et humides.

2.10.2 Délamination

C'est une perte de l'adhérence entre le polymère encapsulant et les cellules ou bien les cellules et le verre avant. Elle entraîne soit l'augmentation de la réflexion lumineuse, soit la pénétration d'eau à l'intérieur du module PV [Munoz et al. 2011]. La délamination peut être causée par divers facteurs tels que des contraintes mécaniques, thermiques ou chimiques. Mais l'humidité ou certains défauts de fabrication peuvent également favoriser son apparition.

2.10.3 Décoloration

C'est le changement de couleur de l'Ethylène Viny Acétate ou EVA, utilisé pour l'encapsulation, soit par jaunissement soit par brunissement de l'EVA [Mellit et al. 2018]. Cela a pour conséquence, la modification de la transmittance et la perte de puissance du module et qui est très bien commenté dans [Djeziri et al. 2022]. Ce changement de la structure chimique [Kim et al. 2021], est lié à une combinaison de l'eau, des UV et à une forte température de l'ordre de 50°C.

La décoloration liée au jaunissement demeure la principale cause de perte de puissance des modules [Kenny et al. 2006, Mellit et al. 2018, Aghaei et al. 2022]. Elle affecte également le courant de court-circuit I_{cc} de 6 à 8 % de la valeur nominale d'un module décoloré entre 10 et 13 % de sa surface totale [Realini 2003].

2.10.4 Fissures et les bris de verre

Les fissures et les bris de verre sont toujours suivis des autres types de dégradations. Le souci économique en milieu industriel, a fait que durant ces dernières années, l'épaisseur des cellules sur les panneaux est passé de 300 μm à 200 μm voire 100 μm pour certains panneaux [Zingbe et al. 2018, Luo et al. 2017], rendant ainsi les cellules plus fragiles et sensibles à ce type de dégradation, tant dans le transport, le stockage que pour l'installation.

2.10.5 Points chauds ou hotspot

Une cellule défectueuse ou faiblement ensoleillée produit un courant inférieur à celui débité par le string auquel il appartient. Alors sa tension devient négative et elle se comporte en récepteur [Fouad et al. 2017, Fernández-Solas et al. 2021]. Les diodes de bypass ont alors pour rôle de protéger ces types de cellules défectueuses dans le module, en court-circuitant le string concerné, pour éviter la circulation du courant dans le sens inverse. La conséquence c'est la réduction de la puissance et la tension de sortie. Un mauvais ensoleillement ou non homogène, une température trop élevée, les dépôts de poussières, de neige ou de feuilles mortes représentent autant de facteur aggravant pour ce type de dégradation [Djeziri et al. 2022].

2.10.6 Bulles

Elles sont la résultante des réactions chimiques qui libèrent des gaz, qui se retrouvent à leur tour, piégés à l'intérieur du module. Elles s'accompagnent généralement de délamination et de gonflement de surface, rendant difficile la dissipation de chaleur. Cela accélère du coup, le vieillissement du module [Kim et al. 2021]. Les bulles situées en surface réduisent l'éclairement arrivant sur la face du module.

2.10.7 PID ou Potential Induced Degradation

Mis en évidence en 2010, son premier symptôme demeure une dégradation rapide et inexplicable de la puissance, liée à une diminution du rendement des modules de près de 20 % en quelques mois sans être liées à un vieillissement classique des modules ni à une mauvaise installation. Ce défaut se caractérise aussi par une dégradation progressive des performances des modules PV, due à la présence d'un courant induit [Mellit et al. 2018]. Ce courant induit naît dans la plupart des systèmes photovoltaïques non mis à la terre, où les panneaux PV ont une tension positive ou négative par rapport à la terre. Ce défaut peut être accentué par l'humidité, la température et la tension de service du module.

En conclusion, on retient que pour [Fernández-Solas et al. 2021] la température, et l'ensoleillement restent les paramètres environnementaux à prendre en compte pour ce type de défaut.

2.10.8 Modèle de dégradation des modules PV

Dans cette partie, les modèles de dégradation présentés dans la littérature sont recensés et discutés. Cette dégradation est évaluée grâce à la mesure de la diminution de la puissance dans le temps par rapport à la puissance initiale. De nos jours, les modèles de dégradation de module photovoltaïque restent à être développés [Mellit et al. 2018] selon les pistes suivantes :

- le modèle de Pan, basé soit sur la dégradation de la corrosion soit de la délamination ;
- le modèle exponentiel, basé sur la diminution de la densité de probabilité de la distribution de puissance ;
- le modèle de Zimmerman basé quant à lui sur la photo dégradation causée par le rayonnement ultraviolet.

Car, force est de constater qu'aucun de ces modèles de dégradation n'incorpore l'ensemble des anomalies et défauts mis en évidence dans ce chapitre. Les insuffisances de ces modèles sont surtout dues aussi au manque de retour d'expérience sur de longues périodes d'utilisation de ces modules dans les générateur PV.

Les modèles recensés ne ciblent pas un mode de dégradation particulier mais plutôt la dégradation globale de la puissance des modules. Ainsi, il est difficile d'étudier l'impact, la vitesse, la fréquence d'un mode de dégradation en particulier. Il est préférable d'étudier les modes et facteurs de dégradation à travers des expériences sur de longues durées. Le développement des modèles et modes de dégradation des modules photovoltaïques reste un champ de recherche intéressant. Cette connaissance permettra d'améliorer la maîtrise du comportement des modules photovoltaïques pendant leur cycle de vie [Mellit et al. 2018].

2.11 Conclusion

Dans ce chapitre, nous avons établi un modèle de simulation tant mathématique qu'électrique représentatif d'un générateur photovoltaïque qui puisse mettre en évidence, les principaux défauts considérés sur la caractéristique I-V résultante en mode sain comme en mode dégradé. Le modèle du générateur PV basé sur le principe de modélisation de la cellule PV par le modèle de Bishop présenté est celui sur lequel nous nous sommes appuyés pour la simulation sous Matlab et Simulink. Il prend effectivement en compte toutes les constantes d'une cellule, et met en avant les paramètres tels le nombre de cellule, la température, l'ensoleillement et les résistances R_s et R_{sh} , tout en respectant les mises en série ou en parallèle des modules. Cela facilite la mise en évidence des modes de fonctionnement aussi bien sain que dégradé en lien avec les anomalies sus dessus citées, qui puissent intervenir lors du fonctionnement du générateur PV.

Les modes de dégradations constatés sur les générateurs PV et mis en évidence dans les travaux de la présente thèse, peuvent être liés à :

- des conditions environnementales (température ou ensoleillement) ;
- techniques (paramètres de fabrication ou condition de manutention) ;
- ou d'exploitations (ombrage, salissures ou branchement).

Les simulations effectuées montrent que le modèle retenu est fiable et robuste, et demeurent une vraie prouesse quand même, nous n'avons pas pu nous pas attaquer à la sensibilité du modèle. LA modélisation et les bons résultats de simulation, nous ont largement permis de voir et comprendre le comportement sain tout comme dégradé du GPV.

Pour la suite, nous entreprendrons la mise en évidence de méthodes de diagnostics éprouvées pour détecter et localiser l'origine des modes défailants engendrant le comportement défailant du GPV afin de ne pas subir leurs mauvais états de fonctionnement. Cela reste préjudiciable techniquement et financièrement pour les exploitants tant en site isolé qu'interconnecté.

Diagnostic de défauts capteurs par relation de redondance analytique

3.1 Introduction

Une attention particulière est portée, dans ce chapitre, aux méthodes de détection et de diagnostic des défauts pour le GPV isolé ou connecté au réseau, qui demeure une démarche hautement stratégique pour protéger les composants du GPV en particulier, contre les dommages et pour éliminer les éventuels risques d'incendie [Bosman et al. 2020, Luo et al. 2017] mais surtout pour permettre un retour à un état normal de fonctionnement garantissant un meilleur retour sur investissement. Le système de diagnostic construit à partir du modèle de comportement d'un GPV, doit permettre le diagnostic et la surveillance à partir des observations des différents états de fonctionnement et de dégradation du générateur.

Les systèmes photovoltaïques sont sujets à différentes formes de pannes pouvant affecter aussi bien les composants du GPV (modules, câblages et système de protections) que la chaîne de redressement (convertisseurs et onduleurs), pour des raisons liées aux conditions de fonctionnement externes. Les défauts dans le GPV sont causés par [Compaoré et al. 2021 a.] : les effets d'ombrage, l'encrassement du module, et inadéquation due à la variation des matériaux de fabrication ou au vieillissement des modules PV. Les principales défaillances catastrophiques des générateurs photovoltaïques que sont : les défauts ligne à ligne, de terre et d'arc [Falvo et al. 2015], entraînent une mise hors service du GPV. Une formulation de recommandations pour prévenir les risques d'incendie des installations a même été proposée dans [Fiorentini et al. 2016], tandis que d'autres auteurs proposent des lignes directrices d'atténuation de tels défauts électriques pouvant entraîner de graves défaillances [Falvo et al. 2015, Brooks 2015].

Pour assurer un fonctionnement fiable et sûr de sécurité des installations photovoltaïques, la surveillance et les systèmes de diagnostic des pannes peuvent être développés pour détecter et résoudre les défauts en temps opportun [Dhass et al. 2022, Papageorgas et al. 2013]. De nombreuses méthodes de surveillance et de diagnostic de pannes pour les systèmes PV ont été également étudiées dans la littérature, allant de la rapidité à la complexité en passant par le besoin en capteurs, ou la capacité d'identification d'un grand nombre de défauts et relayée dans

[Tina et al. 2016, Chine et al. 2016].

Parmi elles, plusieurs méthodes de diagnostic de défauts basés sur des modèles ont été proposé mais incluant le convertisseur. Les meilleures d'entre elles se focalisent sur la partie convertisseur du système PV, sur des défauts de circuit ouvert [Malik et al. 2022, Zeb et al. 2018, Poon et al. 2017] ou sur des défauts de court-circuit sur les transistors bipolaires à grille isolée (IGBT) [Madeti et al. 2017]. Quelques travaux tentent aussi une approche pour des défauts capteurs en mettant l'accent uniquement sur la sortie du convertisseur [Abuelnaga et al. 2021, Jain et al. 2019, Bhattacharya et al. 2017, Oh et al. 2015, Ghimire et al. 2013].

Pour le cas particulier de l'algorithme de détection et de localisation des défauts capteurs unique et multiple développé à partir des relations de redondance analytique (RRA) sur la base des courants alternatifs résiduels et des seuils adaptés pour chaque phase dans [Oh et al. 2015, Abuelnaga et al. 2021, Ghimire et al. 2013], la technique proposée fonctionne bien. Cependant l'effet de propagation des défauts de capteur n'est pas pris en compte, à savoir les phénomènes physiques d'interconnexion dus au couplage entre les sorties courant alternatif et courant continu du système PV. Autre problème non pris en compte, c'est le cas des fausses alarmes ou des défauts manqués qui pourraient affecter l'application de la RRA sur cet ensemble GPV - convertisseur.

Nous notons aussi, l'existence d'une revue de l'application de méthodes non électriques telles l'infrarouge, l'imagerie thermique pour la détection et la localisation des défauts dans [Tsanakas et al. 2015].

Nous rappelons, dès l'entame quelques définitions importantes concernant la terminologie du diagnostic de défauts pour ce chapitre, qui vise à passer en revue l'état actuel de la détection et du diagnostic des défauts capteurs pour les GPV basés sur la méthode de l'analyse des relations de redondance.

Cette méthode basée sur le principe de l'espace de parité, est choisie parmi de nombreuses méthodes de diagnostic proposées au fil des années par les recherches et peut être classée comme étant celle basée sur la connaissance du modèle mathématique du système à étudier. Aussi tenterons nous d'appliquer cette méthode à travers le point de fonctionnement maximal uniquement sur la partie générateur du système PV uniquement.

La méthode de diagnostic sera présentée en termes de complexité à cause de sa mise en œuvre autour du MPPT [Compaoré et al. 2022 b.]; sa capacité à détecter et localiser les éventuels défauts capteurs; et enfin l'évaluation de la performance à travers l'analyse de courbe COR appliquée au cas de ce processus industriel complexe qu'est le GPV. En tant que système d'aide à la décision, l'intérêt de cette méthode de diagnostic sera de donner en temps réel, l'état de santé du système en indiquant les éventuelles occurrences des défauts affectant l'état de bon fonctionnement du système.

Enfin, une discussion sur les performances par l'analyse de la courbe COR, intervient juste avant la conclusion de ce chapitre.

3.2 Définitions

Pour rappel, selon le comité technique de l'IFAC, (International Federation of Automatic Control) [Belaout 2018], un défaut est une déviation non permise d'au moins une propriété ou un paramètre caractéristique du système par rapport à un comportement usuel, nominal ou

acceptable.

La plupart du temps un défaut, peut affecter le système à travers ses capteurs, ses actionneurs, soit le système lui-même. Un défaut qui se mue en panne est un dysfonctionnement, voire une défaillance momentanée et accidentelle, d'une partie ou de tous les composants d'un système matériel.

L'aide à la décision à travers la surveillance et la supervision constitue dès lors un complément du diagnostic. La surveillance en temps réel d'un système est une tâche qui détermine l'état d'un système. Elle se fait à travers les informations de sauvegarde des éventuelles anomalies dans le comportement du système. La supervision quant à elle, se réfère à la prise de décisions appropriées, lors de la sauvegarde des informations du système, afin de maintenir le fonctionnement nominal malgré la survenue d'un défaut dans le système.

Toutes ces actions contribuent à restaurer des performances optimales au système, telles que la disponibilité, la fiabilité et la maintenabilité.

Nonobstant ces définitions, il est important de faire la différence entre un défaut et une perturbation qui reste une entrée inconnue et non commandée, mais qui agit sur le système. Une perturbation reste une entrée exogène au système.

3.3 Caractérisation de défauts

Généralement, les défauts peuvent être caractérisés par leur comportement dans le temps d'une part, et par leur modélisation mathématique d'autre part. Les défauts peuvent être brusques, intermittents ou graduels, additifs ou multiplicatifs tel qu'illustré dans la Figure 3.1, qui montre les types de défauts ainsi que leurs possibles modélisations.

Défaut brusque

Ce type de défaut d'une amplitude constante, apparaît à un instant t_d . Le cas a de la Figure 3.1 illustre le comportement de ce type de défaut.

Défaut intermittent

Cas particulier des défauts brusques, un défaut intermittent est un défaut imprévisible. Son caractère aléatoire le rend difficile à détecter. Ce type de défaut peut représenter des défauts de connexion, d'alimentation voire de faux contacts. Ce type de défaut est représenté par le cas b de la Figure 3.1.

Défaut à dérive lente

Un défaut de type graduel apparaît à un instant t_d . Comparativement au défaut brusque, l'amplitude de ce type de défaut ne reste pas constante. Elle augmente proportionnellement avec le temps. Ce type de défaut est assimilable à des défauts d'usure et est représenté par le cas c de la Figure 3.1.

Modélisation du défaut : additif ou multiplicatif

Les défauts composants affectent les composants du système lui-même. De ce fait ils ne peuvent être classés ni parmi les défauts actionneurs ni parmi les défauts capteurs. Ce type de défaut provoque un changement de la dynamique du système à travers un changement de ces paramètres. Mathématiquement parlant, il est soit additif soit multiplicatif comme illustré sur la Figure 3.1.

Un défaut est dit additif quand il est modélisé par l'ajout d'une variable δx . L'équation de la sortie s'écrit : $S = E + \delta x$.

Quant au défaut multiplicatif, il affecte le système à travers la multiplication de l'entrée E du système par un défaut δx .

L'équation de sortie s'écrit : $S = E(x + \delta x)$.

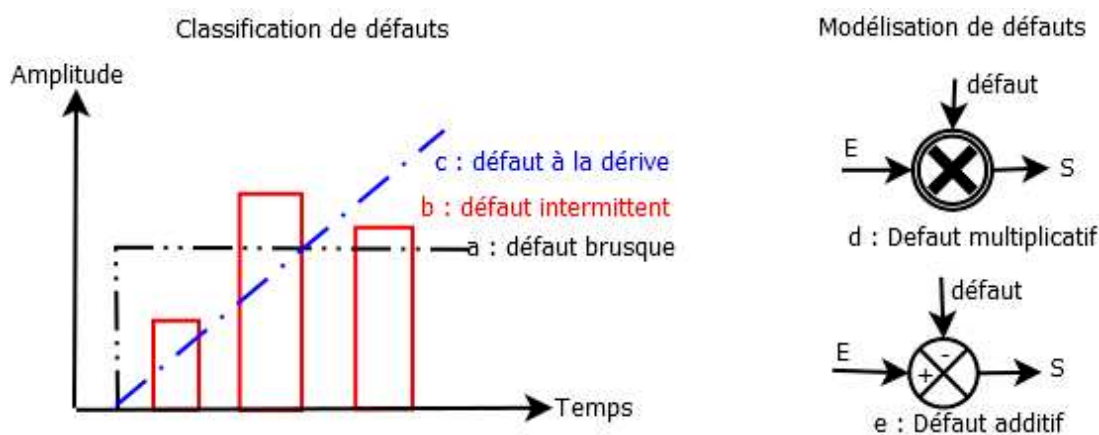


FIGURE 3.1 – Classification en (a, b, c) et modélisation en (d, e) des défauts.

3.4 Différents types de défauts

Les défauts pouvant être aléatoires (défauts cataleptiques), ou progressifs, cas du vieillissement ou de l'usure (défauts évolutifs) provenant du système physique. Ce sont des événements qui apparaissent à différents endroits du système, d'où la raison de leurs classifications dans la littérature, en fonction de leur localisation, définissant alors des types de défauts, tels qu'illustrés sur la Figure 3.2.




FIGURE 3.2 – Différents types de défauts.

Défaut de capteur

Ces types de défauts renvoient de mauvaises images de l'état physique du système, car ils renvoient des valeurs qui ne sont pas en accord avec les grandeurs à mesurer. Ceci peut se traduire par une réduction de la valeur affichée par rapport à la valeur vraie, ou de la présence d'un biais ou de bruit accru empêchant une bonne lecture.

Défaut d'actionneur

Ce type de défaut renvoie à des incohérences entre la consigne d'un actionneur et sa sortie. Agissant au niveau de la partie coopérative et détériorant le signal d'entrée du système, ces types de défauts représentent une perte totale (défaillance) ou partielle d'un actionneur du système. Cela peut être le cas avec une certaine dégradation des actions de l'actionneur sur le système (perte de puissance d'un moteur, fuite dans un vérin, etc).

Défauts composants des systèmes

Le système lui-même peut être en défaut bien souvent, avec des défauts n'appartenant pas à un défaut du type capteur ou actionneur, mais en rapport avec un paramètre intrinsèque du modèle du système. Ce type de défaut altère ou réduit les capacités du système lui-même à effectuer une tâche. On peut considérer par exemple la modification des caractéristiques du système proprement dit (la résistance à Coefficient de Température Négatif, dite CTN d'une chaufferie est cassée, un roulement est altéré, etc)

3.5 Diagnostic par analyse des relations de redondance

Habituellement, le diagnostic est exprimé par les états des composants [Belaout 2018] ou les états des relations de description du comportement [Hadji 2018]. De la non-conformité (ou anomalie) dans le cas d'une défaillance, on passe à une incapacité à accomplir une fonction dans le cas d'une panne.

Cela revient à définir le type de défauts susceptibles d'altérer le bon fonctionnement d'un système. Celui-ci peut être divisé en trois catégories distinctes : les biais, les dérives et les valeurs aberrantes. Il peut s'agir de défauts inhérents aux organes de mesure, c'est-à-dire aux capteurs, ou aux organes de commande, c'est-à-dire aux actionneurs ou encore aux composants du processus, c'est-à-dire au système.

Une redondance analytique existe si une ou plusieurs relations ne font intervenir que des grandeurs mesurables, vraie(s) en l'absence de défaut. L'information issue de ces relations met en évidence la présence d'un ou plusieurs défauts. La redondance analytique permet, d'une part, le diagnostic d'un grand nombre de défauts et d'autre part, de remplacer la redondance matérielle par une redondance informationnelle.

Le diagnostic par redondance analytique tel que proposé à la Figure 3.3, suit une démarche qui peut se résumer comme suit : on dispose d'un modèle décrivant le fonctionnement normal du système et on surveille le fonctionnement réel en testant la cohérence entre ce modèle et les observations disponibles. Si celles-ci ne vérifient pas les équations du modèle, on en déduit que le fonctionnement réel n'est pas normal. On produit alors un symptôme (appelé aussi résidu).

Le diagnostic par redondance analytique, se décompose généralement en deux phases distinctes. La première concerne la génération de résidus caractéristiques de la panne. Ils représentent les écarts observés du système et le comportement en fonctionnement "normal" [Mellit et al. 2018, Fernández-Solas et al. 2021]. Ces résidus sont généralement à moyenne nulle et ont une variance déterminée en l'absence de défauts de fonctionnement. Le problème qui se pose au concepteur du système de diagnostic est de sélectionner les résidus satisfaisant le compromis : sensibilité maximum aux pannes que l'on cherche à détecter - sensibilité minimum aux erreurs de modélisation et aux bruits de mesure. Ces résidus sont donc obtenus principalement à l'aide des deux approches suivantes :

- soit par une approche physique qui se fonde sur l'utilisation d'un modèle de connaissance. Les résidus traduisent alors le degré de satisfaction des lois de la physique, en particulier les lois de conservation de la masse, de l'énergie ou de la quantité de mouvement. Les résidus ont alors une signification physique évidente et constituent des résidus de bilan et s'applique bien à des systèmes sans modèles ;
- soit par une approche mathématique autour d'un formalisme de représentation du type "représentation d'état" qui conduit au concept d'espace de parité simple et généralisé (ou autre méthode liée directement) [Rezgui et al. 2014 b.]. Le formalisme d'état est puissant et bien adapté à une grande classe de problèmes régis par des équations différentielles, donc pour des systèmes à base de modèles.

La seconde phase concerne la prise de décision qui a trait à la détection et éventuellement à la localisation d'un élément défaillant. Elle met en œuvre des techniques de détection de ruptures et de tests multi-hypothèses.

Ces deux phases sont intimement liées et elles doivent être adaptées et étudiées ensemble lors de la résolution du problème.

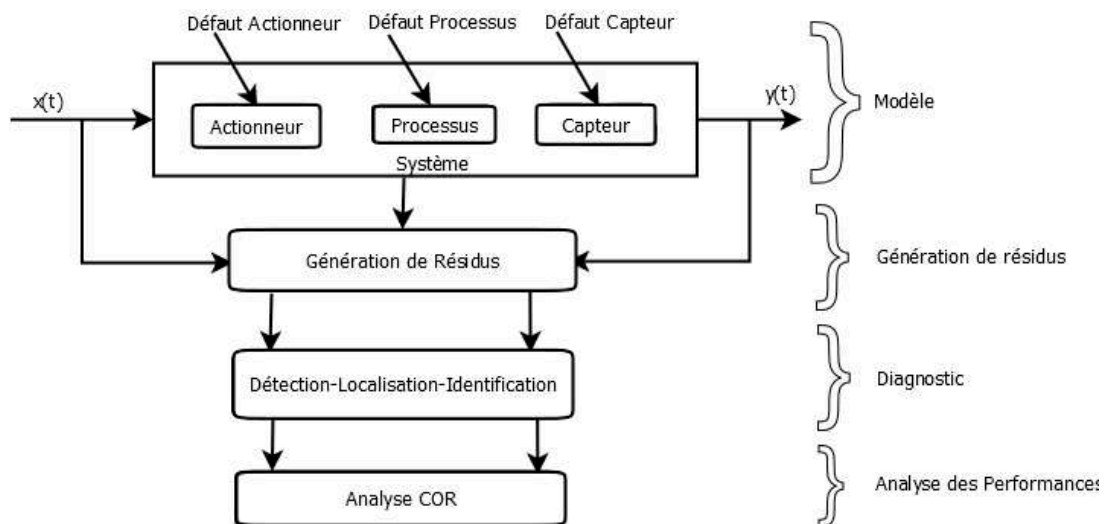


FIGURE 3.3 – Principe de diagnostic.

Le principe du diagnostic résulte de la décision sur l'évolution du résidu $r(t)$ et illustré sur la Figure 3.4.

- en fonctionnement normal, le résidu est inférieur au seuil. Il s'agira donc de poursuivre la tâche de surveillance du système en temps continu ;
- en fonctionnement défaillant, le résidu est supérieur au seuil. Une détection, et une loca-

lisation s'imposent pour en comprendre les causes.

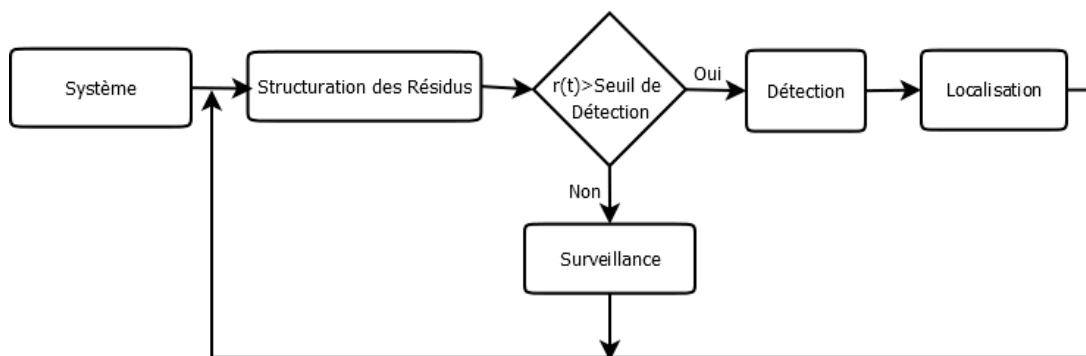


FIGURE 3.4 – Logique de diagnostic.

3.5.1 Synoptique de génération de résidus

De manière générale, la génération des résidus, pour les méthodes basées sur le modèle repose sur le concept de redondance analytique.

La redondance de la relation analytique correspond à l'utilisation des signaux de mesure et de commande disponibles combinés avec le modèle mathématique du système à diagnostiquer. On dispose d'un modèle décrivant le fonctionnement normal du système et on surveille le fonctionnement réel en testant la cohérence entre ce modèle et les observations disponibles de la Figure 3.5. Si celles-ci ne vérifient pas les équations du modèle, on en déduit que le fonctionnement réel n'est pas normal et on produit un résidu. Dans une deuxième phase, l'analyse diagnostic se fait alors en comparant le résultat de test des résidus aux vecteurs binaires des différents défauts contenus dans la matrice d'occurrence. Cela permet de signer l'origine du défaut capteur concerné.

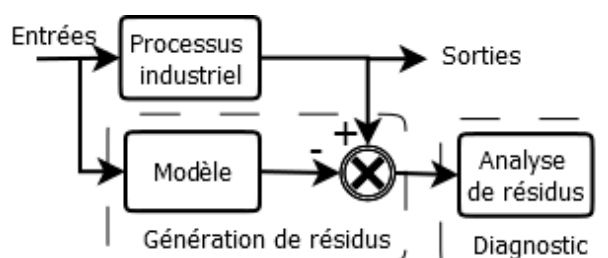


FIGURE 3.5 – Synoptique de diagnostic par la méthode de l'espace de Parité.

3.5.2 Localisation des défauts

Un défaut est détectable si, et seulement si, il a un effet sur au moins une des sorties du système. Cette définition est différente de la détectabilité au sens de l'automatique [Mellit et al. 2018, Parizad et al. 2018]. La localisation du défaut quant à lui renvoie à la signature des symptômes de l'une des signatures de défaut. Pour arriver à la localisation, le diagnostic par redondance analytique a besoin de construire des tests de détection qui reposent sur des modèles testables, appelés relations de redondance analytique (RRA). Ces derniers sont des modèles ne faisant intervenir que des variables mesurées ou connues à l'avance. Ces modèles doivent permettre de

calculer des résidus. Une RRA est constituée d'un ensemble de modèles de composants en éliminant les variables inconnues et son évaluation se fait à partir des observations. Une relation de redondance peut être utilisée pour tester les composants physiques qui constituent son support. Le but des relations de redondance analytique est de permettre de construire des tests de cohérence afin de générer des résidus qui, par filtrage et seuillage, permettront de décider si le fonctionnement s'apparente ou non à un fonctionnement normal.

En effet, la plupart du temps, les valeurs des résidus sont, à chaque instant, comparées à des seuils. Les tests peuvent être réalisés en parallèle et chaque décision issue de ces tests conduit à une valeur booléenne (0 : la valeur du résidu est en dessous du seuil ; 1 : la valeur du résidu a dépassé le seuil fixé). L'ensemble de ces valeurs booléennes forme un vecteur binaire appelé signature de défaut.

Le vecteur binaire est comparé aux différentes signatures de panne ainsi qu'à la signature de fonctionnement normal (vecteur de composantes nulles). Cette comparaison conduit alors à une conclusion sur l'état du système : fonctionnement normal, défaillance identifiée ou finalement défaillance non identifiée. La localisation qui suit la détection peut être effectuée à l'aide de la table de signatures. Les colonnes de cette matrice d'occurrence dans le Tableau 3.1, sont représentatives des différents défauts donnés dans les lignes des différents résidus. Le diagnostic se fait par la localisation des défauts présents dans la table de signatures. La génération de l'état du diagnostic est basée sur une interprétation des colonnes de la table de signatures et consiste à comparer la signature des observations avec celles des défauts. Cette comparaison est considérée à nouveau comme un problème de décision.

Pour que tous les défauts puissent être détectés, aucune colonne de la matrice des signatures théoriques de défauts ne doit être nulle, et pour que tous les défauts puissent être localisés, toutes les signatures théoriques doivent être distinctes sans hypothèse d'exonération selon les trois types de matrices d'incidence de [Hadji 2018, Compaoré et al. 2023 a.] :

- non localisante (une colonne est nulle ou au moins deux colonnes sont identiques) ne permet pas de distinguer certains défauts entre eux ;
- faiblement localisante (les colonnes sont non nulles et distinctes deux à deux) permet de localiser les défauts uniques sous hypothèse d'exonération ;
- fortement localisante (en plus d'être faiblement localisante, aucune colonne ne peut être obtenue à partir d'une autre en remplaçant un "1" par un "0") garantit que les différentes sensibilités des résidus par rapport aux défauts ne conduisent pas à un diagnostic erroné.

3.5.3 Prise de décision : évaluation des résidus

Cette étape consiste en l'analyse du signal issu de la génération des résidus. En effet, dans le cas de défauts multiples, afin de faciliter l'isolation des défauts, la génération de résidus a pour but de construire des résidus structurés. Des résidus structurés sont définis comme des résidus sensibles à un unique défaut et insensibles aux autres. Ces résidus sont générés suivant une matrice d'occurrence, comme le montre le Tableau 3.1.

Ainsi, un résidu non nul informe de l'occurrence du défaut auquel il est sensible.

TABLE 3.1 – Matrice d’occurrence pour le cas de défauts multiples.

Résidus	Défaut d_1	Défaut d_2	Défaut d_3	Défaut d_4	...	Défaut d_i
Résidu r_0	1	0	1	1	...	1
Résidu r_1	0	1	1	0	...	0
Résidu r_2	0	1	0	1	...	0
.....	:	:	:	:	:	:
Résidu r_n	0	1	0	0	...	1

3.5.4 Méthode de l’espace de parité

On considère un système linéaire à temps discret décrit par [Maquin et al. 2000] :

$$\begin{cases} x(k+1) = Ax(k) + Bu(k) + Pf(k) \\ y(k) = Cx(k) + Du(k) + Qf(k) \end{cases} \quad (3.1)$$

où

$x \in \mathbb{R}^n$ est le vecteur des variables à mesurer ;

$u \in \mathbb{R}^p$ est le vecteur des entrées ;

$y \in \mathbb{R}^m$ est le vecteur des sorties ;

$f \in \mathbb{R}^q$ est le vecteur des fautes à détecter.

A , B , C , D , P et Q sont des matrices connues et constantes de la dimension appropriée. Il est en plus considéré que la paire (C, A) soit observable et exprimée par la matrice d’observabilité de la façon suivante :

$$O = \begin{bmatrix} C \\ CA \\ \vdots \\ CA^{n-1} \end{bmatrix} \quad (3.2)$$

La première étape de la procédure de détection de défauts est d’exprimer le vecteur de sortie d’ordre s comme :

$$Y_s(k) = H_s x(k-s) + M_s U_s(k) + N_s F_s(k) \quad (3.3)$$

où s est appelé ordre des relations de parité avec ;

$$\left\{ \begin{array}{l} Y_s(k) = \begin{bmatrix} y(k-s) \\ y(k-s+1) \\ \vdots \\ y(k) \end{bmatrix} \\ U_s(k) = \begin{bmatrix} u(k-s) \\ u(k-s+1) \\ \vdots \\ u(k) \end{bmatrix} \end{array} \right. ; \left\{ \begin{array}{l} F_s(k) = \begin{bmatrix} f(k-s) \\ f(k-s+1) \\ \vdots \\ f(k) \end{bmatrix} \\ H_s = \begin{bmatrix} C \\ CA \\ \vdots \\ CA^s \end{bmatrix} \end{array} \right. \quad (3.4)$$

$$\left\{ M_s = \begin{bmatrix} D & 0 & \cdots & \cdots & 0 \\ CB & D & \ddots & \cdots & 0 \\ CAB & CB & D & \ddots & \vdots \\ \vdots & \ddots & \ddots & \ddots & 0 \\ CA^{s-1}B & CA^{s-2}B & \cdots & \cdots & D \end{bmatrix} \right. ; \left. \begin{bmatrix} Q & 0 & \cdots & \cdots & 0 \\ CP & Q & \ddots & \cdots & 0 \\ CAP & CP & Q & \ddots & \vdots \\ \vdots & \ddots & \ddots & \ddots & 0 \\ CA^{s-1}P & CA^{s-2}P & \cdots & \cdots & Q \end{bmatrix} \right. \quad (3.5)$$

Le but de cette approche est de trouver des relations de parité où tous les états du système sont éliminés à cause des redondances qui les lient :

$$w_s Y_s(k) = w_s M_s U(k) + w_s N_s F_s(k) \quad (3.6)$$

Le vecteur w_s , communément appelé vecteur de parité, est sélectionné dans l'espace de parité défini par :

$$P_s = \{w_s | w_s H_s = 0\} \quad (3.7)$$

Avec la détermination du vecteur de parité, le résidu est exprimé par la relation (3.8) :

$$r(k) = w_s Y_s(k) - w_s M_s U(k) = w_s N_s F_s(k) \quad (3.8)$$

Ainsi, la loi de décision est déduite et consignée dans le tableau 3.1 selon la logique suivante : si le résidu est nul, le système est considéré comme sain, tandis qu'un résidu non nul indique un état fautif.

Pour le cas particulier du régime statique, si nous considérons à un instant k particulier comme un point de repos, nous pouvons écrire l'équation de mesure par la relation (3.9) :

$$y(k) = Cx(k) + \varepsilon(k) + Fd(k) \quad (3.9)$$

où

$d \in \mathbb{R}^p$ est le vecteur des fautes à détecter pouvant affecter certains capteurs ;

$\varepsilon \in \mathbb{R}^m$ est le vecteur des bruits de mesures ;

En considérant le cas où le nombre de mesure m est supérieur au nombre de variables n , cela nous place dans une situation de redondance. Pour établir des relations de redondance qui reste sensibles à certains défauts, entre les mesures indépendantes des grandeurs inconnues, on définit le vecteur de parité, calculé par la relation (3.10) :

$$p(k) = W y(k) \quad (3.10)$$

où W est une matrice de projection orthogonale à C qui explique l'influence des défaillances sur le vecteur de parité par la relation (3.11) :

$$p(k) = W e(k) + W F d(k) \quad (3.11)$$

En l'absence d'erreurs de mesures $e(k)$ et de défaillances $d(k)$, le vecteur de parité est nul, et l'on peut déduire :

$$Wy(k) = 0 \quad (3.12)$$

En généralisant, on peut avoir un vecteur de parité sensible à certaines défaillances $d^+(k)$ à détecter et insensible à d'autres défaillance $d^-(k)$ de la relation (3.13)

$$y(k) = Cx(k) + \varepsilon(k) + F^+d^+(k) + F^-d^-(k) \quad (3.13)$$

où $d^+(k)$ et $d^-(k)$ désignent respectivement les défauts auxquels on veut être sensibles et insensibles tandis que F^+ et F^- sont des matrices associées. La génération du vecteur de parité, passe par la recherche de la matrice W , orthogonale à l'espace engendré par les colonnes CF^- et non orthogonale à l'espace engendré par les colonnes de F^+ .

On peut alors chercher une solution approchée, en générant un vecteur de parité découplé totalement par rapport à l'état x du système, *très insensible* aux perturbations $d^-(k)$ et *très sensibles* aux perturbations à détecter $d^+(k)$. On peut rechercher un vecteur w , solution de ce problème d'optimisation de :

$$\begin{cases} w^T C = 0 \\ \min_w \frac{\|w^T F^-\|^2}{\|w^T F^+\|^2} \end{cases} \quad \text{ou} \quad \begin{cases} w^T C = 0 \\ \min_w \left(\|w^T F^-\|^2 - k^2 \|w^T F^+\|^2 \right) \end{cases} \quad (3.14)$$

Pour le cas du premier problème, on peut montrer que w est solution de :

$$(QA - \lambda QB)w = 0 \quad (3.15)$$

avec

$$\begin{cases} A = F^-(F^-)^T \\ B = F^+(F^+)^T \\ Q = I - C(C^T C)^{-1}C^T \end{cases} \quad (3.16)$$

Et pour le cas du second problème, on montre que le vecteur w doit satisfaire la condition suivante :

$$(QH - \lambda Q)w = 0 \quad (3.17)$$

avec $H = A - k^2 B$

La structure des relations (3.15) et (3.17), montre que w est un vecteur propre généralisé des paires (QA, QB) et (QH, Q) prouvant par la même que λ est la plus petite valeur associée à ce vecteur propre. Il permet de générer le vecteur de parité le plus insensible aux perturbations $d^-(k)$ et le plus sensible aux perturbations $d^+(k)$

3.6 Déteçtabilité par la DCS

La détection consiste à détecter une rupture dans un signal observé x et à estimer l'instant k de son apparition, ce qui se résume à un test d'hypothèse.

Soit X_t le vecteur d'observation de temps discret t , nous supposons que la densité de probabilité en fonction du vecteur X dépende d'un paramètre θ correspondant à $(\epsilon$ et $\gamma)$ la moyenne et

la variance. Le problème consiste à détecter un changement dans θ pouvant affecter la variance du signal, la moyenne ou tous les deux. La plupart des tests statistiques utilisés par les algorithmes de détection sont construits à partir du rapport de vraisemblance [Basseville et al. 1993].

Le principe de la Somme dynamique cumulée (DCS) est basé sur les sommes cumulées des rapports de vraisemblance calculés entre deux hypothèses. Aussi nous pouvons définir la somme dynamique cumulée comme la somme du rapport de vraisemblance entre deux fonctions de densité de probabilité f_a^t et f_b^t estimé avant et après chaque instant j comme indiqué dans la Figure 3.6. Ces fonctions de densité de probabilités sont estimées à l'aide de deux fenêtres de longueur W_a^t : de θ_a à j et W_b^t : de j à θ_b .

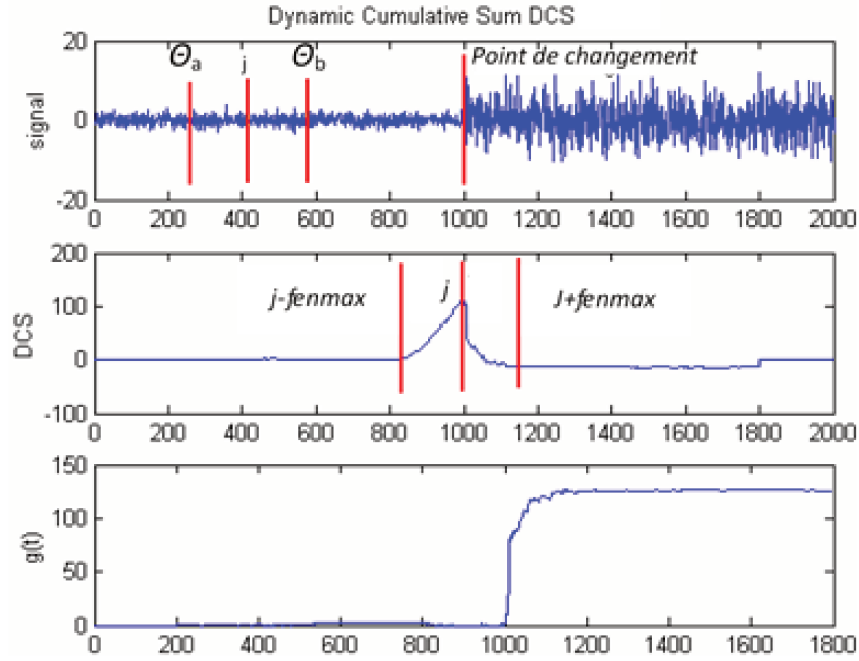


FIGURE 3.6 – Principe de détection basé sur deux fenêtres glissantes [Mustapha et al. 2008]

À l'instant j , nous définissons la DCS par la relation (3.18), comme la somme des logarithmes des rapports de vraisemblance à partir du début du signal jusqu'à l'instant j par [Basseville et al. 1993, Chen et al. 2016, Zhirabok et al. 2019, Ranavolo et al. 2018] :

$$DCS(t) = \sum_{j=t_{p-1}}^t \log \left[\frac{f_{\theta_a^j}(X_j)}{f_{\theta_b^j}(X_j)} \right] = \sum_{j=t_{p-1}}^t S_j, \quad t \geq t_{p-1} \quad (3.18)$$

avec s_j de la relation (3.19) le logarithme du rapport de vraisemblance qui est :

$$S_j = \frac{1}{2} \left[\log \frac{(\gamma_a^2)^j}{(\gamma_b^2)^j} + \frac{(\epsilon_a^2)^j}{(\gamma_a^2)^j} - \frac{(\epsilon_b^2)^j}{(\gamma_b^2)^j} \right] \quad (3.19)$$

et les estimations de :

- l'estimé de la première fenêtre :

$$f_{\theta_a^j} \left(\frac{X}{X_{j-q}^j} \right) = \frac{1}{\sqrt{2\pi(\gamma_a^2)^j}} \exp \left[-\frac{(\epsilon_a^2)^j}{2(\gamma_a^2)^j} \right] \quad \text{où } \theta_a^j = (\gamma_a^2, a_1^a, \dots, a_p^a)^j; \quad (3.20)$$

- l'estimé de la seconde fenêtre :

$$f_{\theta_b^j} \left(\frac{X}{X_{j-q}^j} \right) = \frac{1}{\sqrt{2\pi(\gamma_b^2)^j}} \exp \left[-\frac{(\epsilon_b^2)^j}{2(\gamma_b^2)^j} \right] \text{ où } \theta_b^j = (\gamma_b^2, a_1^b, \dots, a_p^b)^j. \quad (3.21)$$

La fonction de détection utilisée pour estimer l'instant de changement est donnée par la fonction $g(t)$ de la relation (3.22) :

$$g(t) = \max_{t_{p-1} \leq j \leq t} [DCS(j) - DCS(t)] \quad (3.22)$$

L'instant d'arrêt peut donc être défini par la relation (3.23) :

$$t_p = \inf\{n > t_{p-1} : g(n) > h\} \quad (3.23)$$

avec h le seuil de détection à définir.

3.7 Analyse de la performance par la méthode de la courbe COR

Des bruits de mesure, des incertitudes paramétriques et/ou une méconnaissance de la structure des perturbations sont autant de situations qui peuvent engendrer de fausses alarmes ou des non détections.

Une fausse alarme correspond à la détection de "faux" défauts, autrement dit, des défauts qui ne devaient pas être détectés. Une non-détection correspond à la non-détection de "vrais" défauts, autrement dit, une situation dans laquelle des défauts qui affectent réellement le système, n'est pas détectée.

L'une et l'autre sont à éviter dans le sens où elles peuvent entraîner une prise de décision inadéquate. A cause d'une fausse alarme, un défaut, qui n'en est pas un, sera traité en tant que tel avec tout ce que cela implique en termes de sûreté de fonctionnement.

Un algorithme de détection de défauts sera performant si les probabilités des fausses alarmes et de mauvaises détections sont toutes deux les plus petites possible et sera fonction du choix du seuil de détection de défauts.

L'algorithme mis en place cette fois-ci, permet d'estimer un état de détection à partir de n'importe quel signal issu d'un résidu, correspondant à deux hypothèses H_0 ou H_1 [Bradley 1997, Compaoré et al. 2023 b.]. Cet algorithme dépend d'un seuil de détection h dont la valeur doit être fixée pour chaque défaut à mettre en évidence, afin de quantifier leur efficacité à travers les grandeurs statistiques de la sensibilité et de la spécificité.

Pour fixer cette valeur, la méthode usuellement employée est de parcourir l'ensemble des valeurs de seuil possibles, et de calculer pour chacune de ces valeurs, le nombre de détection correspondant. À partir de toutes ces données, il devient possible de déterminer quel est le seuil offrant des performances optimales grâce aux caractéristiques opérationnelles de réception (COR).

3.7.1 Sensibilité

La sensibilité est le nombre de détections correctes (DC) mesurées N_{DC} divisé par le nombre total de DC possibles, sur un nombre statistiquement suffisant d'échantillons, donnée par la relation (3.24) :

$$S_e(h) = \frac{N_{dc}(h)}{N_{H_1}(h)} \quad (3.24)$$

La sensibilité est donc égale au taux de bonnes détections et quantifie la capacité de l'algorithme de détection à apporter une réponse juste quand l'hypothèse est H_1 .

3.7.2 Spécificité

La spécificité est le nombre de non-détections correctes (NC) mesurées N_{nd} , divisé par le nombre total de NC possibles, sur un nombre statistiquement suffisant d'échantillons, donnée par la relation (3.25) :

$$S_p(h) = \frac{N_{nd}(h)}{N_{H_0}(h)} \quad (3.25)$$

La spécificité est donc égale au taux de bonnes non-détections et quantifie la capacité du processus de détection à apporter une réponse juste quand l'hypothèse est H_0 .

3.7.3 Précision

La précision est le nombre total d'états de détection en accord avec l'hypothèse évaluée divisé par le nombre total d'échantillons, donnée par la relation (3.26) :

$$P_r(h) = \frac{N_{dc}(h) + N_{nd}(h)}{N_{H_1}(h) + N_{H_0}(h)} \quad (3.26)$$

La précision permet ainsi de quantifier la capacité du processus de détection à ne pas se tromper. Cependant, elle pose un problème d'interprétation lorsque les deux différentes classes d'origine H_0 et H_1 ne sont pas équivalentes en nombre [Zhirabok et al. 2019].

3.7.4 Courbe COR

Dans le but de vérifier et de comparer la validité intrinsèque pour différentes conditions de mesure, les caractéristiques opérationnelles de réception pour « courbes COR » tracent l'évolution de la probabilité de détection correcte (P_{dc}) en fonction de la probabilité de fausse alarme (P_{fa}) [Bradley 1997]. La variation de ces deux probabilités est observée par rapport à un paramètre de l'algorithme de détection, appelé seuil.

Les courbes COR illustrent ainsi le compromis à réaliser entre le déclenchement des DC et des FA. Ces probabilités sont obtenues par approximation en considérant que les nombres d'échantillons N_{H_0} et N_{H_1} sont suffisamment grands et se résument dans les relations (3.27) et (3.28) :

$$P_{cd} = S_e \quad (3.27)$$

$$P_{fa} = 1 - S_p \quad (3.28)$$

Dans l'espace des courbes COR, la Figure 3.7, permet de voir certains points particuliers.

- le point $(0,1)$ dit **optimal** : correspondant à une probabilité maximale de DC et à une probabilité nulle de FA ;
- le point $(0,0)$, où **aucune détection**, qu'elle soit correcte ou non, ne se produit ;
- le point $(1,1)$ où tout signal, quel que soit son hypothèse H_0 ou H_1 , déclenche une détection ;
- le point $(1,0)$ dit **antagoniste**, et où l'algorithme de détection donne systématiquement une fausse réponse ;
- la **première bissectrice** $P_{dc} = P_{fa}$, est une droite correspondant à une détection aléatoire, c'est-à-dire donnant une probabilité aussi grande de détection pour les deux hypothèses.

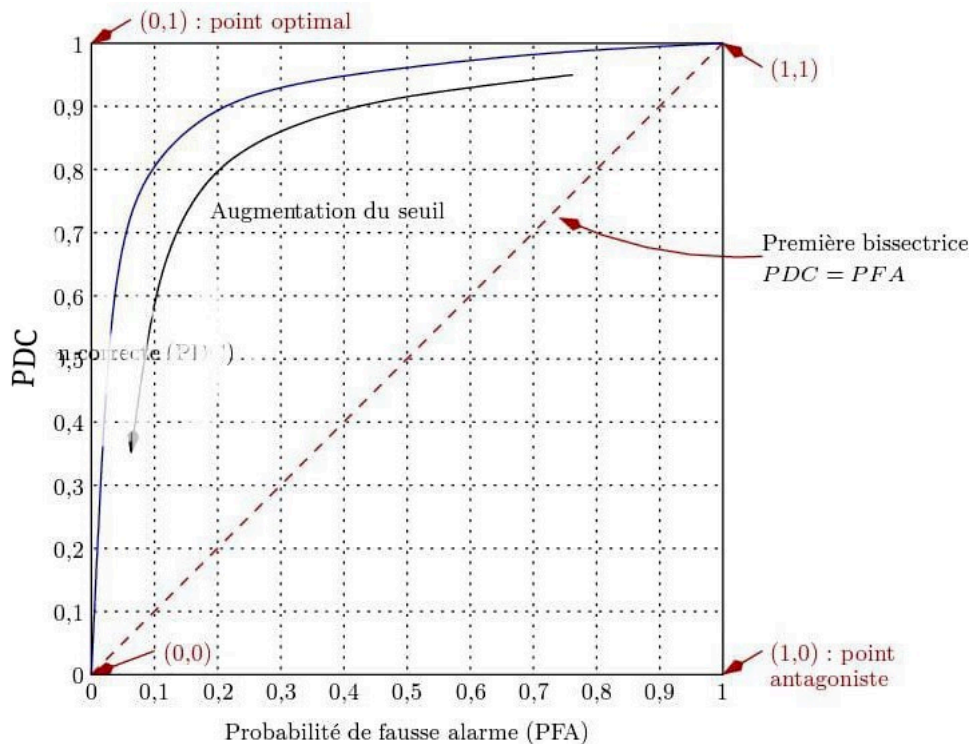


FIGURE 3.7 – Courbe COR.

Les courbes COR sont des courbes paramétriques variant en fonction du paramètre h de l'algorithme de détection, soit $COR = (P_{dc}(h), P_{fa}(h))$. Dans le cas présent où le paramètre unique de l'algorithme est un seuil de détection h , les courbes évoluent toujours depuis le point $(1,1)$ pour un h très faible, voire nul, correspondant à une réponse systématiquement positive de l'algorithme, jusqu'au point $(0,0)$, atteint pour un h supérieur au maximum des signaux associé à une non-détection systématique. Elles doivent normalement à tout moment se situer dans la partie supérieure gauche de l'espace des COR, c'est-à-dire présentant un meilleur compromis que la première bissectrice. Enfin, si la courbe COR atteint le point optimal $(0,1)$, cela signifie qu'il existe un seuil pour lequel toutes les DC possibles sont réalisées sans aucune FA : il s'agit du meilleur réglage possible pour l'algorithme.

3.7.5 Mesure de performance

L'aire sous la courbe COR (ASC) est une mesure souvent utilisée pour apprécier la performance de l'algorithme de détection [Bradley 1997]. C'est l'aire délimitée par la courbe COR, l'axe des abscisses et l'axe de droite $P_{fa} = 1$ de la figure 3.7. L'ASC est une fraction de l'aire de l'espace des COR : sa valeur est comprise entre 0 et 1.

3.8 Application au cas du GPV

3.8.1 Modélisation

Le Générateur photovoltaïque représentant notre processus industriel est constitué d'un ensemble de seize (16) panneaux photovoltaïques, organisé en quatre strings de quatre modules placés en série. Chaque string est doté d'un capteur permettant de mesurer son courant, puis un cinquième capteur permet de mesurer la valeur du courant total du générateur comme illustré sur la Figure 3.8. Un sixième capteur permet quant à lui de mesurer la tension de sortie du générateur.

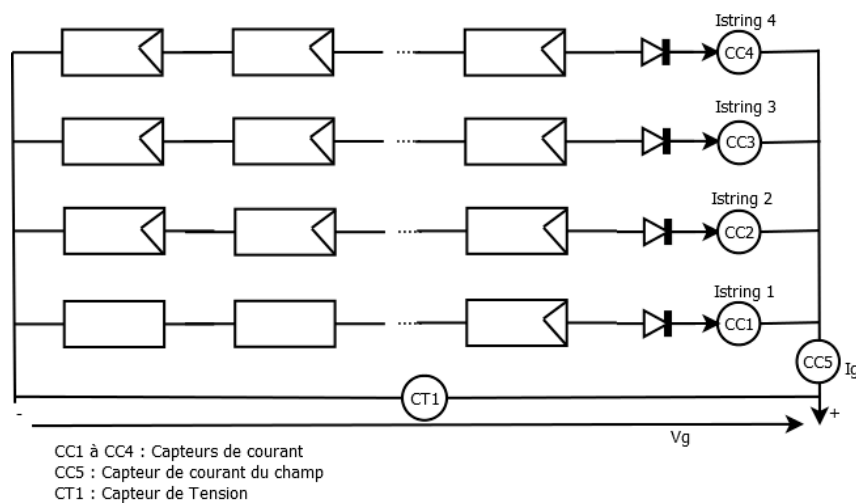



FIGURE 3.8 – Synoptique d'instrumentation des capteurs pour le GPV.

A partir de la caractéristique de fonctionnement I-V et P-V du mode sain de fonctionnement, et dont la configuration est donnée dans le paragraphe ci-dessus, nous nous plaçons au point de fonctionnement optimal appelé la plupart du temps MPPT (Maximum Power Point Tracker) [li et al. 2018] et représentée à la Figure 3.9. Ce point représente l'intersection de la courbe de la caractéristique I-V ou P-V avec une droite arbitrairement tangente. Autour de ce point de fonctionnement, on peut définir le courant de sortie comme étant celui de la relation (3.29) :

$$I_G = a_i \times V_G + b_i \quad (3.29)$$

$$\left\{ \begin{array}{l} a_i = \left. \frac{\partial (I_G, V_G)}{\partial V_G} \right|_{\substack{I=I_{sc} \\ V=V_{oc}}} \quad \text{le coefficient directeur} \\ b_i = I_G - a_i V_G \Big|_{\substack{I=I_{sc} \\ V=V_{oc}}} \quad \text{le coefficient de la pente} \end{array} \right. \quad (3.30)$$

et I_G et V_G respectivement le courant général et la tension générale de sortie du générateur.



(a) MPPT sur la caractéristique I-V.

(b) MPPT sur la caractéristique P-V.

FIGURE 3.9 – Position du MPPT du PGV par rapport aux caractéristiques I-V et P-V.

3.8.2 Génération de résidus

Une relation de redondance peut être utilisée pour tester la fonctionnalité des composants physiques constituant le générateur. Le but de ces relations de redondance analytique est de générer des résidus, qui permettront de décider si le fonctionnement s'apparente ou non à un fonctionnement normal du capteur [Joshi et al. 2017]. Aussi, nous avons construit ces résidus à partir du point rouge de la Figure 3.9a sur le principe du synoptique de la Figure (3.10) ci-dessous.

La connaissance physique du système nous a permis d'écrire les relations linéaires contenues dans les relations (3.31) et (3.32). Chaque relation décrit le comportement d'un string. Le modèle de chaque string exprime les contraintes de courant qu'il impose entre les variables qui lui sont liées sur la base des relations électriques, c'est-à-dire l'ensemble de la loi des nœuds définissant le comportement du string, par rapport aux informations du modèle, par rapport à l'ensemble des variables du système qui sont renseignées (observées ou mesurée). On obtient le modèle du système, décrit par les relations (3.31) suivantes :

$$\left\{ \begin{array}{l} I_G = I_{stg1} + I_{stg2} + I_{stg3} + I_{stg4} \\ V_G = V_{stg1} = V_{stg2} = V_{stg3} = V_{stg4} \\ V_{stgi} = V_{M1stg1} + V_{M2stg1} + V_{M3stg1} + V_{M4stg1} \end{array} \right. \quad (3.31)$$

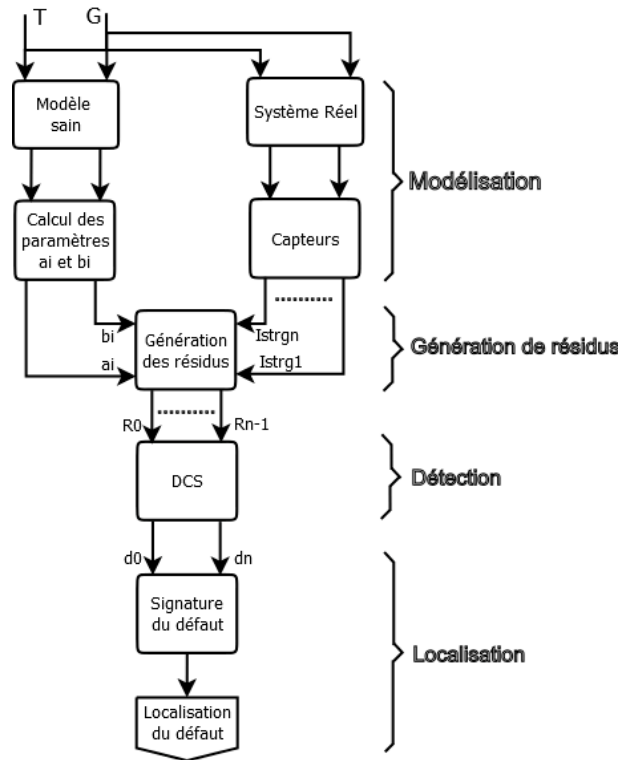


FIGURE 3.10 – Synoptique de la méthode de l'espace de parité du GPV.

où I_G est le courant de sortie du générateur ou la somme des courants des quatre strings du générateur et V_G est la tension de sortie du générateur ou la somme des tensions des quatre modules en série de chaque string du générateur.

Avec les six (6) capteurs judicieusement répartis sur notre processus, nous pouvons écrire les équations de mesures par la relation (3.32) :

$$\begin{cases} \widehat{I}_G = I_G + \epsilon_{I_G} \\ \widehat{I}_{stg1} = I_{stg1} + \epsilon_{stg1} \\ \vdots \\ \widehat{I}_{stgp} = I_{stgp} + \epsilon_{stgp} \\ \widehat{V}_G = V_G + \epsilon_{V_G} \end{cases} \quad (3.32)$$

- où \widehat{I}_G and \widehat{V}_G sont respectivement les mesures de courant et de tension du générateur à l'aide d'un capteur de courant et d'un capteur de tension ;
- \widehat{I}_{stg1} , \widehat{I}_{stg2} , \widehat{I}_{stg3} et \widehat{I}_{stg4} représentent les mesures de courants sur les sorties des strings 1, 2, 3 et 4 par des capteurs de courant ;
- ϵ_{I_G} , $\epsilon_{I_{stg1}}$, $\epsilon_{I_{stg2}}$, $\epsilon_{I_{stg3}}$ et $\epsilon_{I_{stg4}}$ représentent les éventuels bruits de mesures des capteurs de courant ;
- et ϵ_{V_G} l'éventuel bruit de mesure du capteur de tension.

3.8.3 Détection et localisation

Pour rappel, pour arriver à la phase de localisation, le diagnostic par redondance analytique a besoin de construire des tests de détection qui reposent sur des modèles testables, appelés relations de redondance analytique (RRA). Ces derniers sont des modèles ne faisant intervenir que des variables mesurées ou connues à l'avance. Ces modèles doivent permettre de calculer des résidus de la relation (3.33).

Nous avons alors les résidus directs suivants :

$$\begin{cases} R_0 = \hat{I}_G - \hat{I}_{stg1} - \hat{I}_{stg2} - \hat{I}_{stg3} - \hat{I}_{stg4} \\ R_1 = \hat{I}_{stg1} - a_{i1}\hat{V}_{stg1} - b_{i1} \\ R_2 = \hat{I}_{stg2} - a_{i2}\hat{V}_{stg2} - b_{i2} \\ R_3 = \hat{I}_{stg3} - a_{i3}\hat{V}_{stg3} - b_{i3} \\ R_4 = \hat{I}_{stg4} - a_{i4}\hat{V}_{stg4} - b_{i4} \end{cases} \quad (3.33)$$

Les tests peuvent être réalisés en parallèle et chaque décision issue de ces tests conduit à une valeur booléenne

- 0 : la valeur du résidu est en dessous du seuil ;
- 1 : la valeur du résidu a dépassé le seuil fixé.

L'ensemble de ces valeurs booléennes forme un vecteur binaire appelé signature de défaut.

Le vecteur binaire est comparé aux différentes signatures de panne ainsi qu'à la signature de fonctionnement normal. Cette comparaison conduit alors à une conclusion sur l'état du système :

- fonctionnement normal ;
- fonctionnement avec défaillance identifiée ;
- ou finalement défaillance non identifiée.

La localisation qui suit la détection est rendue possible grâce à la table de signatures. Les colonnes de cette table sur le Tableau 3.2, sont représentatives des différents défauts capteurs et les lignes des différents résidus. Les états de diagnostics sont donnés en termes de défauts localisables dans le table de signatures. L'interprétation des colonnes de la table de signatures consiste à comparer la signature des observations avec celle des défauts. Cette comparaison est considérée à nouveau comme un problème de décision.

TABLE 3.2 – Matrice d'occurrence d'un générateur PV.

R_i	I_G	V	I_{stg1}	I_{stg2}	I_{stg3}	I_{stg4}
R_0	1	0	1	1	1	1
R_1	0	1	1	0	0	0
R_2	0	1	0	1	0	0
R_3	0	1	0	0	1	0
R_4	0	1	0	0	0	1

Cette matrice dans le Tableau 3.2 s'avère bien localisante, car aucune des colonnes d'aucun des défauts ne se ressemblent. Aussi chacune d'elle permet d'identifier de façon formelle le défaut auquel elle est associée.

3.9 Résultats et interprétation

Dans cette section nous présentons les résultats du comportement d'un GPV. Pour rappel, il est configuré en quatre strings en parallèle avec quatre modules en série, soumis à l'effet d'un défaut capteur. Nous procédons dans un premier temps à la génération des résidus suivi de leur structuration mettant en évidence le défaut capteur arbitrairement placé dans un des quatre strings; dans un second temps la mise en évidence de la fonction de détection, permet de conclure à une détection fortement localisante du défaut capteur lié au **string 3**, grâce à sa signature dans la matrice d'occurrence. La mesure de la pertinence de la méthode de diagnostic à travers l'utilisation de la courbe COR interviendra dans un troisième et dernier temps.

Il est possible de simuler des défauts sur tous les capteurs du système que nous avons instrumenté. En fonctionnement normal, tous les résidus doivent être statistiquement nuls autour d'un bruit. Pour notre cas d'étude les résidus ne sont pas nuls du fait des bruits. Les Figures 3.11a et 3.14a résumant l'évolution des cinq résidus R_0 , R_1 , R_2 , R_3 et R_4 sur une durée de 5000 secondes et 500 secondes correspondant aux cinq relations de redondance.

Les défaillances sur les capteurs prendront la forme de biais. Pour le cas que nous avons choisi aléatoirement de présenter, un biais sur un capteur de courant est à la sortie de l'un des strings. Le biais débute à l'instant 100 et prend fin à 900 sur la Figure 3.11a respectivement à 100 et 400 sur la Figure 3.14a pour le second scénario. Ce biais est répété cinq fois seulement dans le premier scénario. Le biais est alors répercuté dans les résidus R_0 et R_3 des Figures 3.11b et 3.11e, respectivement 3.14b et 3.14e pour le second scénario. En effet, leurs valeurs ont été retranchée de 2 A et 10 A respectivement. Les autres résidus, ne sont pas affectés.

L'application de l'algorithme *DCS* (Dynamic Cumulative Sum), grâce à la technique des deux fenêtres glissantes, permettra enfin de générer la fonction de détection à travers la courbe $g(t)$ qui sera à chaque instant, comparée à un seuil. Les tests peuvent être réalisés en parallèle et chaque décision issue de ces tests conduit à une valeur booléenne (0 : la valeur du résidu est en dessous du seuil; 1 : la valeur du résidu a dépassé le seuil fixé) tel que confiné dans les Figures 3.12a puis 3.13a.

Sur chacune des Figures 3.11b à 3.11f et 3.14b à 3.14f respectivement pour le premier cas et le deuxième cas ci-dessous, nous avons combiné, toujours dans le même ordre :

- l'action du biais sur la première courbe, représentant le résidu d'ordre i ;
- la fonction $DCS(t)$ en fonction du temps sur la seconde courbe ;
- la fonction de détection $g(t)$ sur la troisième courbe ;
- enfin le résultat du test d_i , en fonction de la localisation du défaut du résidu d'ordre i .

Les résultats de simulation présentés ci-dessous, sont ceux de deux scénarii :

- cas d'un défaut capteur de 2 A de 5000 échantillons sur les Figures 3.11 et 3.12 ;
- cas d'un défaut capteur de 10 A de 500 échantillons sur les Figures 3.14 et 3.13.

3.9.1 Cas d'un défaut de 2 A

Pour le premier cas de cette simulation, nous avons injecté de façon arbitraire, un courant anormal d'amplitude de 2 A dans le système de mesure de l'un des strings. Ce défaut d'amplitude 2 A a été injecté entre les instants 100 et 900, puis répété cinq fois tout au long du signal sur la Figure 3.11a. Ce défaut régulièrement répété a permis d'observer la capacité de robustesse de

l'algorithme de détection. L'ensemble des résidus de 5000 échantillons traités sur la Figure 3.11, permet de mettre en évidence un défaut de capteur dans l'un des string de notre GPV, grâce à la signature donnée par la matrice d'occurrence et illustré à la Figure 3.12.

L'interprétation par rapport à la matrice d'occurrence du Tableau 3.2, pour une fenêtre de taille 20, pour le même seuil de détection de 170 de la Figure 3.12a, nous donne la présence de deux défauts du type capteur connu :

- sur le courant du string 3, entre les instants 1100 à 1400 et 2600 à 5000, avec la signature "10010" ;
- un défaut de nature inconnu, entre les instants 100 à 1100, avec la signature "00010".

Notons que le système semble être en mode sain entre les instants 0 et 100 à travers la signature "00000".

La mesure de la performance se fait ici pour une taille maximale de 20 pour les deux fenêtres glissantes. La courbe COR de la Figure 3.12b, nous indique par ailleurs la qualité de bonne détection par rapport aux fausses alarmes. La courbe COR atteignant même le point optimal avec une aire sous la courbe (ASC) égale à 1, synonyme de l'atteinte d'un seuil optimal de détection correcte.

3.9.2 Cas d'un défaut de 10 A

Pour la simulation du second cas, nous avons injecté aussi de façon arbitraire, un courant anormal d'amplitude de 10A dans le système de mesure de l'un des strings. Un défaut d'amplitude 10 A a été injecté une seule fois entre les instants 100 et 400 sur la Figure 3.14a. L'ensemble des résidus de 500 échantillons traités sur la Figure 3.14, permet de mettre en évidence un défaut de capteur dans l'un des string du GPV, grâce à la signature donnée par la matrice d'occurrence et illustré à la Figure 3.13.

L'interprétation par rapport à la matrice d'occurrence du Tableau 3.2, pour une fenêtre de taille 20, pour le même seuil de détection de 1700 de la Figure 3.13a, nous donne la présence de deux défauts du type capteur connu :

- sur le courant du string 3, entre les instants 98 à 370, avec la signature "10010" ;
- un défaut de nature inconnu, entre les instants 370 à 375, avec la signature "11101".

Notons que le système semble être en mode sain entre les instants 0 et 98 à travers la signature "00000".

La mesure de la performance se fait ici pour une taille maximale de 20 pour les deux fenêtres glissantes. La courbe COR de la Figure 3.13b, nous indique par ailleurs la qualité de bonne détection par rapport aux fausses alarmes. La courbe COR est très approchant du point optimal avec un ASC non loin de 1.

3.10 Conclusion

Nous avons rappelé dans ce chapitre quelques définitions concernant le diagnostic de défauts de capteurs. Le principe de ce diagnostic repose sur deux étapes consécutives, la structuration des résidus et la détection suivie de localisation de défauts. Il est nécessaire que les défauts soient au préalable, détectables puis localisables afin de les diagnostiquer.

Le point fort de ce chapitre réside dans la modélisation du GPV autour de son MPPT en présence de biais, pour l'application de la méthode de diagnostic principalement axé sur la méthode de l'espace de parité.

A cet effet, les signaux résiduels ont été générés afin de permettre la détection des défauts. Les différentes méthodes pour la génération des résidus utilisent la redondance analytique. Elles se basent sur le modèle du système et comparent les variables estimées à partir de ce modèle avec celles mesurées. Les résidus sont donc fonction des sorties estimées et des sorties mesurées.

Il est nécessaire de générer un nombre suffisant de résidus, au moins égal à la dimension des défauts, de manière à avoir un diagnostic fortement localisant et surtout meilleur en terme de localisation.

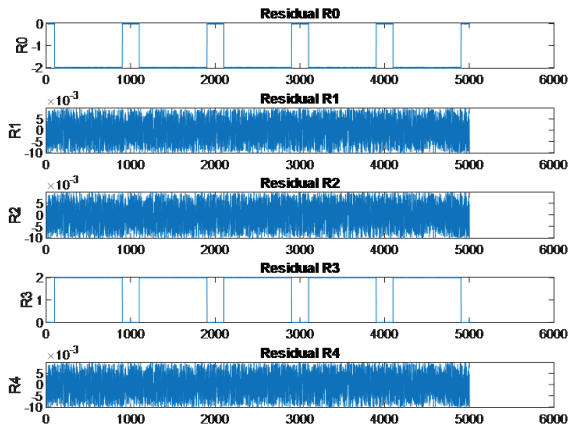
La localisation des défauts est basée sur la comparaison, à chaque instant, de la signature de défaut expérimentale avec les différentes signatures théoriques. La signature expérimentale de défaut des sorties résultantes à partir de l'analyse de la figure 3.12 et 3.13 montre que le défaut est localisé dans le string 3. Les deux signatures d'origines inconnues, prouvent qu'il faille peaufiner d'avantage la nature et le nombre de résidus, basé sur la connaissance des phénomènes physique du processus.

A travers deux scénarii nous avons expérimenté en utilisant la variation de l'amplitude du défaut capteur, la méthode de diagnostic à base des relations de redondance et en particulier l'Espace de Parité appliquée au point de fonctionnement maximal d'un système industriel complexe qu'est le GPV pour prouver l'efficacité et la robustesse de cette méthode. Nous avons mis en œuvre l'algorithme de la somme cumulée dynamique que nous avons expérimenté avec succès, dans le cadre de la détection des défauts capteurs du GPV. Nous avons aussi pu mesurer la performance de la détection à travers l'utilisation de la courbe COR, pour apprécier le faible pourcentage à la fois de fausses alarmes et de non détections.

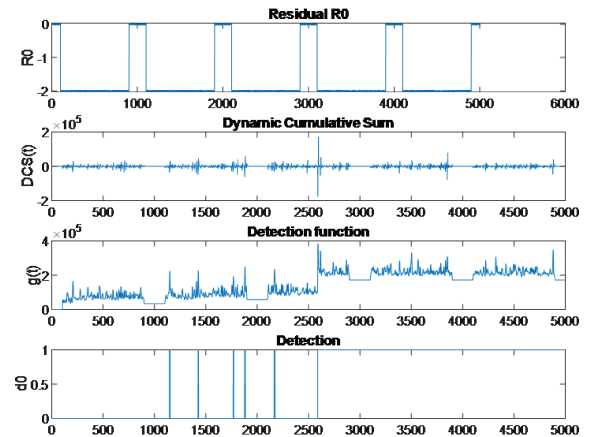
L'amplitude des défauts capteurs (courant ou tension), n'impacte pas l'algorithme de détection de la DCS, mais joue sur la qualité de la courbe COR, car il va du choix du seuil optimal de détection à choisir. La détection des défauts capteurs est fortement localisante, mais nous avons noté que cette technique de diagnostic est complètement aveugle sur la nature ou la partie du système en souffrance. Nous pouvons aussi préciser, que l'application de la méthode de l'espace de parité, doit se faire sous l'hypothèse d'absence de défaut système. Car un défaut système, peut tout aussi bien rendre le comportement du système sensible à cette méthode, alors que le ou les capteurs incriminés n'y seront pour rien. Il nous faut alors envisager d'autres alternatives pour palier à cette insuffisance. Néanmoins, grâce à cette méthode, nous pouvons écarter de façon formelle, un défaut lié à un capteur ou à un instrument de mesure utilisé sur le générateur.

Les premiers résultats sur le diagnostic par la méthode de l'espace de parité sont très encourageants, alors même que ni la détermination des seuils sur la fonction de détection n'ont pas été encore optimisés, ni la fixation de la taille des fenêtres glissante, qui influent elle sur la qualité de la performance à travers la courbe COR.

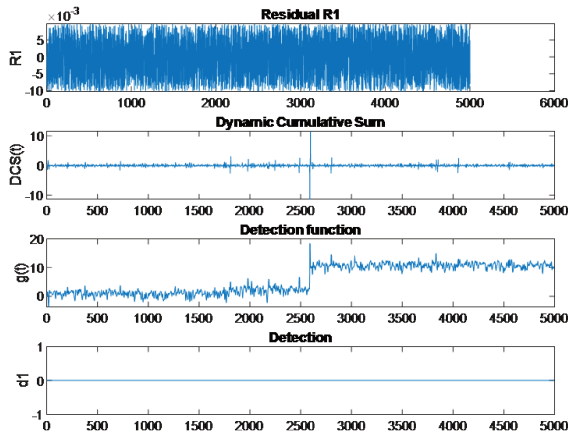
Le chapitre suivant aborde la problématique de détection des défauts système, inhérent au GPV. Il porte, en outre, sur la mise en œuvre d'une nouvelle méthode de diagnostic pour la détection des défauts et la classification des défauts système à travers l'utilisation de la méthode des réseaux de neurones artificiels dans un apprentissage peu profond.



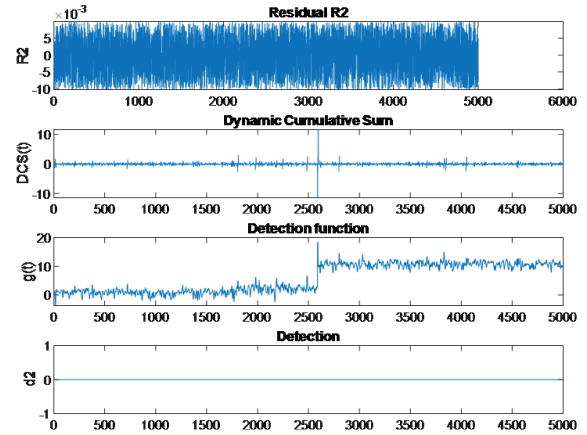
(a) Les cinq résidus pour 2 A.



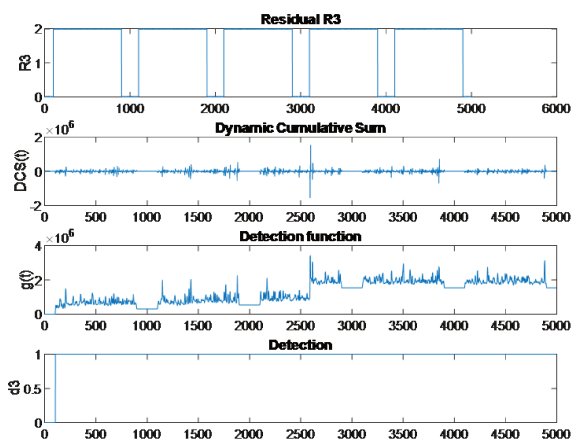
(b) DCS , $g(t)$ et d_i du résidu R_0



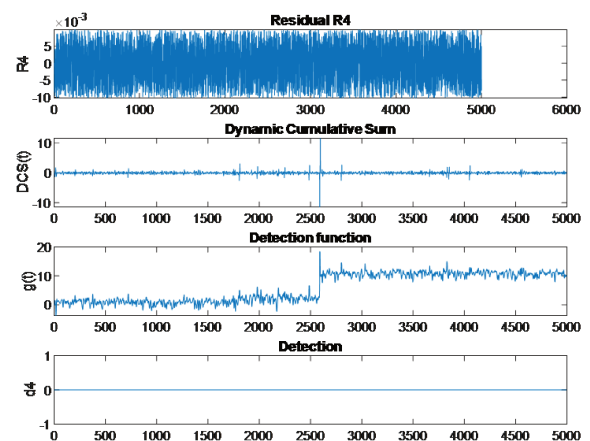
(c) DCS , $g(t)$ et d_i du résidu R_1 .



(d) DCS , $g(t)$ et d_i du résidu R_2 .

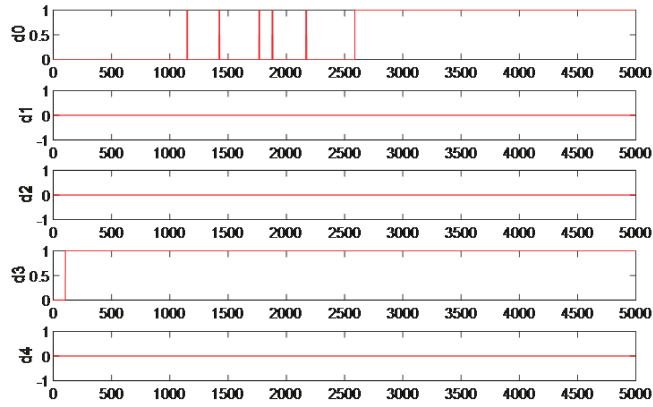
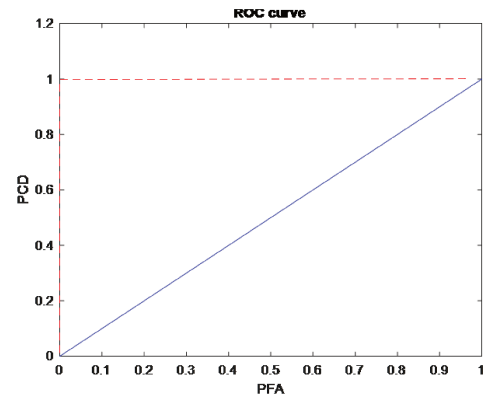


(e) DCS , $g(t)$ et d_i du résidu R_3 .





(f) DCS , $g(t)$ et d_i du résidu R_4 .

FIGURE 3.11 – Traitement des 5 résidus pour un défaut d'amplitude 2A.

(a) Localisation du défaut à travers les d_i 

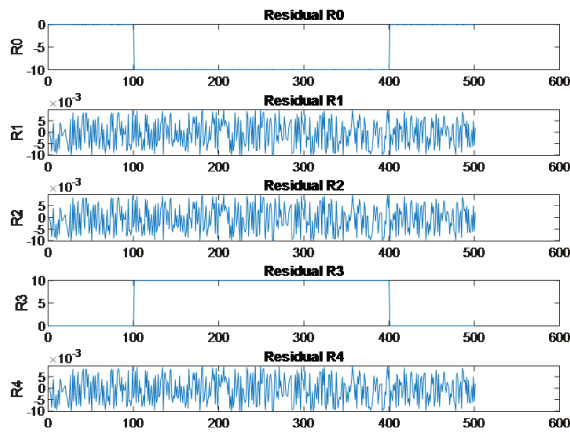
(b) Courbe COR du défaut de 2 A.

FIGURE 3.12 – Localisation et courbe COR pour un défaut d'amplitude 2A.

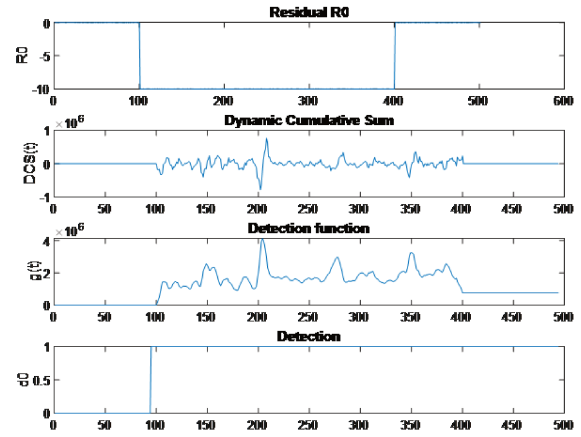
(a) Localisation du défaut à travers les d_i 

(b) Courbe COR du défaut de 10A.


FIGURE 3.13 – Localisation et courbe COR pour un défaut d'amplitude 10A.



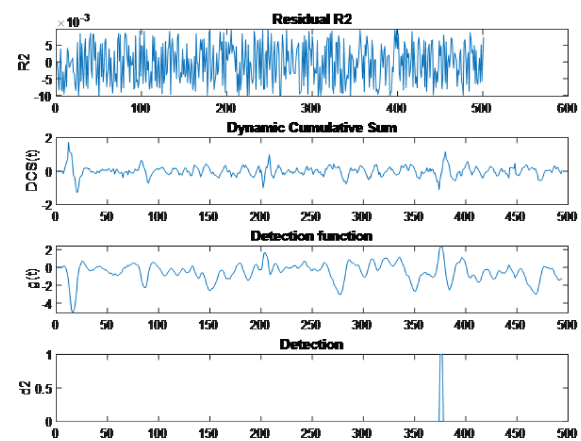
(a) Les cinq résidus pour 10 A.




(b) DCS , $g(t)$ et d_i du résidu R_0 .



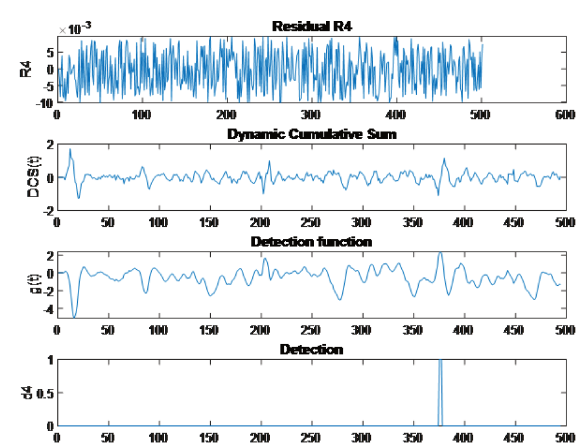
(c) DCS , $g(t)$ et d_i du résidu R_1 .



(d) DCS , $g(t)$ et d_i du résidu R_2 .



(e) DCS , $g(t)$ et d_i du résidu R_3 .



(f) DCS , $g(t)$ et d_i du résidu R_4 .

FIGURE 3.14 – Traitement des 5 résidus pour un défaut d'amplitude 10A.

Diagnostic par intelligence artificielle

4.1 Introduction

Dans le chapitre précédent, nous avons présenté une méthode de diagnostic basée sur l'analyse des relations de redondance principalement axée sur le principe de l'espace de parité pour la détection et la localisation des défauts capteurs dans les GPV.

À présent, nous tentons une autre approche, basée sur l'une des méthodes de l'intelligence artificiel (IA), un terme qui, dans son sens le plus large, indiquerait la capacité d'une machine ou d'un artefact remplissant les mêmes types de fonctions qui caractérisent la pensée humaine. L'IA est la partie de l'informatique consacrée à la conception des systèmes informatiques intelligents [Barr et al. 1981, Ahmad et al. 2021, Tzafestas 2018], c'est-à-dire des systèmes qui présentent des caractéristiques associées à l'intelligence chez l'homme comportement—compréhension, langage, apprentissage, raisonnement, résoudre des problèmes et ainsi de suite [Mellit et al. 2009, Malik et al. 2021, Barr et al. 1981].

Parmi toutes les branches de l'IA, nous pouvons citer entre autres les systèmes experts, les réseaux de neurones artificiels, algorithmes génétiques, la logique floue, la résolution de problèmes et de planification, le raisonnement non monotone, la logique de programmation, le traitement du langage naturel, la vision par ordinateur, la robotique, l'apprentissage, la planification ainsi que les divers systèmes hybrides, résultant de la combinaison de deux ou plusieurs des branches sus dessus mentionnées [Hu et al. 2021, Mellit et al. 2009, Malik et al. 2021, Barr et al. 1981].

Les méthodes de classification sont des méthodes d'apprentissage supervisé où l'étiquette des données symbolise la classe à laquelle appartient la donnée. On distingue parfois les méthodes de classification pour la détection, où les données appartiennent à 2 classes représentées par des étiquettes 0 ou 1 (ou préférentiellement -1 et 1 pour parler de données négatives et positives), et les méthodes de classification pour le diagnostic où chacune des données peut appartenir à une classe parmi N représentées par des étiquettes 1 à N , par exemple. Les étiquettes de classe peuvent arbitrairement être représentées par des entiers ou tout autre type de variable.

Beaucoup d'auteurs de par la littérature, ont essayé de multiples méthodes de détection automatique des défauts systèmes à plusieurs niveaux de la chaîne de conversion, mais il faut

retenir que la plupart s'appuient sur l'arrimage entre le GPV et le convertisseur.

C'est ainsi que de nombreuses techniques de détection avancées peuvent être trouvées dans la littérature, qui sont encore travaillées pour obtenir de meilleurs résultats. Certaines de ces stratégies se concentrent uniquement sur un seul type de défaut système [Barr et al. 1981, Madeti et al. 2017, Chowdhury et al. 2017, Dhumale et al. 2016], alors que certains des articles gèrent plusieurs types de défauts [Khomfoi e al. 2007, Poon et al. 2017, Fatama et al. 2020] de l'ensemble GPV-convertisseur, tandis que d'autres articles sont exclusivement destinés au diagnostic de défauts systèmes dans les convertisseurs d'électronique de puissance [Dhumale et al. 2016, Khomfoi e al. 2007, Abuelnaga et al. 2021, Fang et al 2018].

Cette orientation vers les réseaux de neurones artificiels se justifie, par leur forte adaptation face au comportement des systèmes industriels complexes comme le générateur photovoltaïque. Par l'utilisation des réseaux de neurones nous tenterons la classification pour la détection des défauts ou la classification pour le diagnostic suite à un défaut système particulièrement axée sur le principe du Perceptron Multicouches (PMC) en application sur le GPV uniquement.

Ce chapitre débute par quelques définitions autour des modèles et des topologies des RNA. Nous avancerons quelques clés sur les modes d'apprentissages avant de proposer nos configurations de simulations suivants les deux scénarii retenus. Une série d'interprétation et de synthèse seront faites avant le mot de conclusion du chapitre.

4.2 Du neurone au réseau de neurone

Les RNA sont une formulation mathématique simplifiée des neurones biologiques. Ils ont la capacité de mémorisation, de généralisation et surtout d'apprentissage qui est le phénomène le plus important. S'il est indéniable qu'ils ont une bonne capacité d'adaptabilité et d'auto organisation pour résoudre des problèmes non linéaires avec une bonne approximation, il faut noter aussi, certaines difficultés d'interprétation du comportement des réseaux de neurones comme inconvenient lors de la mise au point de certaines applications. Mais face à l'énormité de leurs qualités, plusieurs applications ont été réalisées avec succès pour des processus industriels, telles que celle envisagée avec le générateur photovoltaïque dans le cadre de cette thèse.

Le neurone biologique est constitué de quatre parties qui sont : le corps cellulaire (Soma), les dendrites, l'axone et les synapses illustré sur la Figure 4.1. Le corps cellulaire contient le noyau du neurone et effectue les transformations biochimiques nécessaires à la synthèse des enzymes et des autres molécules qui assurent la vie du neurone. Les dendrites sont de fines extensions tubulaires ramifiées autour du corps cellulaire.

L'axone sert de moyen de transport pour les signaux émis par le neurone. Il se distingue des dendrites par sa forme et par les propriétés de sa membrane externe.

La synapse est donc le lieu de passage des impulsions d'un neurone à l'autre qui peut être inhibitrice ou excitatrice et se caractérise par l'efficacité avec laquelle elle assure la liaison.

Le neurone formel (ou artificiel), quant à lui, est une modélisation mathématique qui reprend les principes de fonctionnement du neurone biologique.

Le réseau de neurones artificiels est considéré comme un arrangement d'éléments de structure identique appelés neurones interconnectés qui est analogue aux neurones biologiques fondés sur une structure complexe dont les analogies sont résumées dans le Tableau 4.1. Il est composé

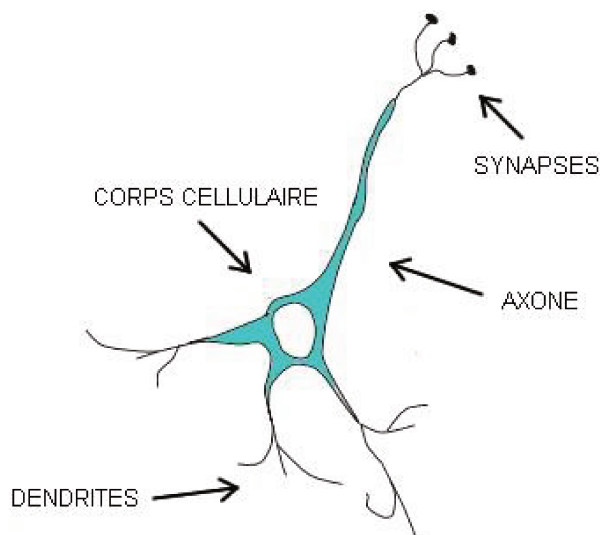


FIGURE 4.1 – Neurone biologique.

également d'une succession de couches connectées de manière à ce que chaque neurone tienne son entrée de la sortie du neurone précédant. Chaque neurone dans ce cas fonctionne indépendamment par rapport aux autres afin que l'ensemble forme un système compact. L'information est emmagasinée de façon répartie dans le réseau sous forme de coefficients synaptiques. Le neurone formel calcule régulièrement un résultat qu'il transmet ensuite aux neurones suivants, chaque calcul est associé à un poids qui définit la force de la connexion [Zhang et al. 2005]. Mathématiquement chaque neurone reçoit des entrées sous forme vectorielle en provenance des neurones situés en amont puis il calcule une somme pondérée de ses entrées pour que le résultat passe ensuite par la fonction d'activation afin de créer une sortie (qui est de nature binaire). A chacune de ses entrées (n en l'occurrence) : $x_1, x_2, x_3, \dots, x_n$ sont associés des poids ($w_1, w_2, w_3, \dots, w_n$) représentatifs de la force de connexion. Chaque entrée est pondérée par un poids synaptique propre w_i .

TABLE 4.1 – Analogie entre le neurone artificiel et le neurone biologique.

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

Le modèle interne du neurone ou perceptron, illustré à la Figure 4.2, résulte de la somme ν , un terme constant donné par la relation (4.1)

$$\nu = \sum_{i=0}^n w_i x_i \quad (4.1)$$

Le passage de la somme ν en ajoutant constamment le biais " b_0 " par la fonction d'activation f donne la sortie générale du neurone y . Le fonctionnement du neurone se résume dans la relation

(4.2) :

$$y = \sum_{i=0}^n w_i x_i - b_i = f(\nu) \quad (4.2)$$




FIGURE 4.2 – Modèle du neurone artificiel.

Plusieurs types de fonctions de transfert sont recensés dans la littérature mais les plus couramment utilisés sont illustrés dans la Figure 4.3. La plupart sont des fonctions continues, offrant une infinité de valeurs admissibles comprises entre $[0, +1]$ ou $[-1, +1]$.

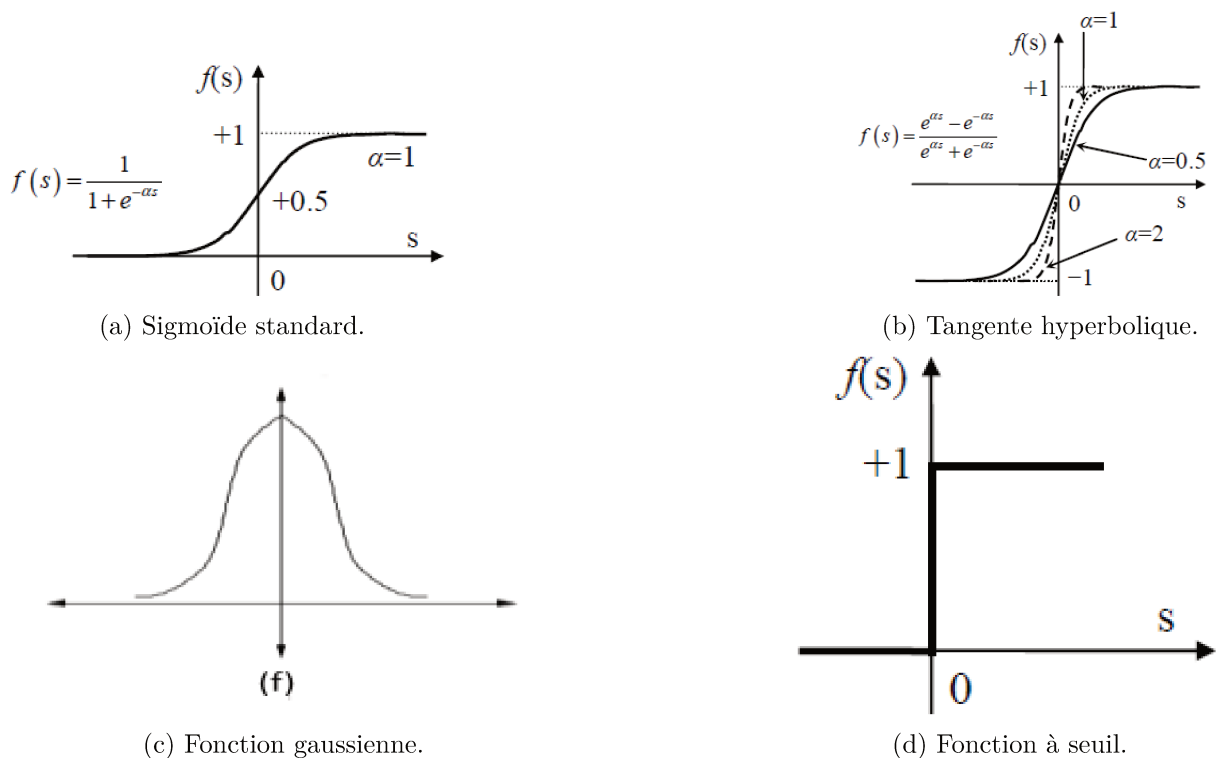


FIGURE 4.3 – Différents types de fonctions de transfert pour le neurone artificiel.

Dans un perceptron multicouche (PMC), tous les neurones d'une couche donnée sont connectés à tous les neurones de la couche suivante, comme illustré dans la Figure 4.4. Les neurones d'une même couche ne sont pas connectés entre eux et toutes les connexions sont unidirectionnelles de la gauche vers la droite, autrement dit, de l'entrée vers la sortie.

$$\nu_j^i = f_j^i \left(\left(\sum_{m=N_{i-2}+1}^{N_{i-1}} w_{j,m}^i \nu_m^{i-1} \right) - b_{0,m}^{i-1} \right) \quad (4.3)$$

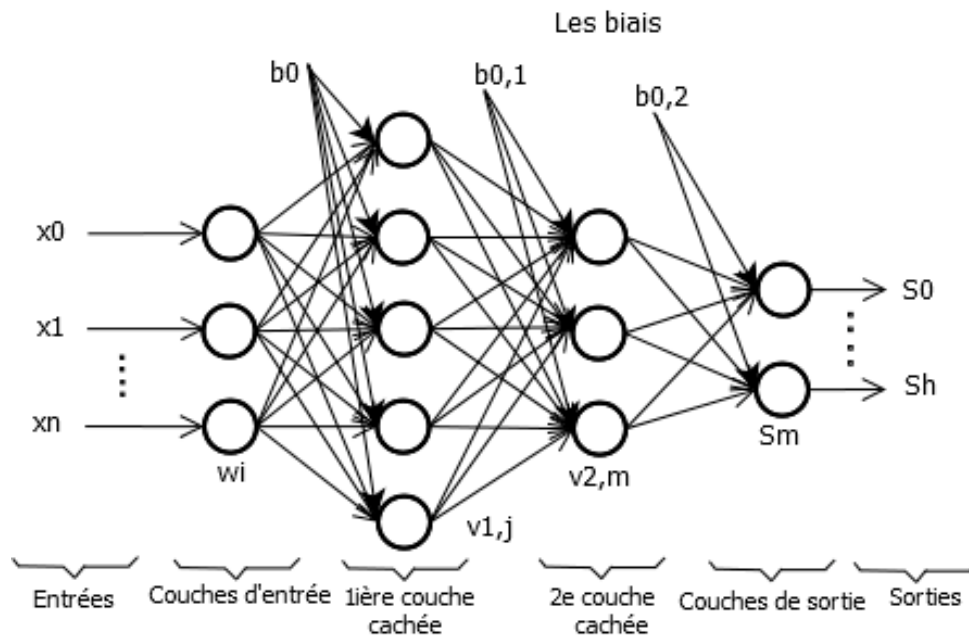


FIGURE 4.4 – Exemple d'un PMC.

avec

$w_{j,m}^i$ le poids de la connexion entre les neurones j de la couche i et m de la couche cachée $(i-1)$;

v_m^{i-1} et $b_{0,m}^{i-1}$ respectivement la sortie et le biais du neurone m de la couche cachée $(i-1)$;

f_j^i la fonction d'activation du neurone j de la couche cachée i ;

Enfin, la sortie S_h du PMC pour $h \in \{1, \dots, M\}$ est exprimée dans la relation (4.4) pour N_k neurone.

$$S_h = f_h\left(\sum_{N_{k-1}+1}^{N_k} w_{h,m} v_m^k - b_{0,m}^k\right) \quad (4.4)$$

En fonction du type d'application, les fonctions d'activations (f_j^i), qui sont du type fonction à seuil, doivent toujours être non linéaires sur les couches cachées, mais être linéaires ou non linéaires sur la couche de sortie (f_h) suivant la nature de l'application.

La phase d'apprentissage de l'algorithme passe par l'ajustement supervisé des paramètres tels les poids $w_{j,m}^i$ ou les biais $b_{0,m}^i$ du réseau, grâce à la minimisation directe de la fonction d'erreur.

Les différentes fonctions d'erreurs quadratiques partielles e^l pour une donnée d'entrée l sont définies dans la relation (4.5) :

$$e^l = \frac{1}{2} \left(\sum_{h=1}^M (h_h^l - S_h^l)^2 \right) \quad (4.5)$$

avec h_h^l et s_h^l les sorties réelles et désirées du réseau.

On obtient alors l'erreur finale de sortie dans la relation (4.6) :

$$e = \sum_l e^l \quad (4.6)$$

Par la méthode de la descente du gradient qui consiste à minimiser l'erreur globale du réseau,

on modifie systématiquement les poids $w_{j,m}^i$ et les biais $b_{0,m}^i$ du réseau, à chaque pas d'itération suivant les relations (4.7) et (4.8) ci-dessous :

$$\Delta w_{j,m}^i(t) = -\eta \frac{\partial e}{\partial w_{j,m}^i} = -\eta \sum_l \frac{\partial e^l}{\partial w_{j,m}^i} \quad (4.7)$$

$$\Delta w_{0,m}^i(t) = -\eta \frac{\partial e}{\partial w_{0,m}^i} = -\eta \sum_l \frac{\partial e^l}{\partial w_{0,m}^i} \quad (4.8)$$

Où η représente le taux d'apprentissage. Cette approche de l'estimation de la descente du gradient reste limitée par le manque de rapidité de sa convergence. Cela a permis de mettre en avant les qualités de la méthode Levenberg-Marquardt qui est plus rapide et avec de meilleurs résultats.

Finalement, le critère d'arrêt de l'algorithme d'apprentissage peut dépendre de l'un des trois critères ci-dessous ou même de leur combinaison, pour éviter le phénomène de sur-apprentissage :

- la limite du nombre maximal d'itération, ce qui évite la divergence de l'algorithme ;
- la fixation d'une borne inférieure de l'erreur quadratique elle-même, garantissant un bon indice de performance ;
- la fixation d'une vitesse limite de progression de l'algorithme d'apprentissage, qui l'arrête lorsque l'erreur quadratique ou bien les valeurs des paramètres ne varient pas trop sur de nouvelle itération.

4.3 Modèle et Topologie

Un réseau de neurone possède une topologie spécifique d'interconnexions entre poids, biais et somme à travers une loi d'apprentissage pour adapter ses points de connexions. Cette organisation est appelée structure ou architecture et possède les propriétés suivantes :

- Le parallélisme : c'est un ensemble d'entrées élémentaires qui travaille simultanément.
- La capacité d'adaptation : c'est la faculté qu'a le réseau de tenir compte des nouvelles contraintes ou des nouvelles données de son environnement extérieur. En tant que système dynamique, il possède une capacité d'auto organisation qui le rend stable.
- La généralisation : cette aptitude permet au réseau de donner une réponse satisfaisante à une entrée qui ne fait pas partie des exemples d'apprentissage.
- La structure de connexion : Les connexions entre les neurones décrivent la "topologie" du modèle qui peut s'avérer variable; ce qui fait apparaître une certaine régularité de l'arrangement des neurones.

Sur la base de ces quatre propriétés d'un réseau, on peut distinguer deux architectures connues à savoir : les réseaux de neurones non bouclés et les réseaux de neurones bouclés [Sarle 1994; Haykin 1994; Burns 2001].

4.3.1 Réseaux de neurones non bouclés « Feed Forward »

C'est un type de réseau dit statique, dans lequel la propagation de l'information se fait uniquement de l'entrée vers la sortie sans aucune rétroaction. En outre, ce type de réseau peut être monocouche ou multicouche.

4.3.2 Réseaux de neurones bouclés « Feed-Back »

C'est un type de réseau, dit dynamique ou récurrent, qui se caractérise par la présence d'au moins d'une boucle de rétroaction au niveau des neurones ou entre les couches. Les connexions rétroactives peuvent exister entre tous les neurones du réseau sans distinction, ou seulement entre certains neurones. Cette structure convient bien à la modélisation dynamique de processus non linéaires où la notion du temps est un élément essentiel tel que celui du diagnostic des défauts dans le générateur photovoltaïque.

4.4 Mode d'apprentissage

L'apprentissage consiste à modifier les poids de connexions du réseau qui correspond à une phase du développement du réseau de neurones durant laquelle on calcule les poids des neurones de telle manière que les sorties soient aussi proches que possible des sorties désirées [Bekkari et al. 2019]. Un ensemble fixé de règles bien définies pour la solution d'un problème d'apprentissage est appelé "un algorithme d'apprentissage". Les trois grands algorithmes d'apprentissages qui existent, sont élaborés à partir de la règle d'apprentissage de Hebb depuis 1949. Ces trois algorithmes d'apprentissage sont : supervisé, non supervisé et semi-supervisé.

4.4.1 Algorithme d'apprentissage supervisé

Dans un algorithme d'apprentissage supervisé, un superviseur fournit une valeur ou un vecteur de sortie désirée ou cible que le réseau de neurones doit associer au vecteur d'entrée. En somme, les paramètres du réseau s'adaptent par comparaison entre le résultat calculé, en fonction des entrées fournies et la réponse attendue en sortie. Le réseau mute ainsi jusqu'à l'obtention d'une erreur minimale [Guezzaz et al. 2020]. Dans le Tableau (4.2), est faite une synthèse des différentes structures utilisables sous ce format d'apprentissage.

4.4.2 Apprentissage non supervisé

Dans un algorithme d'apprentissage non supervisé, seules les valeurs d'entrée sont disponibles. Dans ce cas, les données d'entrée provoquent une auto adaptation du réseau afin d'engendrer des valeurs de sortie qui soient proches en réponse à des valeurs d'entrée similaires. Le Tableau (4.3) illustre quelques architectures, règles d'apprentissage et algorithmes en lien avec l'apprentissage non supervisé.

4.4.3 Apprentissage semi-supervisé

Dans un algorithme d'apprentissage semi supervisé, rarement utilisé, un comportement de référence n'existe pas, mais en revanche, il est possible d'obtenir des indications qualitatives (vrai, faux, ...) sur les performances du réseau.

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

TABLE 4.2 – Différents types d'apprentissages en mode supervisé.

Apprentissage	Architecture	Règle d'apprentissage	Algorithme	Domaines
Supervisé	Perceptron simple ou multicouche	Correction d'erreur	Perceptron, rétropropagation, Adaline, Madaline	Classification, approximation de fonctions, prédiction, contrôle
	Récurrente	Boltzman	Apprentissage de Boltzman	classification
	Multicouches non bouclés	Hebb	Analyse de discriminants linéaires	Analyse de données, classification
	A compétition	Par compétition	LVQ	Caractérisation au sein d'une classe, compression de données
	ART	-	ARTMap	Classification, catégorisation au sein d'une classe

4.5 Configuration du RNA pour le GPV

La démarche scientifique derrière cette partie vise à choisir la meilleure configuration allant dans le sens de la classification des défauts systèmes en vue d'assurer le diagnostic. Pour cela nous procéderons par les deux approches suivantes :

- une classification pour la détection de défaut système ;
- une classification pour le diagnostic d'un défaut système.

Dans chacune des approches, nous considérons une série de simulation essentiellement basée sur la variation de l'un des paramètres du système engendrant un défaut système :

- une variation de la température suite à un ombrage partiel de modules du champ PV ;
- une variation de l'ensoleillement suite à un ombrage partiel du champ PV ;
- une variation de la résistance série suite à des modules du champ partiellement défectueux ;
- une variation de la résistance shunt suite à des modules du champ partiellement court-circuités ou arrachés ;

Nous tenons à préciser d'ors et déjà que le choix osé de prendre la température et l'ensoleillement, les deux seuls signaux d'entrées du processus industriel soumis à étude, comme des paramètres engendrant des défaillances vient du fait que :

- trop de soleil, engendre de la délamination et de la décoloration qui entraînent d'autres problèmes ;
- trop de température engendre de la chaleur et des bulles qui nuisent considérablement aux cellules et à l'encapsulation.

TABLE 4.3 – Différents types d'apprentissages en mode non supervisé.

Apprentissage	Architecture	Règle d'apprentissage	Algorithme	Domaines
Non Supervisé	Multicouches, non bouclées	Correction d'erreur	Projection de Sammon	Analyse de données
	Multicouches ou à compétition	Hebb	Analyse en composante	Analyse de données
	A compétition	Par compétition	VQ	Caractérisation, compression de données
	Carte de Kohonene	-	SOM	Caractérisation, analyse de données
	ART	-	ART-1, ART-2	Catégorisation

4.5.1 Classification pour la détection

Le premier volet de la configuration, c'est de proposer un réseau de neurones qui permet de discerner entre un mode sain et un mode défaillant. La véritable difficulté réside dans la création des données d'entrée et de sortie, essentiellement sur la taille. Les données de la matrice d'entrée quant à elles, s'obtiennent sur la prise en compte d'une donnée de nature unique, sur la puissance, la tension ou le courant de sortie du GPV, qui seront utilisées comme les entrées de notre réseau de neurones. Au regard de ce qui se passe sur la caractéristique P-V, il est indéniable qu'un défaut quelle que soit sa nature, affecte les valeurs du courant et/ou de la tension, et par voie de conséquence la valeur de la puissance. Aussi nous choisissons de prendre pour chaque scénario de simulation comme données d'entrées, les valeurs des mesures de P, V et I obtenues sur le GPV, pour juger de la détectabilité de l'effet du défaut sur l'état de fonctionnement du GPV. Ces données étant accessibles par mesure directe à travers un système d'instrumentation.

La sortie, est la résultante d'une variable binaire unique, indiquant simplement l'état dans lequel, le GPV sera : pas de défaut 0, ou en défaillance 1.

Le changement de scénario, grâce à la variation du type de défaut pour tenir compte de la très grande diversité des causes de dégradation des performances du GPV, permet de juger les différentes performances de la classification pour la détection de défaut dudit GPV, mais surtout reste un meilleur indicateur de la robustesse de la configuration proposée.

Les données d'entrée de chacun des scénarii, sont obtenues suite à une simulation sur notre modèle GPV, prenant en compte un des défauts issus d'un des paramètres du modèle, à même d'impacter l'état de fonctionnement du GPV. Il s'agit entre autres :

- de la température ;
- de l'ensoleillement ;
- de la résistance série ;
- de la résistance shunt.

Nous avons expérimenté quatre scénarii de simulation basé sur les quatre défauts couramment rencontrés, en utilisant les données de :

- la puissance de sortie P du GPV ;
- la tension de sortie V du GPV ;
- le courant de sortie I du GPV.

4.5.1.1 Configuration des quatre scénarii de simulation

Autrement dit, une configuration pour un autre défaut engendrerait aussi des données P , V et I du GPV, que la configuration du RNA de classification pour la détection qui se veut robuste doit pouvoir interpréter le comportement défaillant ou non.

Nous nous sommes fixé, une taille des données d'entrée de 1×101 échantillons, largement suffisant pour l'algorithme de détection utilisé lors de la compilation, pour juger de la capacité de détection de l'existence d'un défaut. Le réseau ainsi configuré comporte une seule sortie indiquant la présence ou pas d'un défaut.

A cet effet, notre réseau est un réseau feedforward de 10 couches cachées, avec une fonction de transfert sigmoïde dans la couche cachée et une fonction de transfert linéaire dans la couche de sortie comme illustré sur la Figure 4.5.




FIGURE 4.5 – Configuration des RNA pour la détection.

4.5.1.2 Analyse de la détection pour un défaut de température

Dans ce scénario, nous commençons par simuler le comportement d'un GPV subissant un défaut système lié à une variation abrupte de la température qui passerait de $T = 293, 15^\circ$ à $T = 308, 15^\circ K$ suite à un ombrage partiel du type imprévu, affectant une partie du champ PV et illustré sur la Figure 4.6a. Nous recueillons l'ensemble des données de sortie du GPV de 101

échantillons illustré sur la Figure 4.6b (avec P en Watt, V en Volt et I en Ampère), avant d'extraire uniquement les données de la puissance P, de la tension V et du courant I devant servir de matrice d'entrée pour la configuration du RNA.

En changeant la nature des données d'entrées suivant les trois cas ci dessous, nous évaluerons les performances mais surtout la pertinence de la détectabilité de ce défaut de température par la classification pour la détection :




FIGURE 4.6 – Conséquence de la variation de T sur les données P, V et I pour la détection.

- Cas 1.** avec les données d'entrée de P, l'erreur quadratique est minimisée sur 79 itérations consécutives sur la Figure 4.7a, et la classification indique l'existence d'un défaut, comme le montre les courbes de performance de la Figure 4.7b ;
- Cas 2.** avec les données d'entrée de V, l'erreur quadratique est minimisée sur 28 itérations consécutives sur la Figure 4.8a, et la classification indique l'existence d'un défaut, comme le montre les courbes de performance de la Figure 4.8b ;
- Cas 3.** avec les données d'entrée de I, l'erreur quadratique est minimisée sur 47 itérations consécutives sur la Figure 4.9a, et la classification indique l'existence d'un défaut, comme le montre les courbes de performance de la Figure 4.9b ;

Synthèse de la détection suite au défaut de T

Le Tableau 4.4 de synthèse des performances montre que le réseau raisonne assez vite pour 10 couches cachées. Les résultats de simulation montrent également que le réseau de neurones détecte et classe bien l'existence du défaut dans les données issues de la puissance, de la tension et du courant de sortie du GPV suite à la variation abrupte de la température alimentant le modèle.

L'utilisation de l'une ou l'autre de ces trois données conduit à la détectabilité de l'existence du défaut ayant affecté les données. Cependant, le modèle de configuration est incapable de préciser la nature ni l'origine du défaut de température mis en exergue ici.

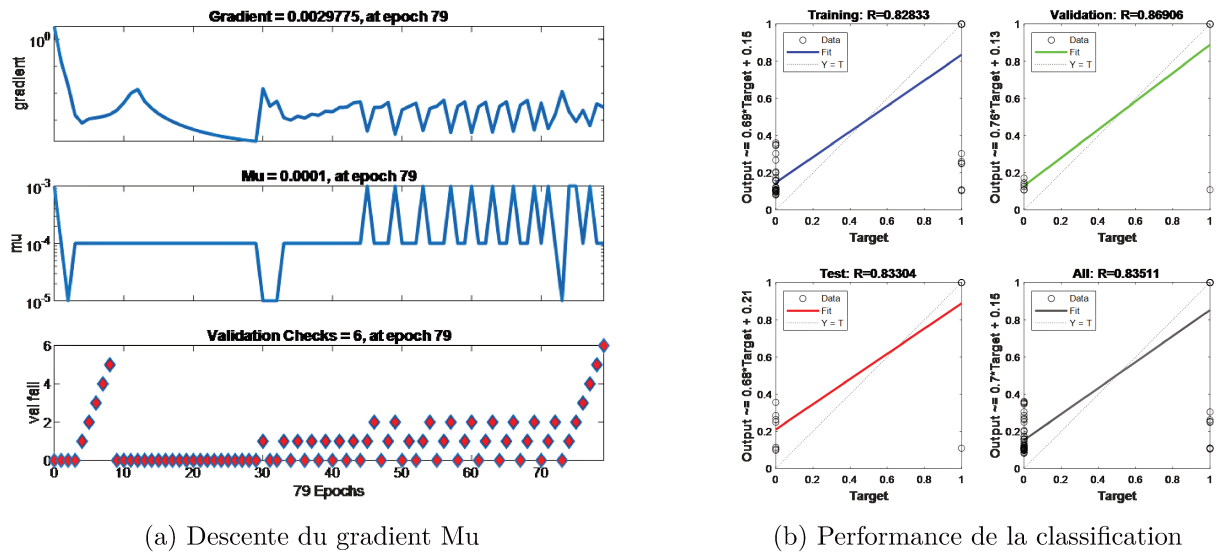


FIGURE 4.7 – Performances du RNA de défaut T avec des données liées à P.

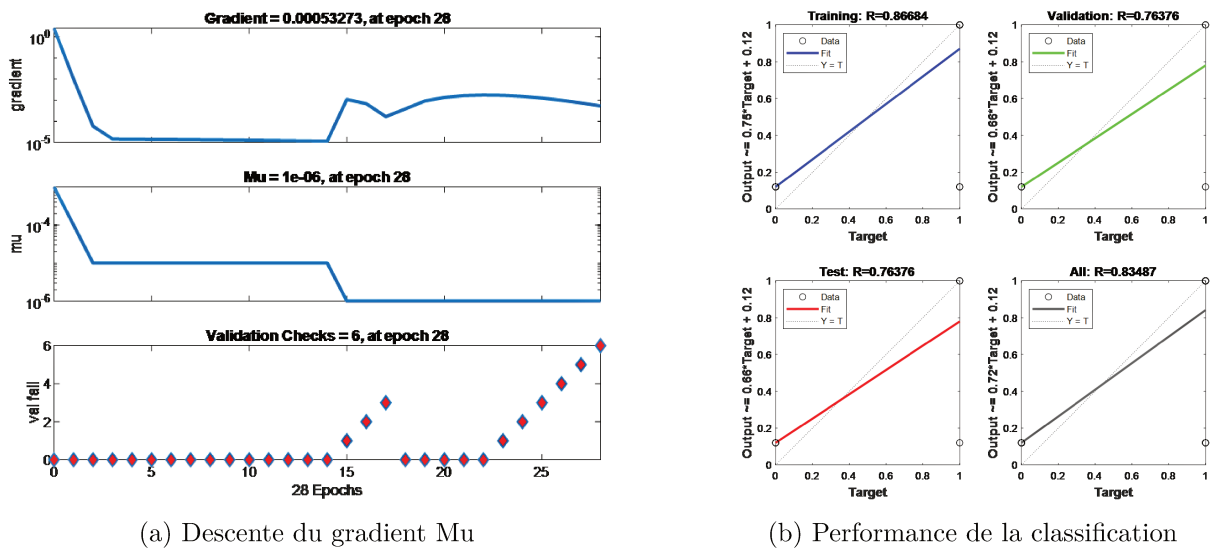


FIGURE 4.8 – Performances du RNA de défaut T avec des données liées à V.

Même si les performances de calcul sont assez bonnes pour les trois cas de simulation, elles pourront certainement être améliorées grâce à une augmentation du nombre de couches cachées.

4.5.1.3 Analyse de la détection pour un défaut d'ensoleillement

Dans ce scénario, nous recommençons la simulation du comportement du GPV qui subit un défaut système lié à une variation abrupte de l'ensoleillement qui passerait de $G = 1000 \text{ W/m}^2$ à $G = 1200 \text{ W/m}^2$ suite à un ombrage de type imprévu affectant le champ PV et illustré sur la Figure 4.10a. Nous recueillons l'ensemble des données de sortie du GPV de 101 échantillons illustré sur la Figure 4.10b (avec P en Watt, V en Volt et I en Ampère), avant d'extraire uniquement les données de la puissance P, de la tension V et du courant I devant servir de matrice d'entrée pour la configuration du RNA.

En changeant la nature des données d'entrées suivant les trois cas ci dessus, nous évaluerons

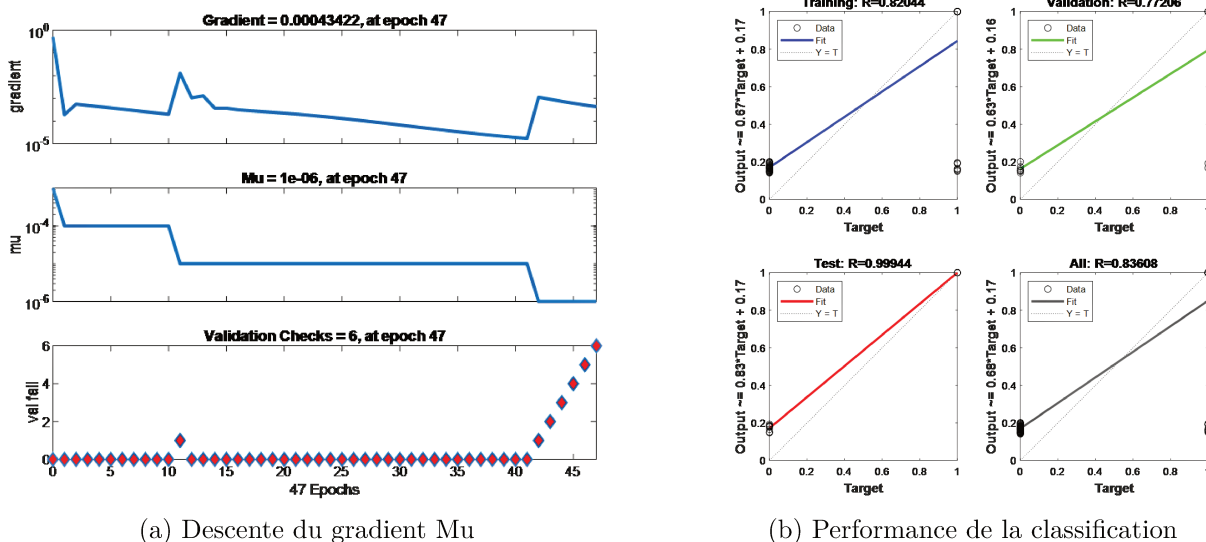


FIGURE 4.9 – Performances du RNA de défaut T avec des données liées à I.

TABLE 4.4 – Performance de la classification avec un défaut T.

	P	V	I
Nombre d'itérations	79	28	47
Durée du test	2"	2"	3"
MSE	$2,98.10^{-3}$	$5,33.10^{-4}$	10^{-7}
$Perf = (1 - MSE)$	99,70%	99,94%	99,99%
Détection	Oui	Oui	Oui

les performances mais surtout la pertinence de la détectabilité de ce défaut d'ensoleillement par la classification pour la détection :

- Cas 1.** avec les données d'entrée de P, l'erreur quadratique est minimisée sur 8 itérations consécutives sur la Figure 4.11a, et la classification indique l'existence d'un défaut, comme le montre les courbes de performance de la Figure 4.11b ;
- Cas 2.** avec les données d'entrée de V, l'erreur quadratique est minimisée sur 115 itérations consécutives sur la Figure 4.12a, et la classification indique l'existence d'un défaut, comme le montre les courbes de performance de la Figure 4.12b ;
- Cas 3.** avec les données d'entrée de I, l'erreur quadratique est minimisée sur 8 itérations consécutives sur la Figure 4.13a, et la classification indique l'existence d'un défaut, comme le montre les courbes de performance de la Figure 4.13b ;

Synthèse de la détection suite au défaut de G

Le Tableau 4.5 de synthèse des performances montre que le réseau raisonne assez vite pour 10 couches cachées. Les résultats de simulation montrent également que le réseau de neurones détecte et classe bien l'existence du défaut dans les données issues de la puissance, de la tension et du courant de sortie du GPV suite à la variation abrupte du niveau d'ensoleillement alimentant le modèle.




FIGURE 4.10 – Conséquence de la variation de G sur les données P, V et I pour la détection.

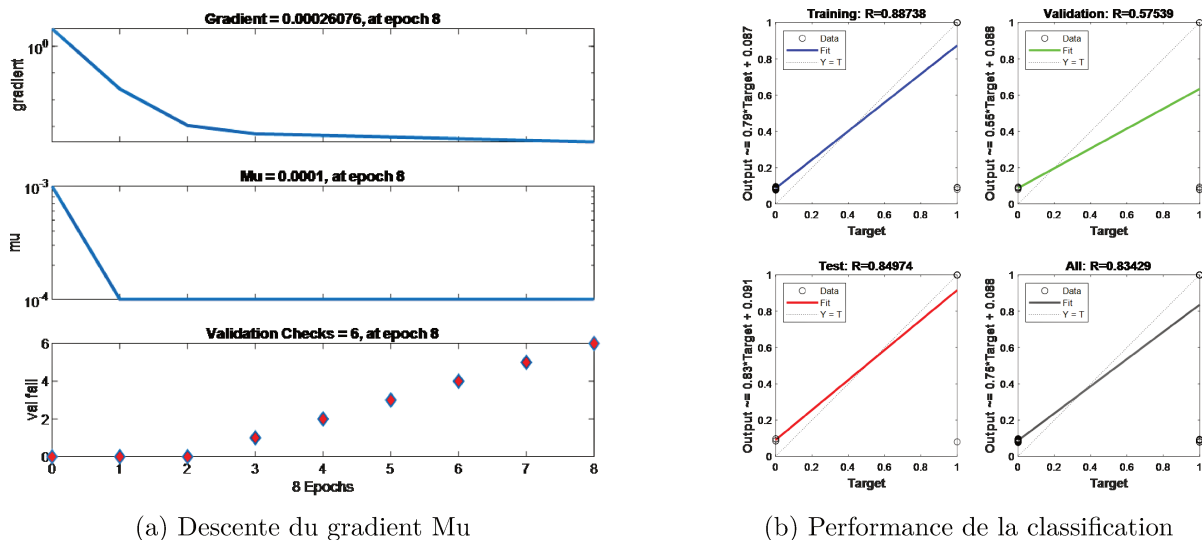



FIGURE 4.11 – Performances du RNA de défaut G avec des données liées à P.

L'utilisation de l'une ou l'autre de ces trois données conduit à la détectabilité de l'existence du défaut ayant affecté les données. Cependant, le modèle de configuration est incapable de préciser la nature ni l'origine du défaut d'ensoleillement mis en exergue ici.

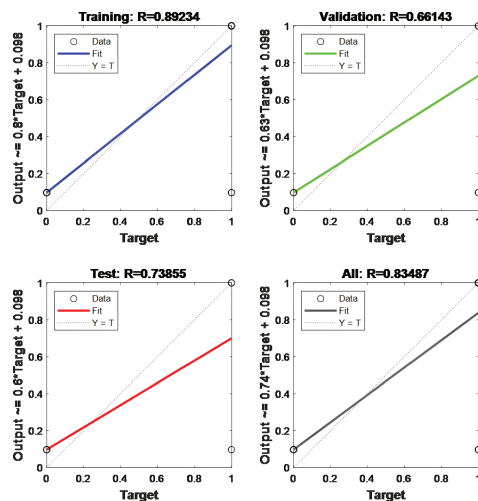
Même si les performances de calcul sont assez bonnes pour les trois cas de simulation, elles pourront certainement être améliorées grâce à une augmentation du nombre de couches cachées.

4.5.1.4 Analyse de la détection pour un défaut de R_s

Dans ce scénario, nous avons recommencé la simulation du comportement du GPV qui subit cette fois les effets d'un défaut système lié à une brusque variation de la résistance série qui passe de $R_s = 0,015 \Omega$ à $R_s = 4 \Omega$ suite à un ombrage partiel affectant certains modules du champ PV et illustré sur la Figure 4.14a. Nous recueillons l'ensemble des données de sortie du GPV de

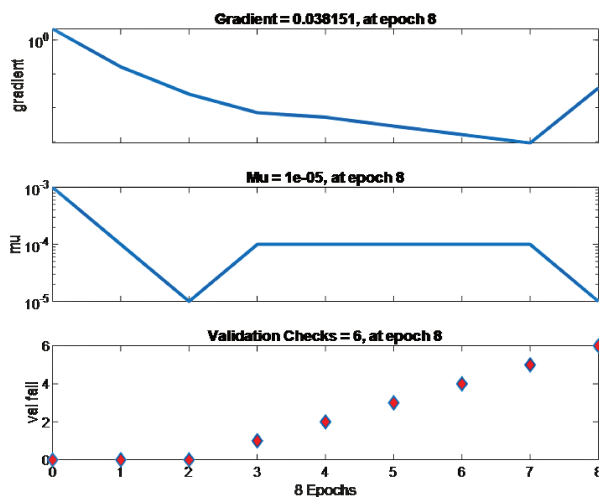


(a) Descente du gradient Mu




(b) Performance de la classification

FIGURE 4.12 – Performances du RNA de défaut G avec des données liées à V.



(a) Descente du gradient Mu



(b) Performance de la classification

FIGURE 4.13 – Performances du RNA de défaut G avec des données liées à I.


101 échantillons illustré sur la Figure 4.14b (avec P en Watt, V en Volt et I en Ampère), avant d'extraire uniquement les données de la puissance P, de la tension V et du courant I devant servir de matrice d'entrée pour la configuration du RNA.

En changeant la nature des données d'entrées suivant les trois cas ci dessous, nous évaluerons les performances mais surtout la pertinence de la détectabilité de ce défaut de résistance série par la classification pour la détection :

- Cas 1.** avec les données d'entrée de P, l'erreur quadratique est minimisée sur 7 itérations consécutives sur la Figure 4.15a, et la classification indique l'existence d'un défaut, comme le montre les courbes de performance de la Figure 4.15b ;
- Cas 2.** avec les données d'entrée de V, l'erreur quadratique est minimisée sur 7 itérations consécutives sur la Figure 4.16a, et la classification indique l'existence d'un défaut, comme le montre les courbes de performance de la Figure 4.16b ;
- Cas 3.** avec les données d'entrée de I, l'erreur quadratique est minimisée sur 7 itérations consé-

TABLE 4.5 – Performance de la classification avec un défaut G.

	P	V	I
Nombre d'itérations	8	115	8
Durée du test	1"	6"	1"
MSE	$2,61.10^{-4}$	$2,06.10^{-4}$	$3,82.10^{-2}$
$Perf = (1 - MSE)$	99,97%	99,97%	96,18%
Détection	Oui	Oui	Oui

FIGURE 4.14 – Conséquence de la variation de R_s sur les données P, V et I pour la détection.

cutives sur la Figure 4.17a, et la classification indique l'existence d'un défaut, comme le montre les courbes de performance de la Figure 4.17b ;

Synthèse de la détection suite au défaut de R_s


Le Tableau 4.6 de synthèse des performances montre que le réseau raisonne assez vite pour 10 couches cachées. Les résultats de simulation montrent également que le réseau de neurones détecte et classe bien l'existence du défaut dans les données issues de la puissance, de la tension et du courant de sortie du GPV suite à la variation abrupte de la résistance série du modèle.

L'utilisation de l'une ou l'autre de ces trois données conduit à la détectabilité de l'existence du défaut ayant affecté les données. Cependant, le modèle de configuration est incapable de préciser la nature ni l'origine du défaut de résistance série mis en exergue ici.

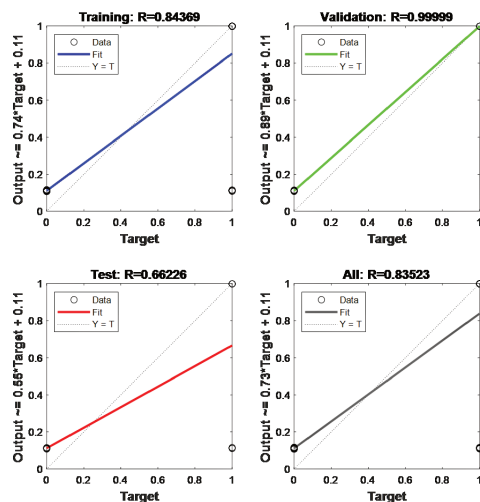
Même si les performances de calcul sont assez bonnes pour les trois cas de simulation, elles pourront certainement être améliorées grâce à une augmentation du nombre de couches cachées.

4.5.1.5 Analyse de la détection pour un défaut de R_{sh}


Dans ce scénario, nous avons recommencé la simulation du comportement du GPV qui subit cette fois les effets d'un défaut système lié à une brusque variation de la résistance série qui



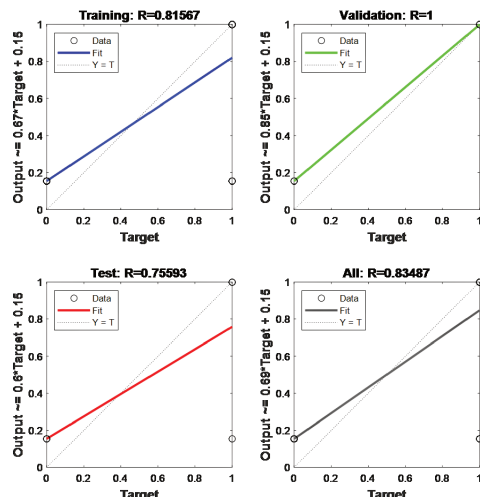
(a) Descente du gradient Mu



(b) Performance de la classification

FIGURE 4.15 – Performances du RNA de défaut R_s avec des données liées à P.

(a) Descente du gradient Mu



(b) Performance de la classification


FIGURE 4.16 – Performances du RNA de défaut R_s avec des données liées à V.

passé de $R_{sh} = 700\,000\ \Omega$ à $R_{sh} = 70\ \Omega$ suite à un ombrage affectant le champ PV et illustré sur la Figure 4.18a. Nous recueillons l'ensemble des données de sortie du GPV de 101 échantillons illustré sur la Figure 4.18b (avec P en Watt, V en Volt et I en Ampère), avant d'extraire uniquement les données de la puissance P, de la tension V et du courant I devant servir de matrice d'entrée pour la configuration du RNA.

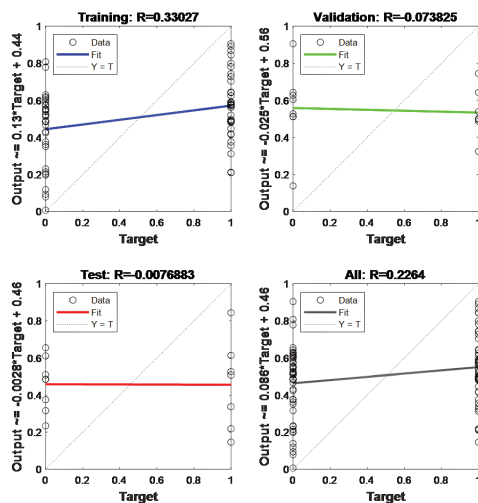
En changeant la nature des données d'entrées suivant les trois cas ci-dessous, nous évaluerons les performances mais surtout la pertinence de la détectabilité de ce défaut de résistance shunt par la classification pour la détection :

Cas 1. avec les données d'entrée de P, l'erreur quadratique est minimisée sur 7 itérations consécutives sur la Figure 4.19a, et la classification indique l'existence d'un défaut, comme le montre les courbes de performance de la Figure 4.19b ;

Cas 2. avec les données d'entrée de V, l'erreur quadratique est minimisée sur 9 itérations consécutives sur la Figure 4.20a, et la classification indique l'existence d'un défaut, comme le



(a) Descente du gradient Mu



(b) Performance de la classification

FIGURE 4.17 – Performances du RNA de défaut R_s avec des données liées à I.TABLE 4.6 – Performance de la classification avec un défaut R_s .

	P	V	I
Nombre d'itérations	7	7	7
Durée du test	2"	2"	2"
MSE	$5,67 \cdot 10^{-4}$	10^{-5}	$3,35 \cdot 10^{-2}$
$Perf = (1 - MSE)$	99,94%	99,99%	96,65%
Détection	Oui	Oui	Oui

montre les courbes de performance de la Figure 4.20b ;

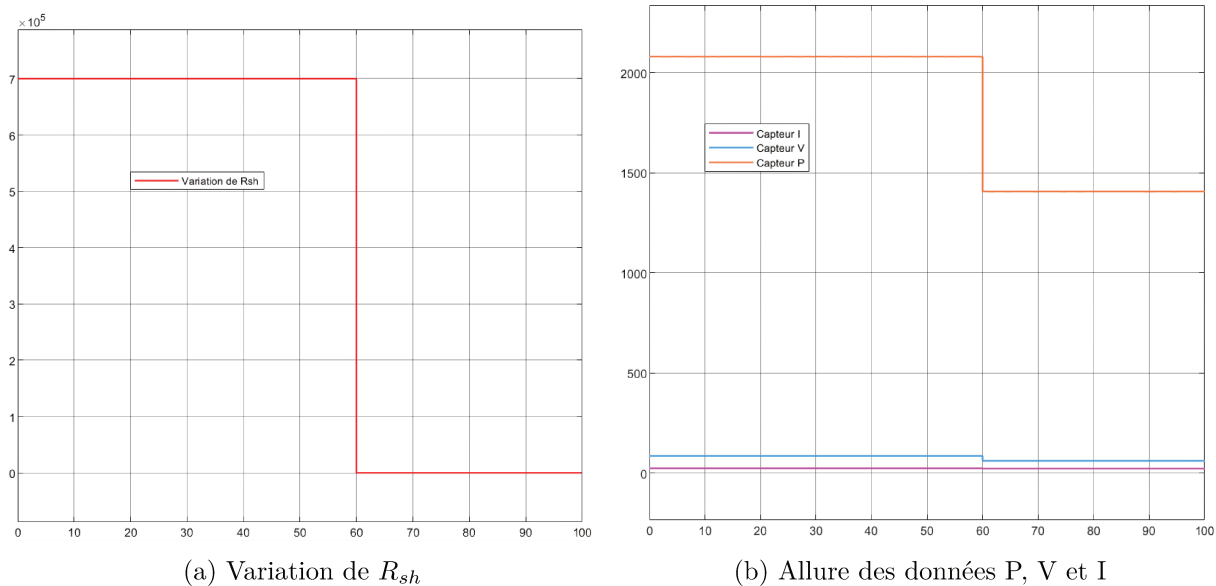
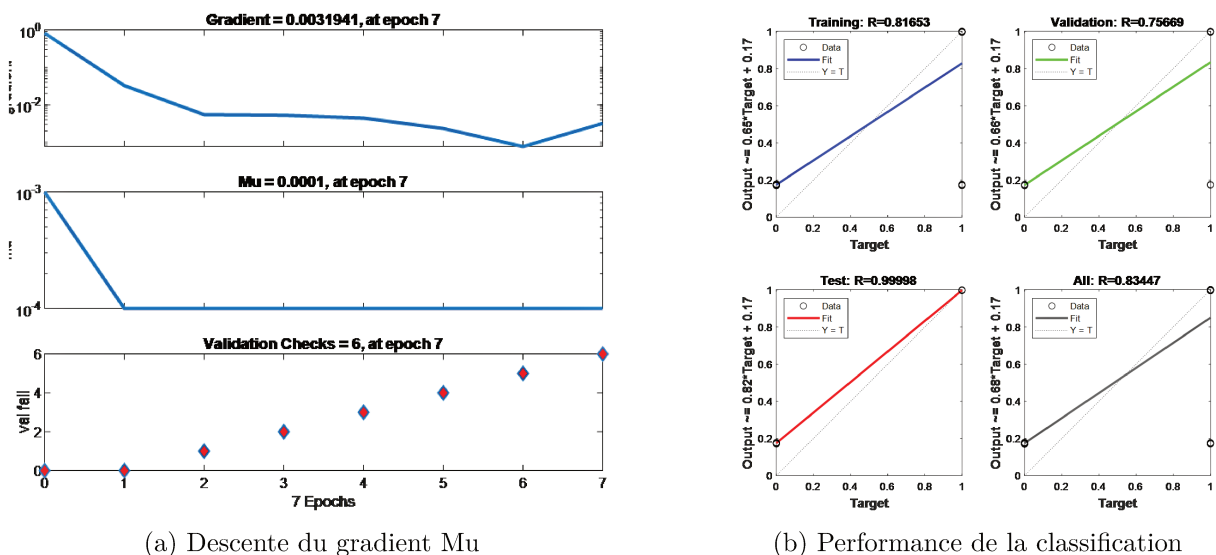
Cas 3. avec les données d'entrée de I, l'erreur quadratique est minimisée sur 7 itérations consécutives sur la Figure 4.21a, et la classification indique l'existence d'un défaut, comme le montre les courbes de performance de la Figure 4.21b ;

Synthèse de la détection suite au défaut de R_{sh}

Le Tableau 4.7 de synthèse des performances montre que le réseau raisonne assez vite pour 10 couches cachées. Les résultats de simulation montrent également que le réseau de neurones détecte et classe bien l'existence du défaut dans les données issues de la puissance, de la tension et du courant de sortie du GPV suite à la variation abrupte de la résistance shunt le modèle.

L'utilisation de l'une ou l'autre de ces trois données conduit à la détectabilité de l'existence du défaut ayant affecté les données. Cependant, le modèle de configuration est incapable de préciser la nature ni l'origine du défaut de résistance shunt mis en exergue ici.

Même si les performances de calcul sont assez bonnes pour les trois cas de simulation, elles pourront certainement être améliorées grâce à une augmentation du nombre de couches cachées.


FIGURE 4.18 – Conséquence de la variation de R_{sh} sur les données P, V et I pour la détection.FIGURE 4.19 – Performances du RNA de défaut R_{sh} avec des données liées à P.

4.5.1.6 Conclusion sur la classification pour la détection

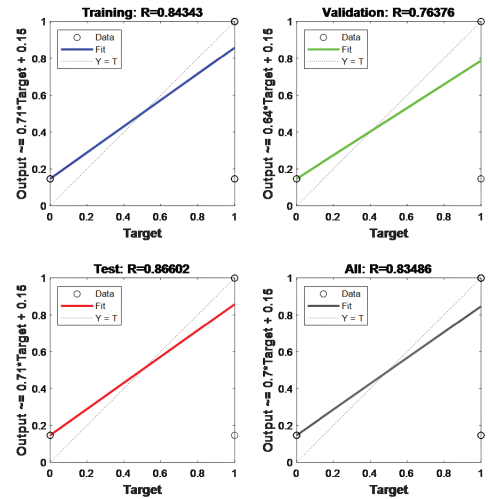
La complexité du RNA dépend fortement de la taille des données d'entrée et de sortie, mais nous avons pu dompter cette contrainte, pour ce premier cas de la détection suivie de la classification d'un type de défaut. En fonction du scénario de simulation choisi parmi les quatre défauts couramment rencontrés, nous avons toujours mis en évidence les trois cas à travers le changement de la nature des données (P, V et I), pour juger du caractère détectable ou pas d'un des défauts simulés (T , G , R_s , et R_{sh}).

Par contre, il n'existe pas une règle théorique pour déterminer le nombre optimal de couches cachées mais les 10 proposées nous donnent des résultats acceptables. Toujours est-il que nous avons pu constater que l'augmentation du nombre de couches cachées, augmente de manière significative les performances des réseaux, mais alourdissent aussi le temps de traitement.


D'après les résultats des quatre scénarii de simulation, nous savons qu'il y a détection d'un



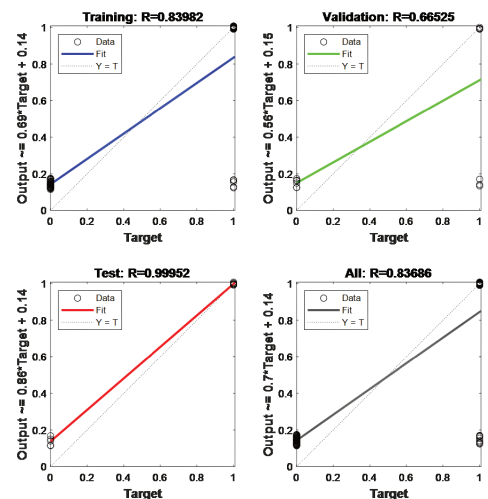
(a) Descente du gradient Mu



(b) Performance de la classification

FIGURE 4.20 – Performances du RNA de défaut R_{sh} avec des données liées à V.

(a) Descente du gradient Mu



(b) Performance de la classification

FIGURE 4.21 – Performances du RNA de défaut R_{sh} avec des données liées à I.

défaut dont nous donnons l'origine lors de la création des données d'entrée, mais la configuration du RNA pour la détection est incapable de nous indiquer sa nature ou son origine. Nous concluons donc sur le caractère détectable de chacune des trois données simulées. Des courbes de simulations obtenues, nous avons bien de bons pourcentages de classification de détection de défaut sans être capable de situer sa nature, c'est à dire liée à une variation de la température, de l'ensoleillement de résistance série ou shunt du modèle du GPV. Ayant pris en compte des amplitudes de variation très franche, il serait aussi souhaitable d'envisager lors d'autres études, les seuils limites de détectabilité des défauts en fonction de la nature et de l'amplitude des défauts.

Une amélioration des performances du réseau obtenu ici, peut passer par :

- un nouvel entraînement ;
- une augmentation du nombre de couches cachées ;
- Une augmentation de la taille des données d'entrée, ce qui accentuerait d'avantage nos problèmes de fluidification de la simulation.

TABLE 4.7 – Performance de la classification avec un défaut R_{sh} .

	P	V	I
Nombre d'itérations	7	9	7
Durée du test	2"	10"	2"
MSE	$3,19 \cdot 10^{-3}$	$7,9 \cdot 10^{-5}$	$1,31 \cdot 10^{-3}$
$Perf = (1 - MSE)$	99,68%	99,99%	99,87%
Détection	Oui	Oui	Oui

Nous déduisons aussi qu'une bonne performance dans le jeu d'apprentissage combiné à une mauvaise performance dans le jeu de test sur les Figures 4.7b à 4.21b, est toujours synonyme d'un sur-ajustement. Dans quel cas, une diminution du nombre de neurone caché aura pour effet d'augmenter considérablement la qualité de la classification de défaut effectuée.

A travers le changement de nature des données dans chaque scénario, nous pouvons confirmer la robustesse de la configuration RNA de la classification pour la détection, mais nous confortons la validation du modèle, qui s'adapte assez bien aux différents changements intrinsèque et dans son environnement.

4.5.2 Classification pour le diagnostic

Le second volet de l'application des réseaux de neurones dans la classification est pour résoudre des problématiques de diagnostic de défauts systèmes. La classification par les réseaux de neurones va affecter l'appartenance des individus aux classes, à une entrée x . Par exemple, si le fichier de données possède trois variables, la puissance P , la tension V , le courant I , un réseau de neurones va affecter chacune des variables d'entrées à l'une de ces huit classes cibles de sortie, correspondant à une combinaison logique de l'état de sortie des trois variables. L'information relative à l'appartenance des individus aux différentes classes est alors transmise à la variable cible t qui est toujours catégorielle. Une variable est dite catégorielle si, dans un premier temps, elle ne comporte que des valeurs discrètes, puis dans un second temps, elle ne peut être classée dans un ordre hiérarchique.

Le comportement du GPV ressemble à celui d'un système statique, mais dont la dynamique de variation des données est assez vivace et riche en information d'un état à un autre. Les données d'entrée utilisées, 501 échantillons contiennent chacune trois variables représentant la puissance, la tension et le courant pouvant être vu à chaque instant, comme un cas particulier d'un point de fonctionnement du GPV, pris à un instant donné. Un défaut système ayant le pouvoir de changer la valeur d'une des variables par rapport aux deux autres, ou changer la valeur des trois à la fois ou pas, cela engendre des données dont la dynamique est parfois liée à la présence ou pas d'un défaut du système.

Ces 501*3 échantillons d'entrée, sont automatiquement répartis en données entre les jeux d'apprentissage, de validation et de test suivant les taux :

- 70% pour l'apprentissage ;
- 15% pour valider que le réseau généralise et arrêter l'apprentissage avant un surajustement encore appelé overfitting ;
- 15% pour tester la généralisation du réseau de manière indépendante.

Pour les besoins de notre travail, nous ferons une mesure de la performance du réseau à travers quatre scénarii, basée sur de fortes variations mais surtout aléatoires de l'un des paramètres de notre modèle. Suite à une variation d'un des paramètres du modèle, nous relevons l'ensemble des données d'entrées P , V et I devant alimenter le RNA. Il s'agit de :

- la température appliquée au GPV ;
- le niveau d'ensoleillement appliqué au GPV ;
- la résistance série ;
- la résistance shunt.

A partir d'une configuration identique du RNA dans les quatre scénarii, nous procéderons au réglage supplémentaire suivant :

- la variation du nombre de 2, 5, 10 et 20 couches cachées ;
- l'utilisation de la fonction d'activation des neurones sur les couches cachées du type : log-sigmoïde ;
- l'apprentissage par l'algorithme de rétro propagation du gradient et l'erreur quadratique, minimisée par la méthode de Levenberg-Marquardt comme indiqué plus haut, continue jusqu'à ce que l'erreur de validation augmente consécutivement sur six itérations ;
- enfin les critères d'arrêt de l'algorithme d'apprentissage définis comme suit :
 - nombre maximum d'itérations = 1000 ;
 - erreur quadratique moyenne $MSE = 10^{-6}$;
 - *gradient minimum* = 10^{-10} ;
 - *Performance* : $Perf = (1 - MSE)$ en pourcentage.

La particularité de cette configuration du réseau de neurones pour le diagnostic, s'appuie sur l'entraînement dans un réseau de neurones artificiels doté d'une certaine connaissance du comportement du GPV, pour voir si la configuration est capable de diagnostiquer et classer un défaut du type système, mieux de pouvoir le situer.

4.5.2.1 Préparation du réseau

Suite à la variation d'un paramètre du GPV, les résultats de simulation engendrent les données d'entrée du RNA constituées de l'ensemble des trois variables que sont $\{la\ puissance\ P, la\ tension\ V, le\ courant\ I\}$, représentant respectivement P_G , V_G , et I_G , pour alléger la notation dans le reste du document.

La sortie de la variable *classe* de la relation (4.9), indique la signature d'un défaut appartenant certainement à une famille du tableau 4.9. Cette signature est obtenue à partir de la variation logique des trois variables P, I et V résultant du comportement du GPV.

$$classe \begin{cases} = 1 & \text{si le défaut existe;} \\ = 0 & \text{s'il n'y a pas de défaut.} \end{cases} \quad (4.9)$$

Le GPV est en mode sain, c'est à dire en fonctionnement normal si la variable *classe* = 0.

Mais la variable *classe* = 1, est synonyme d'un défaut dont la signature est donnée par la combinaison des trois variables avec une indication de la désignation de son origine en rapport avec sa famille concernée dans ledit tableau.

Aussi, cette logique nous permet de construire la matrice de sortie sur la base de la simulation du comportement d'un GPV pour un ensemble de défauts probables suivant le code du tableau

4.9. Il est possible d'identifier de potentiels symptômes utilisables pour remonter à la nature de défauts [Compaoré et al. 2021 b.].

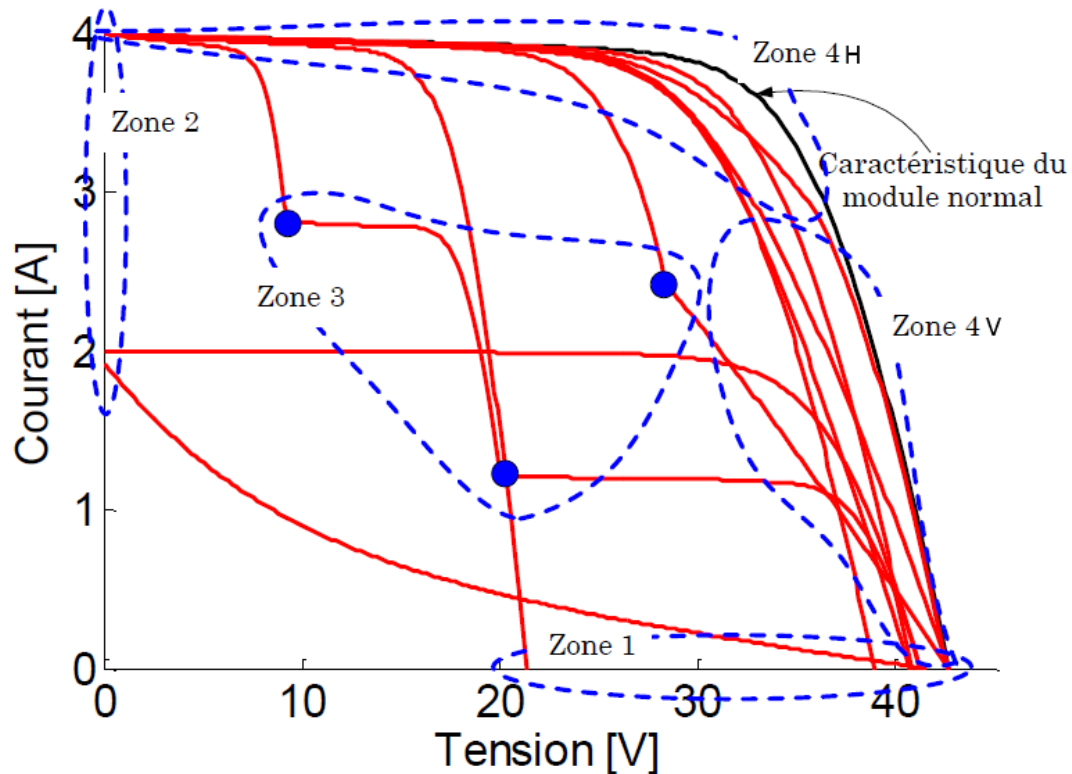


FIGURE 4.22 – Caractéristique I-V en mode sain (noire) et mode dégradé (rouges).

Le lien entre la caractéristique I-V et les défauts, résumé dans le Tableau 4.8, donne en plus, une certaine localisation d'une famille de défauts, fréquemment rencontrés dans le fonctionnement d'un GPV. Nous situons également dans ledit tableau, les zones d'impact probable par rapport à la caractéristique I-V du GPV.

Si la caractéristique I-V se trouve dans la :

- zone 1, c'est qu'il y a variation de la tension du GPV ;
- zone 2, c'est il y a une variation du courant du GPV ;
- zone 3, c'est qu'il y a des modules en moins dans le GPV ;
- zone 4V, c'est qu'il y a eu variation de résistance série ;
- zone 4H, c'est qu'il y a eu variation de la résistance shunt ;

Aussi, la combinaison de certains symptômes identifiés comme des défauts, permet d'identifier des types de défauts responsables du comportement examiné [Bun 2011 a.] et résumé dans le Tableau 4.9. Sur la caractéristique de la Figure 4.22, on peut alors faire un lien entre les principaux types de défauts couramment rencontrés et les cinq zones d'impact de la façon suivante :

- D0 correspond au mode sain, c'est-à-dire en l'absence de tous défauts, car aucune zone n'est impactée. Cette situation assimilable à D1, dans le cas d'un court circuit d'une diode de bypass n'affectera aucune zone ;
- D1' et D9, deux codes de défaut qui se confondent parfaitement et qui affectent de façon similaire les zones 1, 2 et 3. Car la diode de bypass tout comme la connectique, peut être mal connecté, en inversion ou en HZ pour le cas particulier de la diode de bypass ;

TABLE 4.8 – Croisement des défauts et des zones.

Défauts	Code défaut	Zone 1	Zone 2	Zone 3	Zone 4 V	Zone 4 H
Aucun défaut	D0	0	0	0	0	0
Diode de bypass défailante	D1	0	0	0	0	0
Diode de bypass défailante	D1'	1	1	1	0	0
Ombrage sur 1 ou 2 modules	D2	1	0	0	1	1
Connectique	D3	1	0	1	1	0
Module court-circuité	D4	1	0	0	1	0
Module shunté	D5	1	1	1	1	0
Module inversé, perte de string	D6	1	1	0	0	0
Mismatch type R_{sh}	D7	0	1	0	0	1
Mismatch type R_s	D8	1	0	0	1	1
Connectique déconnectée	D9	1	1	1	0	0
Mismatch complet	D10	1	1	0	1	1

- D2 et D8, deux codes qui affectent aussi de façon similaire les zones 1, 3 et 4 verticale comme horizontale. C'est le cas d'un ombrage partiel, ou l'utilisation de module de résistance série différente dans un string ;
- D3 correspond généralement à des défauts en liens avec la connectique, conduisant à la perte d'un ensemble de modules du champs PV, et qui affecte les zones 1, 3 et 4 verticale ;
- D4 fait référence à des défauts liés aux modules PV court-circuités, et qui peut affecter les zones 1 et 4 verticale ;
- D5 fait référence à des défauts liés aux modules shuntés, ce qui peut affecter les zones 1, 2, 3 et 4 verticale ;
- D6 fait référence à des défauts liés aux modules PV inversés, ce qui peut affecter les zones 1 et 2 ;
- D7 résulte d'une variation de la résistance série d'un ou plusieurs modules simultanément. Cela peut affecter les zones 2 et 4 horizontale ;
- D10 apparait dans le cas d'un ombrage total du champ PV, ce qui peut affecter en général une ou plusieurs des zones 1, 2, et 4 verticale comme horizontale.

Sur la base de cette connaissance sur le comportement du GPV, nous proposons le Tableau (4.9) avec les types de défauts, comme principe de raisonnement logique pour l'établissement de la matrice de sortie du RNA avec le code sur trois bits, en lien avec les types de défauts. Lors de la simulation avec les données d'entrées, la configuration du RNA permettra s'il y a lieu, un diagnostic de la localisation de l'origine d'un éventuel défaut système.

4.5.2.2 Performances comparées sur 4 défauts systèmes

Nous rappelons que dans cette série de simulation, les données d'entrée de chacun des scénarii ci-dessous, sont obtenues suite à la variation d'un des quatre défauts systèmes :

- une variation de la température suite à un ombrage partiel du champ ;
- une variation de l'ensoleillement suite à un ombrage partiel du champ ;
- une variation de la résistance série suite à des modules du champ partiellement défectueux ;
- une variation de la résistance shunt suite à des modules du champ partiellement court-

TABLE 4.9 – Matrice de sortie.

Famille du défaut	Désignation du type de défaut	P	I	V	Code	Classe
Aucun défaut	Mode sain ou aucun défaut	0	0	0	000	0
Problème d'ombrage	Mismatch type ombrage ou ensoleillement	0	0	1	001	1
Problème d'ensoleillement ou de température	Module court-circuité ou inversé	0	1	0	010	1
	Mismatch type ombrage partielle, ou saleté	0	1	1	011	1
	Diode de bypass ou Mismatch type R_{sh} ou R_s	1	0	0	100	1
Problème d'ombrage ou d'éclairage	Diode de bypass ou Mismatch type R_s ou R_{sh}	1	0	1	101	1
	Mismatch type R_s	1	1	0	110	1
Plusieurs hypothèses possibles	Nature du défaut inconnue	1	1	1	111	1

circuités ou arrachés.

Nous nous sommes fixé, une taille des données d'entrée de 501×3 échantillons, assez suffisant pour l'algorithme de classification pour le diagnostic utilisé lors de la compilation, pour juger de la capacité de diagnostic des défauts systèmes. Le réseau ainsi configuré comporte trois bits de sortie en relation avec l'état de la classe dans le Tableau (4.9), qui indique la présence ou pas d'un défaut.

4.5.2.2.1 Performance du réseau pour un défaut de température (T)

La simulation se fait ici, pour une température illustrée sur la Figure 4.24a qui passe de $T = 293.15^\circ K$ à $T = 308.15^\circ K$ entre les instants 250 et 400 pour obtenir l'allure des données comme illustrée sur la Figure 4.24b (avec P en Watt, V en Volt et I en Ampère).

Les écarts quadratiques minimisés sur les Figures 4.25a, 4.26a, 4.27a et 4.28a, et les les Figures 4.25b, 4.26b, 4.27b et 4.28b des courbes COR de la classification du diagnostic d'un défaut suite à une variation de la température pour différentes configurations de RNA respectivement pour 2, 5, 10 et 20 couches cachées, prouvent l'existence d'un défaut système et dont l'origine peut être située dans l'un des codes ci dessous, obtenu pour un seuil de défaut de 0,33325 :

- 000 : Aucun défaut ou diode de bypass déconnectée ;
- 001 : Diode bypass court-circuitée ou inversée ou cellule court-circuitée ou mismatch type ombrage complet ou température ;
- 010 : Module court-circuitée ou inversé ;
- 011 : Mismatch type ombrage partiel ;
- 100 : Diode bypass défaillante ou mismatch type R_s ou R_{sh} ou module shunté ;
- 101 : Diode de bypass défaillante ou mismatch type R_{sh} ou R_s ou module shunté ;
- 110 : Mismatch type R_s ;
- 111 : Nature de défaut inconnu.




FIGURE 4.23 – Configuration RNA pour le diagnostic en fonction du nombre de couches cachées.

Synthèse suite à une variation de (T)

Le Tableau 4.10 fait la synthèse des performances de la configuration du RNA suite à un défaut système du type variation de la température. Ici le RNA nous permet, grâce au faisceaux d'indices en rapport avec la matrice de sortie du Tableau 4.9, de conclure sur un défaut du type ombrage, dont le niveau d'ombrage partiel pourrait être à l'origine. Les courbes COR sur les Figures 4.25b, 4.26b, 4.27b et 4.28b, montrent la qualité de la détection du défaut en dépit de la variation du nombre de couches cachées.

TABLE 4.10 – Performance du RNA pour un défaut du type T .

	2 couches	5 couches	10 couches	20 couches
Nombre d'itérations	1000	1000	1000	1000
Durée du test	20"	25"	1'11"	46"
MSE	$1,62 \times 10^{-2}$	$1,03 \times 10^{-3}$	$8,09 \times 10^{-3}$	$6,15 \times 10^{-3}$
$Perf = (1 - MSE)$	98,38%	99,89%	99,19%	99,39%

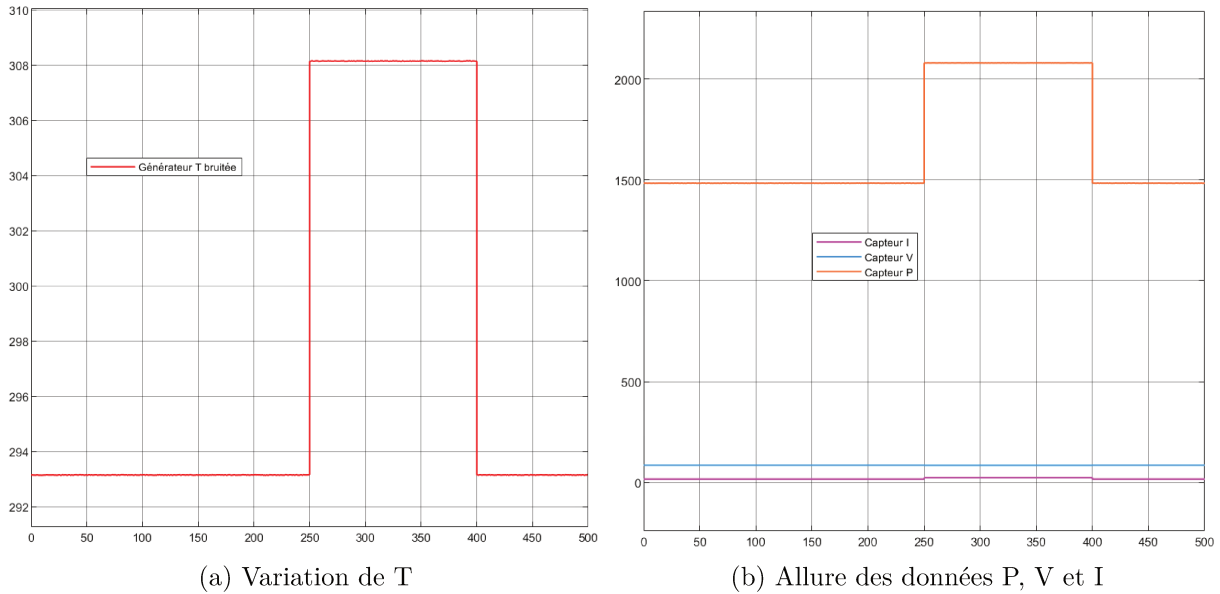


FIGURE 4.24 – Conséquence de la variation de T sur les données P, V et I pour le diagnostic.

4.5.2.2.2 Performance du réseau pour un défaut de l'enseillement (G)

Ici, la simulation se fait pour un ensoleillement sur la Figure 4.29a qui passe de $G = 1000 \text{ W/m}^2$ à 1200 W/m^2 entre les instants 200 et 350 pour obtenir l'allure des données comme illustrée sur la Figure 4.29b (avec P en Watt, V en Volt et I en Ampère).

Les Figures 4.30a, 4.31a, 4.32a et 4.33a des écarts quadratiques minimisés et les Figures 4.30b, 4.31b, 4.32b et 4.33b des courbes COR de la classification du diagnostic d'un défaut suite à une variation du niveau d'ensoleillement pour différentes configurations de RNA, respectivement pour 2, 5, 10 et 20 couches cachées, prouvent l'existence d'un défaut système et dont l'origine peut être située dans l'un des codes ci dessous, obtenu pour un seuil de défaut de 0,33325 :

- 000 : Aucun défaut ou diode de bypass déconnectée ;
- 010 : Module court-circuité ou inversé ;
- 101 : Diode de bypass défaillante ou mismatch type R_{sh} ou R_s ou module shunté ;
- 110 : Mismatch type R_s ;
- 111 : Nature du défaut inconnu.

Synthèse suite à une variation de (G)

Le Tableau 4.11 fait la synthèse des performances de la configuration du RNA suite à un défaut système du type G. Ici le RNA nous permet, grâce aux faisceaux d'indices en rapport avec la matrice de sortie du Tableau 4.9, de conclure sur un défaut du type ombrage, dont le niveau d'ensoleillement peut être l'origine. Les courbes COR de toutes sur les Figures 4.30b, 4.31b, 4.32b et 4.33b montrent la qualité de la détection du défaut lié à l'ensoleillement en dépit de la variation du nombre de couche cachées.

4.5.2.2.3 Performance du réseau pour un défaut de la résistance série (R_s)

La simulation se fait ici, pour une résistance série illustrée sur la Figure 4.34a qui passe de $R_s = 0,015 \Omega$ à 4Ω à partir de l'instant 250 pour obtenir l'allure des données comme illustrée

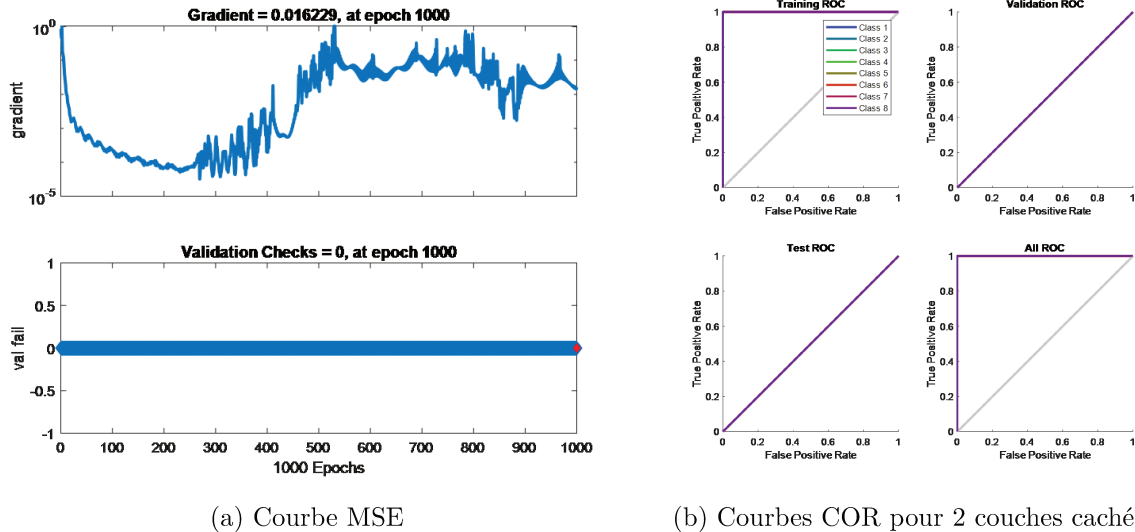


FIGURE 4.25 – Performances du RNA de 2 couches cachées pour un défaut de température.

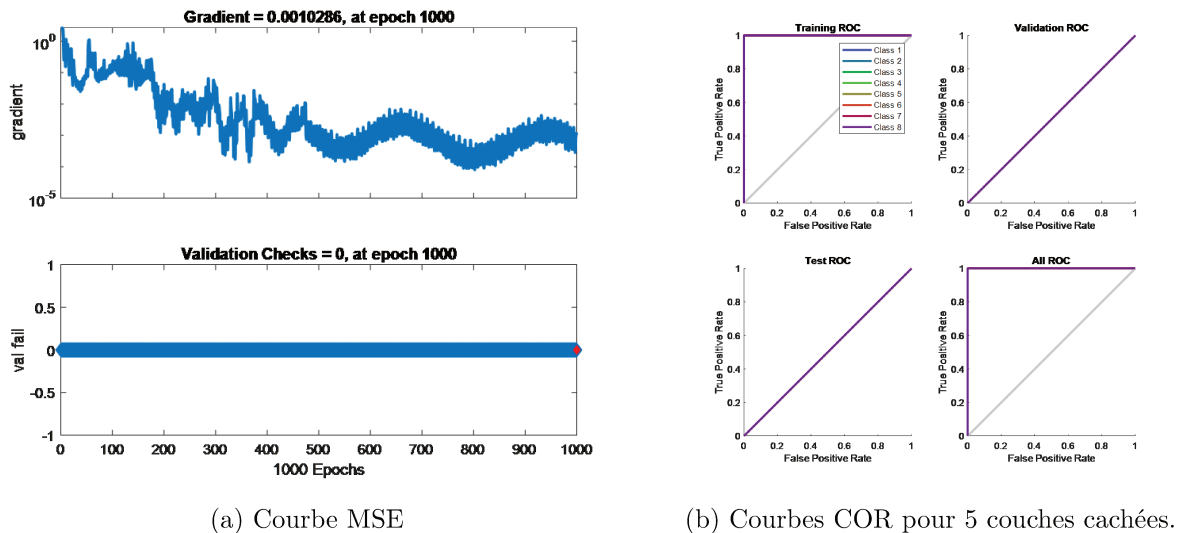



FIGURE 4.26 – Performances du RNA de 5 couches cachées pour un défaut de température.

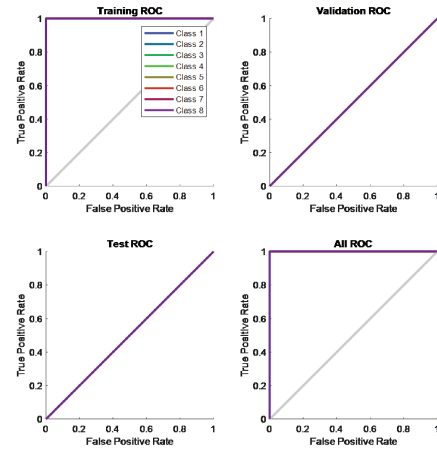
sur la Figure 4.34b (avec P en Watt, V en Volt et I en Ampère). Cette variation concerne uniquement un module de chaque string.

Les écarts quadratiques minimisés sur les Figures 4.35a, 4.36a, 4.37a et 4.38a, et les Figures 4.35b, 4.36b, 4.37b et 4.38b des courbes COR de la classification du diagnostic d'un défaut suite à une variation de la résistance série pour différentes configurations de RNA respectivement pour 2, 5, 10 et 20 couches cachées, prouvent l'existence d'un défaut système et dont l'origine peut être située dans l'un des codes ci-dessous, obtenu pour un seuil de défaut de 0,33325 :

- 000 : Aucun défaut ou diode de bypass déconnectée ;
- 001 : Diode bypass court-circuitée ou inversée ou cellule court-circuitée ou mismatch type ombrage complet ou température ;
- 010 : Module court-circuité ou inversé ;
- 100 : Diode bypass défaillante ou mismatch type R_{sh} ou R_s ou module shunté ;
- 111 : Nature de défaut inconnu.




(a) Courbe MSE

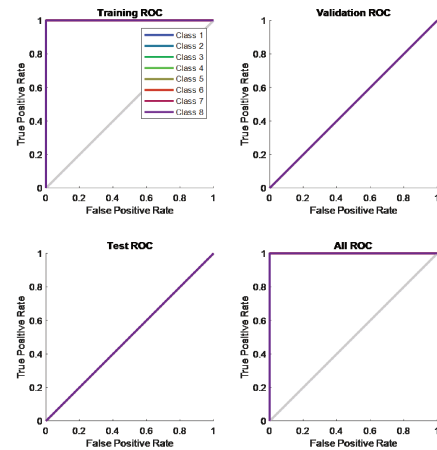


(b) Courbes COR pour 10 couches cachées.

FIGURE 4.27 – Performances du RNA de 10 couches cachées pour un défaut de température.



(a) Courbe MSE



(b) Courbes COR pour 20 couches cachées.

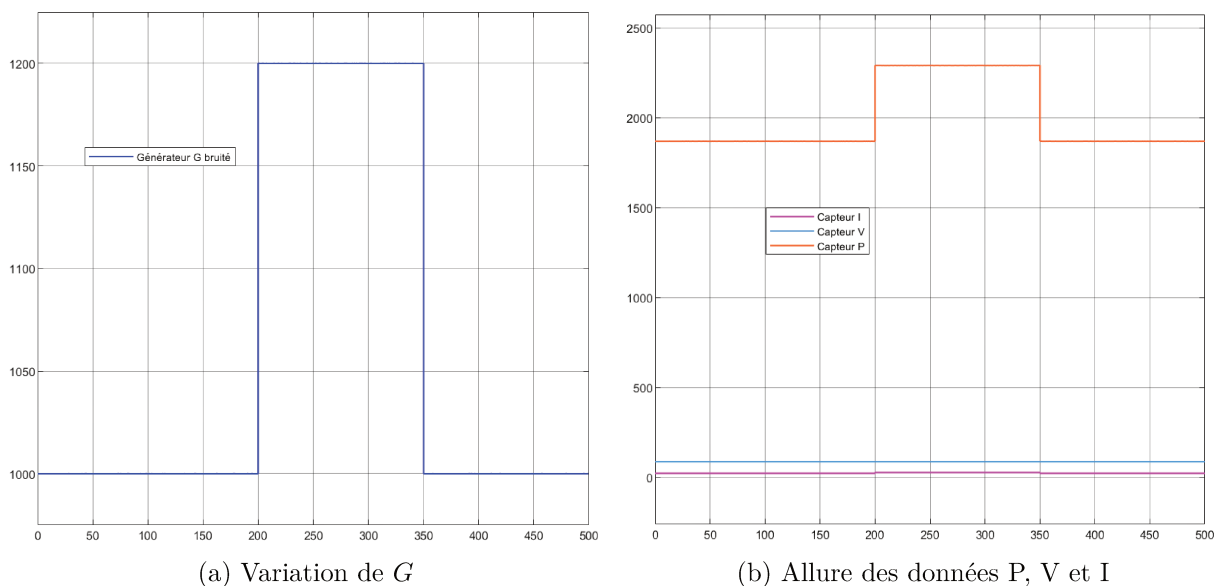
FIGURE 4.28 – Performances du RNA de 20 couches cachées pour un défaut de température.

Synthèse suite à une variation de (R_s)

Le Tableau 4.12 fait la synthèse des performances de la configuration du RNA suite à un défaut système du type R_s . Ici le RNA nous permet grâce à un faisceau d'indice en rapport avec la matrice de sortie du Tableau 4.9, de conclure sur un défaut du type ombrage, dont le l'origine peut plus être liée à des modules court-circuités. La courbe COR de toutes les courbes sur les Figures 4.35b, 4.36b, 4.37b et 4.38b montrent la qualité de la détection du défaut suite à une variation de la résistance série en dépit de la variation du nombre de couche cachées.

4.5.2.2.4 Performance du réseau pour un défaut de la résistance shunt (R_{sh})

Ici, la simulation se fait pour une résistance shunt illustrée sur la Figure 4.39a qui passe de qui passe de $R_{sh} = 700\,000\ \Omega$ à $70\ \Omega$ à partir de l'instant 150 pour obtenir l'allure des données comme illustrée sur la Figure 4.39b (avec P en Watt, V en Volt et I en Ampère). Cette variation concerne tous les quatre modules du premier string.

FIGURE 4.29 – Conséquence de la variation de G sur les données P , V et I pour le diagnostic.TABLE 4.11 – Performance du RNA pour un défaut du type G .

	2 couches	5 couches	10 couches	20 couches
Nombre d'itérations	1000	1000	1000	1000
Durée du test	1'18"	47"	56"	38"
MSE	$4,26 \times 10^{-2}$	$5,08 \times 10^{-4}$	$4,93 \times 10^{-3}$	$3,56 \times 10^{-3}$
$Perf = (1 - MSE)$	95,74%	99,99%	99,51%	99,64%

Les écarts quadratiques minimisés sur les Figures 4.40a, 4.41a, 4.42a et 4.43a, et les Figures 4.40b, 4.41b, 4.42b et 4.43b des courbes COR de la classification du diagnostic d'un défaut suite à une variation de la résistance shunt pour différentes configurations de RNA respectivement pour 2, 5, 10 et 20 couches cachées, prouvent l'existence d'un défaut système et dont l'origine peut être située dans l'un des codes ci dessous, obtenu pour un seuil de défaut de 0,3333 :

- 000 : Aucun défaut ou diode de bypass déconnectée ;
- 001 : Diode bypass court-circuitée ou inversée ou cellule court-circuitée ou mismatch type ombrage complet ou température ;
- 010 : Module court-circuité ou inversé ;
- 100 : Diode bypass défailante ou mismatch type R_{sh} ou R_s ou module shunté ;
- 111 : Nature de défaut inconnu.

Synthèse suite à une variation de (R_{sh})

Le Tableau 4.13 fait la synthèse des performances de la configuration du RNA suite à un défaut système du type R_{sh} . Ici le RNA nous permet, grâce à un faisceau d'indice en rapport avec la matrice de sortie du Tableau 4.9, de conclure sur un défaut du type ombrage, dont l'origine peut être liée à des modules arrachés. La courbe COR de toutes les courbes sur les Figures 4.40b, 4.41b, 4.42b et 4.43b, montrent la qualité de la détection du défaut suite à une variation de la résistance shunte en dépit de la variation du nombre de couche cachées.

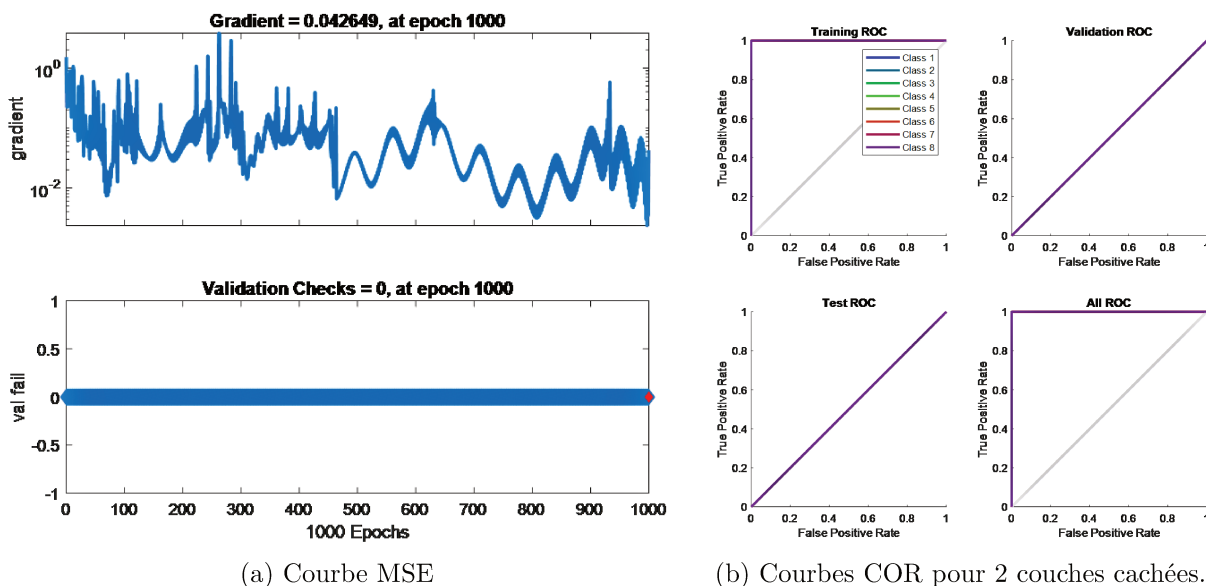


FIGURE 4.30 – Performances du RNA de 2 couches cachées pour un défaut d'ensoleillement.

TABLE 4.12 – Performance du RNA pour un défaut du type R_s .

	2 couches	5 couches	10 couches	20 couches
Nombre d'itérations	1000	1000	1000	1000
Durée du test	53"	45"	44"	38"
MSE	$1,07 \times 10^{-3}$	$8,34 \times 10^{-3}$	$4,81 \times 10^{-3}$	$2,33 \times 10^{-2}$
$Perf = (1 - MSE)$	99,89%	99,17%	99,52%	97,67%

4.5.2.3 Conclusion sur la classification pour le diagnostic de défaut système

La méthode de diagnostic à base des réseaux de neurones artificiels, permet la détection et la classification des défauts du système, selon les quatre scénarii simulés ci-dessus, engendrant des défauts en rapport à la température, à l'ensoleillement, à la résistance série et à la résistance shunt. La technique d'apprentissage peu profond dont le RNA s'appuie, se base sur les données pour détecter et classifier les défauts « **systèmes** » du processus industriel qu'est le GPV.

Comparativement au diagnostic de « **défauts capteurs** », le diagnostic de « **défauts systèmes** », permet de mettre l'accent sur la partie du système en souffrance à travers un faisceau d'indices, généralement lié à l'un des paramètres clés du système que sont R_s , R_{sh} , T ou G et dont la description du codage se trouve confinée dans le Tableau 4.9.

L'apprentissage du RNA est assez simple et nous a permis de classifier les défauts pour le diagnostic. L'amélioration des résultats de simulations ci-dessus ainsi que le pourcentage de détection s'il y a lieu, peut être envisagé pour une meilleure performance du réseau à travers l'ajout des données originales ou nouvelles, ou encore en faisant les actions suivantes :

- entraîner à nouveau ;
- augmenter le nombre de couches cachés ;
- augmenter le nombre de valeurs d'entrée si des informations plus utiles sont disponibles.

Si la performance sur l'ensemble de l'apprentissage est bonne, mais la performance de l'ensemble de test est significativement mauvaise, il faudra alors réduire le nombre de couches cachées pour améliorer les résultats. Mais pour une performance assez acceptable, il suffit d'augmenter

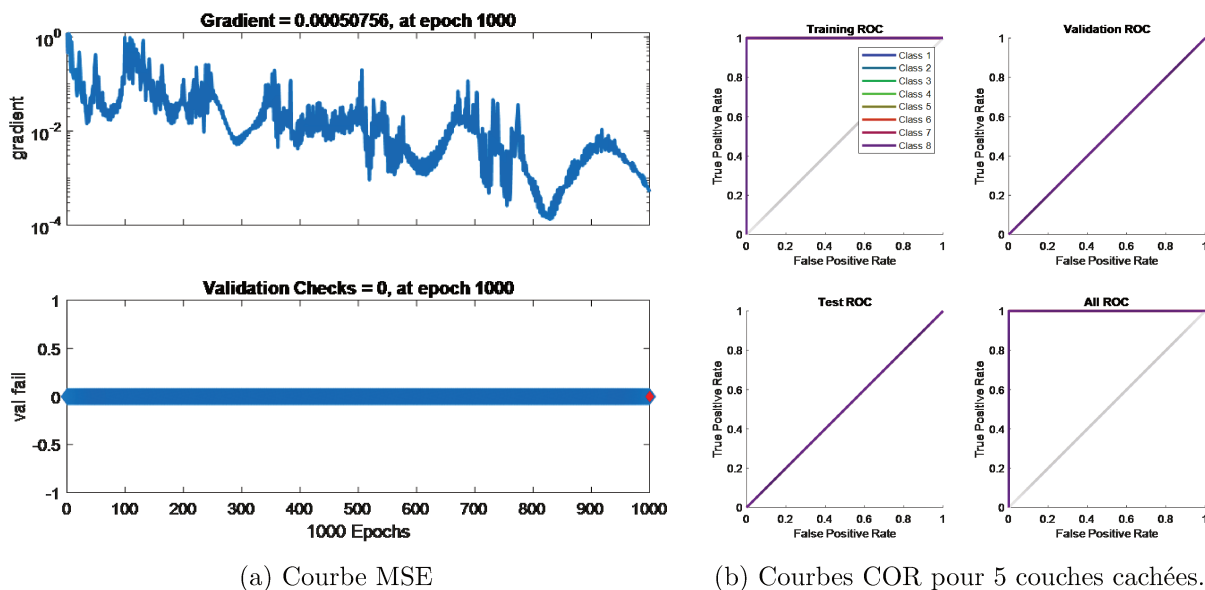


FIGURE 4.31 – Performances du RNA de 5 couches cachées pour un défaut d'ensoleillement.

TABLE 4.13 – Performance du RNA pour un défaut du type R_{sh} .

	2 couches	5 couches	10 couches	20 couches
Nombre d'itérations	1000	1000	1000	1000
Durée du test	21"	21"	32"	1'17"
MSE	$2,39 \times 10^{-4}$	$2,62 \times 10^{-2}$	$1,41 \times 10^{-2}$	$4,46 \times 10^{-2}$
$Perf = (1 - MSE)$	99,98%	97,38%	98,59%	95,54%

le nombre de couches cachées comme le montre nos résultats de simulations contenues dans les figures des courbes COR.

D'un autre côté, le choix du seuil de détection des défauts est difficile car plusieurs valeurs des paramètres changés d'un défaut peuvent apparaître dans un autre défaut ce qui conduit à des fausses alarmes et une mauvaise détection des défauts majeurs.

L'apprentissage s'arrête lorsque l'erreur de validation augmente consécutivement sur six itérations, ce qui se produit assez tard avec un nombre élevé de couches cachées, car le système prend plus de temps pour l'entraînement. La précision des tracés des erreurs d'apprentissage, de validation et de test confortent la bonne tenue de nos configurations RNA et de la pertinence du diagnostic des défauts systèmes par réseau de neurone artificiel pour le GPV.

La complexité des réseaux de neurones se mesure par le nombre de neurones dans la couche cachée. Plus un réseau de neurones comporte de neurones, plus le système sera flexible mais également complexe. Des réseaux de neurones flexibles permettent d'approcher des fonctions de n'importe quelle complexité entre les variables d'entrée et les variables cibles. Le choix du nombre optimal de neurones dépend en grande partie du domaine de la problématique, mais d'une manière générale, il est lié à la taille et au nombre de données d'entrée.

Grâce à cette partie de l'étude du diagnostic sur les RNA pour le GPV, nous pouvons entreprendre plus sereinement les actions de maintenance appropriées pour la remise en état de bon fonctionnement du GPV.

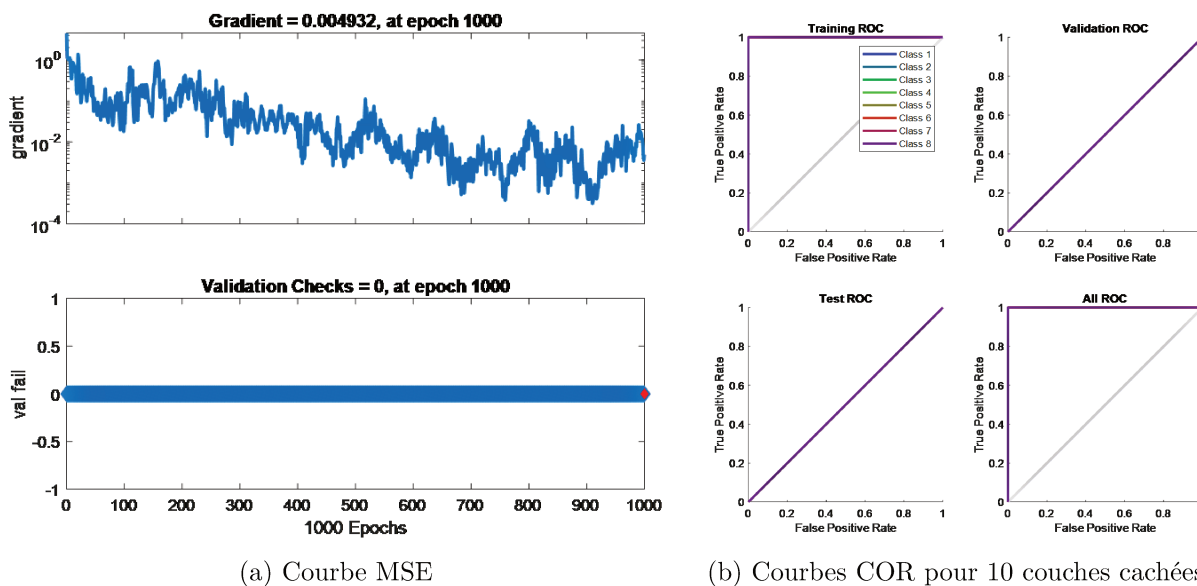


FIGURE 4.32 – Performances du RNA de 10 couches cachées pour un défaut d'ensoleillement.

4.6 Conclusion

A travers ce chapitre, nous nous sommes rendu compte de la puissance mais surtout la suprématie de la méthode de diagnostic à travers l'utilisation de cet algorithme d'apprentissage peu profond qu'est la configuration du RNA pour le diagnostic du système industriel complexe qu'est le générateur photovoltaïque.

Il s'avère plus précis en termes de diagnostic des défauts systèmes que le premier algorithme mis en évidence dans ce même chapitre, à travers l'utilisation de l'un des signaux puissance, tension et courant produit par le générateur PV. S'il permet la détection des défauts, il faut reconnaître qu'il est difficile de localiser ledit défaut afin d'entreprendre avec précision les actions de maintenance appropriées.

La configuration de l'algorithme de classification pour le diagnostic est beaucoup plus intéressant, en ce sens qu'il propose un faisceau d'indices sur une famille de défaut avec certains types de défauts à même d'expliquer les pertes de performances du GPV. Les actions de maintenance à entreprendre dès lors seront largement orientées.

L'algorithme de diagnostic pour le défauts systèmes mis en exergue, pourrait très bien être aussi complémentaire de la méthode de diagnostic mis en avant dans le chapitre 3, pour constituer une complémentarité, non seulement pour rendre plus performant la méthode de diagnostic mais permettre la mise en place d'une méthode de surveillance ou de supervision telle qu'envisager au chapitre 5.

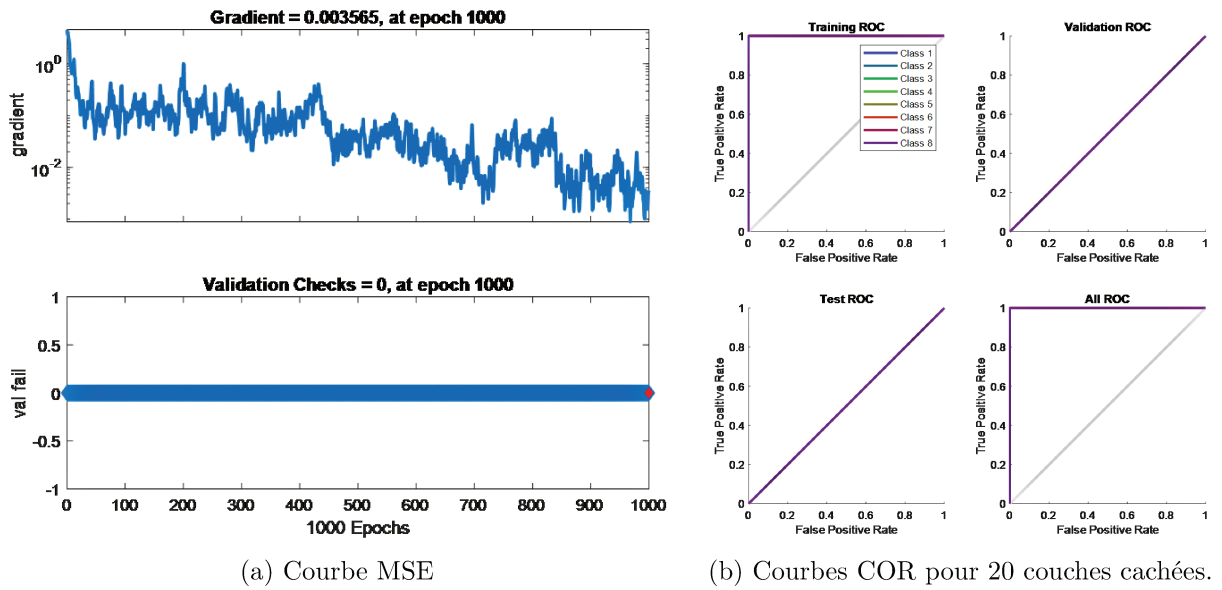


FIGURE 4.33 – Performances du RNA de 20 couches cachées pour un défaut d'ensoleillement.

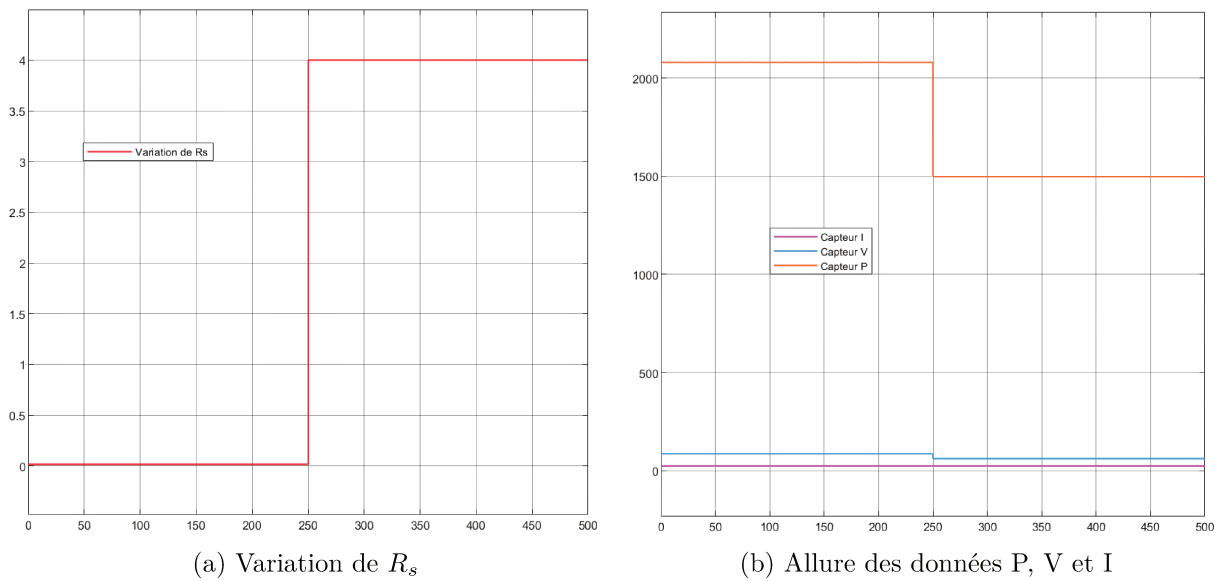

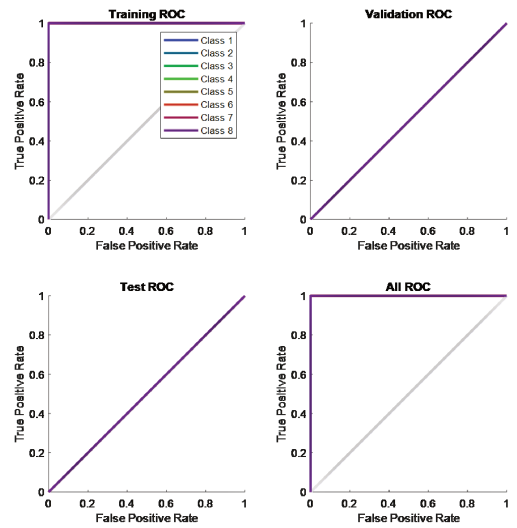


FIGURE 4.34 – Conséquence de la variation de R_s sur les données P, V et I pour le diagnostic.

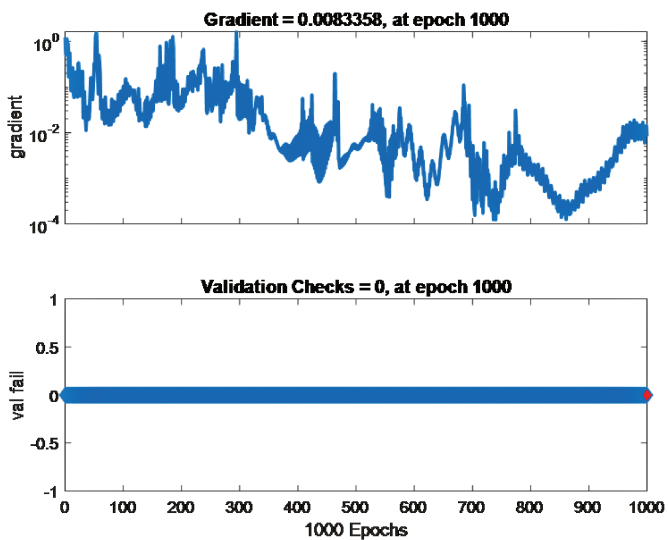


(a) Courbe MSE




(b) Courbes COR pour 2 couches cachées.

FIGURE 4.35 – Performances du RNA de 2 couches cachées d'un défaut de résistance série.




(a) Courbe MSE

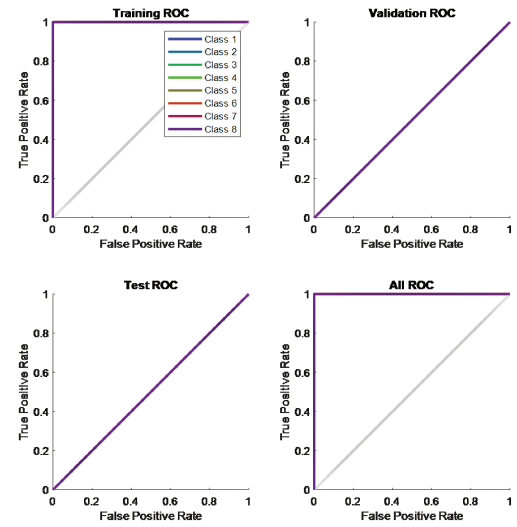


(b) Courbes COR pour 5 couches cachées.

FIGURE 4.36 – Performances du RNA de 5 couches cachées d'un défaut de résistance série.




(a) Courbe MSE

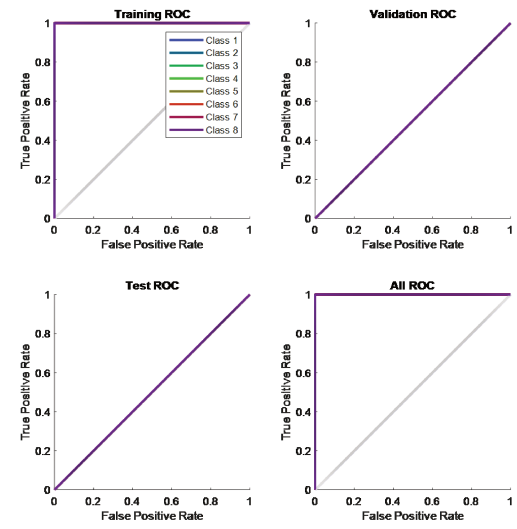


(b) Courbes COR pour 10 couches cachées.

FIGURE 4.37 – Performances du RNA de 10 couches cachées d'un défaut de résistance série.



(a) Courbe MSE



(b) Courbes COR pour 5 couches cachées.

FIGURE 4.38 – Performances du RNA de 20 couches cachées d'un défaut de résistance série.




FIGURE 4.39 – Conséquence de la variation de R_{sh} sur les données P, V et I pour le diagnostic.

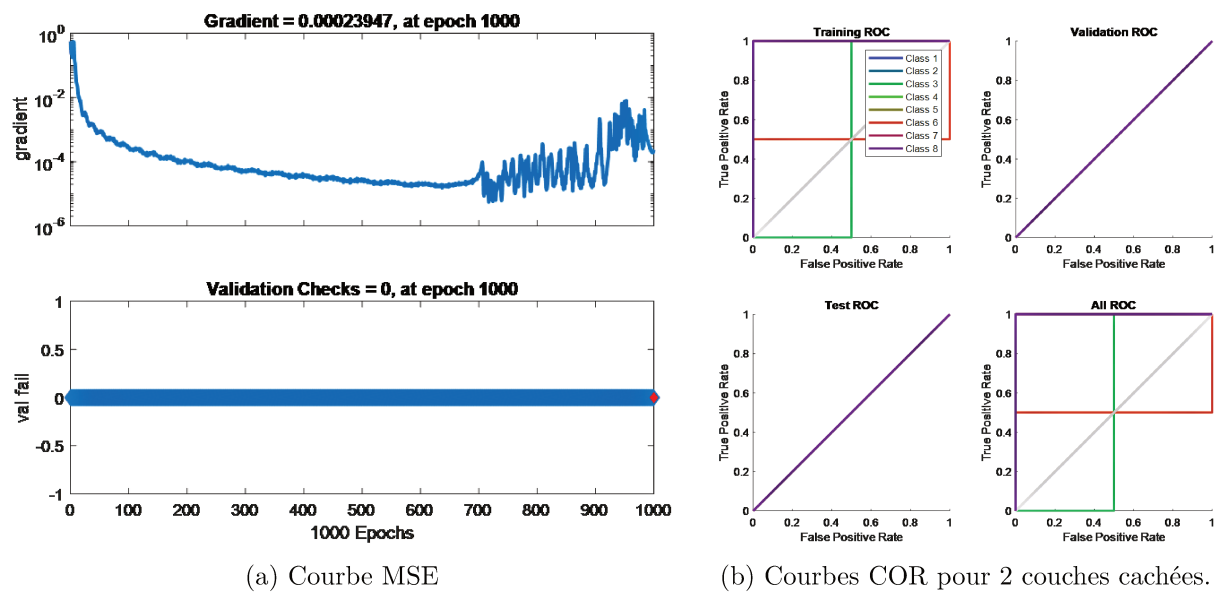




FIGURE 4.40 – Performances du RNA de 2 couches cachées d'un défaut de résistance shunt.




(a) Courbe MSE

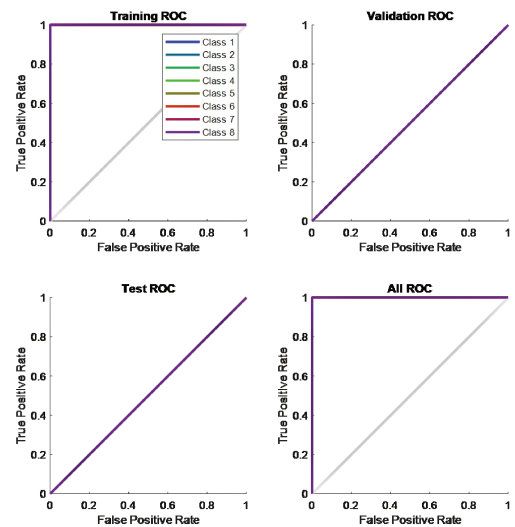


(b) Courbes COR pour 5 couches cachées.

FIGURE 4.41 – Performances du RNA de 5 couches cachées d'un défaut de résistance shunt.




(a) Courbe MSE

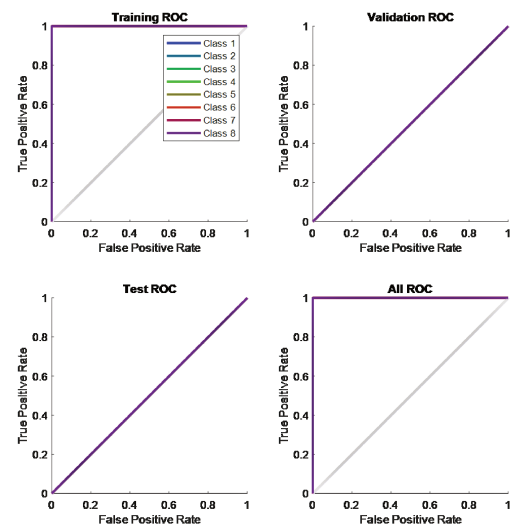


(b) Courbes COR pour 10 couches cachées.

FIGURE 4.42 – Performances du RNA de 10 couches cachées d'un défaut de résistance shunt.



(a) Courbe MSE



(b) Courbes COR pour 20 couches cachées.

FIGURE 4.43 – Performances du RNA de 20 couches cachées d'un défaut de résistance shunt.

Prototype d'IIoT d'acquisition temps réel pour un GPV

5.1 Introduction

Les domaines du diagnostic et du pronostic jouent un rôle important dans l'amélioration de la fiabilité des systèmes et sont des sujets cibles de recherche active, fédérant différentes communautés scientifiques, afin d'établir un lien entre un symptôme observé, la défaillance qui est survenue, et ses causes pour laisser place aux actions de maintenance à entreprendre.

L'objectif de ce chapitre est de mettre en œuvre un système d'acquisition temps réel, basé sur le principe des agents, un paradigme de programmation mettant en évidence l'autonomie et les interactions avec l'environnement et s'inspirant du principe d'Internet of Things (IoT) [Oztemel 2020]. Ce qui facilitera la finalisation de la mise en place d'un système d'aide à la décision pour la maintenance des systèmes PV basée sur une méthode de diagnostic. L'approche proposée met en relation deux parties [Fagroud 2021] :

- la partie des capteurs sources d'informations ;
- et la partie de coordination intelligente, qui reçoit et traite les informations de son environnement à l'aide de capteurs et qui agit, conséquemment.

Pour l'Union Internationale des Télécommunications (UIT), l'Internet des Objets (IdO) en anglais Internet of Things (IoT) [Brous et al. 2020], est un : « réseau ouvert et complet d'appareils physiques qui reçoit et transfère des données sur des réseaux sans fil uniquement, avec une intervention humaine limitée, capable d'agir et de réagir face aux situations et aux changements dans leurs environnements ». En réalité, la définition qui n'est pas figée, fait ressortir deux variantes complémentaires que sont : l'Edge computing et l'Internet Industriel des Objets (IIoT) tel qu'envisagé pour le GPV.

Dans ce chapitre nous présentons l'architecture de la réalisation de notre prototype d'acquisition temps réel, utilisé pour l'acquisition des données réelles devant servir à alimenter l'une des méthodes de diagnostic présentées dans les chapitres 3 et 4. Nous mettons ici en avant l'exploitation des données transmises par notre prototype d'acquisition, à travers deux des méthodes de diagnostic pour juger de l'état dans lequel fonctionne le générateur expérimental. Cette présentation s'achèvera par une conclusion sur les performances et les améliorations attendues du

prototype IIoT déployé.

5.2 Conception du système d'acquisition temps réel sur la base d'un IIoT

Cette section du chapitre, présente une instrumentation optimisée pour la mise en place d'un prototype d'acquisition temps réel pour un GPV, architecturée autour d'une carte Arduino Uno. L'objectif est d'obtenir en temps réel, les données liées à la puissance, aux courants et à la tension de sortie du générateur, afin d'initialiser l'une ou l'autre des méthodes de diagnostic exposée dans les chapitres précédents.

L'étude du système d'instrumentation électronique temps réel a été une première étape dans le développement du système embarqué pour l'acquisition temps réel [Compaoré et al. 2023 b.]. Dans les applications temps réel utilisant des capteurs, le mode et la fréquence de commutation en fonctionnement, notamment lors d'anomalies de fonctionnement [Rohit 2017], peut être source de difficultés pour le bon fonctionnement de la carte.

Grâce à la Figure 5.1, nous visons à travers notre prototype IIoT, une communication possible en tout lieu et à tout moment, mais surtout avec n'importe quel objet [Oztemel 2020], [Babakhouya 2010].

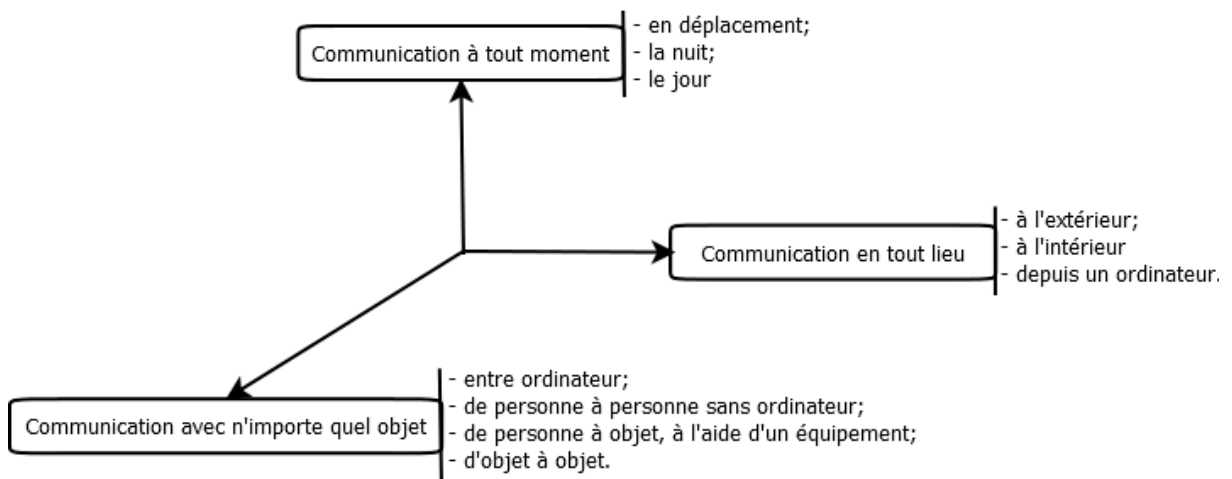


FIGURE 5.1 – Dimensions de l'IoT.

Le premier prototype d'acquisition proposé est basé sur une carte Arduino Uno, utilisant une instrumentation adaptée. Cette maquette autonome nous permet d'acquérir le courant de chaque string du champ, la tension de sortie du GPV, la température et le niveau d'ensoleillement reçu sur le champ PV.

Ce prototype, tel qu'illustré à la Figure 5.2, dispose également d'un système d'horodatage pour figer la date et l'heure des données en plus du niveau de l'ensoleillement, de la température, du courant et de la tension qui sont enregistrés sur la carte SD jointe. Ils seront largement utilisés pour la construction de la caractéristique courant-tension utilisable ultérieurement pour le diagnostic du système ou pour alimenter la méthode de diagnostic hors ligne du GPV.

De plus, le prototype peut afficher en temps réel le niveau d'éclairement, la température, la tension et le courant du GPV auquel il est connecté. La précision du modèle proposé doit être

validée en comparant les caractéristiques comportementales issues de la simulation avec celles obtenues à partir d'essais sur le terrain des mesures.




FIGURE 5.2 – Synoptique d'acquisition temps réel du prototype 1.

Cette architecture présente des limites en termes de gestion des données, ce qui nous conduit à adopter le système d'acquisition temps réel de la Figure 5.3, incorporant la transmission en temps réel des données stockées dans la carte SD.

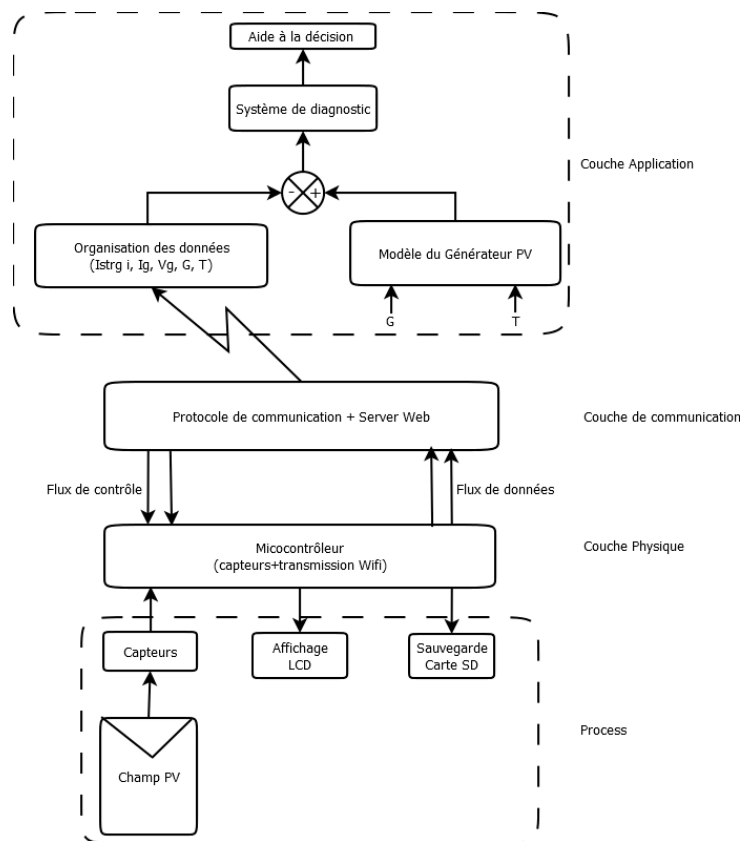


FIGURE 5.3 – Synoptique d'acquisition temps réel du prototype 2.

Aussi, cette instrumentation temps réel pour acquérir des données de production du GPV d'un site isolé que connecté, s'inspire du principe de conception et de fonctionnement d'IIoT

5.3 Différents composants du système d'IIoT

Pour les besoins de notre instrumentation, nous utilisons un ensemble de capteur de courant, de tension, de luminosité et de température pour mesurer les différentes grandeurs sur le générateur photovoltaïque. Cette instrumentation étant fonctionnelle, mais ne se contentant que de sauvegarder les données sur la carte SD, nous avons entrepris l'amélioration dans un second temps, par l'utilisation de la carte ESP32 Wrover. Nous avons ainsi fait évoluer notre système d'une simple acquisition pour stockage, vers un système plus complet comportant à la fois l'acquisition, le stockage et la transmission pour une exploitation en temps réel des données vers l'application de l'une des applications de diagnostic des chapitres 3 ou 4.

La liste des composants utilisés est :

1. Le capteur de courant ACS70331, un module Grove, tel qu'illustré à la Figure 5.4, permet de mesurer l'intensité d'un courant AC et DC allant jusqu'à 5 A. Ce type de capteur a été inséré en série dans chaque string du champ GVP.



FIGURE 5.4 – Capteur de courant ACS70331.

2. Le capteur de courant ACS725, sous forme de module Grove, tel qu'illustré à la Figure 5.5, permet de mesurer l'intensité d'un courant continu jusqu'à 10 A. Ce capteur a été inséré en série dans la chaîne de sortie générale du montage électrique du GVP



FIGURE 5.5 – Capteur de courant ACS725.

3. Le capteur de tension Phidgets P/N 1135, tel qu'illustré sur la Figure 5.6, mesure des tensions continues entre -30 et +30 Vcc avec une bonne précision. Il est utilisé pour la mesure de la tension générale de sortie du GPV.
4. Le capteur de température AHT10, tel qu'illustré à la Figure 5.7 permet de mesurer la température et l'humidité. Il est principalement utilisé ici pour la mesure de la température ambiante dans laquelle fonctionne le GPV.
5. Le capteur de luminosité VEML7700 sous forme de module Grove, tel qu'illustré à la Figure 5.8, permet de mesurer la luminosité ambiante.



FIGURE 5.6 – Capteur de tension Phidgets P/N 1135.




FIGURE 5.7 – Capteur de température AHT10.



FIGURE 5.8 – Capteur de luminosité VEML7700.

6. Le module RTC Clock sous forme d'un module Grove, tel qu'illustré à la Figure 5.9, il est doté d'une batterie au Lithium CR1225, qui donne la date et l'heure au format 12h ou 24h, en tenant compte des années bissextiles. Il favorise alors l'horodatage de notre système.




FIGURE 5.9 – Module RTC Clock.

7. L'afficheur LCD 4*20 soit 4 lignes de 20 caractères rétroéclairés, tel qu'illustré sur la Figure 5.10, est un module qui facilite l'affichage instantané des données qui seront sauvegardées puis transmises.



FIGURE 5.10 – Module d'affichage LCD 4*20 caractères.

8. La carte SD est un module adaptateur de lecture/écriture tel qu'illustré à la Figure 5.11, utilisé pour la sauvegarde des données sur carte Micro SD.



FIGURE 5.11 – Module carte SD.

9. Les panneaux solaires sont un ensemble de 4 modules PV identiques, et illustré sur la Figure 5.12. Ils sont en polysilicium de haute qualité, compressif, durable et résistant à la corrosion. Ces modules conviennent largement pour notre expérimentation.
10. Les cartes à micro-contrôleurs, en tant qu'organes de coordination intelligente, sont des petits circuits électroniques dotés d'entrées/sorties programmables. Elles permettent l'acquisition de données provenant de capteurs, l'envoi de signaux de données ou le contrôle de circuits de puissance. Il existe plusieurs types de cartes à micro-contrôleur, mais nous citons uniquement les deux cartes utilisées dans le cadre de cette thèse, que sont : l'Arduino Uno et l'ESP32 Wrover.






FIGURE 5.12 – Module solaire WBL 1.6.

- la carte Arduino Uno de la Figure 5.13a, possède un micro-contrôleur facilement programmable ainsi que de nombreuses entrées-sorties. Elle existe en plusieurs variantes qui se différencient par la puissance du micro-contrôleur ou par la taille et la consommation de la carte mais elle n'a pas de système de transmission intégré.



(a) Carte Arduino modèle UNO REV3.



(b) Carte ESP32 Wrover.

FIGURE 5.13 – Exemple de carte à microcontrôleur.

- la carte ESP32-WRover M-32 de la Figure 5.13b, est assez proche en terme d'architecture de la carte Arduino Uno mais en plus petit. L'ESP32 peut également être utilisée en complément avec n'importe quel autre micro-contrôleur ou carte de développement, en tant que module de communication. Car elle intègre un mode de communication Wifi et / ou Bluetooth de 2,4 GHz pour toutes autres solutions de configuration IIoT dans un encombrement réduit. Elle a été conçue pour obtenir un meilleur rapport puissance / performances radio fréquence.
- le Tableau 5.1 ci-dessous, résume à titre comparatif, les principales caractéristiques des deux cartes à microcontrôleur les plus utilisés dans les applications IIoT. Le choix d'une des cartes se fera naturellement en fonction des orientations du projet IIoT envisagé.

5.4 Assemblage du premier prototype à base d'une Arduino

Le schéma électronique d'assemblage de la Figure 5.14, s'est fait sous le logiciel Fritzing. L'assemblage électronique ayant permis les essais se trouve à la Figure 5.15.

TABLE 5.1 – Caractéristiques des cartes utilisées.

Caractéristiques	Arduino Uno	ESP 32
Fréquence	16 MHz	160 MHz
Ports digitaux	14	36
Ports analogiques	6	18
PWM	8	10
Bluetooth 4.0 intégré	-	Oui
Wifi Intégré	-	Oui
Alimentation USB	Oui	Oui
Mémoire flash	32 KBits	4 MBits
RAM	2 KBits	512 Kbits
ROM	1 KBits	448 KBits
Processeur	ATmega328	LX6 Dual-Core




FIGURE 5.14 – Schéma électronique avec la carte Arduino Uno.

La Figure 5.16 sous forme de tableau montre les premières données stockées sur le Carte SD [Compaoré et al. 2022 b.]. De la sauvegarde, nous insistons sur l'horodatage, à savoir la prise en compte de la date et de l'heure des données acquises, la luminosité, la tension, le courant et la température à partir du champ PV. La première satisfaction pour ce premier prototype d'acquisition, c'est son interaction face aux variations de luminosité ou de température. Lors de l'exécution, nous avons choisi une période de rafraîchissement des mesures toutes les 5 secondes, pour mieux apprécier la prises en compte des variations de mesure.

Nous avons simplement obstrué la lumière ou capteur de température à certains moments afin d'évaluer la réaction du système d'acquisition à cette action assimilable à un défaut.




FIGURE 5.15 – Assemblage électronique du premier prototype.

Les données de la carte SD sont au format CSV et peuvent être reconverties au format Excel ou Mat dans Matlab pour faciliter leur réutilisation.

Horodatage	Time	Light	Voltage	Current	Temperture
01/01/2022 00:00	14:00:18	708.00	4.83	2.44	43.01
01/01/2022 00:00	14:00:23	703.00	4.88	2.44	42.03
01/01/2022 00:00	14:00:28	701.00	4.93	2.37	40.57
01/01/2022 00:00	14:00:33	701.00	4.93	2.44	38.12
01/01/2022 00:00	14:00:38	717.00	4.93	2.44	36.17
01/01/2022 00:00	14:00:43	702.00	4.96	2.37	36.17
01/01/2022 00:00	14:00:48	712.00	4.96	2.37	35.19
01/01/2022 00:00	14:00:53	710.00	4.98	2.59	42.03
01/01/2022 00:00	14:00:58	710.00	4.96	2.44	41.06
01/01/2022 00:01	14:01:03	714.00	4.96	2.52	39.10
01/01/2022 00:01	14:01:08	709.00	4.96	2.37	39.59
01/01/2022 00:01	14:01:13	733.00	4.98	2.37	37.63
01/01/2022 00:01	14:01:18	724.00	4.98	2.44	36.66
01/01/2022 00:01	14:01:23	720.00	4.96	2.44	44.97
01/01/2022 00:01	14:01:28	766.00	4.96	2.37	42.52

FIGURE 5.16 – Capture d'écran du contenu de la carte SD.

5.5 Assemblage du second prototype à base d'un ESP 32 Wrover

Dans le souci d'incorporer un moyen de transmission temps réel des données sauvegardées, nous avons développé un second prototype basé sur le principe des systèmes IIoT. Le prototype peut se résumer de la façon suivante :

- **paramètres surveillés** : Irradiation, Température, Tension générale Courant général, Courant de chaque string, Date et Heure.
- **capteurs** : Capteur de luminosité, Capteur de température, capteur de tension, Capteurs de courant.
- **contrôleur** : la carte électronique ESP32 Wrover.
- **connectivité de données** : USB C, Communication sans fil, Wifi.
- **logiciel de programmation** : Arduino IDE, Langage C, Fritzing, Eagle, Dia.
- **méthodes de surveillance** : Server web, LCD, SD card.

Le schéma électronique d'assemblage de la Figure 5.17, a été réalisé avec le logiciel Fritzing. L'assemblage électronique ayant permis les essais se trouve à la Figure 5.18.




FIGURE 5.17 – Schéma électronique avec la carte ESP32 Wrover.




FIGURE 5.18 – Assemblage électronique avec la carte ESP32 Wrover.

A travers la Figure 5.19, nous avons les données transmises au serveur web à l'adresse 192.168.15.153. C'est aussi une copie des données qui sont sauvegardées sur la carte SD. Le second prototype est aussi toujours horodaté, avec la date et l'heure de la sauvegarde, la luminosité, la tension, le courant et la température d'un champ de panneaux solaire 2,7 V utilisé pour l'occasion.

L'évolution dans ce second prototype réside dans la transmission en temps réel comme sur le schéma synoptique de la Figure 5.3, tout en permettant à notre solution IIoT de remplir toujours les mêmes missions que le premier prototype d'acquisition avec la même sensibilité face à la prise en compte des aléas de production du GPV.

L'amélioration significative pour ce système IIoT, réside dans le changement de la carte micro-contrôleur ESP32 Wroom, qui incorpore directement un module de transmission wifi, utilisé ici. La capture d'écran de la simulation du second prototype sur la Figure 5.19, recueillie à l'adresse web 192.168.15.153 du server.

Les différents échantillons de mesures correspondant aux données d'acquisition temps réel du second prototype, sont le fruit de la configuration d'un champ PV de deux modules en parallèle. Nous avons fait subir à ce champ PV expérimental, deux types de défauts :

- un stress d'ensoleillement et de température, à travers la projection d'une forte et vive lumière en direction du champ ;
- un mauvais code de conversion pour l'obtention de la valeur du courant sur la PIN d'un string.

Cela nous permet de nous mettre dans les conditions réelles de fonctionnement d'un GPV, de constater que toutes les fluctuations et les variations sont bien prises en compte par le prototype d'acquisition temps réel, afin de mieux régler la fréquence de sauvegarde des données, pour chaque 5 secondes de la Figure 5.21.

Ces données extraites au format CSV se présentent comme suit sur la Figure 5.20.

Ces données d'acquisition sauvegardées sur la carte SD, converties au format .mat, se présentent comme suit, sur la Figure 5.21.

- le courant général de sortie I_G ;
- les courants des deux string I_{stg1} et I_{stg2} ;
- la température T ;
- le niveau d'ensoleillement G ;



FIGURE 5.19 – Capture d'écran de la transmission sur le Server web 192.168.15.153.

	A	B	C	D	E	F	G	H	I	J
586	Monday, 15-May-2023 17:52:03 UTCÀSÀSÀS	1174.73W/m	111.21mv	3054.00mA	838.66mA	374.17mA	0.00mA	0.00mA	27.71_degrees C	
587	Monday, 15-May-2023 17:53:44 UTCÀSÀSÀS	1174.73W/m	110.39mv	3046.00mA	838.66mA	373.76mA	0.00mA	0.00mA	27.71_degrees C	
588	Monday, 15-May-2023 17:55:25 UTCÀSÀSÀS	1170.02W/m	110.39mv	3048.00mA	838.66mA	373.76mA	0.00mA	0.00mA	27.79_degrees C	
589	Monday, 15-May-2023 17:57:06 UTCÀSÀSÀS	1170.02W/m	110.80mv	3055.00mA	838.66mA	373.56mA	0.00mA	0.00mA	27.93_degrees C	
590	Monday, 15-May-2023 17:58:47 UTCÀSÀSÀS	1170.02W/m	111.62mv	3041.00mA	838.66mA	375.60mA	0.00mA	0.00mA	27.97_degrees C	
591	Monday, 15-May-2023 18:00:28 UTCÀSÀSÀS	1160.62W/m	110.39mv	3049.00mA	838.66mA	374.99mA	0.00mA	0.00mA	28.14_degrees C	
592	Monday, 15-May-2023 18:02:09 UTCÀSÀSÀS	1160.62W/m	108.54mv	3046.00mA	838.66mA	375.60mA	0.00mA	0.00mA	28.16_degrees C	
593	Monday, 15-May-2023 18:05:38 UTCÀSÀSÀS	925.88W/m	953.00mv	4095.00mA	4095.00mA	3437.00mA	0.00mA	0.00mA	28.05_degrees C	
594	Monday, 15-May-2023 18:07:19 UTCÀSÀSÀS	944.63W/m	832.00mv	4095.00mA	4095.00mA	3466.00mA	0.00mA	0.00mA	27.81_degrees C	
595	Monday, 15-May-2023 18:09:00 UTCÀSÀSÀS	850.94W/m	848.00mv	4095.00mA	4095.00mA	3450.00mA	0.00mA	0.00mA	27.73_degrees C	
596	Monday, 15-May-2023 18:10:41 UTCÀSÀSÀS	836.90W/m	841.00mv	4095.00mA	4095.00mA	3456.00mA	0.00mA	0.00mA	27.82_degrees C	
597	Monday, 15-May-2023 18:12:23 UTCÀSÀSÀS	827.54W/m	837.00mv	4095.00mA	4095.00mA	3449.00mA	0.00mA	0.00mA	27.74_degrees C	

FIGURE 5.20 – Données au format CSV.

	1	2	3	4	5	6	7	8	9
	Thursday01Jan1970000146UTC	VarName2	VarName3	VarName4	VarName5	VarName6	VarName7	VarName8	VarName9
1	"Monday, 15-y-2023 15:30:18 UTC"	"850.94 "	"622.00 "	"3024.00 "	"2651.00 "	"1837.00 "	"0.00 "	"0.00 "	"27.00 "
2	"Monday, 15-y-2023 15:31:59 UTC"	"925.88 "	"630.00 "	"3047.00 "	"2695.00 "	"1829.00 "	"0.00 "	"0.00 "	"27.20 "
3	"Monday, 15-y-2023 15:33:40 UTC"	"715.33 "	"653.00 "	"3046.00 "	"2519.00 "	"1823.00 "	"0.00 "	"0.00 "	"27.32 "
4	"Monday, 15-y-2023 15:35:22 UTC"	"659.30 "	"666.00 "	"3051.00 "	"2675.00 "	"1825.00 "	"0.00 "	"0.00 "	"27.60 "
5	"Monday, 15-y-2023 15:37:03 UTC"	"1029.06 "	"644.00 "	"3039.00 "	"2670.00 "	"1830.00 "	"0.00 "	"0.00 "	"27.53 "
6	"Monday, 15-y-2023 15:38:44 UTC"	"1014.98 "	"624.00 "	"3047.00 "	"2725.00 "	"1827.00 "	"0.00 "	"0.00 "	"27.45 "
7	"Monday, 15-y-2023 15:41:03 UTC"	"1137.11 "	"643.00 "	"3047.00 "	"2735.00 "	"1819.00 "	"0.00 "	"0.00 "	"27.39 "
8	"Monday, 15-y-2023 15:42:44 UTC"	"1099.51 "	"630.00 "	"3039.00 "	"2762.00 "	"1822.00 "	"0.00 "	"0.00 "	"27.47 "
9	"Monday, 15-y-2023 15:44:25 UTC"	"822.86 "	"546.00 "	"3039.00 "	"2704.00 "	"1821.00 "	"0.00 "	"0.00 "	"27.59 "

FIGURE 5.21 – Données au format .mat exploitées sous Matlab.

- la date et l'heure.

Lors de la restructuration des données, nous construirons pour les besoins de la vérification de nos algorithmes des deux précédents chapitres, les données liées aux :

- résidus pour l'algorithme du diagnostic par la méthode de l'espace de parité grâce à I_G , V_G , I_{stg1} et I_{stg2} ;
- matrices d'entrées de l'algorithme du RNA de la classification pour la détection à travers les données P , V et I ;
- matrices d'entrées de l'algorithme du RNA de la classification pour le diagnostic à travers les données $\{PVI\}$.

N'ayant pas de capteur de puissance lors de l'acquisition, nous avons eu recours au calcul direct pour obtenir $P = VI$.

5.6 Application au diagnostic par la méthode de l'espace de parité

La synthèse des caractéristiques des modules solaires utilisés est donnée dans le Tableau 5.2.

TABLE 5.2 – Paramètres du module PV utilisé.

Paramètres	Valeurs
I_{pvn}	3,8713
I_{scn}	3,56
K_v	0,08
K_i	0,065
N_{cell}	9
V_{oc}	5,4

La construction du générateur s'est faite autour de :

- deux strings de 1 module donnant un courant général $I_G = 3,725 \text{ mA} = I_{stg1} + I_{stg2}$;
- $V_G = V_{stg} = 2,7 \text{ V}$.

Les deux coefficients calculés à partir des paramètres pour GPV sain sont :

- $a_{i1} = -0,8205 \times 10^{-4}$;
- $b_{i1} = 4,0777$.

A partir du calcul de ces deux coefficients, les résidus sont construits à partir du tableau de mesures contenant I_G , V_G , I_{stg1} et I_{stg2} ci-dessus.

- $R_0 = I_G - I_{stg1} - I_{stg2}$;
- $R_1 = I_{stg1} - a_{i1} \times V_G - b_{i1}$;
- $R_2 = I_{stg2} - a_{i2} \times V_G - b_{i2}$.

Ils donnent la matrice d'occurrence du Tableau 5.3.

A partir des données d'acquisitions du 20/7/2023 sur 236 échantillons, nous avons structurer les trois résidus à partir desquels nous avons utilisé l'algorithme de détection DCS avec deux fenêtres de largeur 20 et 50 pour un seuil de détection donné.

TABLE 5.3 – Matrice d'occurrence de la simulation.

R_i	I_G	V_G	I_{stg1}	I_{stg2}
R_0	1	0	1	1
R_1	0	1	1	0
R_2	0	1	0	1

5.6.1 Pour une largeur de fenmax = 20

Dans ce premier scénario de simulation sur la Figure 5.22, la taille de la fenêtre est fixée à 20. Le traitement ($DCS, g(t)$ et d_i) effectué sur les trois résidus est présenté sur les Figures 5.22a, 5.22b et 5.22c suivi de la localisation sur la Figure 5.22d. La taille de la fenêtre fenmax = 20, permet une détection optimale comme indiqué déjà au chapitre 3.

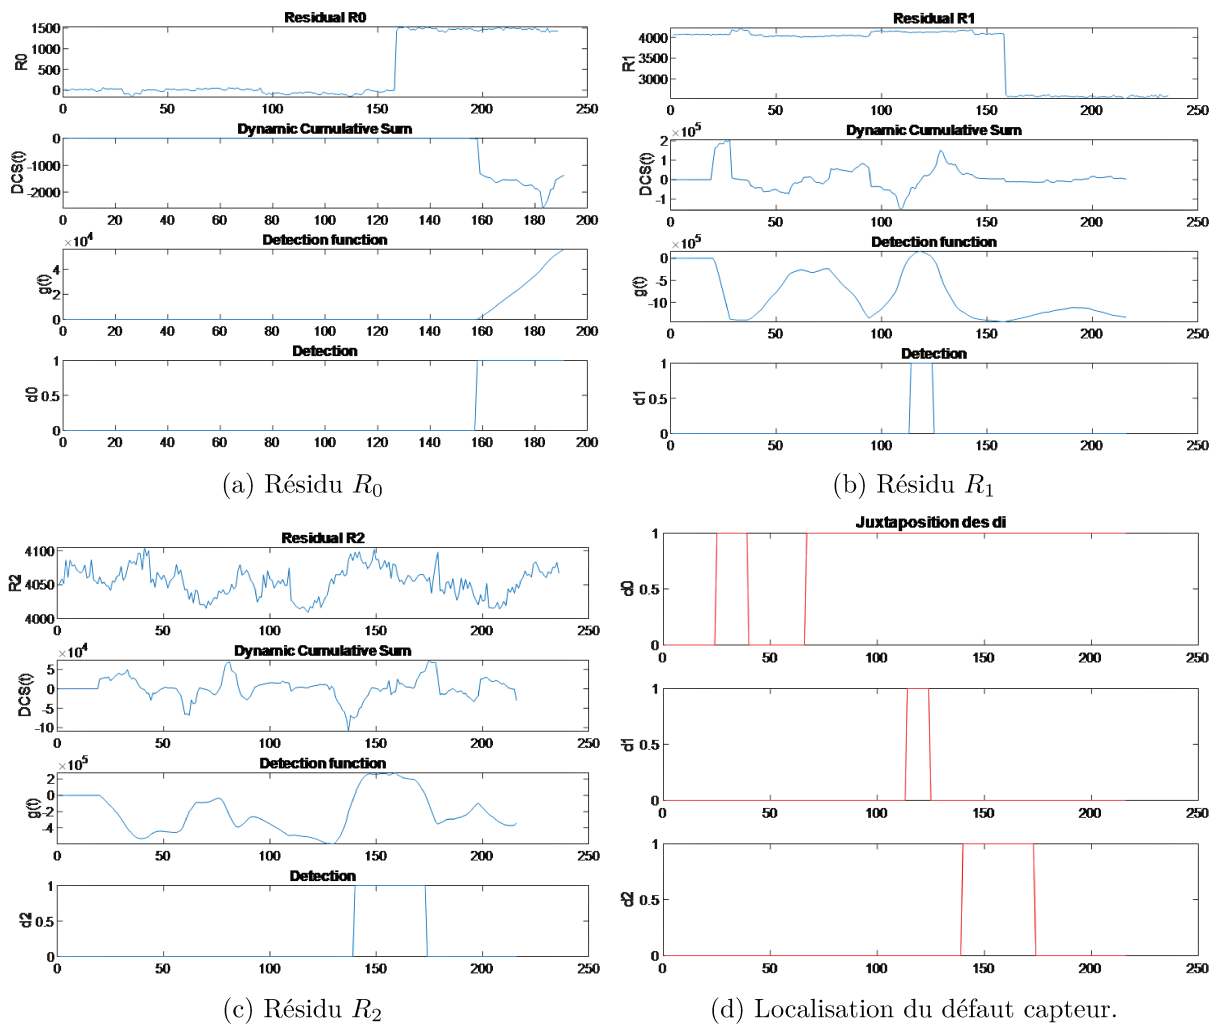


FIGURE 5.22 – Traitement des résidus avec fenmax = 20.

L'interprétation par rapport à la matrice d'occurrence du Tableau 5.3, pour une fenêtre de taille 20 et un seuil de détection de 5 de la Figure 5.22d, nous donne la présence de trois défauts du type capteur :

- sur le courant général, entre les instants 25 à 40, 60 à 120, 13 à 140, et 175 à 200, avec la signature "100" ;

- sur le courant du string 1, entre les instants 120 et 130 avec la signature "110" ;
- sur le courant du string 2, entre les instants 140 et 175 avec la signature "101" ;

Signalons enfin, que le système semble être dans un mode de fonctionnement sain entre les instants 0 à 25 et 40 à 60, à cause de la signature "000" de la matrice d'occurrence du Tableau 5.3.

5.6.2 Pour une largeur de fenmax = 50

Dans ce second scénario de simulation sur la Figure 5.23, la taille de la fenêtre est fixée à 50, juste à la limite des mauvais cas de détection. Le traitement ($DCS, g(t)$ et d_i) des trois résidus est illustré sur les Figures 5.23a, 5.23b et 5.23c suivi de la localisation sur la Figure 5.23d. Au-delà de cette taille de détection ne permet aucune interprétation du principe du diagnostic, comme indiqué déjà au chapitre 3.

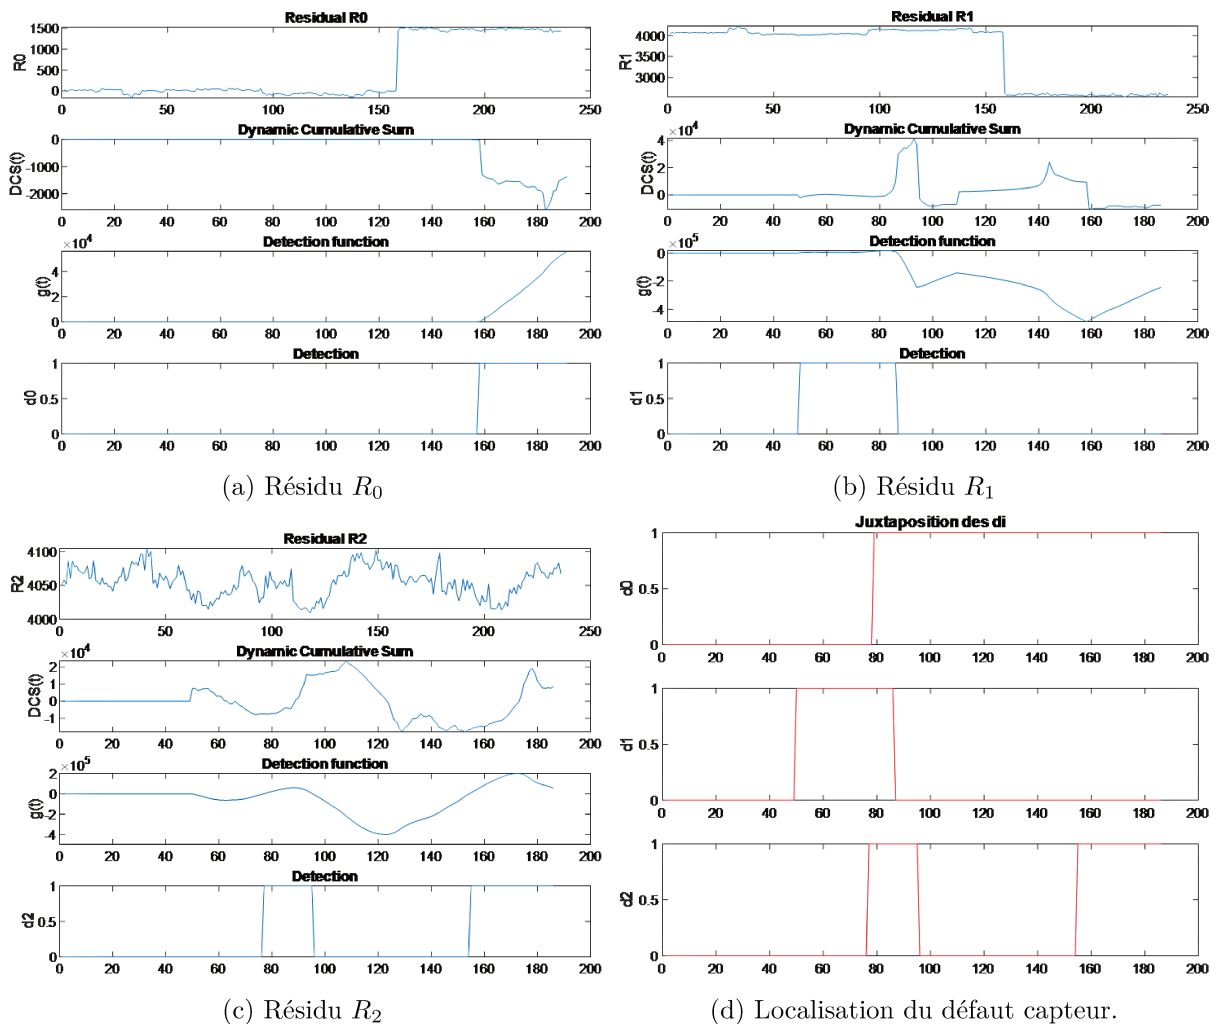


FIGURE 5.23 – Traitement des résidus avec fenmax = 50.

L'interprétation par rapport à la matrice d'occurrence du Tableau 5.3, pour une fenêtre de taille 50, pour le même seuil de détection de 5 de la Figure 5.23d, nous donne la présence de deux défauts du type capteur connu :

- sur le courant général, entre les instants 95 à 155, avec la signature "100" ;
- sur le courant du string 2, entre les instants 85 à 95 et 155 à 200, avec la signature "101".

et deux défauts capteur du type inconnu, à cause du faible nombre de résidus :

- défaut inconnu 1, entre les instants 50 à 75, avec la signature "010" ;
- défaut inconnu 2, entre les instants 75 à 85, avec la signature "111".

Signalons enfin, que le système semble être dans un mode de fonctionnement sain entre les instants 0 à 50, à cause de la signature "000" de la matrice d'occurrence du Tableau 5.3.

5.6.3 Synthèse de l'application de la méthode de l'espace de parité

Nous avons bien la détection de multiples défauts capteurs, mais nous sommes incapables de situer l'origine ni les causes des défauts engendrant la baisse de la valeur de la tension générale ou du courant général de sortie conduisant à la baisse de puissance de production du générateur.

Nous confortons encore l'idée selon laquelle, l'augmentation de la taille des fenêtres coulissantes dégrade la qualité de la détection.

Le fait de n'avoir pas beaucoup de résidus aussi constitue une entrave à la bonne application de cette méthode de diagnostic. En plus, les fortes fluctuations de G et T , introduit lors de la construction des données de mesures, peuvent avoir eu un grand impact sur la baisse de la tension V_G mesurée et du courant général I_G ou peut être avoir d'autres causes liées aussi à variation de l'un des paramètres intrinsèque du modèle. C'est aussi la raison pour laquelle nous enregistrons la détection de défauts d'origine inconnues et dont nous ignorons la signature exacte à travers la matrice d'occurrence.

Nous n'avons pas mesuré les performances de la méthode ici, parce que nous avons utilisé les données produites par la maquette d'acquisition temps réel. Aussi nous ne pouvons pas prédéfinir les deux deux hypothèses pour les détections correctes et là où il y a des détections non-correctes pour la construction de la courbe COR.

5.7 Application au diagnostic par la méthode des RNA

Les différentes configurations pour la simulation du RNA pour 236*3 échantillons d'entrées sont présentées sur la Figure 5.27, pour plusieurs scénarii en rapport avec le nombre de couches cachées, sont destinées à un diagnostic pour des défauts systèmes.

Nous avons enregistré les données avec un ensoleillement et une température très fluctuant, pour tenir compte de la réalité du terrain.

Après avoir organisé les données d'entrée issues du prototype d'acquisition, nous avons procédé à la validation des deux algorithmes de classification à base de RNA, à travers :

- la classification pour la détection ;
- la classification pour le diagnostic.

5.7.1 Classification pour la détection avec les données d'acquisition

La validation par la simulation avec les données d'entrées, issues des mesures, vont permettre de juger de la détectabilité d'un éventuel défaut sur l'état de fonctionnement du GPV.

La sortie, est binaire et indique simplement l'état dans lequel, le GPV sera : pas de défaut 0, ou en défaillance 1.

Nous avons extrait sur l'ensemble des données de sortie du GPV, 101 échantillons, avant d'extraire uniquement les données de la puissance P , de la tension V et du courant I devant servir de matrice d'entrée pour la configuration du RNA.

Le changement de la nature des données d'entrées suivant les trois cas ci dessous, permettra sans doute de répondre à la question de la détectabilité ou non de la présence d'un éventuel défaut par la classification pour la détection :

- Cas 1.** avec les données d'entrée de P , l'erreur quadratique est minimisée sur 10 itérations consécutives sur la Figure 5.24a, et la classification indique l'existence d'un défaut, comme le montre les courbes de performance de la Figure 5.24b ;
- Cas 2.** avec les données d'entrée de V , l'erreur quadratique est minimisée sur 52 itérations consécutives sur la Figure 5.25a, et la classification indique l'existence d'un défaut, comme le montre les courbes de performance de la Figure 5.25b ;
- Cas 3.** avec les données d'entrée de I , l'erreur quadratique est minimisée sur 7 itérations consécutives sur la Figure 5.26a, et la classification indique l'existence d'un défaut, comme le montre les courbes de performance de la Figure 5.26b ;

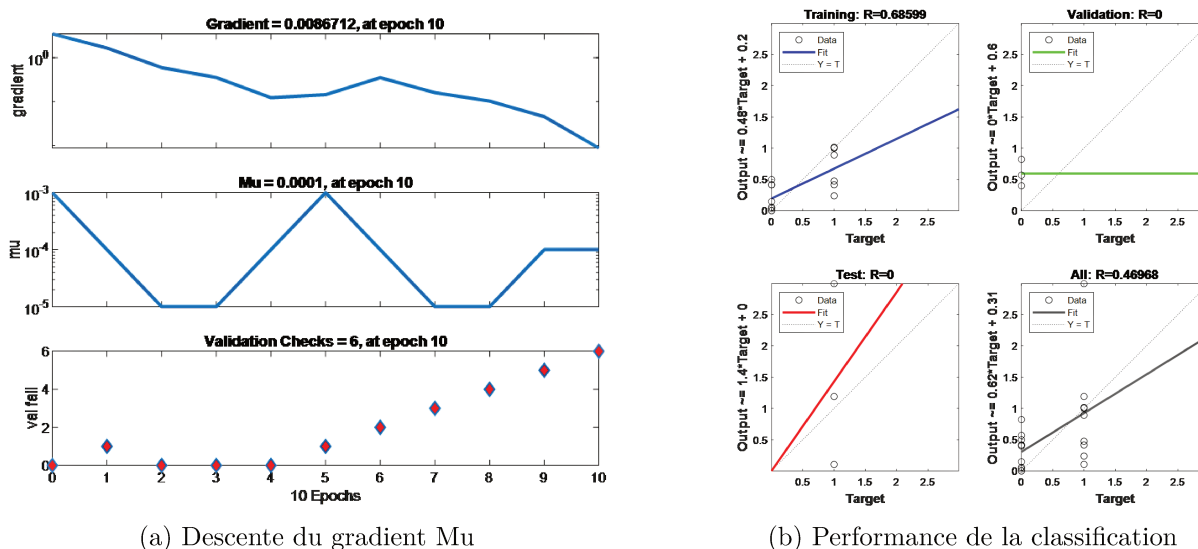



FIGURE 5.24 – Performances du RNA pour la détection avec les données d'acquisition de P .

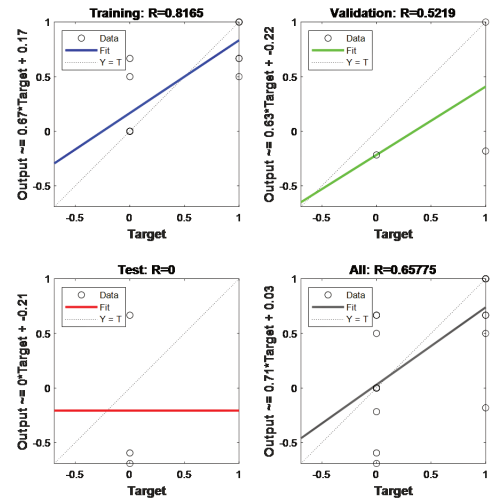
Synthèse de la détection avec les données d'acquisition

Le Tableau 5.4 de synthèse des performances pour 10 couches cachées, donne des résultats pas très loin de ceux obtenus en simulation. Les trois cas de configuration détecte et classifie bien l'existence de défauts dans les données d'acquisition issues de la puissance, de la tension et du courant de sortie du GPV suite aux variations abruptes de la température et de l'ensoleillement qui prend en compte, les conditions réelles de fonctionnement.

L'utilisation de l'une ou l'autre de ces trois données conduit à la détectabilité de l'existence du défaut ayant affecté les données. Cependant le modèle de configuration du RNA pour la détection est aussi incapable de préciser la nature ni l'origine du ou des défauts mis en exergue ici comme nous l'avons déjà indiqué dans le chapitre 4.




(a) Descente du gradient Mu

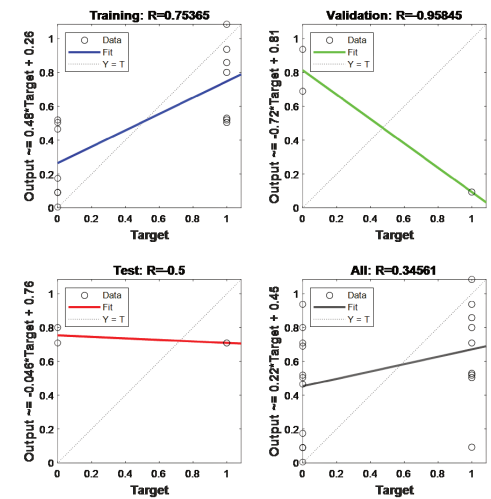


(b) Performance de la classification

FIGURE 5.25 – Performances du RNA pour la détection avec les données d’acquisition de V.



(a) Descente du gradient Mu



(b) Performance de la classification

FIGURE 5.26 – Performances du RNA pour la détection avec les données d’acquisition de I.

Les performances de calcul de la configuration RNA pour la détection sont assez bonnes pour les trois cas de simulation, et pourront être améliorées grâce à une augmentation du nombre de couches cachées.

5.7.2 Classification pour le diagnostic avec les données d’acquisition

La validation par la simulation avec les données d’entrées, issues des mesures, vont permettre de faire le diagnostic d’éventuels défauts systèmes sur l’état de fonctionnement du GPV.

Nous avons extrait des données de sortie du GPV, 236×3 échantillons de *PVI* devant servir de matrice d’entrée pour la configuration du RNA pour le diagnostic.

Nous avons cette fois ci fait varier le nombre de couches cachées, comme dans le chapitre 4, comme sur la Figure 5.27, pour mieux apprécier les performances de la configuration pour le diagnostic par la classification d’éventuels défaut système.

Les écarts quadratiques minimisés sur les Figures 5.28a, 5.29a, 5.30a et 5.31a, et les Figures

TABLE 5.4 – Performances du RNA pour la détection avec les données d’acquisition.

	P	V	I
Nombre d’itérations	10	52	7
Durée du test	1"	4"	20"
MSE	$8,67.10^{-3}$	$2,73.10^{-8}$	$2,12.10^{-3}$
$Perf = (1 - MSE)$	99,13%	99,99%	99,79%
Détection	Oui	Oui	Oui

5.28b, 5.29b, 5.30b et 5.31b des courbes COR de la classification du diagnostic de défaut système suite à différentes fluctuations sur la température et l’ensoleillement pour différentes configurations de RNA pour 2, 5, 10 et 20 couches cachées, prouvent l’existence d’un défaut ou plusieurs défauts systèmes et dont l’origine peut être située dans l’un des codes ci dessous, obtenu pour un seuil de défaut de 0,3333 :

- 000 : aucun défaut ou diode de bypass déconnectée ;
- 011 : mismatch du type ombrage partiel ;
- 100 : diode bypass défaillante ou mismatch du type R_{sh} ou R_s ou module shunté ;
- 111 : nature de défaut inconnu.

Synthèse de la classification pour le diagnostic de défaut système

Les courbes COR des Figures 5.28b, 5.29b, 5.30b et 5.31b montrent que l’utilisation de l’ensemble de données $\{P_G V_G I_G\}$, indiquent qu’il y a bien des défauts dans le système de production de ce GPV, mais d’origine diverse. Les fluctuations naturelles de l’ensoleillement et de la température peuvent justifier ces défauts de production que le réseau de neurone met en évidence. La variation du nombre de couches cachées dans les RNA configurées laisse voir une certaine dynamique des performances résumées dans le Tableau 5.5, indiquant la bonne tenue de la classification pour le diagnostic des défauts systèmes même avec les données issues du prototype d’acquisition.

TABLE 5.5 – Synthèse de la performance du RNA pour un défaut système.

	2 couches	5 couches	10 couches	20 couches
Nombre d’itérations	1000	1000	1000	1000
Durée du test	12"	9"	11"	16"
MSE	$5,85 \times 10^{-3}$	$2,52 \times 10^{-5}$	$8,77 \times 10^{-4}$	$2,46 \times 10^{-3}$
$Perf = (1 - MSE)$	99,41%	99,99%	99,91%	99,75%

Malgré la variation du nombre de couches cachées dans la configuration de ce RNA pour le diagnostic des défaut système, nous obtenons l’indexation suivante en rapport avec le tableau 4.9, qui nous donne une idée des paramètres intrinsèques concernés du GPV.

La configuration du RNA pour de la classification pour le diagnostic des défauts systèmes, permet de voir l’impact du niveau de l’ensoleillement ou de la température vu comme un mismatch du type ombrage partiel. Mieux la fluctuation des deux paramètres d’entrée G ou T , fait croire à la configuration RNA qui le signale, qu’il semble y avoir eu une variation des deux paramètres intrinsèques du système que sont R_{sh} et R_s .




FIGURE 5.27 – Configuration RNA en fonction des couches cachées pour des données réelles.

5.7.3 Synthèse de l'application de la méthode des RNA

D'emblée, nous pouvons dire que les deux méthodes de diagnostic trouvent des résultats concordants par rapport aux résultats attendus pour chacune d'elles.

A titre de comparaison, dans la première méthode de diagnostic par l'espace de parité, les résultats de simulation obtenus au chapitre 3, ont été fortement confortés par les résultats de validation avec des données issues de notre prototype d'acquisition temps réel dans le chapitre 5. La détection, l'isolation et la localisation des défauts multi-capteur grâce à des algorithmes simples et rapides confirment si besoin est encore, le fait que cette méthode soit particulièrement utilisée pour le diagnostic des systèmes industriels complexes.

Toujours à titre de comparaison, mais cette fois pour la seconde méthode par les réseaux de neurones artificiels, les résultats de simulation du chapitre 4, tant pour la classification que la détection que la classification pour le diagnostic, les résultats de validation obtenus avec les données du prototype d'acquisition dans le chapitre 5, sont non seulement conformes mais aussi concordant en terme de logique que de convergence des performances.

Nous notons que pour le cas de la classification pour la détection, que la détectabilité des défauts bien que clairement mise en évidence par l'utilisation des données de simulation obtenues du modèle du chapitre 4, que par les données de validation obtenues du prototype d'acquisition temps réel du chapitre 5, il est impossible de remonter à l'origine et aux causes probables des-dits défauts. Quant à la méthode de la classification pour le diagnostic, nous sommes arrivés dans les deux cas, en simulation comme en validation, à obtenir un faisceau d'indices lié à une famille

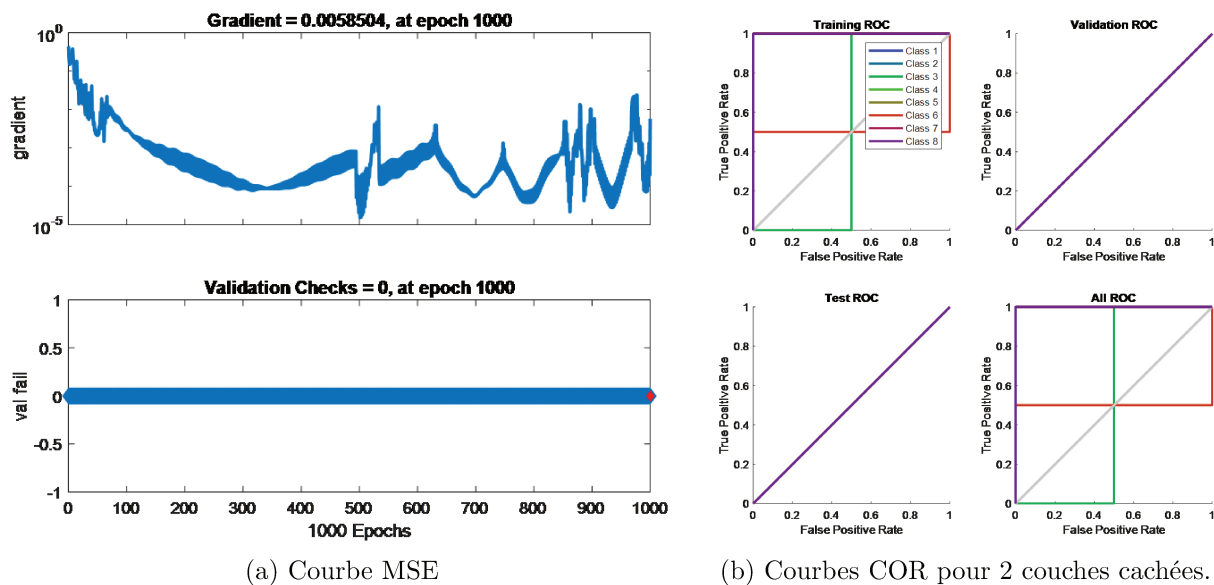


FIGURE 5.28 – Performances du RNA de 2 couches cachées pour des données réelles.

ou à un type de défaut système, permettant de remonter facilement à ses causes ou ses origines.

Si la première méthode par la méthode de l'espace de parité semble plus fine dans la détection du FDI, la deuxième méthode par les réseaux de neurones artificiels nécessite moins de tests et possède une certaine suprématie qui ne se discute plus. Néanmoins une certaine complémentarité pour le diagnostic des défauts systèmes serait souhaitable, ne serait-ce qu'envisagé dans le cadre d'une supervision globale de l'état de santé du GPV.

5.8 Conclusion

Dans ce chapitre, nous avons présenté les différents concepts, composants et les principales caractéristiques liées à l'Internet Industriels des Objets, pour la réalisation d'un système d'acquisition en temps réel pour un système industriel complexe ayant besoin d'un bon diagnostic pour une maintenance corrective et ou préventive des pannes.

De par son utilité et son caractère d'IIoT, ce système d'acquisition technologique contribuera de manière significative, efficace, et en temps réel à l'application et au perfectionnement d'une méthode de maintenance orientée sur les conclusions d'un vrai outil de diagnostic, que nous appelons de tous nos vœux, à faire partie intégrante d'un système d'aide à la décision.

Grâce à notre système à triple technologies, acquisition, stockage et transmission en temps réel, nous voulons contribuer d'une façon efficace au développement du diagnostic, mais en particulier à une maintenance corrective capable de remettre un GPV connecté ou sur site isolé dans un bon état de fonctionnement.

Dans la première partie de ce chapitre, l'instrumentation et l'expérimentation électronique n'ont pas du tout été faciles, à cause du mélange des protocoles de communications d'une part, mais aussi la gestion des conflits entre certaines bibliothèques de la carte ESP 32 d'autre part. Un travail de fond a dû être fait, pour l'étalonnage et la prise en compte des tensions d'offsets de certains des capteurs, car l'ESP32 ne les voyaient pas comme ce que nous connaissons habituellement. Il est aussi bon, de reconnaître que si les essais sont fortement concluants et

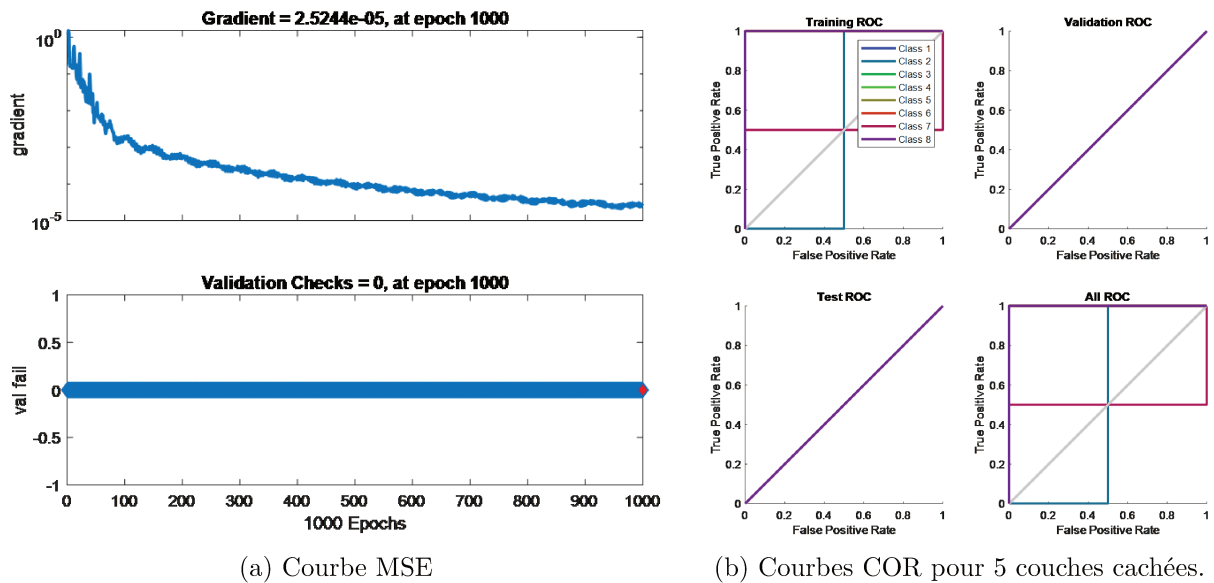


FIGURE 5.29 – Performances du RNA de 5 couches cachées pour des données réelles.

encourageants, il faudrait envisager des réalisations avec des composants plus robustes en tenant compte de la taille et de la puissance des centrales PV ciblées (domestique ou industrielle).

Dans la seconde partie de ce chapitre, nous avons exposé un acquis certain à travers le second prototype d'acquisition temps réel, dont le premier privilège reste la transmission sur réseau wifi à un Server web pour une exploitation des données en vue d'assurer un diagnostic, le stockage des données sur la carte SD, et l'affichage sur écran LCD. Le tout s'exécute bien entendu dans un contexte de temps réel.

Dans la troisième partie de ce chapitre, nous avons exploité, les données mesurées à partir du prototype IIoT tels que les courants des deux strings du champ PV, le courant et la tension général de sortie du générateur, pour alimenter la première méthode de diagnostic basée sur l'espace de parité ainsi que la méthode de diagnostic à base des réseaux de neurones artificiels moyennant quelques aménagements sur l'obtention des données de la puissance.

Ne disposant pas de capteur de puissance, nous avons eu recours au produit direct de la tension générale V_G et du courant général I_G pour produire P dans le tableau des données. Le diagnostic des défauts capteurs à travers la méthode de l'espace de parité nous a permis de faire l'identification et la localisation de plusieurs défauts dans le chapitre 3. Le diagnostic de défauts systèmes, quant à lui, nous a permis de mettre en évidence des défauts systèmes avec plusieurs causes et origines possibles.

Brièvement abordée dans [Compaoré et al. 2022 b.], il serait souhaitable d'envisager une étude complémentaire entre ces deux méthodes de diagnostic que nous avons expérimentées avec succès. Car le diagnostic par la méthode de l'espace de parité identifie certes, la partie du GPV en souffrance, mais est incapable de dire la partie intrinsèque du système en souffrance. La méthode des RNA pourrait être utilisée à la suite d'un diagnostic par la méthode de l'espace de Parité.

Il est aussi bon de signaler que plusieurs obstacles peuvent se montrer comme étant de véritables défis pour les solutions IoT. Pour que notre solution IIoT puisse évoluer, les capteurs utilisés ou futurs à incorporer devront être moins énergétivores, car nos deux prototypes s'ali-

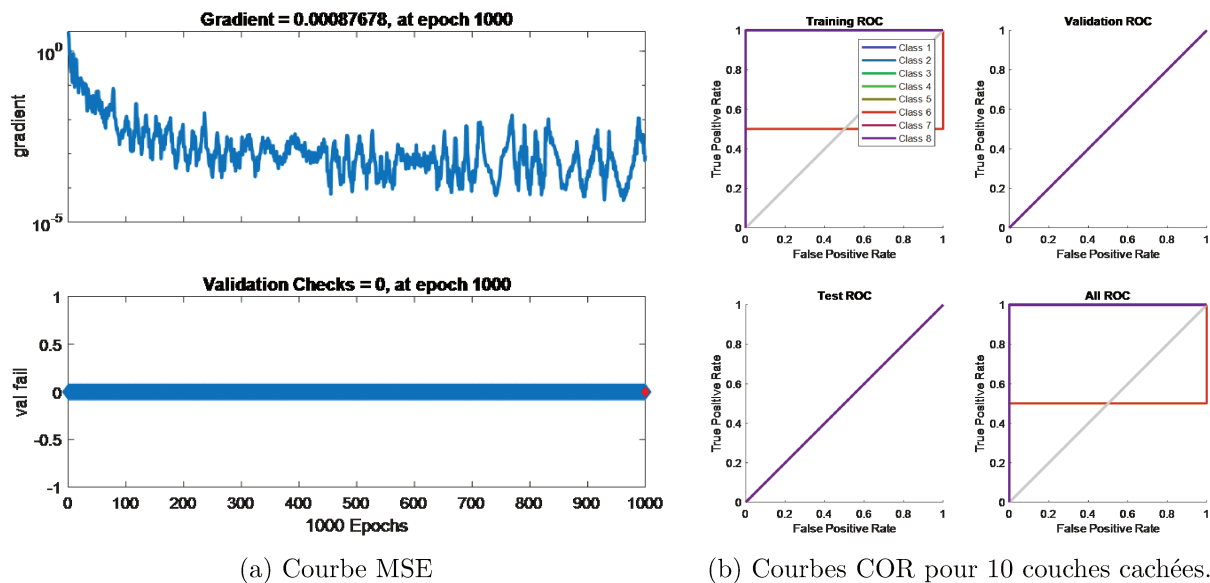
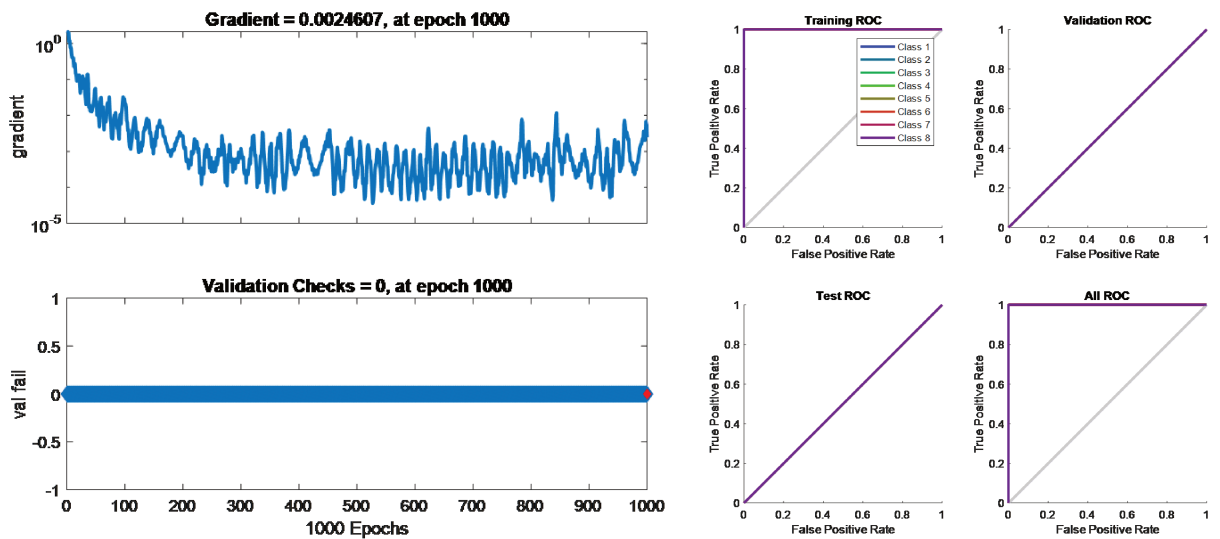


FIGURE 5.30 – Performances du RNA de 10 couches cachées pour des données réelles.

mentent pour l'instant, directement à la source c'est-à-dire sur le GPV.

Nous devons aussi faire d'énormes progrès de mise à jour pour le long terme, notamment dans les domaines de la sécurité, de la confidentialité, de l'architecture et des communications au cas où la solution serait viable et amenée à incorporer plus d'objet. Il ne faut pas non plus occulter le cas où la connexion passerait par un protocole de connexion à base de cartes SIM, et pour laquelle il faudrait prévoir des coûts connexes.

Le prototype mis en avant dans ce chapitre pourrait contribuer largement à l'avènement des smart cities à travers une meilleure maîtrise dans la gestion des sources d'énergies mixtes des villes intelligentes, tant sur le plan de la supervision que de la surveillance des réseaux de production à travers une maintenance corrective.



(a) Courbe MSE

(b) Courbes COR pour 20 couches cachées.

FIGURE 5.31 – Performances du RNN de 20 couches cachées pour des données réelles.

Conclusion générale et perspectives

Conclusion générale et perspectives

Avec des anomalies qui se transforment vite en défaillances, nous avons vu que le GPV, tout comme les systèmes industriels complexes, peut souffrir des multiples défauts pouvant provenir de la fabrication de ses propres éléments constitutifs, de son environnement de fonctionnement ou de ses propres conditions de service. C'est sur cette base de la problématique de l'état de santé des GPV, que nous avons entrepris ce travail de recherche.

Aussi nous nous sommes focalisé sur la validation d'un modèle robuste de GPV, sur lequel nous avons simulé et validé deux méthodes de diagnostic. La diversité des défauts pouvant affectés le bon fonctionnement du GPV a aussi été largement utilisé afin de tester non seulement l'efficacité des méthodes de diagnostic proposées, mais de prouver si besoin était encore, l'utilité des outils d'aide à la décision, pour orienter les actions de maintenance proactive et prédictive.

Nous avons fait dans le chapitre 1, une revue bibliographique assez complète sur le diagnostic et l'existence de ses principales méthodes. Nous avons terminé d'ailleurs ce chapitre en précisant les méthodes assez indiquées et vers lesquelles nous voulions axer notre attention.

Dans le chapitre 2, nous nous sommes mis dans une logique d'identification et de modélisation pour le choix d'un modèle tant électrique que mathématique allant de la cellule au générateur photovoltaïque qui s'appuie fortement sur le modèle de Bishop. Nous l'avons mis en exergue grâce à l'algorithme de Newton-Raphson. La validation du modèle nous donne des résultats de simulation aussi proche de la réalité, qui prend en compte les différents défauts étudiés.

Dans le chapitre 3, nous avons expérimenté une des techniques des RRA fondée sur la méthode de l'espace de parité appliquée au point de fonctionnement maximal du GPV. Après avoir structuré les résidus du modèle sain avec un modèle dégradé, nous avons utilisé l'algorithme de détection de la somme dynamique cumulée (DCS), avec deux fenêtres glissantes. Nous avons montré que la taille des fenêtres, ainsi que le niveau du seuil, modifie la qualité de la détection de cet algorithme. Nous avons aussi pu détecter et localiser très nettement les défauts du type capteur qu'ils soient liés au courant ou à la tension. Le seuil h de détection peut être peaufiné grâce à l'utilisation de la courbe COR en fonction du type, de la nature et de l'amplitude du défaut. Plusieurs défauts capteurs, peuvent être mis en évidence grâce à l'augmentation de la taille de la matrice d'occurrence, et donc du nombre de résidus.

Dans le chapitre 4, nous avons appliqué une seconde méthode de diagnostic basés sur les techniques d'intelligence artificielle. La configuration de deux algorithmes basées sur la méthode des RNA, dont un sur la détection des défauts et l'autre sur le diagnostic des défauts systèmes. Rappelons que ces deux techniques, assez précis et rapides, identifient des défauts systèmes, permettant d'entreprendre des actions de maintenance corrective, en relation avec certains paramètres du modèle en souffrance. Cette technique de diagnostic tire son avantage d'une grande connaissance du comportement du GPV que nous avons minutieusement mis en place.

Le chapitre 5 a permis d'aborder les IoT, la hiérarchisation et la caractérisation des principales composantes des deux prototypes instrumentés pour l'acquisition en temps réel de données d'un GPV afin de valider les résultats de simulations faites. Nous avons obtenu des résultats d'expérimentation satisfaisants. En effet, ces résultats confirment la bonne tenue du diagnostic des défauts capteurs par la méthode de l'espace de parité, ainsi que le diagnostic des défauts systèmes par la méthode des RNA. Le premier prototype ne permet que la sauvegarde sur carte SD uniquement, alors que le second prototype incorpore l'option sauvegarde sur carte SD mais aussi l'option de la transmission en temps réel par Wifi pour le serveur web distant. Ce second prototype est plutôt une réussite pour l'avantage qu'il offre dans la mise en place du système de surveillance. Ainsi, que ce soit sur site isolé ou connecté, en mode on-line ou off-line, il sera possible de faire non seulement le diagnostic et la surveillance nécessaire grâce aux données sauvegardées par l'une ou l'autre méthode avec les deux méthodes de diagnostic proposées mais aussi d'entreprendre les actions de maintenances idoines.

Perspectives

En termes de perspectives, nous privilégierons la création d'une plateforme pour la surveillance, voire la supervision. Ça serait l'occasion de penser à la complémentarité des deux techniques de diagnostic, qui s'avère être une nécessité. Il serait aussi de bon ton, d'envisager l'extension de l'application de ces deux méthodes de diagnostic sur des champs PV beaucoup plus vastes, en prenant en compte des facteurs comme la plage de puissance, l'usage domestique ou industriel.

Le prototype, quant à lui, devrait être repensé avec des composants plus robustes destinés aux usages professionnels, pour tenir compte des bruits et parasites électroniques, de la compatibilité électromagnétique qui pourraient éventuellement affecter ou perturber la sauvegarde ou la transmission temps réel, si toutefois une phase d'industrialisation de conception intégrée au champ de production PV devrait être envisagée.

D'autres alternatives plus robustes en terme de connectivité pourraient être entreprises, à travers des réseaux privés ou propriétaires.

Article de Revue internationale avec comité de lecture

O. W. COMPAORE, G. HOBLOS, Z. KOALAGA. *Sensor Fault diagnosis using parity space approach : Application on a photovoltaic generator*. Measurement – ISSN 0263-2241. En préparation.

Article de Conférence internationale avec comité de lecture

- Art. 1.** O. W. COMPAORE, G. HOBLOS, Z. KOALAGA. "*Analysis of the Complementarity of Two Diagnostic Methods on a PV Generator*", Proceedings of the 5th edition of the Computer Science Research Days, JRI 2022, 24-26 November 2022, Ouagadougou, Burkina Faso. (2023) [DOI:10.4108/eai.24-11-2022.2329810](https://doi.org/10.4108/eai.24-11-2022.2329810) ;
- Art. 2.** O. W. COMPAORE, G. HOBLOS, Z. KOALAGA. "*Performance analysis by the ROC curve following the application of the FDI on a PVG*". 2023 IEEE Multi-conference on Natural and Engineering Sciences for Sahel's Sustainable Development (MNE3SD). 23-25 February 2023. Bobo-Dioulasso, Burkina Faso. [DOI:10.1109/MNE3SD57078.2023.10079773](https://doi.org/10.1109/MNE3SD57078.2023.10079773) ;
- Art. 3.** O. W. COMPAORE, G. HOBLOS, Z. KOALAGA. "*Sensor Fault analysis of an isolated photovoltaic generator*". September 5-7 2022, 15th DPS 2022 Gdank Poland, LNNS 545, pp. 278–290, 2023. [DOI:10.1007/978-3-031-16159-9_23](https://doi.org/10.1007/978-3-031-16159-9_23) ;
- Art. 4.** O. W. COMPAORE, Z. KOALAGA, G. HOBLOS. "*Instrumentation of a real-time acquisition system for diagnostics in a PVG*". 2022 IEEE Multi-conference on Natural and Engineering Sciences for Sahel's Sustainable Development (MNE3SD) February 24-26 2022, IEEE Xplore March 2022 INSPEC Accession Number : 21743472. [DOI:10.1109/MNE3SD53781.2022.9723255](https://doi.org/10.1109/MNE3SD53781.2022.9723255) ;
- Art. 5.** O. W. COMPAORE, G. HOBLOS, Z. KOALAGA. "*Artificial Neural Network based fault diagnosis in an isolated photovoltaic generator*". 4è JRI 2021, November 11-13 2021, pp. 117-130, Bobo-Dioulasso, Burkina Faso Copyright © 2022 EAI. [DOI:10.4108/eai.11-11-2021.2317977](https://doi.org/10.4108/eai.11-11-2021.2317977) ;

Art. 6. O. W. COMPAORE, G. HOBLOS, Z. KOALAGA. "*Analysis of the impact of faults in a photovoltaic generator*", 2021 International Conference on Innovation and Intelligence for Informatics, Computing, and Technologies (3ICT), 2021, pp. 68-73, DOI:10.1109/3ICT53449.2021.9581575.

Présentation orale à une rencontre scientifique

Prés. 1. O. W. COMPAORE. G. HOBLOS, Z. KOALAGA. "*Diagnostic des défauts capteurs Application sur un générateur photovoltaïque*". Réunion GT 3S du Groupe GDR-MACS du 8 Avril 2022. Besancon France ;

Prés. 2. O. W. COMPAORE. G. HOBLOS, Z. KOALAGA. "*Diagnostic des défauts : Application sur un générateur photovoltaïque*". Journée de travail et de restructuration du laboratoire LAME. 24-26 Mars 2022. Ouagadougou Burkina Faso ;

Prés. 3. O. W. COMPAORE. G. HOBLOS, Z. KOALAGA. "*Diagnostic des défauts capteurs : Application sur un générateur photovoltaïque*". Journée des doctorants JDD-IRSEEM, 22 juin 2022. Saint Etienne du Rouvray France ;

Prés. 4. O. W. COMPAORE. G. HOBLOS, Z. KOALAGA. "*Pronostic de défaillances pour une maintenance préventive conditionnelle. Application dans l'énergie solaire*". Journée des doctorants JDD-IRSEEM, 22 juin 2021. Saint Etienne du Rouvray France ;

Prés. 5. O. W. COMPAORE. G. HOBLOS, Z. KOALAGA. "*Pronostic de défaillances pour une maintenance préventive conditionnelle. Application dans l'énergie solaire*" Poster pour la JDD-IRSEEM, 24 juin 2020. Saint Etienne du Rouvray France ;

Prés. 6. O. W. COMPAORE. "*DEVELOPEMENT URBAIN DURABLE face aux Objectifs de Développement Durable*". Ambassadeur des objectifs du développement durable, 21 juin 2022. Canteleu France ;

Prés. 7. O. W. COMPAORE. "*Second prix des lauréats Pépité d'Entreprise à travers la présentation du projet « Fruinted »*". Hackaton organisée du 24 au 27 novembre 2020 par Normandie Université et PEPITE Vallée de Seine, dont les thèmes majeurs portaient sur « la sensibilisation à l'innovation, la création d'entreprise innovante et l'entrepreneuriat. ». Saint Etienne du Rouvray France.

- [Abdelghani 2017] Abdelghani Chahmi. *Identification paramétrique de la machine asynchrone dédiée au diagnostic. Energie électrique*. Université des sciences et technologie d'Oran -MB. Français. NNT : tel-01658902. (2017).
- [Abuelnaga et al. 2021] A. Abuelnaga, M. Narimani, A.S. Bahman, *A review on IGBT module failure modes and lifetime testing*. IEEE Access 9 (2021) 9643–9663, <https://doi.org/10.1109/ACCESS.2021.3049738>. (2021).
- [Aggab 2016] Aggab Toufik. *Pronostic des systèmes complexes par l'utilisation conjointe de modèle de Markov caché et d'observateur*. Thèse de doctorat. Université d'Orléans. (2016).
- [Aghaei et al. 2022] Aghaei, M., FAIRBROTHER, A., GOK, A., et al. *Review of degradation and failure phenomena in photovoltaic modules*. Renewable and Sustainable Energy Reviews, 2022, vol. 159, p. 112160.
- [Ahmad et al. 2021] Ahmad, Tanveer, Zhang, Dongdong, Huang, Chao, et al. *Artificial intelligence in sustainable energy industry : Status Quo, challenges and opportunities*. Journal of Cleaner Production, vol. 289, p. 125834. (2021).
- [Akhsassi et al. 2016] Akhsassi, M., El Fathi, A., Erraissi, N., et al. *Confrontation à l'expérience de divers modèles du comportement thermique de modules solaires photovoltaïques*. 4ème Congrès de l'Association Marocaine Therm, p. 1-7. (2016).
- [Atsu et al. 2020] Atsu, Divine, Seres, Istvan, Aghaei, Mohammadreza, et al. *Analysis of long-term performance and reliability of PV modules under tropical climatic conditions in sub-Saharan*. Renewable Energy, vol. 162, p. 285-295. (2020).
- [Aziz et al. 2018] Aziz, Shujahadeen B., Woo, Thompson J., Kadir, M. F. Z., et al. *A conceptual review on polymer electrolytes and ion transport models*. Journal of Science : Advanced Materials and Devices, vol. 3, no 1, p. 1-17. (2018).
- [Azizi 2018] Azizi, Amina, et al. *"Impact of the aging of a photovoltaic module on the performance of a grid-connected system."* Solar Energy 174 (2018) : 445-454. (2018)
- [Babakhouya 2010] Babakhouya, Abdelaziz, et al. *Securing Distance Vector Routing Protocols for Hybrid Wireless Mesh Networks*. CERIST, 2010.

- [Baouche et al. 2022] Baouche, Fatima Zohra, Abderzzak, Bilal, Ladmi, Abdennour, et al. *Design and Simulation of a Solar Tracking System for PV*. Applied Sciences, vol. 12, no 19, p. 9682. (2022).
- [Barr et al. 1981] Barr, Avron, Feigenbaum, Edward A., et Cohen, Paul R. *The handbook of artificial intelligence*. (ed.) HeurisTech Press, 1981.
- [Basseville et al. 1993] Basseville, Michele, NIKIFOROV, Igor V., et al. *Detection of abrupt changes : theory and application*. Englewood Cliffs : prentice Hall, (1993).
- [Batteux 2011] Batteux, Michel. *Diagnosticabilité et diagnostic de systèmes technologiques pilotes*. Thèse de doctorat. Université Paris Sud-Paris XI. (2011).
- [Bekkari et al. 2019] Bekkari, Naceureddine, and Aziez Zeddouri. *Using artificial neural network for predicting and controlling the effluent chemical oxygen demand in wastewater treatment plant*. Management of Environmental Quality : An International Journal 30.3 (2019) : 593-608.
- [Belaout 2018] Belaout, Abdesslam. *Etude et diagnostic des défauts fréquents aux systèmes photovoltaïques (PV) par emploi de la caractéristique courant-tension*. Thèse de doctorat. (2018).
- [Bessam 2016] Bessam, Bisma. *Analyse et détection des défauts dans la machine asynchrone à base des techniques intelligentes*. Thèse de doctorat. Université Mohamed Khider-Biskra. (2016).
- [Bey et al. 2019] Bey, Abdelkader Baghdad, Talbi, Abbassia, Hebali, Mourad, et al. *Numerical Study of the Impact of Junction Depth and the Surface Recombination Velocity on Electrical Parameters of GaAs-Solar Cell*. International journal of advanced Science and Engineering, vol. 5, no 3, p. 1064-1071. (2019).
- [Bhattacharya et al. 2017] M. Bhattacharya, S. Saha, D. Khan, T. Nag, *Wavelet based component fault detection in diode clamped multilevel inverter using probabilistic neural network*. in : 2017 2nd Int. Conf. Converg. Technol. I2CT 2017 2017-Janua, 2017, pp. 1163–1168, <https://doi.org/10.1109/I2CT.2017.8226310>. (2017).
- [Bishop 1988] Bishop, J. *Computer Simulation of the Effects of Electrical Mismatches in Photovoltaic Cell Interconnection Circuits*. Solar Cells, 25 : 7389 (1988).
- [Bishop 1995] Bishop, Christopher M. *Neural networks for pattern recognition*. Oxford university press (1995).
- [Bosman et al. 2020] Bosman, Lisa B., Leon-Salas, Walter D., Hutzel, William, et al. *PV system predictive maintenance : Challenges, current approaches, and opportunities*. Energies, vol. 13, no 6, p. 1398. (2020).
- [Boukhers 2017] Boukhers, Djamil, and A. Bouzid. *"Optimisation d'un système d'énergie photovoltaïque. Application au pompage"*. (2017).
- [Bradley 1997] A.P. Bradley *The use of the area under the ROC curve in the evaluation of machine learning algorithms*. Pattern Recognition Letters, 30(7) :1145–1159, (1997).
- [Brooks 2015] Brooks W. *Field guide for testing existing photovoltaic systems for ground faults and installing equipment to mitigate fire hazards*. FNREL National Renewable Energy Laboratory (NREL). (2015).

- [Brous et al. 2020] Brous, Paul, Marijn Janssen, and Paulien Herder. "The dual effects of the Internet of Things (IoT) : A systematic review of the benefits and risks of IoT adoption by organizations." *International Journal of Information Management* 51 (2020) : 101952.
- [Bun 2011 a.] L. Bun. *Détection et localisation de défauts pour un système PV*. Thèse de doctorat, Université de Grenoble, France (2011).
- [Bun et al. 2011 b.] L. Bun, B. Raison, G. Rostaing, S. Bacha, A. Rumeau, A. Labonne. "Development of a Real Time Photovoltaic Simulator in Normal and Abnormal Operations". IECON 2011-37th Annual Conference on IEEE Industrial Electronics Society. November (2011).
- [Ceban 2012] Ceban, Andrian. *Méthode globale de diagnostic des machines électriques*. Thèse de doctorat. Artois, (2012).
- [Chakour et al. 2016] Chakour, Nora, and Amrane Hadda. *Contribution à l'étude du Management du risque au niveau des industries des eaux embouteillées cas «Unité Lalla Khedidja»*. Université Mouloud Mammeri, (2016).
- [Chao et al. 2010] K. Chao, C. Chen, M. Wang, C. Wu. *Novel Fault Diagnosis Method Based-on Modified Neural Networks for Photovoltaic Systems* ICSI 2010, Part II, LNCS 6146, pp. 531–539. © Springer-Verlag Berlin Heidelberg. (2010).
- [Charaf et al. 2019] Charaf eddine Amine, Benaouag, and Rahmani Mounir. *Les barrières au développement des énergies renouvelables en Algérie Barriers to the development of renewable energies in Algeria*. *Revue Stratégie et développement* Volume 9.03 (2019) : 261-273. (2019).
- [Chebira 2021] S. Chebira. *Diagnostic et évaluation du risque incendie par la démarche RNA - Analyse statistique : cas de l'industrie Algérienne*. Thèse de doctorat. Université de Batna 2, Algérie. (2021).
- [Chen et al. 2016] Chen, Z. Zhang, K. Ding, S. X. *Improved canonical correlation analysis-based fault detection methods for industrial processes*. In *Journal of Process Control* 41 : 26–34. (2016).
- [Chine et al. 2016] Chine W, Mellit A, Lughi V, Malek A, Sulligoi G, Pavan AM. *A novel fault diagnosis technique for photovoltaic systems based on artificial neural networks*. *Renew Energy* 90 :501–12. (2016).
- [Chowdhury et al. 2017] D. Chowdhury, M. Bhattacharya, D. Khan, S. Saha, A. Dasgupta, *Wavelet decomposition based fault detection in cascaded H-bridge multilevel inverter using artificial neural network*. in : RTEICT 2017 - 2nd IEEE Int. Conf. Recent Trends Electron. Inf. Commun. Technol. Proc. 2018-Janua, pp. 1931–1935, <https://doi.org/10.1109/RTEICT.2017.8256934>. (2017).
- [Compaoré et al. 2021 a.] Compaoré, O. W. Hoblos, G. and Koalaga, Z. *Analysis of the impact of faults in a photovoltaic generator*. *International Conference on Innovation and Intelligence for Informatics, Computing, and Technologies (3ICT)*, 2021, pp. 68-73, [doi: 10.1109/3ICT53449.2021.9581575](https://doi.org/10.1109/3ICT53449.2021.9581575). (2021).
- [Compaoré et al. 2021 b.] Compaoré, O. W. Hoblos, G. and Koalaga, Z. *Artificial Neural Network based fault diagnosis in an isolated photovoltaic generator*. In *4th Conf EAI. JRI 2021*. <https://doi.org/10.4108/eai.11-11-2021.2317977>. (2021).

- [Compaoré et al. 2022 a.] Compaoré, O.W., Hoblos, G., Koalaga, Z. *Analysis of the Complementarity of Two Diagnostic Methods on a PV Generator*. JRI 2022. Ouagadougou. Burkina Faso. doi.org/10.4108/eai.24-11-2022.2329810. (2022).
- [Compaoré et al. 2022 b.] Compaoré, O.W., Koalaga, Z., Hoblos, G. "Instrumentation of real-time acquisition system for diagnosis in a photovoltaic generator." IEEE Multi-conference on Natural and Engineering Sciences for Sahel's Sustainable Development (MNE3SD). IEEE, 2022. DOI : [10.1109/MNE3SD53781.2022.9723255](https://doi.org/10.1109/MNE3SD53781.2022.9723255). (2022).
- [Compaoré et al. 2023 a.] Compaoré, O.W., Hoblos, G., Koalaga, Z. *Sensor Fault Analysis of an Isolated Photovoltaic Generator*. In : Kowalczyk, Z. (eds) Intelligent and Safe Computer Systems in Control and Diagnostics. DPS 2022. Lecture Notes in Networks and Systems, vol 545. Springer, Cham. https://doi.org/10.1007/978-3-031-16159-9_23. (2023).
- [Compaoré et al. 2023 b.] Compaoré, O.W., Hoblos, G., Koalaga, Z. "Performance analysis by the ROC curve following the application of the FDI on a PVG" 2023 IEEE Multi-conference on Natural and Engineering Sciences for Sahel's Sustainable Development (MNE3SD). 23-25 February 2023. Bobo-Dioulasso, Burkina Faso. DOI : [10.1109/MNE3SD57078.2023.10079773](https://doi.org/10.1109/MNE3SD57078.2023.10079773). (2023).
- [Cui et al. 2019] Cui, S. & Sun, L. *Sensor fault detection and isolation of electromechanical actuator based on structural residual parity space*. The Proceedings of the 2018 Asia-Pacific International Symposium on Aerospace Technology (APISAT 2018), pp. 2574-2585. (2019).
- [Da Silva et al. 2018] Da Silva, Paula Renatha Nunes, GABBAR, Hossam A., JUNIOR, Petrônio Vieira, et al. *A new methodology for multiple incipient fault diagnosis in transmission lines using QTA and Naïve Bayes classifier*. International journal of electrical power & energy systems, vol. 103, p. 326-346. (2018).
- [Dhass et al. 2022] Dhass, A. D., Beemkumar, N., Harikrishan, S., et al. *A review on factors influencing the mismatch losses in solar photovoltaic system*. International Journal of Photoenergy, 2022, vol. p. 1-27. (2022).
- [Dhimish 2018] M. Dhimish. "Fault Detection and Performance Analysis of Photovoltaic Installations." University of Huddersfield Thesis. (2018).
- [Dhoke et al. 2018] Dhoke, Amit, Sharma, Rahul, et Saha, Tapan Kumar. *PV module degradation analysis and impact on settings of overcurrent protection devices*. Solar Energy, vol. 160, p. 360-367. (2018).
- [Dhumale et al. 2016] R.B. Dhumale, S.D. Lokhande. *Neural network fault diagnosis of voltage source inverter under variable load conditions at different frequencies*. Meas. J. Int. Meas. Confed. 91 565–575, <https://doi.org/10.1016/j.measurement.2016.04.051>. (2016).
- [Dilmi 2022] Dilmi, Imene, and Souaad Dilmi. *Conception d'un outil de diagnostic pour installation photovoltaïque*. Diss. University of M'sila, 2022.
- [Ding 2008] Ding, Steven X. *Model-based fault diagnosis techniques : design schemes, algorithms, and tools*. Springer Science & Business Media, (2008).
- [Djeziri et al. 2022] DJEZIRI, Mohand A., BENMOUSSA, Samir, SANSHEZ, R. Tapia, et al. *Solar cell modeling in normal and degraded operations for simulation and monitoring*. Sustainable Energy Technologies and Assessments, 2022, vol. 51, p. 101990. (2022).

- [Doumane 2011] R. Doumane. *Modélisation du Vieillissement d'un Module Photovoltaïque*. Thèse de Doctorat, Université M'hamed Bougara Boumerdes Algérie (2011).
- [Fadhel et al. 2016] Fadhel, Siwar, Trablesi, Mohamed, Bahri, Imen, et al. *Faults effects analysis in a photovoltaic array based on current-voltage and power-voltage characteristics*. In : 2016 17th International Conference on Sciences and Techniques of Automatic Control and Computer Engineering (STA). IEEE, p. 223-228. (2016).
- [Fagroud 2021] Fagroud, Fatima Zahra. *"Vers un Feu Tricolore Intelligent basé sur l'Internet des objets et le traitement d'images."* Colloque sur les Objets et systèmes Connectés-COC'2021. 2021.
- [Falvo et al. 2015] Falvo MC, Capparella S. *Safety issues in PV systems : design choices for a secure fault detection and for preventing fire risk*. Case Stud Fire Saf 3 :1–16. (2015).
- [Fang et al 2018] Fang, Jingyang, LI, Hongchang, TANG, Yi, et al. *On the inertia of future more-electronics power systems*. IEEE Journal of Emerging and Selected Topics in Power Electronics, vol. 7, no 4, p. 2130-2146. (2018).
- [Fatama et al. 2020] A.Z. Fatama, M.A. Khan, V.S.B. Kurukuru, A. Haque, F. Blaabjerg. *Co-ordinated reactive power strategy using static synchronous compensator for photovoltaic inverters*. Int. Trans. Electr. Energy Syst. 30 (6) (2020) 1–18, <https://doi.org/10.1002/2050-7038.12393>. (2020).
- [Fernández-Solas et al. 2021] Fernández-Solas, Álvaro, Micheli, Leonardo, Almonacid, Florencia, et al. *Optical degradation impact on the spectral performance of photovoltaic technology*. Renewable and Sustainable Energy Reviews, vol. 141, p. 110782. (2021).
- [Fiorentini et al. 2016] Fiorentini L, Danzi E, Puccia V. *Fires in Photovoltaic Systems : Lessons Learned from Fire Investigations in Italy*. sessed May). (2016).
- [Fouad et al. 2017] Fouad, M. M., Shihata, Lamia A., et Morgan, ElSayed I. *An integrated review of factors influencing the performance of photovoltaic panels*. Renewable and Sustainable Energy Reviews, vol. 80, p. 1499-1511. (2017).
- [Frini et al. 2019] Frini Marouane, Soualhi Abdenour, et EL Badaoui Mohamed. *Gear faults diagnosis based on the geometric indicators of electrical signals in three-phase induction motors.*, Mechanism and Machine Theory, vol. 138, p. 1-15. (2019).
- [Gandhi et al. 2020] Gandhi, Oktoviano, et al. *"Review of power system impacts at high PV penetration Part I : Factors limiting PV penetration."* Solar Energy 210 : 181-201. (2020).
- [Gao et al. 2015] Gao, Zhiwei, Carlo Cecati, and Steven X. Ding. *"A survey of fault diagnosis and fault-tolerant techniques—Part I : Fault diagnosis with model-based and signal-based approaches."* IEEE transactions on industrial electronics 62.6 (2015) : 3757-3767. (2015)
- [Gertler 1998] Gertler, Janos. *Fault detection and diagnosis in engineering systems*. CRC press, (1998).
- [Ghimire et al. 2013] Ghimire, Pramod, et al. *"A review on real time physical measurement techniques and their attempt to predict wear-out status of IGBT."* 2013 15th European Conference on Power Electronics and Applications (EPE). IEEE, 2013.
- [Ghorbanian et al. 2015] Ghorbanian, Vahid et Faiz, Jawad. *A survey on time and frequency characteristics of induction motors with broken rotor bars in line-start and inverter-fed modes*. Mechanical Systems and Signal Processing. vol. 54, p. 427-456. (2015).

- [Gorjian et al. 2021] Gorjian, Shiva, Sharron, H., Ebadi, Hossein, et al. *Recent technical advancements, economics and environmental impacts of floating photovoltaic solar energy conversion systems*. Journal of Cleaner Production, vol. 278, p. 124285. (2021).
- [Guezzaz et al. 2020] Guezzaz Azidine, et al. *A multilayer perceptron classifier for monitoring network traffic..* Big Data and Networks Technologies 3. Springer International Publishing, (2020).
- [Guillerm 2011] Guillerm, Romaric. 2011. *Intégration de la Sûreté de Fonctionnement dans les Processus d'Ingénierie Système*. Thèse de doctorat. Université de Toulouse.
- [Hacke et al. 2018] Hacke, Peter, et al. "A status review of photovoltaic power conversion equipment reliability, safety, and quality assurance protocols." Renewable and Sustainable Energy Reviews 82 (2018) : 1097-1112.
- [Hadji 2018] Hadji, Slimane. *Optimisation de la conversion énergétique pour les systèmes à énergie Photovoltaïque*. Thèse de doctorat. Université de Béjaïa-Abderrahmane Mira. (2018).
- [Hafaifa et al. 2015] Hafaifa, A., Guemana, M. & Daoudi, A. *Vibrations supervision in gas turbine based on parity space approach to increasing efficiency*. Journal of Vibration and Control, 21(8), pp.1622-1632. (2015).
- [Haithem 2009] Haithem Derbel. *Diagnostic à base de modèles des systèmes temporisés et d'une sous-classe de systèmes dynamiques hybrides*. Thèse de doctorat. Université Joseph-Fourier-Grenoble I. (2009).
- [Han et al. 2018] Han, Weixin, Wang, Zhenhua, et Shen, Yi. *Fault estimation for a quadrotor unmanned aerial vehicle by integrating the parity space approach with recursive least squares*. Proceedings of the Institution of Mechanical Engineers, Part G : Journal of Aerospace Engineering, vol. 232, no 4, p. 783-796. (2018).
- [Haque et al. 2019] Haque A, Bharath KVS, Kahan MA, Khan I, Jaffery ZA, *Fault diagnosis of photovoltaic modules*. Energy Sci. Eng. 2019 ;7 ;622-644. <https://doi.org/10.1002/ese3.255>
- [Hatem et al. 2019] Hatem, Bellahcene, and Noura Rezika. *Aide au diagnostic des systèmes dynamiques hybrides*. Thèse de doctorat, Université de Béjaïa, Algérie. (2019).
- [Hemetsberger 2023] Hemetsberger. M. Schmela. *Mobilising Investments in Emerging Markets Picture Global Market Outlook for Solar Power / 2019 – 2023*. www.wolarpowereurope.org
- [Hernandez 2007] Hector Ricardo Hernandez de Leon. *Supervision et diagnostic des procédés de production d'eau potable*. Automatique / Robotique. INSA de Toulouse. Français. NNT : tel-00136157. (2007).
- [Hoblos 2008] Hoblos G. *Diagnostic et surveillance des systèmes complexes*. HDR, Université de Rouen, 2008.
- [Hotait 2020] Hotait, Hassane. *Contribution au processus de surveillance intelligente des machines tournantes : cas des roulements à billes*. Thèse de doctorat de l'université de HOTAIT, Hassane. Contribution au processus de surveillance intelligente des machines tournantes : cas des roulements à billes. Thèse de doctorat de l'Université de Reims (2020).
- [Hu et al. 2020] Hu, Xiaosong, et al. "Advanced fault diagnosis for lithium-ion battery systems : A review of fault mechanisms, fault features, and diagnosis procedures." IEEE Industrial Electronics Magazine 14.3 : 65-91. (2020).

- [Hu et al. 2021] Hu, Jiefeng, Shan, Yinghao, Guerrero, Josep M., et al. *Model predictive control of microgrids—An overview*. Renewable and Sustainable Energy Reviews, vol. 136, p. 110422. (2021).
- [Hua et al. 1998] C. C. Hua and C. M. Shen, “*Study of maximum power tracking techniques and control of dc-dc converters for photovoltaic power system,*” in Proceedings of 29th annual IEEE Power Electronics Specialists Conference, vol. 1, pp. 86-93, (1998).
- [Idrighuen et al. 2018] Idrighuen, Sonia et Bahloul, Wissam. *Réalisation d’un Système de Reconnaissance Biométrique Multimodal*. Thèse de doctorat. Université Akli Mouhand Oulhadj-Bouira. (2018).
- [Jahn et al. 2020] Jahn, Benjamin, Brüchner, Michael, Gerber, Stanislav, et al. *Sensor fault detection for salient pmsm based on parity-space residual generation and robust exact differentiation*. IFAC-PapersOnLine, vol. 53, no 2, p. 86-91. (2020).
- [Jain et al. 2019] Jain, Palak, POON, Jason, SINGH, Jai Prakash, et al. *A digital twin approach for fault diagnosis in distributed photovoltaic systems*. IEEE Transactions on Power Electronics, 2019, vol. 35, no 1, p. 940-956. (2019).
- [Jamil 2023] Jamil, Irfan, et al. “*Performance evaluation of solar power plants for excess energy based on energy production.*” Energy Reports 9 (2023) : 1501-1534. (2023).
- [Jia et al. 2019] Jia Liu, Xi Chen, Sunliang Cao, Hongxing Yang. “*Overview on hybrid solar photovoltaic-electrical energy storage technologies for power supply to buildings,*” in Energy Conversion and Management. Vol. 187, Pages 103-121, (1 May 2019).
- [Joshi et al. 2017] Joshi, Puneet et Arora, Sudha. *Maximum power point tracking methodologies for solar PV systems—A review*. Renewable and Sustainable Energy Reviews, vol. 70, p. 1154-1177. (2017).
- [Jurasz et al. 2020] J. Jurasz, A. Kies, P. Zajac. *Synergetic operation of photovoltaic and hydro power stations on a day-ahead energy market*. Energy 212 118686. (2020)
- [Kaplan et al. 2017] Kaplan, Elliott D. et Hegarty, Christopher. *Understanding GPS/GNSS : principles and applications*. (ed.) Artech house. (2017).
- [Karoui 2011] Karoui Mohamed. *Surveillance des processus dynamiques événementiels*. Thèse de doctorat. Grenoble. (2011).
- [Kazem et al. 2020] Kazem, Hussein A., Chaichan, Miqdam T., Al-Waeli, Ali Ha, et al. *A review of dust accumulation and cleaning methods for solar photovoltaic systems*. Journal of Cleaner Production, vol. 276, p.123187. (2020).
- [Kenny et al. 2006] Kenny R.P., Dunlop E.D., Ossenbrink H.A., Mullejans H. “*A practical method for the energy rating of c-Si photovoltaic modules based on standard tests*”. Progress in Photovoltaics : Research and Applications 14 (2), 155–166, (2006).
- [Kim et al. 2021] Kim, Jaeun, Rabelo, Matheus, Padi, Siva Parvathi, et al. *A review of the degradation of photovoltaic modules for life expectancy*. Energies, vol. 14, no 14, p. 4278. (2021).
- [Khomfoi et al. 2007] S. Khomfoi, L.M. Tolbert, *Fault diagnostic system for a multilevel inverter using a neural network*. IEEE Trans. Power Electron. 22 (3) (2007) 1062–1069, <https://doi.org/10.1109/TPEL.2007.897128>. (2007).

- [Koester et al. 2022] Koester, L., et al. "Review of photovoltaic module degradation, field inspection techniques and techno-economic assessment." *Renewable and Sustainable Energy Reviews* 165 (2022) : 112616.
- [Kortbi et al. 2019] Ben Kortbi, Fatma Zohra, and Amel Abbadi. "Suivi des défauts de roulement par des techniques de l'intelligence artificielle". Université Yahia Farès de Médéa Algérie (2019).
- [Kumar et al. 2022] Kumar, Rahul R., Andriollo, Mauro, Cirrincione, Giansalvo, et al. *A Comprehensive Review of Conventional and Intelligence-Based Approaches for the Fault Diagnosis and Condition Monitoring of Induction Motors*. *Energies*, vol. 15, no 23, p. 8938. (2022).
- [li et al. 2018] G. Li, Yi Jin, M.W. Akram, Xiao Chen, J. J. *Application of bio-inspired algorithms in maximum power point tracking for PV systems under partial shading conditions – A review*. *Renewable and Sustainable Energy Reviews* 81 840–873. (2018).
- [Luo et al. 2017] Luo, Wei, Khoo, Yong Sheng, Hacke, Peter, et al. *Potential-induced degradation in photovoltaic modules : a critical review*. *Energy & Environmental Science*, vol. 10, no 1, p. 43-68. (2017).
- [Maamar et al. 2018] A.E. T. Maamar, S. Ladjouzi, R. Taleb and Y. Kacemi. *Détection et classification de défauts pour un GPV : Etude comparative entre la méthode de seuillage et réseaux de neurones*. *Revue des Energies Renouvelables* Vol.21 N°1 45-53(2018).
- [Maamar et al. 2019] A.E. T. Maamar, S. Ladjouzi, R. Taleb and Y. Kacemi. *Detection and classification of faults in a photovoltaic system using the neuronal approach* ISSN 2676-248X (2019).
- [Madeti et al. 2017] Madeti, Siva Ramakrishna et SINGH, S. N. *A comprehensive study on different types of faults and detection techniques for solar photovoltaic system*. *Solar Energy*, vol. 158, p. 161-185. (2017).
- [Malik et al. 2021] A. Malik and A. H. V. S. Bharath Kurukuru. *Deep learning based fault diagnostic technique for grid connected inverter*. pp. 1390–1395, 2021.
- [Malik et al. 2022] Malik, Azra, et al. "Overview of Fault Detection Approaches for Grid Connected Photovoltaic Inverters." *e-Prime-Advances in Electrical Engineering, Electronics and Energy* (2022) : 100035.
- [Mansouri 2021] Mansouri, M. Trabelsi, M. Nounou, H. and Nounou, M. *Deep Learning-Based Fault Diag-nosis of Photovoltaic Systems : A Comprehensive Review and Enhancement Prospects*. *IEEE Access*. DOI10.1109/ACCESS.2021.3110947. Volume 9 (2021).
- [Maquin et al. 2000] Maquin Didier et Ragot José. *Diagnostic des systèmes linéaires* Paris, Hermès Science Publications. ISBN 2-7462-0133-X. (2002).
- [Martín-Chivelet et al. 2022] Martín-Chivelet, Nuria, Kapsis, Konstantinos, Wilson, Helen Rose, et al. *Building-Integrated Photovoltaic (BIPV) products and systems : A review of energy-related behavior*. *Energy and Buildings*, p. 111998. (2022).
- [Md Nor et al. 2020] Md Nor, Norazwan, Che Rosmani Che Hassan, and Mohd Azlan Hussain. "A review of data-driven fault detection and diagnosis methods : Applications in chemical process systems." *Reviews in Chemical Engineering* 36.4 : 513-553. (2020).

- [Mellit et al. 2009] Mellit, Adel, Kalogirou, Soteris a., Hontoria, Leocadio, et al. *Artificial intelligence techniques for sizing photovoltaic systems : A review*. Renewable and Sustainable Energy Reviews, vol. 13, no 2, p. 406-419. (2009).
- [Mellit et al. 2018] Mellit, Adel, Tina, Giuseppe Marco, et Kalogirou, Soteris A. *Fault detection and diagnosis methods for photovoltaic systems : A review*. Renewable and Sustainable Energy Reviews, 91(), 1–17. <http://doi:10.1016/j.rser.2018.03.062>. (2018).
- [Mendil 2018] Mendil, Abderraouf. *Développement de modèles mathématiques d'aide au diagnostic des systèmes photovoltaïques*. Thèse de doctorat de l'Université Mohamed Boudiaf-M'sila, 2018.
- [Migan-Dubois et al. 2019] Migan-Dubois Anne, Claude Delpha and Demba Diallo. *"New four-stage classification method for Fault Detection and Diagnosis applied to photovoltaic power plants."*, European Photovoltaic Solar Energy Conference and Exhibition (EU PVSEC 2019). (2019).
- [Munoz et al. 2011] Munoz, M. A., Alonso-Garcia, M. Carmen, Vela, Nieves, et al. *Early degradation of silicon PV modules and guaranty conditions*. Solar energy, vol. 85, no 9, p. 2264-2274. (2011).
- [Mustapha et al. 2008] Oussama, MUSTAPHA, KHALIL, Mohamad, HOBLOS, Ghaleb, et al. *Fault Detection by Means of DCS Algorithm Combined with Filters Bank-Application to the Tennessee Eastman Challenge Process*. In : International Conference on Informatics in Control, Automation and Robotics. SCITEPRESS, 2008. p. 102-107
- [Ndiaye 2013] A. Ndiaye. *Étude de la dégradation et de la fiabilité des modules photovoltaïques – Impact de la poussière sur les caractéristiques électriques de performance*. Sciences de l'ingénieur [physics]. Ecole Supérieure Polytechnique (ESP) - UCAD, (2013).
- [Nguyen et al. 2019] Nguyen, Anh-Tu, Taniguchi, Tadanari, Eciolaza, Luka, et al. *Fuzzy control systems : Past, present and future*. IEEE Computational Intelligence Magazine, vol. 14, no 1, p. 56-68. (2019).
- [Oh et al. 2015] H. Oh, B. Han, P. McCluskey, C. Han, B.D. Youn. *Physics-of-failure, condition monitoring, and prognostics of insulated gate bipolar transistor modules : A review*. IEEE Trans. Power Electron. 30 (5) (2015) 2413–2426, <https://doi.org/10.1109/TPEL.2014.2346485>. (2015).
- [Oztemel 2020] Oztemel, Ercan, and Samet Gursev. *"Literature review of Industry 4.0 and related technologies."* Journal of intelligent manufacturing 31 (2020) : 127-182. (2020).
- [Pachauri et al. 2020] Pachauri, Rupendra Kumar, Mahela, Om Prakash, Sharma, Abhishek, et al. *Impact of partial shading on various PV array configurations and different modeling approaches : A comprehensive review*. IEEE Access, vol. 8, p. 181375-181403. (2020).
- [Pantic et al. 2016] Pantic, Lana S., Pavlovic, Tomislav M., Milosavljevic, Dragana D., et al. *The assessment of different models to predict solar module temperature, output power and efficiency for Nis, Serbia*. Energy, vol. 109, p. 38-48. (2016).
- [Papageorgas et al. 2013] Papageorgas, P., Piromalis, D., Antonakoglou, K., et al. *Smart solar panels : In-situ monitoring of photovoltaic panels based on wired and wireless sensor networks*. Energy Procedia, vol. 36, p. 535-545. (2013).

- [Parizad et al. 2018] Parizad, Ali, Mohamadian, Sobhan, Iranian, Mohamad Esmail, et al. *Power system real time emulation : a practical virtual instrumentation to complete electric power system modeling*. IEEE Transactions on Industrial Informatics, vol. 15, no 2, p. 889-900. (2018).
- [Park et al. 2020] Park, You-Jin, Fan, Shu-Kai S., et Hsu, Chia-Yu *A review on fault detection and process diagnostics in industrial processes*. Processes, vol. 8, no 9, p. 1123. (2020).
- [Patan 2008] Patan, Krzysztof. *Artificial neural networks for the modelling and fault diagnosis of technical processes*. Springer, (2008).
- [Peng et al. 2018] Peng, Zhao, Chen, Liangkai, Zhu, Yalun, et al. *Current major degradation methods for aflatoxins : A review*. Trends in food science & technology, vol. 80, p. 155-166. (2018).
- [Poon et al. 2017] J. Poon, P. Jain, I.C. Konstantakopoulos, C. Spanos, S.K. Panda, S.R. Sanders. *Model-based fault detection and identification for switching power converters*. IEEE Trans. Power Electron. 32 (2) (2017) 1419–1430, <https://doi.org/10.1109/TPEL.2016.2541342>. (2017).
- [Quaschnig 2016] Quaschnig, Volker. *Understanding renewable energy systems*. Routledge, (2016). <https://doi.org/10.4324/9781315800493>
- [Ranavolo et al. 2018] Ranavolo, Alberto, Draicchio, Francesco, Varrecchia, Tiwana, et al. *Wearable monitoring devices for biomechanical risk assessment at work : Current status and future challenges—A systematic review*. International journal of environmental research and public health, 2018, vol. 15, no 9, p. (2018).
- [Realini 2003] Realini A. *Mean Time before Failure of Photovoltaic Modules*. Final Report (MTBF Project), Federal Office for Education and Science Tech. Rep., BBW 99.0579, (2003).
- [Rezgui et al 2014 a.] Wail Rezgui, Leïla-Hayet Mouss, Kinza Nadia Mouss, Mohamed Djamel Mouss, Yassine Amirat and Mohamed Benbouzid. *Electrical faults modeling of the photovoltaic generator*. International Review on Modelling and Simulations, 7 (2), pp.245-257. Hal-01017387. (2014).
- [Rezgui et al. 2014 b.] W. Rezgui, N. K. Mouss, L. H. Mouss, M. D. Mouss, Y. Amirat, M. Benbouzid, “*Development of a New Methodology for Modeling the PV Generator Behavior in the Presence of Open-Circuit and Short-Circuit Faults.*” In IEEE EFEA, Nov 2014, Paris, France. (2014).
- [Ribot 2009] Ribot, Pauline. *Vers l’intégration diagnostic/pronostic pour la maintenance des systèmes complexes*. Thèse de doctorat. Université Paul Sabatier-Toulouse III. (2009).
- [Ringkjøb et al. 2018] Ringkjøb, Hans-Kristian, Haugan, Peter M., et Solbrekke, Ida Marie. *A review of modelling tools for energy and electricity systems with large shares of variable renewables*. Renewable and Sustainable Energy Reviews, vol. 96, p. 440-459. (2018).
- [Rohit 2017] A. K. Rohit et al. “*Virtual lab based real-time data acquisition, measurement and monitoring platform for solar photovoltaic module.*” In : Resource-Efficient Technologies, 3(4) (Apr. 2017), pp. 446–451.

- [Sallami et al. 2016] Sallami, Abderrahmène, Zangouri, Nadia, et Ksouri, Mekki. *Robust diagnosis of a DC motor by bond graph approach*. Am. J. Eng. Applied Sci, vol. 9, p. 432-438. (2016).
- [Sebbane et al. 2022] Sebbane, Saliha, Ncir, Noamane, et El Akchioui, Nabil. *Diagnosis and classification of photovoltaic panel defects based on a hybrid intelligent method*. In : The Proceedings of the International Conference on Electrical Systems & Automation : Recent Advances in Renewable Energy—Volume 1. Singapore : Springer Singapore, p. 59-69. (2022).
- [Seguy 2008] Seguy Anne. *Décision collaborative dans les systèmes distribués-Application à la E-Maintenance*. Thèse de doctorat. Institut National Polytechnique de Toulouse-INPT. (2008).
- [Sharaf et al. 2015] Sharaf, Omar Z. et Orhan, Mehmet F. *Concentrated photovoltaic thermal (CPVT) solar collector systems : Part I-Fundamentals, design considerations and current technologies*. Renewable and Sustainable Energy Reviews, vol. 50, p. 1500-1565. (2015).
- [Shukla et al. 2015] A. Shukla, M. Khare, K. N. Shukla. "Modeling and Simulation of Solar PV Module on MATLAB/Simulink." In International Journal of Innovative Research in Science, Engineering and Technology. (An ISO 3297 : 2007) Vol. 4, Issue 1, (January 2015).
- [Singh et al. 2015] Singh, Pulkit, Palwalia, D. K., Gupta, Amit, et al. *Comparison of photovoltaic array maximum power point tracking techniques*. Int. Adv. Res. J. Sci. Eng. Technol, vol. 2, no 1, p. 401-404. (2015).
- [Singh et al. 2016] Singh, Amresh Kumar, Hussain, Ikhlâq, et Singh, Bhim. *An improved P&O MPPT algorithm for single stage three-phase grid integrated solar PV system*. In : IEEE 7th power India international conference (PIICON). IEEE, 2016. p. 1-6. (2016).
- [Soleimani et al. 2021] Soleimani, Morteza, Campean, Felician, et Neangu, Daniel. *Diagnostics and prognostics for complex systems : a review of methods and challenges*. Quality and Reliability Engineering International, vol. 37, no 8, p. 3746-3778. (2021).
- [Tahiri 2020] Tahiri, Imane, Parant, Alexandre, GELLOTT, François. *Design and Application of a Reconfigurable Control to a Cyber-Physical System*. In : ICINCO. p. 718-725. (2020).
- [Tahmi et al. 2022] Tahmi, Faris, Oulad Hadjou, Hammou, et al. *Dimensionnement d'un système de pompage d'eau photovoltaïque destiné à l'irrigation (Cas de la région de M'sila)*. Thèse de doctorat. University of M'sila. (2022).
- [Telidjane 2017] Telidjane, Mohammed. *Modélisation des panneaux photovoltaïques et adaptation de la cyclo stationnarité pour le diagnostic*. Thèse de doctorat. Université de Lyon. (2017).
- [Tidriri et al. 2016] Tidriri, Khaoula, CHATTI, Nizar, VERRON, Sylvain, et al. *Bridging data-driven and model-based approaches for process fault diagnosis and health monitoring : A review of researches and future challenges*. Annual Reviews in Control, vol. 42, p. 63-81. (2016).
- [Tidriri et al 2018] Tidriri, Khaoula, Tiplica, Teodor, Chatti, Nizar, et al. *A generic framework for decision fusion in fault detection and diagnosis*. Engineering Applications of Artificial Intelligence, vol. 71, p. 73-86. (2018).

- [Tina et al. 2016] Tina GM, Cosentino F, Ventura C. *Monitoring and diagnostics of photovoltaic power plants*. In : Sayigh A, editor. *Renewable Energy in the Service of Mankind, Vol II*. Cham : Springer ; p. 505–16. (2016).
- [Tsanakas et al. 2015] Tsanakas Ja, Vannier G, Plissonnier A, Ha L, Barruel F. *Fault diagnosis and classification of large-scale photovoltaic plants through aerial orthophoto thermal mapping*. In : *Proceedings of the 31st European photovoltaic solar energy conference and exhibition (EU PVSEC) Hamburg, Germany*. (2015).
- [Tzafestas 2018] Tzafestas, Spyros G. *Mobile robot control and navigation : A global overview*. *Journal of Intelligent and Robotic Systems* 91 (2018) : 35-58. (2018).
- [Vieira et al. 2020] Vieira, Romênia G., De Araujo, Fábio Mu, Dhimish, Mahmoud, et al. *A comprehensive review on bypass diode application on photovoltaic modules*. *Energies*, vol. 13, no 10, p. 2472. (2020).
- [Zarmai et al. 2015] Zarmai, Musa T., Ekere, N. N., Oduoza, C. F., et al. *A review of interconnection technologies for improved crystalline silicon solar cell photovoltaic module assembly*. *Applied energy*, 2015, vol. 154, p. 173-182. (2015).
- [Zeb et al. 2018] Zeb, Kamran, Uddin, Waqar, Khan, Muhammad Adil, et al. *A comprehensive review on inverter topologies and control strategies for grid connected photovoltaic system*. *Renewable and Sustainable Energy Reviews*, vol. 94, p. 1120-1141. (2018).
- [Zerdoudi et al. 2015] Zerdoudi, Assia et Chenni, Rachid. *Etude de l'influence des différents paramètres sur un module photovoltaïque*. *Sciences & Technology. A, exactes sciences*, p. 19-24. (2015).
- [Zhang et al. 2005] Zhang, Zhiyong, Jingang Liu, and Zhongzhi Shi. *"An improved relative criterion using BP algorithm."* *Advances in Neural Networks–ISNN 2005 : Second International Symposium on Neural Networks, Chongqing, China, May 30-June 1, 2005, Proceedings, Part I 2*. Springer Berlin Heidelberg, 2005.
- [Zhirabok et al. 2019] Zhirabok, D. A. N. Zuev, A. V. and Shumskii, A. E. *Diagnosis of Linear Systems Based on Sliding Mode Observers*. SSN 1064-2307, *Journal of Computer and Systems Sciences International*, Vol. 58, No. 6, pp. 898–914. (2019).
- [Zhong et al. 2015] Zhong, M., Song, Y. & Ding, S. X. *Parity space-based fault detection for linear discrete time-varying systems with unknown input*. *Automatica*, 59(1), pp. 120-126. (2015).
- [Zhonghai et al. 2018] Zhonghai, M., Shaoping, W., Jian, S., Tongyang, L. & Xingjian, W. *Fault diagnosis of an intelligent hydraulic pump based on a nonlinear unknown input observer*. *Chinese Journal of Aeronautics*, 31(2), pp. 385-394. (2018).
- [Zingbe et al. 2018] Zingbe, Epiphane, Agbomahena, Macaire Bienvenu, et Kounouhewa, Basile. *Etude de l'évolution de l'absorption du film organique P3HT-PCBM par caractérisation UV-visible*. Thèse de doctorat. (2018).
- [Zwingelstein 1995] G. Zwingelstein. *Failures diagnosis. Theory and practice for industrial systems ; Diagnostic des défaillances*. *Theorie et pratique pour les systemes industriels*. (1995).