



**HAL**  
open science

# Approches neuronales adaptatives pour le contrôle tolérant aux défauts de systèmes pile à combustible

Christophe Lin-Kwong-Chon

► **To cite this version:**

Christophe Lin-Kwong-Chon. Approches neuronales adaptatives pour le contrôle tolérant aux défauts de systèmes pile à combustible. Energie électrique. Université de la Réunion, 2020. Français. NNT : 2020LARE0008 . tel-02935101

**HAL Id: tel-02935101**

**<https://theses.hal.science/tel-02935101>**

Submitted on 10 Sep 2020

**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.



Université de La Réunion  
École doctorale "Sciences, Technologie et Santé" E.D. 542

THÈSE DE DOCTORAT  
PHYSIQUE ÉNERGÉTIQUE

*Présentée en vue de l'obtention du grade de :*

DOCTEUR EN ENERGETIQUE, GENIE DES PROCÉDES

*Spécialité : AUTOMATIQUE*

APPROCHES NEURONALES ADAPTATIVES POUR  
LE CONTRÔLE TOLÉRANT AUX DÉFAUTS DE SYSTÈMES  
PILE À COMBUSTIBLE

*Présentée par :*

CHRISTOPHE LIN-KWONG-CHON

*Soutenue le 10 juin 2020*

**Composition du jury :**

<b>Pr. Marie-Cécile Péra</b>	Université Bourgogne Franche-Comté	Rapporteur
<b>Pr. Rachid Outbib</b>	Université d'Aix-Marseille	Rapporteur / Président
<b>H.D.R. Nadia Yousfi Steiner</b>	Université Bourgogne Franche-Comté	Examinatrice
<b>Pr. Brigitte Grondin-Pérez</b>	Université de La Réunion	Directrice
<b>H.D.R. Jean-Jacques A. Kadjo</b>	Université de La Réunion	Codirecteur
<b>H.D.R. Cédric Damour</b>	Université de La Réunion	Encadrant
<b>Pr. Frédéric Cadet</b>	Université de La Réunion	Invité

**Contact**

Christophe LIN-KWONG-CHON

Pr. Brigitte GRONDIN-PEREZ

H.D.R. Jean-Jacques Amangoua KADJO

H.D.R. Cédric DAMOUR

[christophe.lin-kwong-chon@univ-reunion.fr](mailto:christophe.lin-kwong-chon@univ-reunion.fr)

[brigitte.grondin@univ-reunion.fr](mailto:brigitte.grondin@univ-reunion.fr)

[amangoua.kadjo@univ-reunion.fr](mailto:amangoua.kadjo@univ-reunion.fr)

[cedric.damour@univ-reunion.fr](mailto:cedric.damour@univ-reunion.fr)

**Adresse**

Laboratoire d'Énergétique, d'Électrique et  
Procédés - LE2P EA4079

15 Av. René Cassin, CS 92003

97744 Saint-Denis Cedex 9

École doctorale "Sciences, Technologies et  
Santé" - ED 541

15 av. René Cassin, CS 92003

97744 Saint-Denis Cedex 9

# Remerciements

Ce projet a bénéficié du soutien financier de la Région Réunion sous le numéro de convention direction de l'éducation *DIRED/20161446*, et de la Commission européenne sous le numéro de convention programme opérationnel fonds européen de développement régional *PO FEDER/2014-2020* - île de La Réunion - Fiche Action 1.06 "Améliorer les compétences au service de l'économie de la connaissance - allocations régionales de recherche" ARR *20170628-0013794*.

# Résumé

## APPROCHES NEURONALES ADAPTATIVES POUR LE CONTRÔLE TOLÉRANT AUX DEFAUTS DE SYSTÈMES PILE À COMBUSTIBLE

La pile à combustible à membrane échangeuse de protons est un convertisseur électrochimique prometteur pour la production électrique à partir du vecteur hydrogène décarboné. Toutefois, certains verrous technologiques limitent encore son déploiement, tels que sa durabilité, sa fiabilité ou son coût financier. La stratégie de contrôle tolérant aux défauts actif est une des solutions pour atténuer tout défaut suivant trois actions : un diagnostic, une décision et un contrôle. Cette étude propose d'élaborer un module contrôleur générique et adaptatif aux états de santé par le biais des réseaux de neurones. Le contrôleur par programmation dynamique, l'apprentissage par renforcement et les modèles à états échoïques sont combinés pour la construction du contrôleur adaptatif. Ce contrôleur emploie trois modèles neuronaux avec des rôles spécifiques : un acteur, un prévisionneur et un critique. Les défauts de noyage et d'assèchement de la membrane sont considérés dans cette étude.

Le contrôleur a pu démontrer des capacités intéressantes en simulation pour la régulation multi-variables de la stœchiométrie en oxygène, de la différence de pression à la membrane et de la température. Les résultats montrent des performances supérieures du contrôleur proposé face à un contrôleur proportionnel intégral dérivé. Des analyses de stabilité accompagnent l'étude et prouvent de la continuité du contrôleur adaptatif. Le contrôleur a été validé expérimentalement sur un banc d'essai avec une monocellule. La configuration du banc d'essai a imposé des contraintes propres à une application en ligne et en temps réel. Le caractère générique du contrôleur offre ici la possibilité de passer d'une configuration à l'autre sans devoir concevoir un autre contrôleur. Plusieurs tests sont effectués avec comme consigne la différence de pression nulle à la membrane. Le contrôleur a pu être validé sur l'apparition des défauts de noyage, d'assèchement de la membrane, y compris les perturbations en courant, les non-linéarités des actionneurs et de la purge en eau cathodique.

La démarche et le contrôleur générique adaptatif aux états de santé proposés dans cette thèse permettent de répondre à des besoins de régulation autour de la stratégie de contrôle tolérant aux défauts. Le premier intérêt réside dans la compensation des effets multilatéraux des défauts qui entraîne des modifications dynamiques non voulues. Un autre intérêt est de pouvoir modifier *in situ* les conditions opératoires de fonctionnement, les composants ou même les auxiliaires tout en étant capable d'assurer un contrôle stable et optimal.

---

MOTS-CLEFS : Pile à combustible, PEMFC, contrôle tolérant aux défauts, contrôleur adaptatif aux états de santé, programmation dynamique, apprentissage par renforcement, réseaux de neurones, temps réel et en ligne.

# Abstract

## ADAPTIVE NEURAL APPROACHES FOR FAULT-TOLERANT CONTROL OF FUEL CELL SYSTEMS

The proton exchange membrane fuel cell is a promising electrochemical converter for production of electricity from the decarbonated hydrogen carrier. However, some technological challenges limit its deployment, such as durability, reliability or financial cost. The active fault-tolerant control strategy is one of the solutions to mitigate any system fault according to three actions: diagnosis, decision and control. This study proposes to develop a generic controller module adaptive to health states through neural networks. Dynamic programming controller, reinforcement learning, and echo-state models are combined for the design of the adaptive controller. This controller employs three neural models with specific roles: an actor, a predictor and a critic. Flooding and membrane drying faults are considered in this study.

The proposed controller was able to demonstrate interesting capabilities on a simulation fuel cell model in multi-variable regulation for oxygen stoichiometry, membrane pressure difference and temperature. The results show superior performance of the proposed controller compared to a proportional integral derivative controller. Stability analyses were conducted to prove the continuity of the adaptive controller. The controller has been validated experimentally on a single cell test-bench. The configuration of the test-bench imposed constraints specific to an on-line and real-time application. The generic nature of the controller offers the possibility to switch from one configuration to another without having to design another controller. Several tests are carried out for regulation of the zero-pressure difference at the membrane. The controller was validated on the occurrence of flooding and membrane dryness faults, including actuator and water purging disturbances.

The approach and the generic controller adaptive to the states of health proposed in this thesis allow to satisfy control requirements regarding the fault-tolerant control strategy. The first interest lies in the compensation of the multilateral effects of faults that lead to unwanted dynamic changes. Another interest is to be able to modify *in situ* operating conditions, components or even auxiliaries while being able to ensure a stable and optimal control.

---

KEYWORDS : Fuel cell, PEMFC, fault-tolerant control, state-of-health adaptive controller, dynamic programming, reinforcement learning, neural networks, online and real-time.

# Table des matières

<b>Remerciements</b>	<b>i</b>
<b>Résumé</b>	<b>ii</b>
<b>Abstract</b>	<b>iii</b>
<b>Table des matières</b>	<b>iv</b>
<b>Table des figures</b>	<b>viii</b>
<b>Liste des tableaux</b>	<b>xii</b>
<b>Nomenclature</b>	<b>xiv</b>
<b>Introduction générale</b>	<b>1</b>
<b>1 Vers le contrôle adaptatif aux états de santé de la pile type PEMFC</b>	<b>5</b>
<b>1.1 Préambule général sur les piles à combustible</b>	<b>6</b>
1.1.1 Principe de fonctionnement électrochimique	6
1.1.2 Histoire et émergence de la pile à combustible	7
1.1.3 Différents types de piles à combustible	7
1.1.4 Pile à combustible à membrane échangeuse de protons	8
<b>1.2 Composants du système pile à combustible type PEMFC</b>	<b>9</b>
1.2.1 Cœur de pile	10
1.2.2 Actionneurs et capteurs	13
<b>1.3 Défauts du système pile à combustible type PEMFC</b>	<b>17</b>
1.3.1 Dynamiques des défauts	17
1.3.2 Conditions de défauts du système	17
1.3.3 Les conséquences des défauts du système	19
1.3.4 Perturbations de fonctionnements du défaut	19
<b>1.4 Stratégie de contrôle tolérant aux défauts actif</b>	<b>22</b>
1.4.1 Diagnostic du défaut	23
1.4.2 Prise de décision	23
1.4.3 Contrôle du système	24
<b>1.5 Positionnement de l'étude au sein de la stratégie AFTC</b>	<b>24</b>
1.5.1 Contexte scientifique	24
1.5.2 Problématiques	25
1.5.3 Objectifs de thèse	26

<b>2</b>	<b>Le réseau de neurones pour le contrôleur adaptatif</b>	<b>28</b>
<b>2.1</b>	<b>Évolution du perceptron vers les structures profondes</b>	<b>29</b>
<b>2.2</b>	<b>Algorithmes d'optimisation utilisés en ligne et en temps réel</b>	<b>31</b>
2.2.1	Optimisation automatique des paramètres	32
2.2.2	Optimisation automatique des hyperparamètres	32
<b>2.3</b>	<b>Conditions de stabilité et de convergence</b>	<b>34</b>
2.3.1	Stabilité au sens de Lyapunov	34
2.3.2	Convergence globale de l'apprentissage	35
<b>2.4</b>	<b>État de l'art sur les structures de contrôle neuronal adaptatives</b>	<b>35</b>
2.4.1	Contrôleur neuronal adaptatif par modèle inverse	36
2.4.2	Contrôleur neuronal adaptatif par modèle de rétroaction	38
2.4.3	Contrôleur neuronal adaptatif hybride	40
2.4.4	Contrôleur neuronal adaptatif par programmation dynamique	41
2.4.5	Contrôleur neuronal adaptatif proportionnel intégral dérivé	43
2.4.6	Contrôleur neuronal adaptatif par retour d'état	46
2.4.7	Contrôleur neuronal adaptatif par rétrogradation	48
2.4.8	Contrôleur neuronal adaptatif par mode glissant	50
2.4.9	Contrôleur neuronal adaptatif par commande prédictive	52
<b>2.5</b>	<b>Synthèse et discussion sur l'état de l'art</b>	<b>53</b>
2.5.1	Tableaux de synthèses sur l'état de l'art	53
2.5.2	Discussion sur l'état de l'art	58
<b>2.6</b>	<b>Choix de la structure de contrôle</b>	<b>59</b>
2.6.1	Définitions et pondérations des critères de sélection	59
2.6.2	Justification de la valorisation des solutions	60
2.6.3	Notation des structures de contrôles	61
<b>3</b>	<b>L'élaboration du contrôleur adaptatif aux états de santé de la pile</b>	<b>64</b>
<b>3.1</b>	<b>Théorie de la programmation dynamique</b>	<b>65</b>
3.1.1	Principe d'optimalité	65
3.1.2	Différentes structures de programmation dynamique	67
3.1.3	Ajustement prospectif ou rétrospectif du modèle critique	68
<b>3.2</b>	<b>Estimation des fonctions inconnues</b>	<b>69</b>
3.2.1	Évaluation des modèles neuronaux	69
3.2.2	Analyse des hyperparamètres du modèle ESN	74
3.2.3	Logique floue pour le réglage en ligne des coefficients d'apprentissage	78
<b>3.3</b>	<b>Programmation dynamique adaptative aux défauts du système</b>	<b>83</b>
3.3.1	Interférence des signaux de commandes	83
3.3.2	Banque de contrôleurs adaptatifs dans la stratégie AFTC	84
<b>3.4</b>	<b>Structure de contrôle ADP et sorties cibles d'apprentissages</b>	<b>85</b>
3.4.1	Structure de contrôle ADP basé HDP	85

3.4.2	Apprentissages des modèles ESN.....	86
<b>3.5</b>	<b>Algorithme du contrôle ADP.....</b>	<b>88</b>
<b>3.6</b>	<b>Études de stabilité et de convergence de la stratégie de contrôle.....</b>	<b>88</b>
3.6.1	Stabilité du contrôleur ADP basé HDP.....	89
3.6.2	Stabilité et convergence globale du modèle ESN.....	90
<b>4</b>	<b>Test de la procédure de contrôle adaptatif en simulation.....</b>	<b>93</b>
<hr/>		
<b>4.1</b>	<b>Dispositif de simulation et le modèle cœur de pile.....</b>	<b>94</b>
4.1.1	Modèle PEMFC, les variables de contrôles et de commandes.....	95
4.1.2	Scénarios de tests et les mises en conditions de défauts.....	95
<b>4.2</b>	<b>Les contrôleurs et leurs paramétrages.....</b>	<b>98</b>
4.2.1	Contrôleur PID.....	98
4.2.2	Contrôleur par programmation dynamique heuristique.....	99
4.2.3	Le temps de calcul des contrôleurs.....	100
<b>4.3</b>	<b>Résultats de simulation obtenus sur un empilement de cellules.....</b>	<b>101</b>
4.3.1	Suivi de consigne stœchiométrique en fonctionnement sain – Scénario S1.1.....	101
4.3.2	Régulation avec rejet de perturbation en condition de fonctionnement sain – Scénario S1.2.....	104
4.3.3	Régulation en présence du défaut de noyage – Scénario S2.....	106
4.3.4	Suivi de consigne en présence du défaut d’assèchement de la membrane – Scénario S3.....	108
<b>4.4</b>	<b>Analyse et interaction des modèles neuronaux.....</b>	<b>110</b>
<b>4.5</b>	<b>Synthèse et discussion sur les résultats de simulation.....</b>	<b>113</b>
<b>5</b>	<b>La validation du contrôleur adaptatif par l’expérimentation.....</b>	<b>116</b>
<hr/>		
<b>5.1</b>	<b>Dispositif expérimental.....</b>	<b>117</b>
5.1.1	Banc d’essai et pile à combustible à disposition.....	117
5.1.2	Communication entre capteurs et actionneurs.....	118
<b>5.2</b>	<b>Scénarios de tests et les mises en conditions de défauts.....</b>	<b>119</b>
5.2.1	Variables de contrôle.....	119
5.2.2	Conditions de fonctionnement en mode sain et en présence de défauts.....	122
<b>5.3</b>	<b>La configuration du contrôleur ADP.....</b>	<b>126</b>
<b>5.4</b>	<b>Résultats d’expérimentations obtenus sur la mono-cellule.....</b>	<b>127</b>
5.4.1	Capacités d’apprentissage et d’adaptation – Scénario S1.1.....	127
5.4.2	Régulation avec rejet de perturbation stœchiométrique sous forme de paliers croissant – Scénario S1.2.....	129
5.4.3	Régulation avec rejet de perturbation stœchiométrique avec de forts paliers – Scénario S1.3.....	132
5.4.4	Régulation avec rejet de perturbations stœchiométrique sous forme de paliers rapides – Scénarios S1.4.....	135
5.4.5	Régulation en présence du défaut de noyage – Scénario S2.....	138

---

5.4.6 Régulation en présence du défaut d'assèchement de la membrane – Scénario S3	142
<b>5.5 Analyse des résultats d'expérimentations .....</b>	<b>147</b>
<b>Conclusions générales</b>	<b>149</b>
<b>Perspectives</b>	<b>153</b>
<b>Annexe A1 Les structures des réseaux de neurones</b>	<b>I</b>
<b>Annexe A2 Les algorithmes d'optimisations</b>	<b>VII</b>
<b>Annexe B La sélection de la structure de contrôle</b>	<b>XI</b>
<b>Annexe C Le modèle physique PEMFC</b>	<b>XVII</b>
<b>Références</b>	<b>XXV</b>

---

# Table des figures

<b>Figure 1</b>	a) Répartition des consommations d'énergie primaire en 2018 b) Répartition de la production électrique en 2018 (OER, 2019) .....	2
<b>Figure 2</b>	Principe électrochimique d'une pile à combustible de type PEMFC .....	7
<b>Figure 3</b>	Vues d'une (a) monocellule et d'un (b) empilement de cellules .....	10
<b>Figure 4</b>	Vue éclatée d'une monocellule .....	10
<b>Figure 5</b>	Différents espaces de commandes de la pile à combustible .....	13
<b>Figure 6</b>	Différentes régulations en pression (Li et al., 2015) .....	14
<b>Figure 7</b>	Arbre de défaillance menant au défaut de noyage (Dijoux, 2019) .....	18
<b>Figure 8</b>	Arbre d'événements à la suite de l'apparition du défaut de noyage .....	19
<b>Figure 9</b>	Graphe de structure pour le défaut de noyage (Dijoux, 2019) .....	20
<b>Figure 10</b>	Graphe de structure pour le défaut d'assèchement de la membrane (Dijoux, 2019) .....	21
<b>Figure 11</b>	Différentes approches du contrôle dans la stratégie FTC .....	22
<b>Figure 12</b>	Composantes d'une stratégie AFTC .....	23
<b>Figure 13</b>	Structure de contrôle AFTC mise en place par Lebreton (2015) .....	25
<b>Figure 14</b>	Module de décision mis en place par Dijoux (2019) .....	25
<b>Figure 15</b>	Représentation fonctionnelle du projet de recherche .....	26
<b>Figure 15</b>	Évolution des réseaux de neurones .....	30
<b>Figure 16</b>	Structure de contrôle par modèle neuronal inverse .....	36
<b>Figure 17</b>	Structure de contrôle par modèle neuronal de rétroaction .....	38
<b>Figure 18</b>	Structure de contrôle hybride neuronale .....	40
<b>Figure 19</b>	Structure de contrôle par programmation dynamique neuronale .....	42
<b>Figure 20</b>	Structure de contrôle PID neuronale .....	44
<b>Figure 21</b>	Réseau de neurones imitant le contrôleur PID .....	45
<b>Figure 22</b>	Structure de contrôle par retour d'état neuronale .....	47
<b>Figure 23</b>	Structure de contrôle par retour d'état neuronale avec contrôleur linéaire .....	47
<b>Figure 24</b>	Structure de contrôle par rétrogradation neuronale .....	49
<b>Figure 25</b>	Principe de correction par mode glissant .....	50
<b>Figure 26</b>	Structure de contrôle par MPC neuronale .....	52
<b>Figure 27</b>	Diagrammes de Kiviat des contrôleurs au regard des critères de sélection .....	61
<b>Figure 28</b>	Classement des structures de contrôle au regard des critères de sélection .....	62
<b>Figure 29</b>	Choix de la structure de contrôle à adopter .....	63
<b>Figure 30</b>	L'approche critique adaptative .....	67
<b>Figure 31</b>	La méthode HDP .....	67
<b>Figure 32</b>	La méthode DHP .....	68
<b>Figure 33</b>	Base de données utilisée pour l'évaluation des modèles neuronale .....	70

<b>Figure 34</b> Résultats des tests de calcul des différents modèles.....	73
<b>Figure 35</b> Influence des hyperparamètres sur la précision (MAPE) de modélisation en tension .....	76
<b>Figure 36</b> Fonctions d'appartenance associées à l'erreur et à sa variation pour le processus de fuzzification .....	79
<b>Figure 37</b> Fonctions d'appartenance associées au taux d'apprentissage pour le processus de défuzzification.....	80
<b>Figure 38</b> Visualisation de combinaisons véritables, de 1 à 12 .....	81
<b>Figure 39</b> Surface floue relative au taux d'apprentissage .....	83
<b>Figure 40</b> Application de la logique floue sur le taux d'apprentissage.....	83
<b>Figure 41</b> Diagramme fonctionnel du contrôleur adaptatif aux états de santé dans la stratégie AFTC .....	85
<b>Figure 42</b> Structure de contrôle adaptative par programmation dynamique.....	86
<b>Figure 43</b> Dynamiques du modèle PEMFC sur un fonctionnement nominal sans régulation .....	96
<b>Figure 45</b> Dynamiques du modèle PEMFC en présence d'un défaut de noyage sans régulation .....	97
<b>Figure 46</b> Dynamiques du modèle PEMFC sur un défaut d'assèchement sans régulation....	98
<b>Figure 47</b> Comparaison des temps de calcul des contrôleurs durant la simulation. ....	100
<b>Figure 47</b> Réponse du système PEMFC durant le suivi de consigne stœchiométrique – Scénario S1.1. a) Contrôle en stœchiométrie b) Contrôle en différence de pression à la membrane c) Contrôle en température.....	101
<b>Figure 48</b> Erreurs de modélisation des modèles ESN durant le suivi de consigne – Scénario S1.1 .....	103
<b>Figure 49</b> Réponse du système PEMFC en présence des perturbations en courant – Scénario S1.2. a) Contrôle en stœchiométrie b) Contrôle en différence de pression à la membrane c) Contrôle en température.....	104
<b>Figure 50</b> Réponse du système PEMFC en présence du défaut de noyage – Scénario S2. a) Contrôle en stœchiométrie b) Contrôle en différence de pression à la membrane c) Contrôle en température .....	106
<b>Figure 51</b> Réponse du système PEMFC aux différents contrôleurs durant S2.....	108
<b>Figure 52</b> Réponse du système PEMFC en présence du défaut d'assèchement de la membrane – Scénario S3 .....	108
<b>Figure 53</b> Réponse du système PEMFC en présence du défaut d'assèchement de la membrane – Scénario S3. a) Contrôle en stœchiométrie b) Contrôle en différence de pression à la membrane c) Contrôle en température.....	109
<b>Figure 54</b> Analyse de la stabilité au sens de Lyapunov. a) dérivée de la fonction candidate de Lyapunov b) résidu entre la fonction candidate et sa borne maximale.....	111
<b>Figure 55</b> Sorties et cibles pour l'apprentissage des modèles ESN lors du suivi de consigne – Scénario S1 .....	112
<b>Figure 56</b> Sorties et cibles pour l'apprentissage des modèles ESN lors du suivi de consigne – Scénario S1 .....	112
<b>Figure 57</b> Sorties et cibles pour l'apprentissage des modèles ESN lors du suivi de consigne – Scénario S1 .....	113

<b>Figure 58</b> Histogramme résumant les performances de simulation lors du contrôle de la stœchiométrie.....	113
<b>Figure 59</b> Histogramme résumant les performances de simulation lors du contrôle de la différence de pression à la membrane.....	114
<b>Figure 60</b> Histogramme résumant les performances de simulation lors du contrôle de la température .....	114
<b>Figure 61</b> Banc d'essai FCT du laboratoire LE2P avec sa mono-cellule .....	117
<b>Figure 62</b> Synoptique du banc d'essai (Dijoux, 2019).....	118
<b>Figure 63</b> Schéma de communication du banc d'essai du laboratoire.....	119
<b>Figure 64</b> Régulations possibles sur le banc FCT.....	119
<b>Figure 65</b> Photographie d'une destruction de la MEA à l'entrée de la mono-cellule.....	120
<b>Figure 66</b> Schéma de contrôle pour l'expérimentation.....	120
<b>Figure 67</b> Réponse de la pile en présence de perturbation sous forme de créneaux équivalents sur les pressions de sortie anodique et cathodique – Scénario S0 .....	121
<b>Figure 68</b> Réponse de la pile en présence de perturbation sur la pression d'entrée cathodique sans régulation .....	123
<b>Figure 69</b> Réponse de la pile en présence du défaut de noyage sans régulation.....	124
<b>Figure 70</b> Réponse de la pile en présence du défaut d'assèchement de la membrane sans régulation .....	125
<b>Figure 71</b> Réponse du système PEMFC en présence d'une perturbation récurrente – Scénario S1.1 .....	127
<b>Figure 72</b> Réponse du système.....	129
<b>Figure 73</b> Taux d'apprentissage calculés et erreurs de modélisation des modèles ESN en présence de perturbation stœchiométrique sous forme de paliers croissants – Scénario S1.2 .....	131
<b>Figure 74</b> Réponse du système PEMFC en présence de perturbations stœchiométriques sous forme de paliers importants – Scénario S1.3 .....	133
<b>Figure 75</b> Taux d'apprentissage calculés et erreurs de modélisation des modèles ESN en présence de perturbations stœchiométriques sous forme de paliers importants – Scénario S1.3 .....	134
<b>Figure 76</b> Réponse de la pile en présence de perturbation stœchiométrique sous forme de paliers rapides – Scénario S1.4 .....	136
<b>Figure 77</b> Taux d'apprentissage calculés et erreurs de modélisation des modèles ESN en présence de perturbations stœchiométriques sous forme de paliers rapides – Scénario S1.4.....	137
<b>Figure 78</b> Réponse de la pile en présence du défaut de noyage – Scénario S2 .....	139
<b>Figure 79</b> Logique floue et apprentissage des modèles sous l'apparition du défaut de noyage S2 .....	141
<b>Figure 80</b> Réponse de la pile en présence du défaut d'assèchement de la membrane – Scénario S3 .....	143
<b>Figure 81</b> Logique floue et apprentissage des modèles sous l'apparition du défaut d'assèchement S3.....	145
<b>Figure 82</b> Ordre d'optimisation et de réactualisation.....	154
<b>Figure 83</b> Diagramme d'optimisation des hyperparamètres .....	154
<b>Figure 84</b> Les principaux types de neurones.....	I

---

<b>Figure 85</b>	Réseau de neurones à trois couches.....	II
<b>Figure 86</b>	Réseau de neurones de type ARX .....	IV
<b>Figure 87</b>	Réseau de neurones de type ESN .....	IV
<b>Figure 88</b>	Réseau de neurones de type LSTM .....	V
<b>Figure 89</b>	Schéma bloc de la pile (Pukrushpan, 2003) .....	XVII

# Liste des tableaux

<b>Tableau 1</b>	Caractéristiques des différentes piles à combustible .....	8
<b>Tableau 2</b>	Caractéristiques des différents composants de la pile à combustible .....	11
<b>Tableau 3</b>	Synthèse des variables de contrôle et des actionneurs pour le cœur de pile.....	16
<b>Tableau 4</b>	Défauts du cœur de pile les plus courants.....	17
<b>Tableau 5</b>	Désignation de l'arbre de défaillance pour le défaut de noyage.....	18
<b>Tableau 6</b>	Désignation du graphe de structure pour le défaut de noyage .....	20
<b>Tableau 7</b>	Désignation du graphe de structure pour le défaut d'assèchement de la membrane .....	21
<b>Tableau 8</b>	Modèles neuronaux les plus couramment utilisés .....	30
<b>Tableau 9</b>	Exemples de paramètre et d'hyperparamètres pour les modèles neuronaux .....	31
<b>Tableau 10</b>	Algorithmes d'optimisation des paramètres .....	32
<b>Tableau 11</b>	Algorithmes d'optimisation des hyperparamètres .....	33
<b>Tableau 12</b>	Synthétisation des structures de contrôles adaptatifs neuronaux appliquées pour la pile PEMFC.....	54
<b>Tableau 13</b>	Récapitulatif des structures de contrôles adaptatifs neuronaux appliqués au contrôle de stœchiométrie .....	56
<b>Tableau 14</b>	Récapitulatif des structures de contrôles adaptatifs neuronaux appliqués au contrôle de tension .....	57
<b>Tableau 15</b>	Récapitulatif des structures de contrôles adaptatifs neuronaux appliqués au contrôle de température.....	57
<b>Tableau 16</b>	Récapitulatif de la structure de contrôle adaptatif neuronale appliqué au contrôle de pression .....	57
<b>Tableau 17</b>	Barèmes de notation et de pondération pour le choix de la structure de contrôle .....	60
<b>Tableau 18</b>	Tableau de notations des structures de contrôles.....	62
<b>Tableau 19</b>	Entrées et sortie pour la comparaison des modèles de neurones .....	69
<b>Tableau 20</b>	Configurations des réseaux de neurones évalués.....	71
<b>Tableau 21</b>	Temps de calcul moyen d'une itération par modèle .....	72
<b>Tableau 22</b>	Performances MAPE des modèles au cours de plusieurs tests .....	72
<b>Tableau 23</b>	Plages de variation des hyperparamètres .....	75
<b>Tableau 24</b>	Synthèse sur l'optimisation des hyperparamètres pour un modèle de prévision ESN en tension.....	78
<b>Tableau 25</b>	Entrées et sortie de la méthode de logique floue .....	79
<b>Tableau 26</b>	Zones d'action des règles floues et de leurs recouvrements .....	82
<b>Tableau 27</b>	Matrice d'interférence entre les variables de commandes et les variables spécifiques au défaut de noyage et d'assèchement de la membrane .....	84

---

<b>Tableau 28</b>	Synthèse des modèles PEMFC avec défauts .....	94
<b>Tableau 29</b>	Condition de fonctionnement en mode sain et en présence de défauts pour la simulation.....	96
<b>Tableau 30</b>	Entrées et sorties des modèles ESN en simulation .....	99
<b>Tableau 31</b>	Configuration des hyperparamètres du contrôleur ADP en simulation .....	100
<b>Tableau 32</b>	Indices d'échométrie des modèles ESN lors des 3 scénarios de simulation.....	111
<b>Tableau 33</b>	Organes majeurs du banc d'essai et du système PEMFC.....	118
<b>Tableau 34</b>	Condition de fonctionnement en mode sain et en présence de défauts pour l'expérimentation .....	122
<b>Tableau 35</b>	Entrées et sorties des modèles ESN en expérimentation .....	126
<b>Tableau 36</b>	Liste des paramètres utilisés pour le modèle (Wu and Zhou, 2016).....	XVIII

# Nomenclature

## Acronymes

CGDD	Commissariat général au développement durable
FDFC	international conference on Fundamentals and Development of Fuel Cells
GDR	Groupement De Recherche
INSEE	Institut National de la Statistique et des Etudes Economiques
IPCC	Intergovernmental Panel on Climate Change
IRENA	International Renewable Energy Agency
NCAR	National Center for Atmospheric Research
OER	Observatoire Energie Réunion
REN21	Renewable Energy Policy Network for the 21st century
WMO	World Meteorological Organisation
AFC	Alcaline Fuel Cell
DBFC	Direct Borohydride Fuel Cell
DEFC	Direct Ethanol Fuel Cell
DMFC	Direct Methanol Fuel Cell
FAFC	Formic Acid Fuel Cell
HT-PEMFC	High Temperature Proton Exchange Fuel Cell
MCFC	Molten Carbonate Fuel Cell
PAFC	Phosphoric Acid Fuel Cell
PEMFC	Proton Exchange Fuel Cell
SOFC	Solid Oxyde Fuel Cell
AFTC	Active FTC
C3H6O2	Acétate de méthyle
CO	Monoxyde de carbone
CUTE	Clean Urban Transport for Europe
FDD	Fault Detection and Diagnosis
FTC	Fault Tolerant Control
GDL	Gas Diffusion Layer
HyFleet-CUTE	Hydrogen Fleet Clean Urban Transport for Europe
HYPER	Installation pertaining guidance for hydrogen and fuel cell stationary hydrogen systems
JIVE	Joint Initiative for hydrogen Vehicles accross Europe
MEA	Membrane Electrode Assembly
MFC	Mass Flow Controler
PFTC	Passive FTC
RH	Relative Humidity

SOH	State Of Health
ADP	Adaptive Dynamic Programming
ARX	Auto-Régressif avec des entrées exogènes
BP	Back-Propagation
CNN	Covolutional Neural Network
ED	Evolutionnal Differential
ESN	Echo State Network
GD	Gradient Descent
GMV	Generalized Minimum Variance
IIR	Infinite Impule Response Filter
LSTM	Long Short-Term Memory
ML	Multi-Layer
MPC	Model Predictive Control
PCA	Principal Component Analysis
PI	Proportionnal Integral
PID	Proportionnal Integral Derivate
RBF	Radial Basis Functions
RC	Reservoir Computing
RF	Recurrent Fuzzy
RLS	Recursive Least-Square
RN	Réseau de neurones
TD	Time Delay
DHP	Dual heuristique Dynamic Programming
GDHP	Global Dual heuristique Dynamic Programming
HDP	Heuristic Dynamic Programming
MAPE	Mean Absolute Percentage Error
MPE	Mean Percentage Error
RMSE	Relative Mean Square Error
LMI	Linear Matrix Inequality
R2	Coefficient de détermination

### Notations mathématiques

$N_{cell}$	Nombre de cellules
$\lambda_{H_2}$	Stœchiométrie en hydrogène
$\lambda_{O_2}$	Stœchiométrie en oxygène
$\phi_{in}$	Humidité relative en entrée
$I_{st}$	Courant de pile
$P_{H_2O}$	Pression de la vapeur d'eau
$P_{H_2O,sat}$	Pression saturante en eau
$q_{in}$	Débit d'entrée
$q_{out}$	Débit de sortie
$T_{canal}$	Température de canalisation
$T_{fc}$	Température de pile

$T_{hum}$	Température du ballon d'humidification
$\lambda$	Contenu en eau de la membrane
$\Phi_{H_2O}^{diff}$	Flux de diffusion de l'eau dans la membrane
$\Phi_{H_2O}^{osm}$	Flux électro osmotique de l'eau dans la membrane
$I_{fc}$	Courant de pile
$F_{noy}$	Défaut de noyage
$P_{O_2}$	Pression d'oxygène
$P_{sc,O_2}$	Pression partielle de l'oxygène à la couche catalytique
$P_{s,O_2}$	Pression de sortie d'oxygène
$q_{c,O_2}$	Débit consommé d'oxygène
$q_{O_2}$	Débit d'oxygène
$q_{O_2,hum}$	Débit d'oxygène humidifié
$V_{fc}$	Tension de la pile
$R_m$	Résistivité de la membrane
$F_{dry}$	Défaut d'assèchement de la membrane
$e_m(k)$	Erreur de modélisation
$e(k)$	Erreur de position
$x(k)$	Etat du système
$y(k)$	Sortie du système
$J(x, y)$	Fonction coût
$V(x)$	Fonction candidate de Lyapunov
$k_{p,i,d}$	Coefficient du contrôleur PID
$u(k)$	Commande d'un contrôleur
$u^*(k)$	Commande idéale
$\hat{u}(k)$	Commande estimée
$U(k)$	Fonction utilitaire, ou signal de renforcement
$\gamma$	Coefficient d'actualisation pour l'apprentissage du modèle prévisionneur
$n_{in}$	Nombre d'entrée
$n_{out}$	Nombre de sortie
$c_{in}$	Coefficient appliqué à l'entrée
$c_{out}$	Coefficient appliqué à la sortie
$n_{Deep}$	Nombre de réservoirs de neurones
$n_{Res}$	Nombre de neurones
$C_o^l$	Indice de connectivité
$\alpha^l$	Taux de fuite du réservoir de neurones
$\rho(W^{res})$	Rayon spectral du réseau de neurones
$\eta$	Taux d'apprentissage du réseau de neurones
$W^{in}$	Matrice d'entrée
$W^{out}$	Matrice de sortie
$W^{res}$	Matrice interne ou réservoir
$A$	Fonction d'appartenance à une ensemble flou

---

$\mu_{A^i}$	Degré d'appartenance à une fonction d'appartenance
$v_i$	Degré de vérité à une règle floue
$d(k)$	Signal de perturbation
$\zeta$	Coefficient d'atténuation pour l'apprentissage du modèle acteur
$f_{a,p,c}$	Fonction d'activation du modèle acteur, prévisionneur ou critique
$P(k)$	Matrice de covariance de l'erreur d'estimation
$P_s$	Matrice symétrique positive pour le critère de Schur



# Introduction générale

L'organisation WMO<sup>1</sup> a annoncé que l'année 2019 (anomalie +0,98 °C) est la seconde année la plus chaude jamais enregistrée après 2016 (anomalie +1,01 °C). Le corps des Nations Unies IPCC<sup>2</sup> a déclaré une hausse de température de surface de 1,5 °C depuis l'ère industrielle. L'activité humaine dans les domaines du transport, de l'agriculture, du tertiaire et du résidentiel est à l'évidence l'origine de ces dégradations climatiques brusques. Dans l'hémisphère nord, les phénomènes météorologiques sont en nombre supérieur à la moyenne. L'Australie a connu en 2019 l'année la plus sèche jamais enregistrée, les feux massifs ont été dévastateurs pour la faune et les écosystèmes. Les températures extrêmes impactent également l'agriculture, ce qui laisse présager des difficultés alimentaires. Dans le pire des scénarios, l'institut de recherche NCAR<sup>3</sup> prévoit une montée en température de 5,3 °C d'ici la fin du siècle.

## Une volonté mondiale d'une transition énergétique

Le processus de transition énergétique est un des enjeux sociétal et climatique pour notre espèce. L'accord de Paris de 2016 vise à limiter la hausse de température à 2 °C au-dessus de la moyenne préindustrielle, voire de la maintenir à 1,5 °C. Pour y parvenir, une volonté de tous les acteurs est primordiale. La feuille de route mondiale<sup>4</sup> de 2018 mis en place par l'agence IRENA pour l'horizon 2050 repose sur 6 volets :

- La synergie entre l'efficacité énergétique et les énergies renouvelables décarbonées.
- L'accroissement de la pénétration des énergies renouvelables dans le réseau électrique.
- Le recours à l'électricité décarbonée dans le transport, le bâtiment, et l'industrie.
- Le soutien de l'innovation pour la recherche et le développement technologique.
- L'adaptation en temps réel du cadre politique et réglementaire en matière d'investissement socioéconomique.
- La collaboration de l'ensemble de la société humaine pour le partage équitable des coûts de développement et l'accès universel à l'énergie.

Le rapport du groupement REN21<sup>5</sup> pour 2017 présente la part des énergies renouvelables dans la consommation énergétique mondiale à 19 %, les énergies fossiles à 79 % et l'énergie nucléaire à 2 %.

---

<sup>1</sup> WMO « World Meteorological Organization » (2019)

<sup>2</sup> IPCC « Intergovernmental Panel on Climate Change » (2019)

<sup>3</sup> NCAR « National Center for Atmospheric Research » (2019)

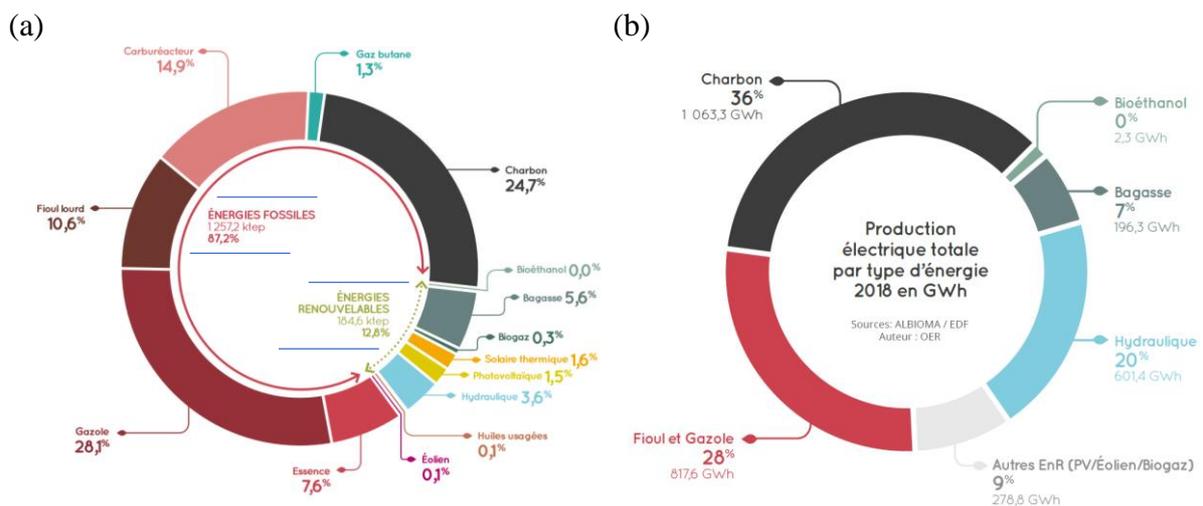
<sup>4</sup> IRENA « International Renewable Energy Agency » (2018), Global Energy Transformation : A Roadmap to 2050, Abu Dhabi (ISBN 978-92-9260-059-4)

<sup>5</sup> REN21 « Renewable Energy Policy Network for the 21st Century »

Le dernier rapport du service statistique français CGDD<sup>1</sup> de 2019 pour 2017 présente une consommation totale d'énergie primaire (DOM-TOM compris) de 251,4 Mtep. La part des énergies renouvelables représente 10,7 %, le nucléaire représente 40,0 %, les produits pétroliers 28,9 % et le gaz 15,7 %.

## Les spécificités du territoire de La Réunion

La Réunion est une île de l'océan Indien qui fait partie des territoires français d'outre-mer. Elle compte en 2017, un total de 853 659 habitants<sup>2</sup> pour une superficie totale de 2 512 km<sup>2</sup>. En 1982, La Réunion était indépendante énergétiquement à 99% (Savidan et al., 2008). Cependant, plusieurs facteurs ont dégradé ce taux d'indépendance, tels que la croissance de la démographie, l'élévation du niveau de vie, la limite de production hydroélectrique et les orientations politiques. La dernière étude en date de 2019 sur les chiffres de 2018, présente une dépendance aux énergies fossiles importées de 87,2% (OER, 2019) pour une consommation totale d'énergie primaire de 1 441,8 ktep. La répartition des consommations d'énergie primaire tirée de cette étude est donnée à la Figure 1.



**Figure 1** a) Répartition des consommations d'énergie primaire en 2018 b) Répartition de la production électrique en 2018 (OER, 2019)

Le taux de pénétration des énergies renouvelables sur le réseau électrique est de 36,5%, en progression de 4,1 points par rapport à 2017. Ces énergies renouvelables étant pour la plupart intermittentes, leurs intégrations sur le réseau sont restreintes par plusieurs contraintes sécuritaires. Une solution pour accroître ce taux consiste à employer des solutions de stockage associé à une gestion intelligente pour améliorer la stabilité de la distribution électrique des énergies renouvelables, des travaux récemment publiés vont dans ce sens (K/Bidi, 2019; Tapachès, 2020). Le caractère insulaire du territoire est une des caractéristiques qui encourage les efforts actuels visant au retour à l'indépendance énergétique. Il s'agit, comme pour les îles

<sup>1</sup> CGDD « Commissariat Général au Développement Durable »

<sup>2</sup> Insee Réunion (2017), Recensement de la population

bretonnes d'un véritable laboratoire d'expérimentation pour la maîtrise de l'énergie, mais à une échelle différente.

## **Le vecteur hydrogène et la pile à combustible**

La pile à combustible est un convertisseur électrochimique qui génère du courant électrique à partir du vecteur hydrogène. Ce système apporte la possibilité d'exploiter davantage les énergies renouvelables stockées sous forme d'hydrogène. Ce vecteur peut être produit à partir de l'électrolyse de l'eau qui utilise une énergie électrique produite par des sources d'énergies renouvelables, telles que le solaire, l'éolien ou encore l'énergie marine. Dans ce cas, la pile à combustible présente plusieurs avantages par rapport aux énergies issues des hydrocarbures :

- Production électrique non carbonée, si l'hydrogène est produit par électrolyse de l'eau
- Fonctionnement silencieux
- Fonctionnement à « basse » température
- Meilleur rendement énergétique qu'un moteur thermique

## **Les verrous technologiques et sociaux**

Bien qu'étant un convertisseur énergétique prometteur, les verrous de la pile à combustible restent actuellement des sujets de recherches et de développement majeurs. Ses verrous techniques et sociétaux sont les suivants :

- Sa durabilité pour sa durée de vie
- Sa fiabilité de fonctionnement
- Son coût de fabrication et le coût de l'hydrogène
- La méconnaissance de l'hydrogène

## **Le contexte scientifique et l'orientation de l'étude de recherche**

Les travaux entrepris dans cette thèse sont une continuité des études menées dans le domaine de la fiabilité de fonctionnement des systèmes pile à combustible. Plusieurs problématiques et axes de recherches seront identifiés, ce qui amènera à proposer des avancées scientifiques dans le domaine en cours. L'étude est basée sur le développement d'outils de contrôle générique et adaptatif aux états de santé pour contribuer au pilotage du système. Et les travaux s'inscrivent dans le cadre d'une stratégie globale visant à atténuer les perturbations pouvant influencer voire dégrader les performances du système.

## **L'organisation du manuscrit**

Le manuscrit débute par le présent chapitre, l'introduction générale introduit le contexte énergétique et l'orientation de l'étude. Ensuite, le chapitre 1 décrit et analyse notre objet d'étude. Nous tâchons d'identifier les besoins, les fonctions et les questions scientifiques qui guideront les objectifs de notre étude. A la suite de cela, dans le chapitre 2, un état de l'art est

mené pour une recherche exhaustive de solutions. Le chapitre 3 est ensuite consacré au développement des procédés et algorithmes que nous proposons. Les premiers résultats sont présentés dans le chapitre 4, il s’agit d’essais en simulation. À partir d’un modèle de simulation et de plusieurs scénarios de tests, nous démontrons les atouts de la méthode proposée. Le chapitre 5 validera en ligne et en temps réel le contrôleur générique et adaptatif aux états de santé. Les réponses aux besoins et questions scientifiques identifiées précédemment sont données dans les conclusions générales. Nous apporterons une critique sur la méthode et les résultats obtenus. Des perspectives amènent ensuite vers une continuité des travaux et à de nouveaux axes d’études.

## **Publication et communications scientifiques**

- Article de revue ([Lin-Kwong-Chon et al., 2019](#))

C. Lin-Kwong-Chon, B. Grondin-Pérez, J.-J. A. Kadjo, C. Damour, and M. Benne, “A review of adaptive neural control applied to proton exchange membrane fuel cell systems”, *Annual Reviews in Control*, vol. 47, pp. 133–154, 2019.

- Conférence international avec acte

C. Lin-Kwong-Chon, C. Damour, J.-J. A. Kadjo, B. Grondin-Pérez and M. Benne, “An Online Adaptive Dynamic Programming Control for PEMFC”, *8<sup>th</sup> International Conference on Fundamentals and Development of Fuel Cells – FDFC 2019*, Nantes.

- Groupement de recherche national avec acte

C. Lin-Kwong-Chon, C. Damour, M. Benne, J.-J.A. Kadjo, B. Grondin-Perez, « Contrôle adaptatif aux états de santé d’une PEMFC par une approche programmation dynamique et réseaux de neurones », *5<sup>e</sup> Réunion plénière du GdR 3652 du CNRS HySPàC*, Croisic.

# CHAPITRE 1

## VERS LE CONTROLE ADAPTATIF AUX ETATS DE SANTE DE LA PILE TYPE PEMFC

### Sommaire

---

<b>1.1</b>	<b>Préambule général sur les piles à combustible</b> .....	<b>6</b>
1.1.1	Principe de fonctionnement électrochimique.....	6
1.1.2	Histoire et émergence de la pile à combustible .....	7
1.1.3	Différents types de piles à combustible .....	7
1.1.4	Pile à combustible à membrane échangeuse de protons .....	8
<b>1.2</b>	<b>Composants du système pile à combustible type PEMFC</b> .....	<b>9</b>
1.2.1	Cœur de pile.....	10
1.2.2	Actionneurs et capteurs.....	13
<b>1.3</b>	<b>Défauts du système pile à combustible type PEMFC</b> .....	<b>17</b>
1.3.1	Dynamiques des défauts .....	17
1.3.2	Conditions de défauts du système.....	17
1.3.3	Les conséquences des défauts du système .....	19
1.3.4	Perturbations de fonctionnements du défaut.....	19
<b>1.4</b>	<b>Stratégie de contrôle tolérant aux défauts actif</b> .....	<b>22</b>
1.4.1	Diagnostic du défaut .....	23
1.4.2	Prise de décision .....	23
1.4.3	Contrôle du système.....	24
<b>1.5</b>	<b>Positionnement de l'étude au sein de la stratégie AFTC</b> .....	<b>24</b>
1.5.1	Contexte scientifique .....	24
1.5.2	Problématiques.....	25
1.5.3	Objectifs de thèse .....	26

---

## Introduction

Un système est fiable lorsqu'il remplit sa mission sur une période correspond à la durée de vie indiquée dans son cahier des charges. Or, le pilotage adéquate des commandes du système pile à combustible est primordiale pour éviter l'apparition de phénomènes non désirés, nommés défauts. Un défaut, au niveau du système pile à combustible mais aussi au niveau de ses auxiliaires, est défini<sup>1</sup> comme une condition anormale ou accidentelle de fonctionnement qui peut conduire à une défaillance. Auquel cas, la durée de vie ou le pronostic vital du composant ou du sous-système peut être engagé.

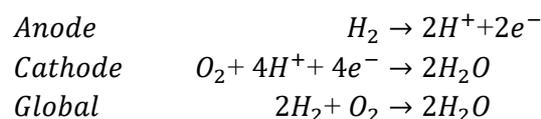
Une solution pour améliorer la fiabilité du système pile à combustible consiste à mettre en œuvre des stratégies de pilotage afin de limiter les temps d'exposition aux défauts. Dans les meilleures situations, le défaut est totalement recouvert et le système retrouve complètement un fonctionnement sain, aucune dégradation n'est alors à noter sur le composant ou le sous-système.

Ce chapitre est une introduction aux stratégies développées pour le contrôle des piles à combustible. La première section retrace l'histoire du système pile à combustible et décrit son fonctionnement général. La deuxième est consacrée aux composants de la pile à combustible à membrane échangeuse de protons ou PEMFC. Elle aborde les différents moyens de contrôle par le biais des actionneurs et capteurs. La troisième section répertorie les pertes de performances engendrées par les défauts qui mettent à l'épreuve la fiabilité du système. La quatrième section traite de la stratégie de contrôle actif tolérant aux défauts. La dernière partie est consacrée au positionnement de cette étude au sein de cette stratégie.

### 1.1 Préambule général sur les piles à combustible

#### 1.1.1 Principe de fonctionnement électrochimique

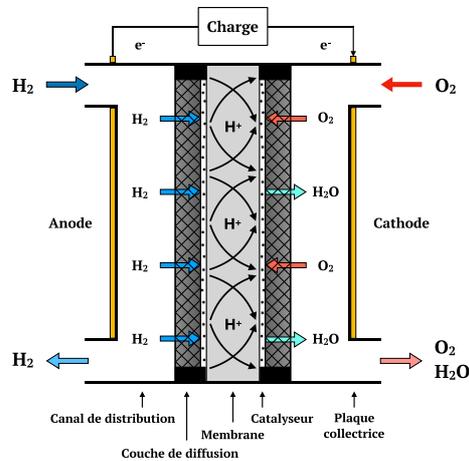
La pile à combustible est un convertisseur électrochimique d'énergie. Ayant un fonctionnement semblable à celui d'une pile électrique courante, ce dispositif se base sur une réaction d'oxydoréduction. Comme le montre la [Figure 2](#), trois composants interviennent dans ce processus, deux substances chimiques et un électrolyte qui joue le rôle de séparateur. De part et d'autre de cet électrolyte, à l'anode et à la cathode, des demi-réactions se produisent sur des sites actifs d'un catalyseur. Pour la pile à combustible à membrane échangeuse de protons (PEMFC), le dihydrogène et le dioxygène sont respectivement les molécules utilisées comme substances réductrice et oxydante.




---

<sup>1</sup> ISO 10303-226 "Automation systems and integration — Product data representation and exchange"

Le travail fourni par la réaction électrochimique se présente sous trois formes : un travail sous forme électrique par l'intermédiaire du circuit de la charge, un travail sous forme de chaleur dégagée lors des demi-réactions exothermiques et un travail mécanique par le dégagement des produits de réactions.



**Figure 2** Principe électrochimique d'une pile à combustible de type PEMFC

### 1.1.2 Histoire et émergence de la pile à combustible

La découverte de l'électrolyse inverse repose sur une succession de recherches et de publications scientifiques. Seuls les faits marquants du XVIII - XIX siècles sont présentés ci-dessous (Andújar and Segura, 2009).

- 1766** : Identification de l'élément hydrogène par Henry Cavendish.
- 1780** : Démonstration du potentiel d'électrode par Luigi Aloisio Galvani.
- 1799** : Publication de la pile voltaïque par Alessandro Volta.
- 1800** : Mise en évidence de l'électrolyse de l'eau par William Nicholson et Anthony Carlisle.
- 1802** : Phénoménologie de la pile à combustible par Humphry Davy.
- 1838** : Publication sur le processus de pile à combustible par Christian Schönbein.
- 1839** : Construction du premier modèle pile à combustible par William Grove.

Durant le XX siècle, de nombreuses recherches ont permis d'étudier différents types de pile à combustible. Pour finir, ces systèmes ont été exploités dans divers domaines spécialisés, notamment les programmes spatiaux Gemini<sup>1</sup> et Apollo<sup>2</sup>.

### 1.1.3 Différents types de piles à combustible

Le type de pile à combustible est tout d'abord défini par la nature de son électrolyte. Ces systèmes sont aussi caractérisés par leur température de fonctionnement ou bien encore

<sup>1</sup> Gemini 1-12 (1965-1966) : 3 PEMFC d'une puissance de 1 kW mise en parallèle (Burke, 2003).

<sup>2</sup> Apollo 1,7-17 (1967-1972) : 3 PEMFC d'une puissance de 2.3 kW mise en parallèle (Burke, 2003).

par leur tolérance à l’empoisonnement par monoxyde de carbone CO (Nehrir and Wang, 2009) ou par acétate de méthyle  $C_3H_6O_2$ . Les principaux types de piles à combustible et leurs caractéristiques intrinsèques sont détaillés dans le [Tableau 1](#).

**Tableau 1** Caractéristiques des différentes piles à combustible

Pile à combustible	Électrolyte	Catalyseur	Température d’usage	Tolérance
Alcaline (AFC)	Hydroxyde de potassium	Platine	80 – 260 °C	< 50 ppm CO
Hydruure de bore direct (DBFC)	Membrane polymérique	Or et platine	20 – 85 °C	< 50 ppm CO
Éthanol direct (DEFC)	Membrane polymérique	Métal commun	80 – 130 °C	< 50 ppm CO
Méthane direct (DMFC)	Membrane polymérique	Platine et ruthénium	50 – 120 °C	< 50 ppm CO
Acide formique (FAFC)	Membrane organique	Platine ou palladium	90 – 120 °C	< 50 ppm $C_3H_6O_2$
Acide phosphorique (PAFC)	Acide phosphorique liquide	Platine	200 °C	< 1 % CO
Membrane échangeuse de protons (PEMFC)	Membrane polymérique	Platine	< 80 °C	< 50 ppm CO
Membrane échangeuse de protons haute température (HT-PEMFC)	Membrane polymérique	Platine	120 – 200 °C	< 50 ppm CO
Carbonate liquide (MCFC)	Carbonate liquide	Métal commun	600 – 700 °C	Compatible CO
Oxyde solide (SOFC)	Oxyde solide	Métal commun	600 – 1000 °C	Compatible CO

### 1.1.4 Pile à combustible à membrane échangeuse de protons

#### Les applications portables

Les PEMFC élaborées pour des applications portables possèdent une capacité de 1 W à 5 kW avec un poids inférieur à 10 kg.

Un projet de recherche nommé HYPER (2012-2015) a démontré la capacité de la PEMFC en utilisation réelle. Le premier essai est un générateur de terrain d’une puissance de 100 W et le deuxième est un prolongateur d’autonomie de 500 W destiné à un drone aérien.

Actuellement, la durabilité de la pile et son coût global élevé (Kundu and Dutta, 2016) font partie des deux principaux verrous pour le développement des applications portables.

#### Les applications dans le domaine du transport

Les systèmes PEMFC pour le transport possèdent une capacité de 1 kW à 300 kW et un des objectifs de recherche est d’obtenir une durée de vie minimum est de 5 000 h (< 10% de pertes de performances), soit l’équivalent de 240 000 km pour un véhicule de tourisme (Kurtz et al., 2019).

Le plus célèbre démonstrateur est le chariot élévateur à fourche. De 2009 à 2017, on dénombre en cumulé un total de 21 838 chariots élévateurs à pile à combustible aux États-Unis (Devlin et al., 2018). Les transports en commun sont également un moyen de démonstration pour inciter au développement de la technologie. Les projets CUTE (2001-2006) et HyFLEET:CUTE (2006-2009) ont mis en service 27 et 47 bus à hydrogène en Europe, en Chine et en Australie. Les projets JIVE (2017-2022) et JIVE2 (2018-2023) comptent déployer 139 et 152 bus électriques à hydrogène répartis sur neuf villes européennes. Depuis 2018, le train à hydrogène est en plein essor en Europe, et précisément en Allemagne où un total de 41 trains a été commandé. Des tests sont en cours depuis 2019 aux Pays-Bas pour la démonstration de maturité technologique, de disponibilité et de fiabilité.

Le véhicule à PEMFC est actuellement proposé par certains constructeurs automobiles, malgré tout, sa popularité reste faible. En 2018, 2 300 voitures à piles à combustible ont été vendues aux États-Unis, contre 361 307 voitures électriques ou hybrides. Récemment, une volonté de changement vers les voitures à pile à combustible a été exprimée par le gouvernement chinois<sup>1</sup>. Les objectifs étaient d'atteindre 30 000 voitures à pile à combustible en 2019, et parvenir à un parc de 100 000 unités d'ici 2025.

En collaboration avec Toyota, l'université marine et de technologie de Tokyo, Kaiyōdai, développe actuellement (2019-2020) des générateurs électriques compacts destinés à alimenter des bateaux de loisirs, des camions et des trains.

### **Les applications stationnaires**

Les PEMFC destinés aux applications stationnaires sont caractérisés par des puissances qui varient de 0,5 kW à 2 MW, leur objectif de durée de vie est d'atteindre les 40 000 h.

Démarrées en 2009, trois projets de PEMFC stationnaires ont démontré la viabilité économique et technique possible du système (EERE:U.S., 2016). Les objectifs sont de fournir une alimentation de secours pour les sites critiques des pylônes de téléphone cellulaire et les réseaux de services publics. À la suite de ces démonstrations, plus de 7 600 groupes électrogènes à hydrogène de types commerciaux ont été déployés sur des sites critiques, tels que les hôpitaux, les centres de données, et les stations de police ou de pompier.

Sur un fonctionnement en cogénération, la chaleur générée est récupérée pour chauffer des maisons individuelles ou des locaux d'entreprises. Débutée en 2009 au Japon, la commercialisation de pile résidentielle a atteint en 2015 plus de 50 000 unités vendues. Le principal fournisseur de gaz du pays entrevoit d'atteindre les 300 000 unités d'ici 2020.

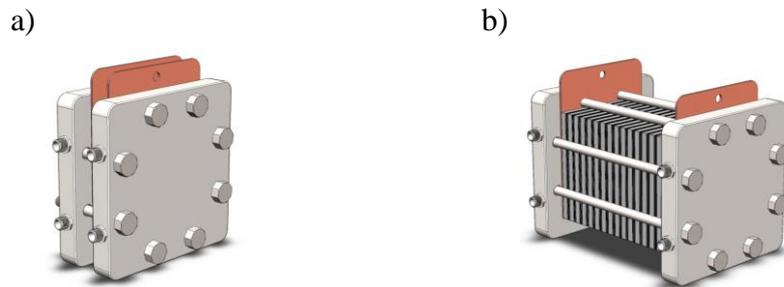
## **1.2 Composants du système pile à combustible type PEMFC**

La pile à combustible est un assemblage de composants élémentaires. Il s'agit de l'assemblage membrane électrode ou MEA (« Membrane Electrode Assembly ») et des plaques bipolaires. Son dimensionnement dépend, en autres, de son application et de la puissance requise. Deux paramètres sont essentiels à la conception du système : le nombre de

---

<sup>1</sup> Ministère de la finance de la République Populaire de Chine visité le 22 avril 2019 sur « [jjs.mof.gov.cn/zhengwuxinxi/zhengcefagui/201903/t20190326\\_3204190.html](http://jjs.mof.gov.cn/zhengwuxinxi/zhengcefagui/201903/t20190326_3204190.html) »

cellules et la surface active. La force électromotrice, appelée communément la tension à l'OCV (« Open Cell Voltage ») est obtenue par l'équation de Faraday. La tension théorique maximale délivrée par la réaction, sous des conditions de formation d'eau liquide à la cathode est calculé à  $E_{(l)}^0 = 1,253 \text{ V}$ . Pour répondre à des besoins de haute puissance, les cellules  $N_{cell}$  sont reliées électriquement en série soit  $V_{N_{cell}, H_2O(l)} = 1,253 \times N_{cell}$ . Cette configuration est illustrée sur la [Figure 3](#). La capacité à fournir de forts courants dépend de la surface de la membrane. L'augmentation de la surface active permet à l'énergie disponible du système PEMFC d'être dépensée plus rapidement, mais ne modifie pas la quantité d'énergie disponible.

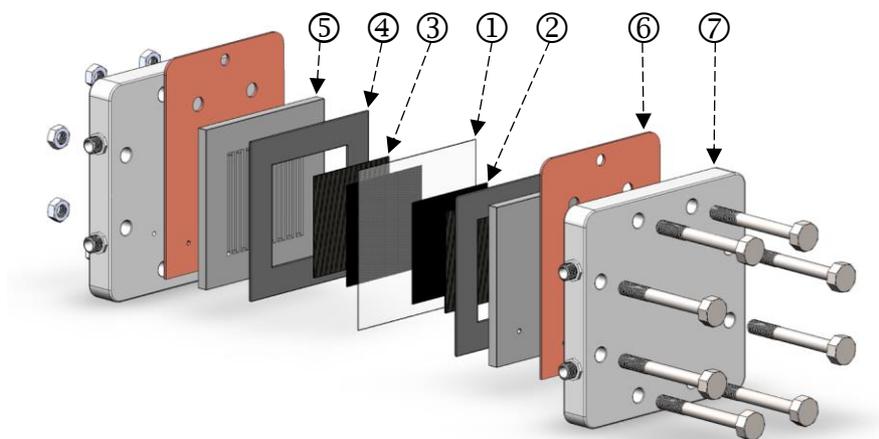


**Figure 3** Vues d'une (a) monocellule et d'un (b) empilement de cellules

Pour une puissance donnée, deux configurations sont donc concevables, une monocellule avec une large surface active ou un empilement de cellules dont les surfaces sont moins importantes. D'autres critères peuvent être considérés lors du dimensionnement, tels que la masse, les limites structurelles des composants, l'acheminement des fluides, la régulation en température, le coût de fabrication, ou encore le rendement du système.

### 1.2.1 Cœur de pile

Au total, sept composants constituent le cœur de pile, ces éléments sont indiqués sur la [Figure 4](#) et sont explicités au [Tableau 2](#).



**Figure 4** Vue éclatée d'une monocellule

**Tableau 2** Caractéristiques des différents composants de la pile à combustible

Composant	Fonctions	Matière possible	Détail
Membrane échangeuse de protons ①	Permettre la circulation des protons Sépare les espèces chimiques anodiques et cathodiques Être stable face à un milieu oxydant Avoir une résistance mécanique élastomère	Copolymère fluoré ou communément Nafion® par la société DuPont	Faible et forte épaisseur <sup>1</sup> 20-50 µm pour efficacité ↗ 280-381 µm pour résistance ↗
Couche catalytique ou électrode ②	Améliore les réactions électrochimiques Augmente la surface de réactions si dispersion uniforme sur le support carbone Avoir une résistance dans des milieux acides et corrosifs Avoir une forte réactivité de liaison avec l'hydrogène	Alliage de platine, palladium, iridium, argent, cuivre, cobalt, et autres	Concentration de 5% à 80% avec un support carbone <sup>1</sup>
Couche de diffusion ou GDL ③	Garantis la diffusion uniforme des gaz réactifs Assure le transport de l'eau produite vers les canaux pour son évacuation et assure le passage des électrons Conserve une humidité à la surface de la membrane Conduit la chaleur générée par les réactions électrochimiques	Tissu de carbone Papier carbone Feutre de graphite	Caractéristique hydrophobe
Joint d'étanchéité ④	Assure le confinement des fluides Protège du phénomène d'écrasement de la membrane	Téflon™, silicone, caoutchouc, polyester	Résistant à la température
Plaque polaire ou bipolaire ⑤	Alimente la couche de diffusion en gaz à l'aide des canaux de distribution Permette la régulation de température par le passage d'un fluide calorifique Assure le pont électrique d'une cathode à l'anode suivante	Acier inoxydable, carbone, composite	Revêtement anticorrosion des canaux de distribution, chromium-nitride (Haghighat Ghahfarokhi et al., 2016) Différentes géométries possibles
Collecteur ⑥	Collecte le courant électrique aux extrémités pile	Cuivre	
Plaque de compression ⑦	Maintien l'ensemble de la pile Comprime suffisamment pour éviter les fuites Permet l'entrée et la sortie des fluides Permet l'entrée et la sortie du fluide calorifique	Graphite, garolite®	Privilégier le plus grand nombre de vis et une géométrie de contact hexagonale (Dey et al., 2019)

<sup>1</sup> Marchand Fuel Cell Store visité le 22 avril 2019 sur « fuelcellstore.com »

## Mécanisme permettant la circulation des protons dans la membrane

Le téflon contenu dans la membrane est hydrophobe et le groupe acide sulfurique est hydrophile. Lorsque les groupes hydrophiles se gorgent en eau, la membrane devient plus conductrice aux protons  $H^+$ . Cette séparation de phases hydrophobe/hydrophile crée des voies humides (Satterfield, 2007) qui facilitent le passage des protons d'un site acide à un autre, et par conséquent de l'anode à la cathode. Le mécanisme qui induit le mouvement des ions s'appelle la chimiosmose. Au contact du catalyseur, la réduction du dihydrogène à l'anode provoque la libération de deux électrons. Pour retrouver un équilibre, l'électron migre vers la cathode. Cette chaîne de transport agit par la suite comme une pompe à protons pour aspirer ces derniers au travers de la membrane. Lorsque l'humidité de la membrane diminue, la résistance protonique augmente ce qui réduit les déplacements des ions. De plus, la membrane perd en résistance élastique, ce qui facilite les déformations et les déchirements.

Des études récentes proposent la conception de membrane avec des matériaux différents pour diminuer le coût financier (Frèlon et al., 2019). Ou encore, l'intégration de nano composite pour l'amélioration des performances (Charradi et al., 2019).

## Réactions aux sites catalytiques

Le catalyseur est déposé sur un support en carbone, celui-ci joue le rôle d'extendeur électrique en permettant de réduire les limites des trois phases anode/électrolyte/cathode. Le processus mis en œuvre ici est la chimisorption (Sheng et al., 2010), c'est-à-dire l'adsorption au point de contact des molécules et du catalyseur. La réduction du dioxygène et le produit de l'eau mettent en jeu un nombre d'électrons plus important que la réaction anodique. Lorsque la quantité de platine n'est pas suffisante à la cathode, la liaison du dioxygène ne se brise pas sur l'électrode et réagit directement avec le proton d'hydrogène (Lyons, Teliska, Baker & Pietron, 2005). Cette situation peut générer par réactions successives de l'acide hydrofluorique (Sethuraman et al., 2008) qui va irrémédiablement dégrader la surface de la membrane.

Malgré ces phénomènes, pour des raisons économiques et stratégiques, des études récentes tendent à diminuer la quantité de platine voire à utiliser des matériaux alternatifs (Chandran et al., 2018; Kongkanand et al., 2016).

## Couche de diffusion

Les transports des réactifs et produits au niveau de la GDL sont assurés par des forces de capillarités. Ces forces sont générées par la différence de pression entre les phases liquide et gazeuse, et résultent d'un gradient en concentration d'eau (Pasaogullari and Wang, 2004). Or, pour de hautes densités de courant, la production d'eau et sa condensation à la surface des sites catalytiques de la cathode génèrent une barrière naturelle au transport du dioxygène. Deux types de matériaux sont couramment utilisés pour la couche de diffusion, du papier de carbone ou du tissu de carbone tressé. Ces derniers sont recouverts par une couche de téflon afin d'augmenter leurs caractéristiques hydrophobes et faciliter l'évacuation des gouttelettes d'eau (Mortazavi and Tajiri, 2014). Cependant, une présence excessive de téflon augmente la résistance électrique (Su et al., 2016), de plus, celui-ci se dégrade au cours du temps.

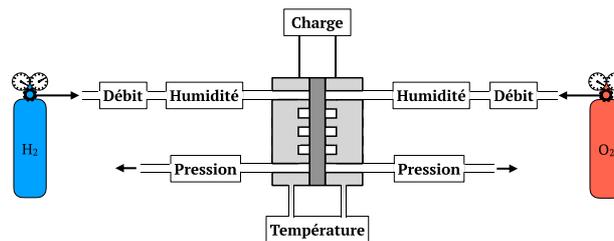
Une étude récente propose la conception de couche de diffusion gradée ayant des tailles de pores spécifiques à l'aide de fibres nanoscopiques (Balakrishnan et al., 2019). Ce développement vise à améliorer nativement l'évacuation de l'eau et la conductivité thermique pour finalement accroître les performances du système.

### 1.2.2 Actionneurs et capteurs

Le fonctionnement du système PEMFC nécessite plusieurs auxiliaires qui auront pour fonction de contrôler différentes variables. Ces fonctions sont illustrées à la Figure 5 :

- (A) Le **contrôle des débits** pour l'acheminement des gaz réactifs.
- (B) Le **contrôle des pressions** anodique et cathodique pour la réponse en tension.
- (C) Le **contrôle de l'humidité relative** des gaz réactifs pour la teneur en eau de la membrane et des canaux de distribution.
- (D) Le **contrôle de la température** du corps de pile.
- Le **contrôle de la charge électrique**.

La charge qui pilote le courant électrique est un auxiliaire en aval de pile. Elle représente une perturbation pour le système et est une variable mesurable.



**Figure 5** Différents espaces de commandes de la pile à combustible

#### A. Contrôle du débit en gaz réactifs

Le débit fluidique des gaz est la première variable à réguler. Les gaz réactifs circulent dans les canaux de distribution et influencent l'évacuation de l'eau. Les débits consommés sont définis par l'équation (91, page XXI) pour l'hydrogène et (73, page XIX) pour l'oxygène. Un nombre stœchiométrique ou rapport d'excès en réactifs ( $\lambda_{H_2}$  et  $\lambda_{O_2}$ ) est appliqué aux débits. Les dynamiques électrochimiques sont plus rapides ( $< 1$  ms) que les dynamiques fluidiques ( $< 1$  s), par conséquent les valeurs de rapport d'excès doivent être supérieures à l'unité pour éviter tout phénomène d'appauvrissement. Ils doivent tout de même être contenus afin d'éviter une sur-stœchiométrie, qui aurait pour conséquence une dilapidation des gaz réactifs et une évacuation forcée du contenu en eau de la pile.

##### A1. Compresseur

Un compresseur sert à augmenter la pression d'un fluide. En supposant la présence de fluide incompressible, la différence de pression entre l'entrée et la sortie du compresseur permet

l'estimation du débit de gaz. Connaissant la pression d'entrée, la variable recherchée devient alors la pression de sortie du compresseur pour atteindre la consigne en débit voulue. Cette pression dépend directement de la vitesse du rotor et donc de la tension appliquée au moteur. Ainsi une courbe caractéristique contenant le ratio de pression et du débit peut être construite. Le temps de réponse à 5% d'une consigne de 10 % à 90 % du débit maximum d'un tel organe est de 5 s pour une pile automobile de 75 à 150 kW (UQM, 2018).

	Variable de commande	Variable à contrôler
(Han et al., 2019)	Tension du moteur	Débit d'air

## A2. Régulateur de débit massique numérique

Un régulateur de débit massique (« Mass Flow Controller » ou MFC) est un organe calibré qui permet un contrôle précis du débit. Un capteur de débit est mis en parallèle du circuit fluidique primaire et un contrôleur pilote une valve de nature fermée en respectant une consigne donnée. Le temps de réponse d'un tel organe pour une pile de 1 kW est inférieur à 2 s pour un fonctionnement de 0 % à 100 % du débit maximum (MKS, 2018a), la précision quant à elle est de  $\pm 1$  % du débit maximum.

## B. Contrôle des pressions dans les canaux de distribution

La pression au sein des canaux influence les performances de la pile par l'intermédiaire des pressions partielles des gaz réactifs, elle modifie la cinétique des réactions au niveau des électrodes de platine et le transfert de masse (Zhang et al., 2013). La Figure 6 montre que la régulation de la pression anodique ou cathodique peut être réalisée par trois actionneurs : un compresseur, un régulateur de pression d'entrée ou par l'intermédiaire d'un couple de régulateurs de débit et de contre-pression. Pour conserver l'intégrité physique de la membrane, la différence de pression anode/cathode doit être relativement faible, voire nulle. Cette condition opératoire doit être vérifiée, quelles que soient les variations fluidiques qui pourraient résulter d'un changement de courant ou de la présence d'un défaut.

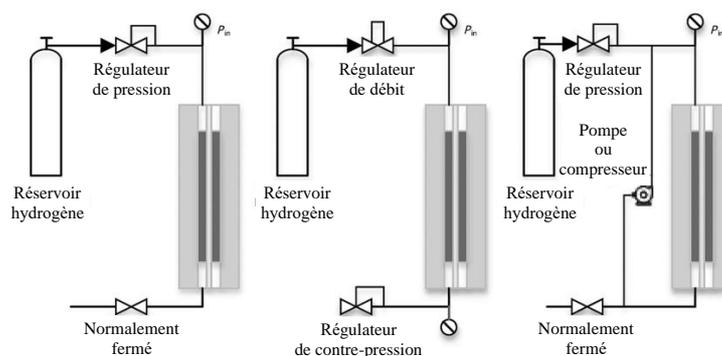


Figure 6 Différentes régulations en pression (Li et al., 2015)

## B1. Compresseur

Les caractéristiques sont équivalentes au contrôle du débit.

### B2. Régulateur de pression numérique

Le régulateur de pression numérique est accompagné d'un contrôleur proportionnel qui agit sur une valve mécanique. Le temps de réponse d'un tel organe pour une pile de 1 kW est inférieur à 1 s pour un fonctionnement de 0 % à 100 % de la pression maximale (MKS, 2018b), la précision est de  $\pm 0,2$  % de la pression maximale.

### B3. Régulateur de contre-pression

Le transducteur de pression électropneumatique est un diaphragme obstruant qui est mis à l'équilibre avec la pression de la pile à l'aide d'une pression tierce. Cet actionneur assure l'application de la commande à l'aide d'un champ électrique qui agit sur le diaphragme. Le temps de réponse de 10 % à 90 % de la pression maximale d'un tel organe est de 0.3 s à 2.5 s en fonction du volume traité (CONOFLOW, 2004).

## C. Contrôle de l'humidité relative

L'auto-humidification d'une membrane assure la présence d'eau pour une mobilité accrue des protons. En revanche deux cas de figure peuvent être problématiques : la première est une pile qui fonctionne à faible courant donc avec une production d'eau insuffisante, la deuxième est le cas contraire c'est-à-dire une pile qui fonctionne à fort courant, mais avec une présence d'eau obstruant les gaz réactifs. Deux types d'actionneurs autorisent le pilotage de l'humidité relative (RH) : les injecteurs d'eau et les actionneurs de température pour le point de rosée. D'autres éléments peuvent éventuellement agir indirectement sur l'indice RH, tels que les actionneurs de températures pour l'évaporation ou l'intensité du courant de la charge.

### C1. Injecteur d'eau

L'injection d'eau est réalisée par une combinaison de pompe à eau et de buses d'injection au sein d'un mélangeur en amont de pile. Plusieurs configurations existent, comme l'injection directe sur la membrane ou l'injection en amont d'un serpentin (Evans, 2003). Une plaque chauffante peut être rajoutée pour s'assurer de l'évaporation des gouttelettes d'eau.

	Variable de commande	Variable à contrôler
(Wu and Zhou, 2016)	Le débit d'eau injecté	L'humidité relative

### C2. Actionneurs de température pour le point de rosée

La gestion du point de rosée est assurée par la différence de température entre un ballon d'humidification et un canal de distribution. La différence de température adéquate est estimée par l'équation de Clapeyron. Le gaz sec est injecté dans un bain d'eau à une température donnée ce qui amène la saturation du gaz en eau. Le gaz humide à 100 % d'humidité relative passe ensuite au travers des conduites thermorégulées. Suivant la température, la vapeur d'eau peut se condenser ou se vaporiser. La température des canaux de distribution et de la pile est la même afin d'éviter un second étage de transformation.

	<b>Variable de commande</b>	<b>Variable à contrôler</b>
(Evans, 2003)	La température des conduites thermorégulées	L'humidité relative

## D. Contrôle thermique

L'organe de chauffe est généralement utilisé au démarrage de la pile, lorsque cette dernière ne produit pas suffisamment de chaleur. Le refroidissement est effectué sous forme de convection, par ventilation forcée ou par la circulation d'un fluide caloporteur. Le choix de régulation varie en fonction du dimensionnement de la pile :

### D1. Mono-cellules

Le dégagement de chaleur des mono-cellules est faible, dans ce cas de figure, la régulation de température est assurée par des cartouches chauffantes et une ventilation forcée. Les temps de réponse en température vont dépendre des matériaux et des échanges thermiques entre composants. Quoiqu'il en soit, les variations de température sont les phénomènes qui ont les dynamiques les plus lentes des systèmes PEMFC.

### D2. Empilement de cellules

Les empilements de cellules dégagent davantage de chaleur, la température doit être régulée par un système de refroidissement liquide associé à un radiateur et une ventilation forcée.

	<b>Variable de commande</b>	<b>Variable à contrôler</b>
(Wu and Zhou, 2016)	Le débit d'eau injecté La vitesse de ventilation	La température de pile

Une synthèse des différents commandes et actionneurs agissant sur le cœur de pile est donnée au [Tableau 3](#).

**Tableau 3** Synthèse des variables de contrôle et des actionneurs pour le cœur de pile

<b>Nature</b>	<b>Variable à contrôler</b>	<b>Actionneurs</b>
<b>Fluidique</b>	Stœchiométrie	Contrôleur de débit massique (J. Zhang et al., 2008; Zhang et al., 2006) Contrôleur de débit massique, courant de charge et valve de sortie (Danzer et al., 2009)
	Pressions à la membrane	Régulateur de pression (Matraji et al., 2012; Wu and Zhou, 2016)
	Humidité relative	Bouilleur et préchauffeur (Arif et al., 2008; Kim and Hong, 2008) Compresseur d'air (Kunde et al., 2010) Contrôleur de débit massique (Damour et al., 2015)
<b>Thermique</b>	Température	Échangeur de chaleur (Li et al., 2006) Pompe de refroidissement liquide (Fang et al., 2017) Contrôleur débit massique (Sun et al., 2005) Compresseur d'air (Kunde et al., 2010)
<b>Électrique</b>	Puissance	Régulateur de pression (Karimi, 2012; Wu and Zhou, 2016, p. 201) Régulateur de contre-pression (Zhang et al., 2009)

## 1.3 Défauts du système pile à combustible type PEMFC

Un défaut est remarquable par un écart non voulu d'au moins une grandeur physique caractéristique du système par rapport à un état en fonctionnement normal ou acceptable (Edwards et al., 2010). Les défauts peuvent avoir lieu au niveau d'un composant, au niveau du cœur de pile ou au niveau d'un auxiliaire ou sous-système. Ces phénomènes apparaissent généralement suite à une mauvaise gestion des variables de commandes ou peuvent être dus à une anomalie d'assemblage ou de fabrication. L'impact d'un défaut peut aller d'une réduction minimale des performances à une dégénérescence pouvant aboutir à une défaillance du système. Les réductions de performances peuvent être permanentes ou non. On parle alors respectivement de dégradations ou de perturbations réversibles nommées défauts. Dans ce travail, seuls les défauts qui concernent le cœur de pile seront étudiés.

### 1.3.1 Dynamiques des défauts

Chaque défaut peut être défini suivant une dynamique spécifique qui correspond à sa période d'établissement. Les défauts les plus courants sont donnés au [Tableau 4](#).

**Tableau 4** Défauts du cœur de pile les plus courants

	Défaut	Dynamique	Observations
(Kakati et al., 2016)	Empoisonnement aux polluants	$10^1 - 10^5$ s	Présence d'impuretés, de polluants dans les gaz réactifs
(Dijoux et al., 2017)	Noyage	$10^0 - 10^3$ s	Obstruction en eau des canaux de distribution ou réduction des sites catalytiques actifs par la présence d'eau
(Barbir, 2005)	Assèchement	$10^0 - 10^3$ s	Augmentation de la résistance membranaire par la perte en humidité
(Yousfi-Steiner et al., 2009)	Sous-alimentation	$10^{-3} - 10^1$ s	Compensation du courant par le carbone et corrosion du support carbone
(Silva et al., 2014)	Court-circuit	$10^{-6} - 10^{-2}$ s	Forte consommation en gaz réactifs

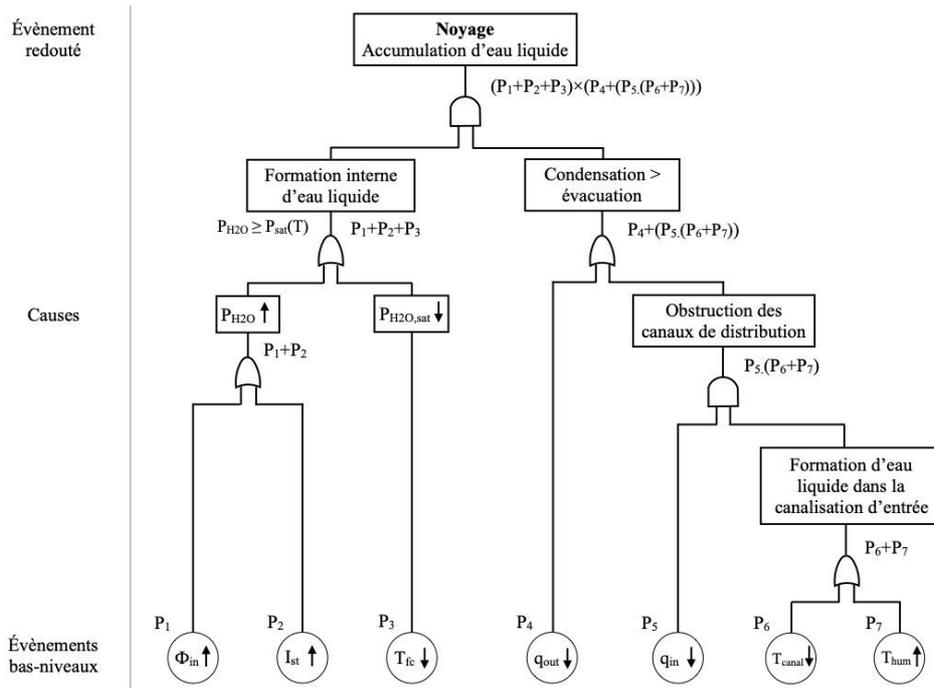
La réactivité du contrôleur doit prendre en compte ces dynamiques afin de réduire le temps d'exposition aux dégradations. L'étude présentée ici considère les défauts de noyage et d'assèchement de membrane. Il s'agit des défauts les plus couramment observés et qui induisent des effets clairement perceptibles. Les défauts de court-circuit et de sous-alimentation nécessitent des outils et matériels fonctionnant à haute fréquence, ce qui est une contrainte matérielle importante.

### 1.3.2 Conditions de défauts du système

L'apparition de ces défauts est étroitement liée à la combinaison d'événements ou de conditions de fonctionnement. L'analyse par les arbres de défaillance est une approche déductive qui permet la mise en relation de l'apparition d'un défaut à une combinaison de

conditions de bas niveau, il s'agit d'une représentation graphique décroissante. Un exemple sur le défaut de noyage cathodique est décrit dans les travaux de [Yousfi Steiner et al. \(2012\)](#) et repris par [Dijoux \(2019\)](#), l'arbre de défaillance correspondant est présenté à la [Figure 7](#).

Le bloc rectangulaire haut représente l'événement de haut niveau redouté, autrement dit le défaut. Les blocs rectangulaires inférieurs représentent des événements intermédiaires qui sont les causes menant à l'apparition du défaut. Ces causes s'articulent autour de deux portes logiques,  $\text{ET}$  (ET) et  $\text{OU}$  (OU). Enfin, les blocs circulaires représentent les conditions de bas niveau associé aux grandeurs caractéristiques du système.



**Figure 7** Arbres de défaillance menant au défaut de noyage ([Dijoux, 2019](#))

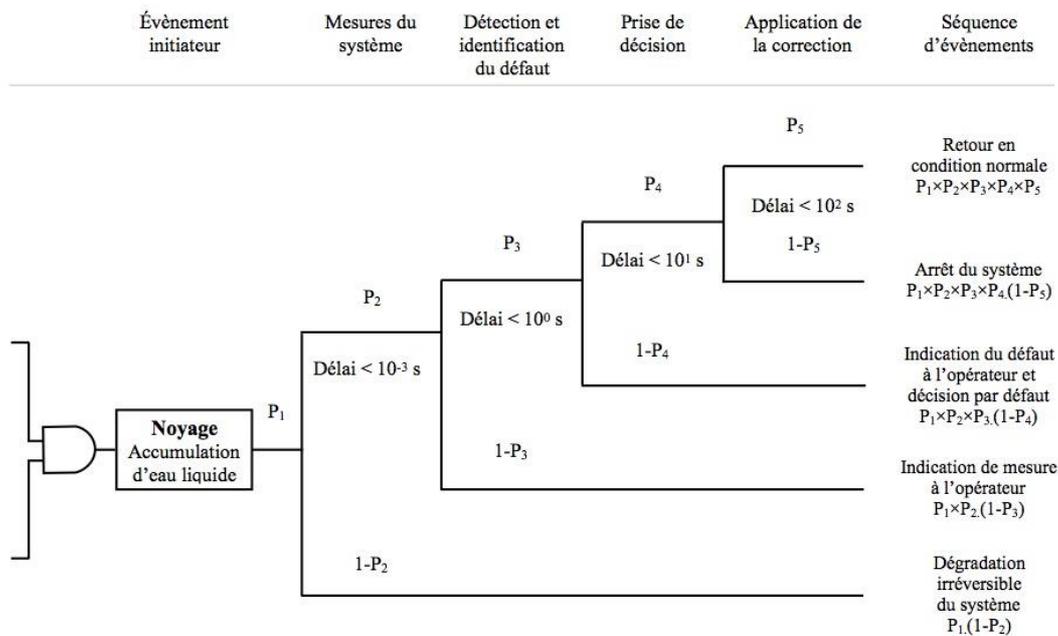
**Tableau 5** Désignation de l'arbre de défaillance pour le défaut de noyage

$\phi_{in}$	Humidité relative en entrée
$I_{st}$	Courant de pile
$P_{H_2O}$	Pression de la vapeur d'eau
$P_{H_2O,sat}$	Pression saturante en eau
$q_{in}$	Débit d'entrée
$q_{out}$	Débit de sortie
$T_{canal}$	Température de canalisation
$T_{fc}$	Température de pile
$T_{hum}$	Température du ballon d'humidification

Ce graphique peut être accompagné de définitions probabilistes afin de quantifier la probabilité d'occurrence de l'événement redouté. Permettant ainsi d'obtenir la fréquence d'apparition de la défaillance, il s'agira ici d'une valeur dénommée  $F_{défaut}$ .

### 1.3.3 Les conséquences des défauts du système

Les conditions amenant l'apparition du défaut sont ainsi clairement identifiées. Une fois le défaut mis en place, plusieurs événements peuvent avoir lieu. De telles actions sont organisées dans un arbre d'évènements, appelé arbre de conséquences. Le cas d'un défaut de noyage est présenté à la Figure 8. Ce graphique peut également être accompagné de définition probabiliste pour quantifier la probabilité de chaque scénario ou de chaque séquence d'évènements.

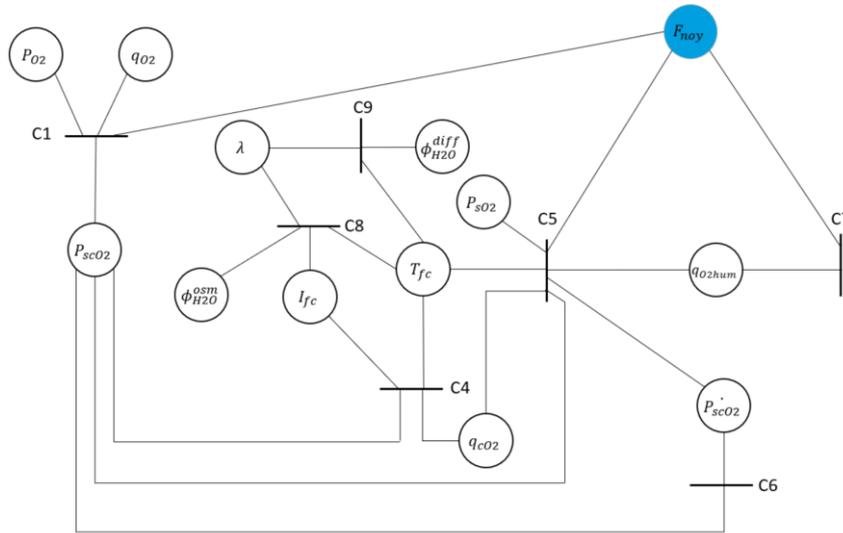


**Figure 8** Arbre d'évènements à la suite de l'apparition du défaut de noyage

Un arbre d'évènements sert à anticiper les décisions à prendre pour ramener le système à un fonctionnement normal. Ce retour peut être entaché de perturbations supplémentaires qui sont étroitement liées à la nature du défaut encouru.

### 1.3.4 Perturbations de fonctionnements du défaut

Pour identifier les perturbations de fonctionnement, un outil d'analyse structurelle permettant la visualisation de ces relations a été proposé dans les travaux de [Dijoux \(2019\)](#). Celui-ci est basé sur la mise en place d'un graphe de structure construit à partir d'équations décrivant les fonctionnalités du système étudié. Le graphe de structure traitant le défaut de noyage est représenté à la [Figure 9](#).



**Figure 9** Graphe de structure pour le défaut de noyage (Dijoux, 2019)

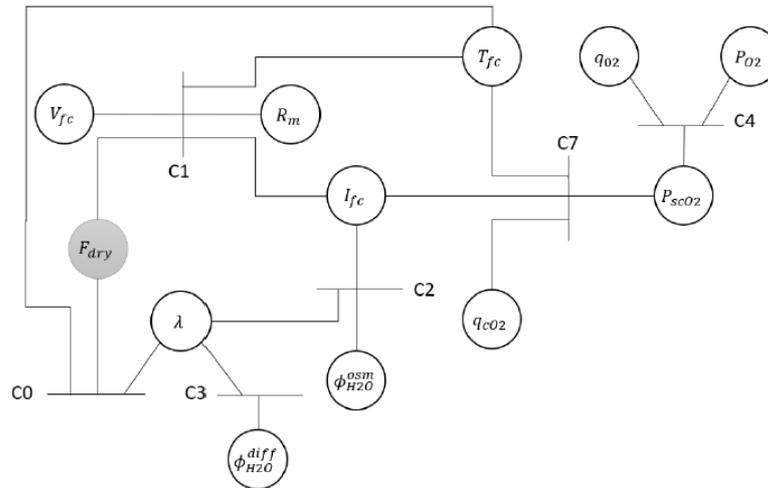
**Tableau 6** Désignation du graphe de structure pour le défaut de noyage

$\lambda$	Contenu en eau de la membrane	C1	Contrainte du débit de gaz par la différence de pression entrée/sortie
$\phi_{H_2O}^{diff}$	Flux de diffusion de l'eau dans la membrane	C2	Contrainte de la pression partielle en eau par la pression totale tolérée
$\phi_{H_2O}^{osm}$	Flux électro osmotique de l'eau dans la membrane	C3	Contrainte de l'eau injectée par la quantité nécessaire
$I_{fc}$	Courant de pile	C4	Contrainte du débit réagit par l'évacuation des gaz ou du courant
$F_{noy}$	Défaut de noyage	C5	Contrainte de la capacité hydraulique par le volume de la couche de diffusion et des débits
$P_{O_2}$	Pression d'oxygène	C6	Contrainte de la dynamique de la pression partielle par la différence de débit entrée/sortie
$P_{sc,O_2}$	Pression partielle de l'oxygène à la couche catalytique	C7	Contrainte de la perméabilité de la couche de diffusion par le défaut de noyage
$P_{s,O_2}$	Pression de sortie d'oxygène	C8	Contrainte du flux électro osmotique par la teneur en eau de la membrane et du courant
$q_{c,O_2}$	Débit consommé d'oxygène	C9	Contrainte du flux diffusif par la répartition de l'eau dans la membrane
$q_{O_2}$	Débit d'oxygène		
$q_{O_2,um}$	Débit d'oxygène humidifié		

Le graphe de structure montre que la variable  $F_{noy}$  modélisant le défaut de noyage intervient directement au niveau de la GDL (C5 et C7) et des canaux de distribution (C1). Ce défaut influence, de manière différente, la perméabilité de la membrane, le volume de gaz contenu dans la membrane, la pression de sortie d'hydrogène, la pression et le débit d'entrée en oxygène. Ceci est valable à la condition que ces variables ne soient pas régulées.

Il apparaît aussi qu'en vue d'une atténuation de ce défaut, l'utilisation de variables telle que la température provoque un effet multilatéral (C4, C5, C8 et C9) déstabilisant potentiellement le fonctionnement normal du système. Ces déstabilisations interviennent par les évolutions des grandeurs caractéristiques liées aux contraintes mises en jeu par l'apparition ou l'atténuation du défaut.

La même démarche est entreprise pour le défaut d'assèchement de la membrane. Le graphe de structure s'y référant est donné à la [Figure 10](#).



**Figure 10** Graphe de structure pour le défaut d'assèchement de la membrane (Dijoux, 2019)

**Tableau 7** Désignation du graphe de structure pour le défaut d'assèchement de la membrane

$V_{fc}$	Tension de la pile	C3	Contrainte sur le maximum d'eau transporté par le flux diffusif
$R_m$	Résistivité de la membrane	C4	Contrainte sur la pression minimale dans la circulation dans les canalisations
$F_{dry}$	Défaut d'assèchement de la membrane	C5	Contrainte exprimant la pression totale limite dans le circuit
C0	Contrainte sur les contenances limites en eau de la membrane	C6	Contrainte sur le mélange réactif/vapeur d'eau
C1	Contrainte sur la résistivité ohmique cellulaire maximale	C7	Contrainte sur le courant limite pouvant être demandé par la charge
C2	Contrainte sur le maximum d'eau transporté par le flux osmotique	C8	Contrainte sur l'équilibre thermodynamique vapeur/liquide entre la GDL et la membrane

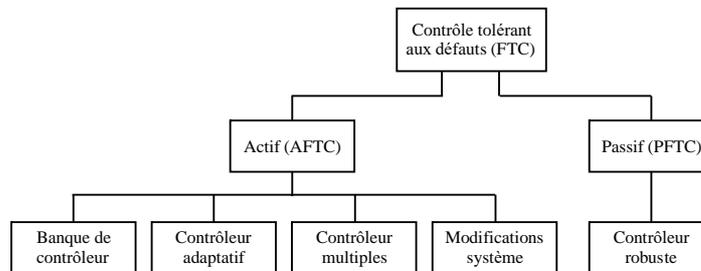
L'apparition du défaut d'assèchement de la membrane induit des perturbations sur deux contraintes (C0 et C1), le contenu en eau et la résistivité électrique de la membrane. De même pour son atténuation, l'utilisation d'une incrémentation en courant, ou la modification de la température influent plusieurs contraintes (C1, C2, C7) qui perturbent d'autres variables associées.

## 1.4 Stratégie de contrôle tolérant aux défauts actif

Plusieurs stratégies de contrôle ont été appliquées pour le système pile à combustible avec des objectifs différents :

- L'économie de la consommation d'hydrogène ou de la consommation électrique des auxiliaires.
- L'amélioration de la puissance électrique.
- Le maintien du système sur fonctionnement normal.

Parmi les approches permettant d'améliorer la fiabilité du système, on retrouve le contrôle tolérant aux défauts (« Fault Tolerant Control » ou FTC). La stratégie FTC vise à augmenter la résilience du système en assurant un fonctionnement optimal ou suboptimal malgré l'apparition de défauts. Une stratégie de contrôle FTC est une boucle fermée susceptible de tolérer un certain nombre de fonctionnements défectueux tout en garantissant les performances désirées et la stabilité du système (L. Zhang et al., 2008).

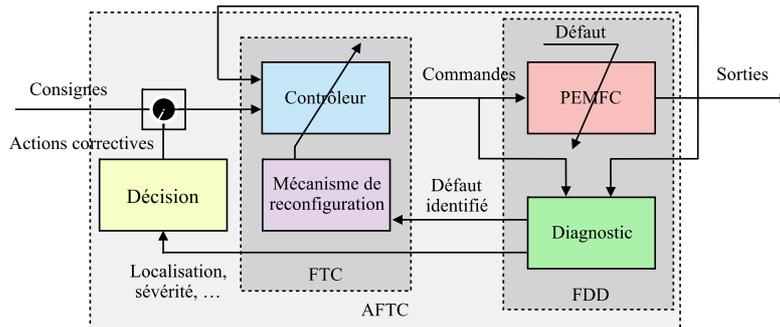


**Figure 11** Différentes approches du contrôle dans la stratégie FTC

Deux classes se reflètent dans cette stratégie, la classe passive et la classe active. L'approche passive (« Passive FTC » ou PFTC) se focalise sur la capacité de robustesse d'un contrôleur. Ainsi en présence de défauts, le contrôleur est préalablement conçu pour gérer ces situations. Le contrôleur assure seul le retour du système sur un fonctionnement nominal. À l'opposé de la stratégie PFTC, l'approche active (« Active FTC » ou AFTC) fait appel à la reconfiguration du contrôleur en fonction du défaut encouru. Illustré sur la [Figure 12](#), un outil de détection et de diagnostic de défaut (« Fault Detection and Diagnosis » ou FDD) autorise l'estimation du type de défaut. D'autres estimations peuvent également avoir lieu, telles que la sévérité du défaut ou sa localisation. De manière générale, trois modules composent une stratégie AFTC :

- Un **module de diagnostic** pour détecter et isoler la nature du défaut.
- Un **module de décision** pour gérer les actions correctrices, déterminer les variables à contrôler et leurs intensités.
- Un **module contrôleur** reposant sur un contrôleur reconfigurable qui assure le respect de la consigne, quel que soit le défaut mis en jeu.

Une stratégie AFTC en ligne et en temps réel impose le choix de modules compatibles avec un fonctionnement en temps réel sur le système.



**Figure 12** Composantes d'une stratégie AFTC

### 1.4.1 Diagnostic du défaut

Un module de diagnostic est généralement basé sur une approche non intrusive qui s'appuie sur l'observation et l'analyse de variables mesurées reflétant l'état de santé du système. Il délivre des informations, telles que l'état de santé du système (« State Of Health » ou SOH), la nature d'un défaut, sa localisation, la sévérité ou encore le temps d'exposition. Ces informations sont ensuite reprises par le module de décision. Un état de l'art des méthodes et outils de diagnostic a été réalisé par [Hissel & Pera \(2016\)](#). Parmi les méthodes existantes, certaines sont basées sur une génération de résidus par l'intermédiaire d'un modèle de fonctionnement sain du système ([Steiner et al., 2010](#)). D'autres se basent sur des analyses temporelles ou fréquentielles des variables mesurables ([Lu et al., 2019](#)).

Parmi les approches récentes, on retrouve [Bethapudi & al. \(2019\)](#) qui ont proposé une méthode de diagnostic d'une monocellule via une approche acoustique, ou encore [Ifrek & al. \(2019\)](#) qui ont proposé une méthode de diagnostic d'un stack via une méthode par champ magnétique. [Li et al. \(2019\)](#) ont proposé le diagnostic de 7 défauts par le biais d'outil de classification et de transformation basé sur les mesures de tension et/ou de champ magnétique. Le diagnostic de défauts additifs et multiplicatifs a été abordé par [Niane \(2018\)](#) à l'aide d'observateurs adaptatifs pour l'estimation d'états et de paramètres inconnus. [Jullian \(2019\)](#) a proposé un diagnostic robuste au vieillissement de la membrane basé sur un modèle multiphysique.

### 1.4.2 Prise de décision

Le module de décision permet de définir les actions à mettre en œuvre pour un retour en fonctionnement normal. Lorsque cela n'est pas possible, il assure une continuité de fonctionnement en mode dégradé. Il récupère les informations provenant du module de diagnostic et établit un suivi de santé du système. En fonction des différents résultats du diagnostic, le module de décision peut modifier temporairement ou de manière permanente la valeur de consigne, le point de fonctionnement, ou encore la variable de commande.

Une première méthode a été développée par [Dijoux \(2019\)](#) pour le recouvrement de défauts fugaces par l'intermédiaire de décisions rapides et le recouvrement de défauts persistant par l'intermédiaire de décisions permanentes.

### 1.4.3 Contrôle du système

Les actions correctives sont ensuite transmises du module de décision au contrôleur. Il existe 3 approches pour le module contrôleur :

- Une banque de contrôleurs est associée à un module de gestion qui adresse le contrôleur correspondant au défaut identifié. Cette approche offre une continuité des performances de contrôle et la compensation des perturbations provoquées par le défaut ([dos Santos et al., 2016](#)). Il s'agit d'une méthode systématique dans le cas de système à changement de dynamiques.
- Le contrôleur adaptatif, appelé également reconfigurable voit ses paramètres varier au cours du temps en fonction des performances de contrôle. De cette manière, il est capable de régler ses propres paramètres ou modifier sa propre loi de régulation afin de s'adapter aux changements dynamiques du processus.
- Le contrôleur par modèles multiples est l'association, par zone de fonctionnement, de plusieurs sous-modèles. Chaque modèle illustre un état du système, un défaut, et l'association de ces modèles cherche à définir la dynamique la plus complète du système. Un contrôleur est ensuite défini sur ce modèle global.

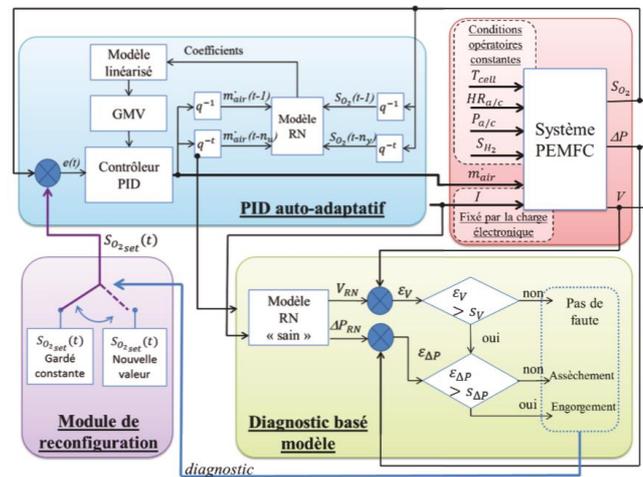
[Niane \(2018\)](#) a récemment répertorié dans sa thèse l'ensemble des commandes du système PEMFC, et à développer une commande du rapport d'excès d'oxygène via une méthode de stabilisation par rétroaction. [Daud et al. \(2017\)](#) ont réalisé un état de l'art des différentes méthodes de contrôle pour la stœchiométrie, dont le contrôle adaptatif. Cependant, peu de travaux y sont recensés sur des contrôleurs reconfigurables en fonction de l'état de santé de la PEMFC. [Wu & Zhou \(2016\)](#) ont proposé une banque de contrôleurs pour trois états du système, un état normal, un défaut de noyage et un défaut d'assèchement. Les lois de commandes ont été prédéfinies à partir d'un modèle paramétrique et ont été validées en simulation au sein d'une stratégie FTC. [Rotondo et al. \(2016\)](#) ont également traité la stratégie FTC, mais en considérant les défauts d'actionneurs. Une approche intéressante a été proposée sur une pile de type DMFC par [Keller et al. \(2017\)](#). Il s'agit de la mise en place d'une stratégie AFTC avec un contrôleur par commande prédictive multiple. Une pré-étude est effectuée sur les défauts pour définir les paramètres qui sont utilisés par le contrôleur MPC. Un contrôleur est donc défini pour chaque scénario de défaut. Plus récemment, [Abbaspour et al. \(2019\)](#) ont proposé une stratégie FTC avec FDD pour la compensation des défauts directement sur les signaux de commandes. Le développement de régulateurs reconfigurables en fonction de l'état de santé du système PEMFC est une problématique importante.

## 1.5 Positionnement de l'étude au sein de la stratégie AFTC

### 1.5.1 Contexte scientifique

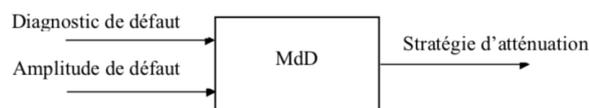
Les travaux présentés dans ce manuscrit concernent le verrou technologique de fiabilité. Ils s'inscrivent dans la continuité des travaux du laboratoire portant sur la stratégie AFTC par [Carole Lebreton \(2015\)](#) et [Etienne Dijoux \(2019\)](#).

Les premiers travaux concernent la mise en place d'une stratégie de contrôle tolérant aux défauts active composée de trois modules : un réseau de neurones (RN) pour le diagnostic par franchissement de seuil, une suite de commande stœchiométrique pour le recouvrement du défaut, et un contrôleur autoréglable neuronal. La stratégie a été validée expérimentalement sur les défauts de noyage, d'assèchement, et de défaillance actionneur MFC.



**Figure 13** Structure de contrôle AFTC mise en place par Lebreton (2015)

Les seconds travaux apportent un module de décision avancée pour l'atténuation des défauts. La première étape met en œuvre une méthode de logique floue pour l'analyse des résultats stochastiques du diagnostic. Le module permet ensuite la sélection de la variable de commande adéquate vis-à-vis du défaut. La seconde étape autorise la prise de décision rapide pour le recouvrement des événements fugaces. Si le défaut est persistant, la troisième étape autorise la prise de décision permanente pour une correction de manière durable. Ce module de décision a été également validé en temps réel et en ligne sur les défauts de noyage et d'assèchement de la membrane.



**Figure 14** Module de décision mis en place par Dijoux (2019)

## 1.5.2 Problématiques

Une problématique entière réside dans la définition du contrôleur, en effet, le contrôleur mis en place lors des études précédentes n'est pas de nature générique. Il nécessite une modélisation préalable en mode hors-ligne. Ce processus de définition est généralement effectué sur un modèle paramétrique qui doit être modifié suivant l'état de santé de la pile, les conditions opératoires de fonctionnement ou même les composants. Pour pallier cette contrainte, tout en répondant à une problématique importante qui est la stratégie AFTC, les travaux de recherche présentés visent au développement d'un contrôleur adaptatif permettant la prise en compte de l'état de santé du système.

Le contrôle adaptatif a pour avantage de compenser automatiquement toutes les variations dynamiques du système de sorte que le suivi de consigne reste optimal vis-à-vis d'un critère. Il prend en considération toute dégradation de performances au cours du temps, qu'elle soit liée à un changement de point de fonctionnement, à un défaut, un vieillissement ou même à une perturbation externe (Elba and Eren, 2016). De manière générale, les méthodes de commandes adaptatives conviennent principalement aux systèmes dont les dynamiques sont suffisamment connues. Ceci afin de définir correctement la dynamique du processus de contrôle. Elles requièrent ainsi une quantité d'informations et de mesures du système importantes (Zhang, 2010), or ces éléments font actuellement défaut pour le système PEMFC. D'autant que chaque système, de par la configuration des actionneurs ou des composants du cœur de pile, possède des caractéristiques qui lui sont propres. Il existe différentes méthodes afin de réaliser le caractère adaptatif du contrôleur (Lunze and Richter, 2008).

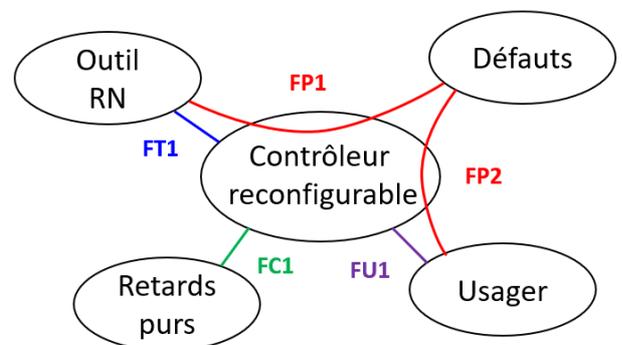
Dans le but de respecter le caractère générique du contrôleur, nous adopterons une méthode par auto-apprentissage qui permettra de réaliser une adaptation en ligne. Cette approche se construit sur un apprentissage de type basé données d'un modèle de la classe d'apprentissage-machine (« Machine Learning »). Nous emploierons les modèles réseau de neurones pour réaliser le contrôleur par auto-apprentissage. Les modèles réseaux de neurones sont des outils utilisés dans la littérature depuis une 50<sup>ème</sup> d'années et qui démontrent de performances intéressantes, notamment en termes d'estimation, de prévisions et de flexibilité. De plus, il s'agit d'une approche exclusivement basée sur les données d'acquisitions du système PEMFC.

### 1.5.3 Objectifs de thèse

L'objectif principal de ce travail de thèse est l'élaboration d'un contrôleur neuronal générique et adaptatif aux états de santé, pour une intégration dans une stratégie AFTC.

Pour y parvenir, plusieurs fonctions scientifiques principales, techniques, d'usage et de contraintes guideront nos recherches. Ces fonctions sont présentées à la Figure 15.

- FP 1** Considérer les états de santé du système dans la définition du contrôleur.
- FP 2** Concevoir une méthode générique pour la définition du contrôleur.
- FT 1** Adopter les réseaux de neurones pour l'estimation de grandeurs inconnues.
- FU 1** Automatiser les processus d'identification des modèles neuronaux.
- FC 1** Assimiler les retards purs tout au long de la chaîne de contrôle.



**Figure 15** Représentation fonctionnelle du projet de recherche

Pour répondre à ses fonctions, plusieurs démarches seront entreprises. Tout d'abord un état de l'art sera mené pour initier la résolution des fonctions **FP 1** et **FP 2**. Une analyse comparative sera ensuite réalisée pour le choix du réseau de neurones **FT 1**. Des algorithmes d'optimisation et des analyses sécuritaires devront être mis en place pour répondre à la fonction **FU 1**. La fonction **FC 1** sera considérée tout au long de l'étude. Un modèle de simulation sera identifié pour tester la faisabilité et la pertinence du contrôleur, avant toute phase d'expérimentation. Le développement d'un modèle propre ne faisant pas partie des objectifs de cette thèse, un modèle de la littérature sera donc employé. Dans nos cas d'étude, l'expérimental présentera une configuration différente que la simulation, malgré tout, il s'agira d'une occasion d'éprouver le contrôleur générique sur les deux compositions différentes.

Des questions peuvent être soulevées vis-à-vis des fonctions énoncées précédemment, l'étude tentera d'y répondre :

- Q 1** Quel est l'apport d'un contrôleur adaptatif par rapport à un contrôleur traditionnel ?
- Q 2** Existe-t-il un risque d'intégrité du système dans le cas d'un contrôle adaptatif ?
- Q 3** Comment garantir la stabilité d'un contrôleur en perpétuelle évolution ?
- Q 4** Peut-on s'assurer de la fidélité des résultats entre chaque exécution ?
- Q 5** Peut-on s'assurer de la précision des estimateurs neuronaux ?
- Q 6** Quelles sont les différences entre la simulation et l'expérimentation ?
- Q 7** Peut-il exister des interférences entre l'adaptation du contrôleur et la stratégie AFTC ?

## Conclusion

Les conditions opératoires correspondant à un fonctionnement nominal du système PEMFC garantissent une durée de vie optimisée. Or, une simple déviation de ces conditions ou même une perturbation extérieure peuvent amener le système dans un mode de fonctionnement en défaut. Ce sont là des situations encore peu connues et qui font intervenir des interactions complexes entre variables. Certains défauts sont même irréversibles ce qui peut endommager définitivement les composants internes du système. Une stratégie de tolérance aux défauts contribue à garantir au cours du temps un fonctionnement sain du système.

Pour mettre en place une telle stratégie en ligne et en temps réel, des modules possédant des rôles spécifiques sont développés. De nombreux progrès ont été effectués dans la littérature, cependant des méthodes génériques restent à être développées et validées sur des systèmes réels.

Le chapitre suivant introduit la notion de contrôleur neuronal adaptatif par l'association des réseaux de neurones artificiels et des structures contrôleurs. Les modèles réseau de neurones seront tout d'abord introduits. Leurs fonctionnements et les algorithmes d'optimisations seront ensuite présentés. Les équations de ces modèles étant connues, elles seront disponibles en annexes de ce manuscrit. Pour finir, un état de l'art sera réalisé sur les contrôleurs neuronaux présents dans la littérature. Une sélection sera ensuite conduite afin de sélectionner le contrôleur à adopter et à développer.

# CHAPITRE 2

## LE RESEAU DE NEURONES POUR LE CONTROLEUR ADAPTATIF

### Sommaire

---

<b>2.1</b>	<b>Évolution du perceptron vers les structures profondes</b> .....	<b>29</b>
<b>2.2</b>	<b>Algorithmes d'optimisation utilisés en ligne et en temps réel</b> .....	<b>31</b>
2.2.1	Optimisation automatique des paramètres .....	32
2.2.2	Optimisation automatique des hyperparamètres .....	32
<b>2.3</b>	<b>Conditions de stabilité et de convergence</b> .....	<b>34</b>
2.3.1	Stabilité au sens de Lyapunov.....	34
2.3.2	Convergence globale de l'apprentissage.....	35
<b>2.4</b>	<b>État de l'art sur les structures de contrôle neuronal adaptatives</b> .....	<b>35</b>
2.4.1	Contrôleur neuronal adaptatif par modèle inverse.....	36
2.4.2	Contrôleur neuronal adaptatif par modèle de rétroaction .....	38
2.4.3	Contrôleur neuronal adaptatif hybride .....	40
2.4.4	Contrôleur neuronal adaptatif par programmation dynamique.....	41
2.4.5	Contrôleur neuronal adaptatif proportionnel intégral dérivé .....	43
2.4.6	Contrôleur neuronal adaptatif par retour d'état .....	46
2.4.7	Contrôleur neuronal adaptatif par rétrogradation .....	48
2.4.8	Contrôleur neuronal adaptatif par mode glissant .....	50
2.4.9	Contrôleur neuronal adaptatif par commande prédictive.....	52
<b>2.5</b>	<b>Synthèse et discussion sur l'état de l'art</b> .....	<b>53</b>
2.5.1	Tableaux de synthèses sur l'état de l'art .....	53
2.5.2	Discussion sur l'état de l'art .....	58
<b>2.6</b>	<b>Choix de la structure de contrôle</b> .....	<b>59</b>
2.6.1	Définitions et pondérations des critères de sélection.....	59
2.6.2	Justification de la valorisation des solutions.....	60
2.6.3	Notation des structures de contrôles .....	61

---

## Introduction

Avant d'aborder l'état de l'art sur les contrôleurs adaptatifs neuronaux, nous tacherons ici d'apporter une certaine connaissance au sujet des modèles réseaux de neurones. En effet, toute la méthodologie décrite au chapitre précédent nous renvoie à l'identification d'un modèle de type RN. Pour y parvenir, plusieurs étapes essentielles doivent être réalisées :

- La première étape est la **sélection des variables d'entrées / de sorties** et la mise en place de tout traitement de données qui peut être nécessaire, tels que le nettoyage de valeurs aberrantes, le changement d'unités, la normalisation, etc.
- L'étape suivante est l'**identification d'un type de réseau de neurones** en considérant l'application mise en œuvre. Cette structure peut être construite à l'aide d'un algorithme d'optimisation.
- Une fois que le modèle est construit, un processus indispensable d'**ajustement des poids neuronaux** est mené. Ce processus est effectué par le biais d'un algorithme d'apprentissage qui combine le modèle identifié et les données d'entrées / de sorties.
- Enfin, une **étude de stabilité et de convergence** du modèle est entreprise pour garantir les performances du modèle RN.

La première partie de ce chapitre présente ainsi ces différentes étapes : en premier lieu, les différentes topologies neuronales et les algorithmes d'apprentissage pour un ajustement en ligne, puis les algorithmes d'optimisation et pour terminer les analyses de stabilité et de convergence.

La construction d'un contrôleur adaptatif à partir d'un modèle RN doit aussi respecter trois principales contraintes :

- La contrainte de **temps réel** induisant l'utilisation un modèle neuronal suffisamment rapide dans son exécution.
- Fournir une **commande optimale** en fonction d'un critère ou d'un ensemble de critères (*e.g.* précision, stabilité, temps d'établissement) vis-à-vis d'une consigne donnée.
- Et enfin, une **adaptation temporelle** pour assurer le contrôle et l'intégrité du système même en présence d'irrégularités de fonctionnement.

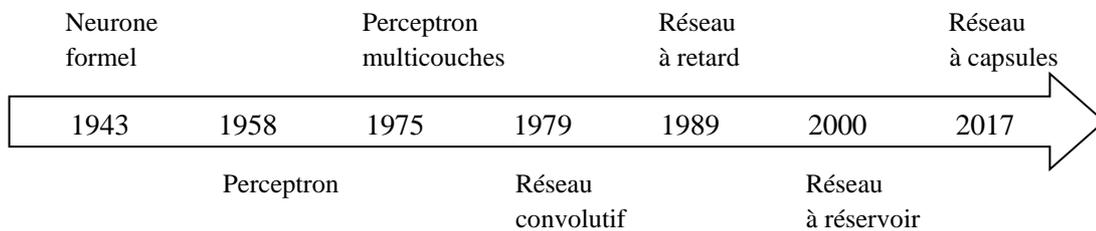
La seconde partie de ce chapitre est un état de l'art sur les contrôleurs neuronaux adaptatifs. Cette partie met en évidence les méthodes de la littérature répondant aux contraintes citées précédemment. Le chapitre se termine ensuite par la mise en place d'une démarche de sélection dans le but de déterminer judicieusement la structure d'un contrôleur à développer.

## 2.1 Évolution du perceptron vers les structures profondes

Les modèles RN sont construits sur un paradigme biologique, il s'agit de la représentation d'un neurone. Sa vocation n'est pas la reproduction parfaite du neurone biologique, mais d'imiter ses principales fonctions qui sont le traitement et le transport de l'information. Le traitement est effectué par le biais de fonctions non linéaires, ou fonction d'activation  $f_n(x)$  où  $n$  représente le neurone. Le transport de l'information est réalisé par

l'intermédiaire d'interconnexions pondérées par des coefficients  $W_{n,l}$  (*i.e.* poids neuronaux) où  $l$  représente la couche cachée.

La structuration de plusieurs neurones formels forme ce qu'on appelle un réseau de neurones. Au sein de ces structures, les neurones ou couches cachés de neurones peuvent avoir des fonctions spécifiques, telles que des couches d'entrées pour une normalisation des données, des couches cachées avec des pondérations ajustables, des couches rétroactives qui gardent des informations (*e.g.* d'entrées, interne, de sorties) en mémoire, etc. Il s'agit d'un ensemble de fonctionnalités totalement modulable qui permet de concevoir au mieux le modèle pour une application donnée. De nos jours, les structures neuronales se sont développées, complexifiées, dans le but d'atteindre des degrés de précision de plus en plus performantes. Une évolution chronologique de l'apparition des modèles les plus couramment utilisés est présentée sur la [Figure 16](#).



**Figure 16** Évolution des réseaux de neurones

Le [Tableau 8](#) donne un exemple d'usage de ces modèles. Le type de neurone, les illustrations et les équations de ces modèles sont disponibles dans la littérature et sont synthétisés dans l'[Annexe A1](#).

**Tableau 8** Modèles neuronaux les plus couramment utilisés

Modèle neuronal	Application
Perceptron multicouche (ML)	Estimation de variables
Modèle à fonctions de base radiales (RBF)	Approximation de fonctions inconnues
Modèle convolutif (CNN)	Reconnaissance de motifs
Modèle à retard ( <i>e.g.</i> ARX ou TD)	Prévision considérant la latence
Modèle à réservoir (RC)	Prévision temporelle
Modèle à mémoire long et court terme (LSTM)	Reconnaissance vocale
Modèle à capsules (CapsNet)	Classification d'images

Pour chaque application, une structure de modèle est à privilégier. Dans la situation où le système pile à combustible subit des retards purs de la part de ces actionneurs et des dynamiques fluidiques, un modèle à capacité temporelle est à privilégier.

Une étude comparative est menée au chapitre suivant, elle répond au choix du modèle neuronal à implémenter. Nous observerons les temps de calcul de chaque modèle et leurs précisions dans une application de prévision. Le modèle répondant le mieux aux critères de temps de calcul et de précision sera retenu.

Une fois la sélection du modèle effectué en adéquation avec l'application désirée, l'étape suivante est l'optimisation de ses paramètres. Les paramètres neuronaux sont apparentés à deux classes, les paramètres neuronaux et les hyperparamètres.

- Les paramètres neuronaux correspondent essentiellement aux poids neuronaux, aux coefficients variables estimés par des algorithmes d'apprentissage.
- Les hyperparamètres correspondent à l'architecture du modèle, aux paramètres estimés par l'utilisateur ou par des algorithmes d'optimisation.

Quelques exemples de paramètres et d'hyperparamètres sont donnés dans le [Tableau 9](#).

**Tableau 9** Exemples de paramètre et d'hyperparamètres pour les modèles neuronaux

	<b>Paramètres</b>	<b>Hyperparamètres</b>
Méthode courante d'optimisation	Automatique	Manuel Automatique
Exemples	Poids neuronaux Type des fonctions d'activations $f_n(x)$	Nombres d'entrées Nombres de sorties Nombres de neurones Nombres de couches Fonctions d'activations Normalisation des entrées Normalisation des sorties Taux d'apprentissage, etc.

La section suivante est une synthèse des algorithmes utilisés pour l'optimisation de ces paramètres et hyperparamètres.

## 2.2 Algorithmes d'optimisation utilisés en ligne et en temps réel

Les algorithmes d'apprentissage machine permettent d'ajuster progressivement les paramètres ou les hyperparamètres en fonction de critères d'erreurs (*i.e.* erreurs de modélisation). L'optimisation en ligne est réalisée à partir des données d'entrée  $x(k)$  et de sortie  $y(k)$  récupérées à chaque période d'échantillonnage. Une fonction coût  $J(x, y)$  est calculée à partir d'une erreur résiduelle de modélisation  $e_m(k) = y_{cible}(k) - y(k)$ . Cette erreur de modélisation est ensuite employée par l'algorithme d'optimisation qui a pour but de minimiser la fonction coût  $J(x, y)$ .

Pour éviter d'ajouter des retards purs supplémentaires qui peuvent être engendrés par l'algorithme d'optimisation, une contrainte consiste à s'assurer de la synchronisation entre l'obtention d'une commande (sortie du modèle neuronal) et l'envoi de celle-ci vers les actionneurs. Les algorithmes d'optimisation neuronale doivent donc avoir un temps de calcul inférieur à la période d'échantillonnage.

### 2.2.1 Optimisation automatique des paramètres

Le [Tableau 10](#) dresse une synthèse des algorithmes en ligne les plus couramment utilisés pour les processus d'apprentissage en temps réel. De même que pour la section précédente, les équations, les coefficients, et les détails des algorithmes d'optimisation des paramètres sont disponibles dans l'[Annexe A2](#).

**Tableau 10** Algorithmes d'optimisation des paramètres

Algorithmes	Avantages	Inconvénients
Descente du gradient stochastique (SGD) avec échantillon unitaire	Apprentissage rapide ( <a href="#">Nakama, 2009</a> )	Sensible aux bruits des signaux Possible entrave sur des minimums locaux ( <a href="#">Wang et al., 2017</a> ) Choix des coefficients
Moindres carré récursif (RLS)	Apprentissage stable Obtention de la solution optimale ( <a href="#">Cho and Chow, 1999</a> )	Tendance au sur-apprentissage ( <a href="#">Cho and Chow, 1999</a> ) Choix des coefficients
Évolution génétique (ED) heuristique	Exploration large de solutions Insensible aux bruits signaux ( <a href="#">Prado et al., 2020</a> ) Permet de sortir des minimums locaux ( <a href="#">W. Jia et al., 2016</a> )	Optimisation lente Précision de nature stochastique ( <a href="#">Yan et al., 2020</a> ) Choix des coefficients

Dans une application où la stabilité du modèle est essentielle, l'algorithme RLS sera privilégié. En revanche, dans les applications en simulations c'est l'approche GD qui est la méthode la plus utilisée, en effet elle offre un apprentissage plus rapide. Ces deux approches sont compatibles pour des apprentissages supervisés (où la présence de cibles  $y_{cible}(k)$  est connue) ou alors pour des apprentissages par renforcement (où seul le coût  $J(x, y)$  est connu). L'approche ED est quant à elle pertinente pour des apprentissages non supervisés (où la présence de cibles  $y_{cible}(k)$  est inconnue).

L'ajustement des paramètres est un processus infini. L'opération d'arrêt anticipé (« early stopping ») consiste à limiter le processus d'apprentissage afin d'éviter les phénomènes de sur-apprentissage (« over-training ») qui limiterait les capacités d'extrapolation du modèle neuronale. En pratique, cela se traduit par l'arrêt des ajustements neuronaux dès le franchissement d'un seuil prédéfini.

### 2.2.2 Optimisation automatique des hyperparamètres

Une modification en ligne de la structure neuronale ne peut être concevable. Son action sur les performances de modélisation ou même de contrôle ne sont pas connues. On peut ainsi définir deux classes d'hyperparamètres :

- Les **hyperparamètres variables** sont des paramètres modifiables en ligne, tels que les fonctions d'activations, les taux d'apprentissage, les taux de rétroactions, les coefficients de mémoire, les coefficients de normalisation ou la plupart des coefficients intermédiaires.
- Les **hyperparamètres fixes** sont des paramètres qui ne peuvent être modifiés en ligne sans une redéfinition partielle ou totale du modèle. Il s'agit par exemple, du nombre d'entrée et de sorties, le nombre de neurones, le nombre de couches cachées.

De même que pour les structures neuronales ou pour l'optimisation des paramètres, le détail des algorithmes pour l'optimisation des hyperparamètres présentés [Tableau 11](#) est disponible dans l'[Annexe A2](#).

**Tableau 11** Algorithmes d'optimisation des hyperparamètres

Algorithmes	Avantages	Inconvénients
Essai-erreur itérative	Recherche exhaustive de toutes les solutions possibles	Recherche de solution lente Effort de calcul important
Recherche quadrillée aléatoire	Exploration large de solutions Permet de sortir des minimums locaux ( <a href="#">Khalid and Javaid, 2020</a> )	Recherche de solution lente
Optimisation bayésienne	Recherche de solution rapide ( <a href="#">Cerina et al., 2019</a> )	Dépendant d'un estimateur de tendance
Méthode hyperbande	Exploration large de solutions Délimitation des plages de sélections pour accélérer l'optimisation Recherche de solution très rapide ( <a href="#">Li et al., 2016</a> )	Choix des coefficients pour les plages de sélections
Arbre de décision par la fenêtre de Parzen	Exploration large de solutions	Dépendant d'un estimateur de tendance

La méthode essai-erreur de l'ensemble des domaines de fonctionnement des hyperparamètres est la méthode la plus couramment utilisée en modélisation hors ligne. Les méthodes essais-erreur itérative ou bayésienne présentent une solution intéressante pour une application en ligne.

Pour optimiser la dimension des RN, des approches de réduction dimensionnelles ont récemment été développées. Ainsi, [Sussillo & Corrado \(2017\)](#) ont proposé une réduction des tailles des couches cachées via l'analyse des composantes principales (« Principal Component Analysis » or PCA). La PCA est une méthode factorielle de réduction de dimension qui autorise la synthétisation de variables, les variables ici font appel à l'activité des neurones. Il reste ainsi possible de moduler le nombre de neurones actif dans le processus de calcul en passant par des outils de traitement de l'information.

## 2.3 Conditions de stabilité et de convergence

L'utilisation du réseau de neurones pour le contrôle adaptatif implique le respect de certaines conditions, telles que la stabilité, la convergence globale ou la répétabilité des résultats :

- La **stabilité** représente l'aptitude d'un système dynamique se trouvant à un point quelconque d'atteindre un point d'équilibre, ou un point fixe par l'intermédiaire de trajectoires périodiques.
- La **convergence globale** se réfère à l'aptitude de l'algorithme d'apprentissage à atteindre le minimum global de la fonction coût en un temps fini. En utilisant une fonction coût quadratique, c'est-à-dire de nature convexe, un minimum global est intuitivement formé. Or, cette qualité n'est concevable uniquement en présence d'un système ayant une réponse de nature semblable. Dans le cas contraire, il existe un risque d'obtenir de multiples solutions locales.
- La **répétabilité** des résultats se réfère à la capacité d'un modèle d'obtenir une consistance de ses résultats au cours du temps. L'initialisation des modèles étant globalement aléatoire, les résultats peuvent fluctuer entre chaque test.

### 2.3.1 Stabilité au sens de Lyapunov

En théorie du contrôle, un ensemble d'états est sûr si les trajectoires du système sont limitées dans un domaine  $S_\pi$  et convergent asymptotiquement vers un point fixe sous l'influence d'une commande donnée (Richards et al., 2018). La stabilité au sens d'Aleksandr Lyapunov est l'une des méthodes les plus couramment utilisées pour démontrer l'existence du domaine délimité  $S_\pi$  pour un système dynamique en boucle fermée  $x_{t+1} = f_\pi(x_t)$ .

**Théorème 1.** La stabilité au sens de Lyapunov (Kalman and Bertram, 1960)

On suppose que le système  $f_\pi$  est localement Lipschitz et possède un point d'équilibre en  $x_0 = 0$ . La fonction  $V: X \rightarrow \mathbb{R}$  est localement Lipschitzienne sur l'espace  $X$ .

S'il existe un ensemble  $D_V \subseteq X$ , contenant le point  $x_0 = 0$ , où  $V$  est défini positive et  $\Delta V(x) := V(f_\pi(x)) - V(x) < 0$ , avec  $\forall x \in D_V \setminus \{0\}$ , alors  $x_0 = 0$  est un point d'équilibre asymptotique. Dans ce cas,  $V$  est considérée comme une fonction de Lyapunov pour le système dynamique en boucle fermée  $f_\pi$ .

Typiquement, le but du concepteur est d'identifier une fonction définie positive, nommée « la fonction candidate de Lyapunov », dont la dérivée par rapport au temps est contrainte, à l'aide des entrées du système, à être une fonction définie négative. Les trajectoires du système convergent donc vers le point d'équilibre  $V(x) = 0$ , soit  $x_0 = 0$ . En pratique, l'identification de ce domaine attractif  $S_\pi$  est obtenue par la vérification itérative de la condition  $\Delta V(x) < 0$  pour tout états  $x$  du domaine de validité de  $V$ .

### 2.3.2 Convergence globale de l'apprentissage

La condition de stabilité implique implicitement une convergence, or ce point de convergence n'est pas forcément un minimum global. Sortir d'un minimum local implique un bond dans l'ajustement des poids neuronaux. La gestion de telles actions s'appuie sur le choix approprié d'un taux d'apprentissage  $\eta$ , ou du taux d'apprentissage dans le cas où chaque connexion neuronale en posséderait un. Une stratégie pour y parvenir a été mise en place par [Magoulas, Plagianakos & Vrahatis \(2002\)](#), elle permet d'assurer une convergence globale, quel que soit l'algorithme d'apprentissage mis en place. Pour des algorithmes de type moindres carrés, la convergence globale est généralement assurée par un encadrement du domaine du taux d'apprentissage. Cet encadrement est obtenu à partir d'études aux limites effectuées sur l'erreur de modélisation.

La prochaine section est un état de l'art concernant les structures de contrôle neuronal adaptatif. La dernière partie du chapitre décrit une démarche rigoureuse mise en œuvre pour la sélection d'une structure de contrôle à développer.

## 2.4 État de l'art sur les structures de contrôle neuronal adaptatives

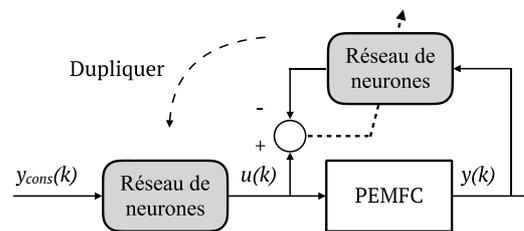
Dans la littérature, un certain nombre de travaux concernent l'utilisation de modèles RN comme contrôleurs pour le système PEMFC. Deux types de structure de boucle fermée peuvent être distingués :

- Les boucles fermées utilisant le réseau de neurones comme contrôleur direct, ceux-ci peuvent prendre différentes formes :
  - Le contrôleur par modèle inverse
  - Le contrôleur par modèle de rétroaction
  - Le contrôleur hybride
  - Le contrôleur par programmation dynamique
  - Le contrôleur proportionnel intégral dérivé neuronal
- Les boucles fermées utilisant le réseau de neurones comme outil d'estimation pour un contrôleur traditionnel comme :
  - Le contrôleur proportionnel intégral dérivé ou PID
  - Le contrôleur par retour d'état
  - Le contrôleur par rétrogradation
  - Le contrôleur par mode glissant
  - Le contrôleur par commande prédictive

Il est difficile de comparer objectivement les performances des structures de contrôle entre elles. En effet, les critères d'erreurs employés dans les différentes études, les scénarios d'asservissement ou de régulation, la taille du système PEMFC, ou encore les environnements de tests ne sont pas équivalents. Malgré tout, les performances de chacun pourront être analysées et comparées aux différents besoins identifiés du chapitre précédent.

### 2.4.1 Contrôleur neuronal adaptatif par modèle inverse

Le contrôleur neuronal inverse est une approche par action anticipatrice. Comme le décrit la [Figure 17](#), l'objectif recherché est d'identifier les actions et réactions d'un système pour en faire un modèle qui sera par la suite inversé. Une condition préalable est d'assurer la réversibilité du système. Plusieurs méthodes de tests sont décrites dans la littérature. Ainsi, les travaux de [Wang, Zhao, Luan, Gao & Deng \(2018\)](#) utilisent la méthode de la dérivée pour prouver la réversibilité d'un système de suspension active pour véhicules. Pour le système PEMFC, une étude a été menée par [Boulon, Hissel, Bouscayrol & Pera \(2010\)](#) sur le principe du contrôle par modèle inverse qui est par conséquent naturellement construit sur la réversibilité des relations entre les variables de commandes et de sorties.



**Figure 17** Structure de contrôle par modèle neuronal inverse

Pour prévenir de la situation de sous-alimentation en oxygène, [Li, Zhu, Sui, Hu & Hu \(2009\)](#) ont proposé, en simulation, une régulation avec rejet de perturbations de la stœchiométrie via la tension du compresseur. Le contrôleur est un réseau de neurones récurrent de type logique flou (« Recurrent Fuzzy » ou RF). Des connexions de rétroaction sont ajoutées dans la structure du réseau de neurones pour fournir une capacité de mémoire, augmentant ainsi la faculté du modèle à capturer la réponse dynamique du système. Les taux d'apprentissage sont obtenus par logique floue et les paramètres du modèle RF sont ajustés par une méthode d'apprentissage GD. Les résultats de la simulation montrent un suivi de consigne effectif et les performances obtenues sont supérieures au contrôleur Proportionnel Intégrale (PI). De plus, un régulateur proportionnel est implémenté pour s'assurer de la différence nulle entre les pressions anodique et cathodique. Quatre niveaux de perturbations en courant de 0,1 à 0,3 A/cm<sup>2</sup> sont testés, ils provoquent des déviations stœchiométriques de l'ordre de  $\pm 0,1$  à  $\pm 0,4 \lambda_{O_2}$ . La méthode proposée ne présente pas de dépassements de consigne ni d'oscillations, et le système retrouve la consigne stœchiométrique de  $2 \lambda_{O_2}$  avec des temps de réponse à 5 % de la consigne pouvant atteindre les 10 secondes. Le régulateur PI mis en place est efficace pour une application en suivi de pression autour de la membrane. Le contrôleur neuronal présenté montre ainsi des temps de réponse non négligeables et plutôt importants pour un contrôle de la stœchiométrie.

[Sedighzadeh & Rezazadeh \(2010\)](#) ont proposé en simulation un asservissement avec rejet de perturbations d'un empilement de cellules d'une puissance de 1 kW. L'objectif étant de contrôler la puissance de la pile par le pilotage en eau de la membrane via une commande sur l'humidité relative de l'hydrogène. Cet article développe un réseau de neurones de type ondelette avec un traitement en sortie basé sur un filtre à réponse impulsionnelle infinie (« infinite impulse response filter » ou IIR). La structure du réseau de neurones de type

ondelette est semblable à un modèle RBF. Dans le concept des ondelettes, une super ondelette est une combinaison linéaire d'ondelettes filles. Cette décomposition de fonctions permet l'identification simplifiée de système complexe non linéaire. Le bloc IIR crée une double architecture de réseau local, permettant un apprentissage et une convergence rapides du modèle. Les coefficients IIR sont fixes et les paramètres du réseau de neurones sont ajustés par la méthode RLS. Trois scénarios de tests sont mis en place, un fonctionnement normal, un fonctionnement avec bruit blanc en entrée de contrôleur et un fonctionnement avec bruit blanc en sortie de pile. Le suivi de consigne en tension se montre efficace, quelle que soit la situation, cependant la présence de forts dépassements et d'oscillations sur les résultats semble probablement liée au choix de la variable de commande (HR% de l'hydrogène) peu commune et possédant une dynamique lente.

Pour les systèmes non linéaires à fortes incertitudes, [Shafiq \(2016\)](#) a récemment proposé un contrôleur inverse basé sur deux modèles ML différents. Un premier modèle ML est utilisé pour estimer la sortie du système, son rôle est donc d'apporter la dynamique du système. Ses poids sont ajustés par une méthode de rétropropagation (« back-propagation » ou BP) basée sur l'erreur de modélisation. Ce premier modèle est ensuite dupliqué, l'erreur de position est utilisée comme entrée de ce dernier. Ce modèle dupliqué fournit alors une sortie qui est utilisée comme erreur de modélisation pour le second modèle ML, un modèle qui joue le rôle de contrôleur. Cette configuration indirecte donne des propriétés de robustesse à la boucle de contrôle. Les résultats de la simulation montrent une bonne performance en asservissement, un suivi de consigne sans dépassement ni d'oscillations et un bon rejet des perturbations sur un système Hammerstein. Il s'agit de système souvent mis en œuvre pour modéliser des procédés chimiques. La régulation mise en place dans cette application atteint un temps de réponse de l'ordre de 0,15 s. La période d'échantillonnage n'étant pas fournie, il est impossible d'évaluer ce temps de réponse. D'autre part, cette méthode induit de forts dépassements uniquement aux premières itérations, d'un ordre de grandeur de 3 fois la valeur de consigne. La stabilité et la convergence du contrôleur sont traitées au sens de Schur dans un article postérieur ([Shafiq, Shafiq, & Yousef, 2017](#)).

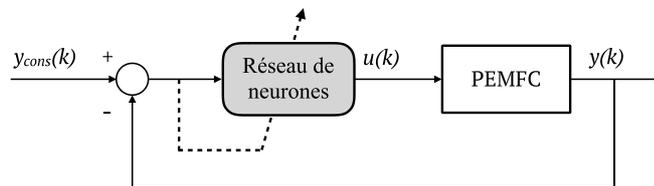
Une approche de contrôleur inverse présentant peu de dépassements a été récemment développée par [Jordanou, Antonelo, Camponogara & de Aguiar \(2017\)](#). Elle consiste à contrôler la pression du fond d'un puits de pétrole à l'aide d'un modèle RC inverse. Le type de modèle employé est un « Echo State Network » ou ESN. Les objectifs de contrôle sont le suivi des paliers de pression et le rejet des perturbations. L'apprentissage ESN est effectué avec une méthode RLS, puis la couche de sortie est dupliquée dans un contrôleur ESN. Les résultats de la simulation montrent une capacité à faire face à des changements de pression importants et présentent une capacité intéressante de rejet des perturbations. En condition normale de fonctionnement, la méthode induit de faibles dépassements, d'un ordre de grandeur de 5 bars sur une consigne de 200 bars. Les dépassements aux premières itérations sont tout de même plus importants avec une valeur de 30 bars sur une consigne de 190 bars. Une perturbation est ajoutée sur l'entrée de gaz. Ce scénario de test donne des résultats montrant un temps de réponse à 5 % de la consigne plus important et la présence de quelques oscillations en périodes transitoires. Il est à noter que cinq essais aléatoires ont été nécessaires pour identifier des poids

neuronaux viables permettant la mise en place du processus de contrôle. La répétabilité des résultats n'est pas considérée dans cette étude.

En résumé, la structure neuronale inverse est particulièrement adaptée au contrôle de systèmes non linéaires avec incertitudes. Cependant, les suivis de consignes présentent de forts dépassements et des temps de réponse assez élevés en situation de rejet de perturbations. Ce qui s'explique par une adaptation par contrecoup. Pour réduire le temps de montée du contrôleur, l'ajout d'un deuxième réseau de neurones permet d'anticiper les actions de celui-ci en apportant la dynamique du système. Grâce à l'utilisation de modèles neuronaux avancés et à des méthodes d'apprentissage basées sur les moindres carrés, des travaux ont démontré la possibilité de garantir la convergence globale de l'apprentissage, tout en augmentant la robustesse face aux perturbations.

## 2.4.2 Contrôleur neuronal adaptatif par modèle de rétroaction

Le contrôleur par modèle de rétroaction utilise le signal d'erreur résiduel en entrée, ce qui modifie sa fonction de dynamique inverse en un contrôleur pur. Comme illustré sur la [Figure 18](#), la phase d'apprentissage de cette structure est généralement effectuée en ligne. C'est pourquoi une période d'initialisation est donc nécessaire durant laquelle les performances du contrôleur augmentent progressivement.



**Figure 18** Structure de contrôle par modèle neuronal de rétroaction

[Sánchez et al. \(2010, 2014\)](#) ont travaillé sur une régulation stœchiométrique en air avec rejet de perturbations pour une PEMFC en utilisant un réseau de neurones de type B-Spline ([dos Santos Coelho and Pessôa, 2009](#)). La méthodologie B-Spline est construite sur un pré-traitement des données d'entrée à l'aide de fonctions. Il s'agit d'un système à  $n$  ordre B-Spline qui est une fonction polynomiale par morceaux de degré  $n-1$  dans une variable  $x$ . La forme du vecteur d'entrée neuronal devient plus fluide au lieu d'être saccadée, ce qui améliore les capacités du RN pour l'estimation de courbes. Les poids neuronaux sont estimés en ligne à l'aide d'une méthode GD. Les déviations stœchiométriques engendrées par la perturbation en courant de 100 à 300A varient entre  $+0.1$  et  $-0,8 \lambda_{O_2}$  pour une consigne à  $2 \lambda_{O_2}$ . Les résultats de simulation montrent moins d'oscillations et une réduction notable des dépassements par rapport à un régulateur PI. Au démarrage du contrôle, le temps de réponse à 5% est de 8 s pour atteindre ensuite la seconde, ce qui est intéressant pour l'atténuation des défauts de noyage ou d'assèchement. Une erreur résiduelle permanente est présente sur le contrôleur statique alors

qu'elle est totalement réduite sur la méthode proposée. De très faibles oscillations restent tout de même présentes sur les premières itérations.

Dong, Cao & Zhu (2003) ont présenté une régulation de température par le pilotage des débits d'hydrogène, d'oxygène et du débit de refroidissement. L'effet de ces débits sur le fonctionnement global du système est différent les uns des autres, c'est pourquoi une régulation par zones est établie. Pour une erreur maximale de  $\pm 4$  °C, les variables de commandes sont les débits des gaz. Pour une erreur plus importante, la variable de commande devient le débit du liquide de refroidissement. Le réseau de neurones mis en place possède cinq couches cachées. La méthode de logique floue Takagi-Sugeno est appliquée pour les fonctions d'activations. Les poids sont ajustés par une méthode BP. Le contrôleur de température est évalué sur une situation de démarrage, et la stabiliser à la consigne de 80 °C. Les résultats de la simulation montrent un contrôle sans oscillations ni dépassement des différents débits et peu de fluctuations durant la période de transition.

Un autre article aborde la régulation de la température à l'aide de deux réseaux de neurones. Sun, Yan, Cao & Zhu (2005) ont conçu un contrôleur basé sur la méthode de logique floue Takagi-Sugeno pour stabiliser la température d'une pile PEMFC de 30 cellules via les débits de gaz. Le contrôle de la température par les débits de gaz a des conséquences importantes sur les stœchiométries des gaz réactifs. Ici, son influence est supposément négligeable, car l'application est effectuée sur de faibles niveaux de courant. Deux réseaux de neurones de type logique flou sont utilisés pour la conception du contrôleur, le premier est un modèle d'identification du système et le second est un contrôleur de rétroaction. Le premier modèle est ajusté par un algorithme BP. L'information jacobienne de ce modèle qui la sensibilité de la sortie du système à chaque commande  $\partial y/\partial u$  est ensuite récupérée pour ajuster le second modèle. La méthode proposée est testée sous une simulation de démarrage, la température atteint les 80 °C sans dépassements ni oscillations. La consigne est respectée, et les commandes présentent peu de variations.

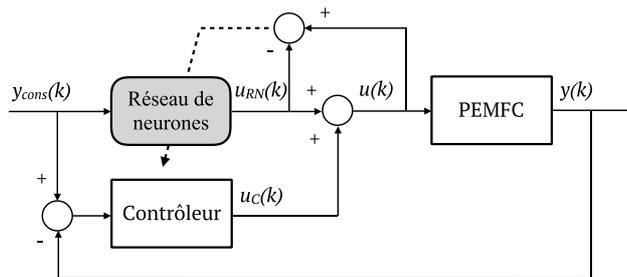
Au sein de la littérature, l'utilisation de la matrice jacobienne est très répandue pour le processus d'adaptation. Shirzadeh, Amirkhani, Jalali & Mosavi (2015) ont proposé une régulation pour le suivi de position d'un drone aérien. Un modèle de rétroaction RBF est utilisé pour l'estimation de l'information jacobienne et un second modèle est implémenté pour la génération du signal de commande. La convergence des deux réseaux de neurones est garantie par une sélection appropriée des taux d'apprentissages. Malgré la présence de forces et de couples perturbateurs, les résultats de simulation montrent une bonne performance en suivi de consigne.

Plus récemment, Jon, Wang, Luo & Jong (2017) ont étudié une combinaison d'un réseau de neurones de type Elman récurrent et un module de compensation pour le suivi de consigne d'un servomoteur synchrone à aimants permanents. Dans ce cas d'étude, les poids des neurones et le taux d'apprentissage sont ajustés en ligne par une méthode GD. La stabilité et la convergence du contrôleur sont préalablement analysées au sens de Lyapunov. Les résultats de la simulation montrent un temps de convergence bien inférieur à ceux d'un contrôleur PID passant de 150 à 40 ms et la suppression complète des oscillations dans les changements transitoires. Cette étude aborde le choix du taux d'apprentissage comme étant un compromis entre le temps de montée et l'instabilité du contrôleur.

L'adaptabilité et le temps de convergence sont les principaux atouts de cette structure de contrôle, limitant ainsi les oscillations durant les phases transitoires. Pour la régulation stœchiométrique en oxygène, le temps de convergence rapide de ce contrôleur neuronale peut être pertinent pour des situations de défauts à dynamique équivalente. De plus, une sélection adéquate du taux d'apprentissage semble être la clé pour améliorer les performances de régulation, tout en veillant au compromis fait avec la stabilité du contrôleur. Analogiquement, la stabilité et la convergence doivent être préalablement garanties, ce qui manque dans les travaux effectués sur la PEMFC.

### 2.4.3 Contrôleur neuronal adaptatif hybride

La combinaison du réseau de neurones inverse avec un contrôleur de rétroaction apporte des capacités supplémentaires permettant théoriquement de meilleures performances. Comme illustré sur la [Figure 19](#), le contrôleur à rétroaction est utilisé en cas de perturbations en régime permanent. Cette action est réalisée par l'apprentissage en ligne, ce qui augmente sa plage de fonctionnement ([de Man and Preumont, 1996](#)). Le contrôleur traditionnel est utilisé pour la compensation des perturbations en régime transitoire.



**Figure 19** Structure de contrôle hybride neuronale

[Rakhtala, Ghaderi & Ranjbar \(2011\)](#) ont développé une combinaison du réseau de neurones ML inverse avec un contrôleur PID pour la régulation en tension d'une pile PEMFC de 6 kW via la pression d'entrée en air. L'objectif du contrôle est d'améliorer la stabilité de la tension et de réduire les périodes transitoires engendrées par les changements de courant. L'algorithme d'apprentissage est basé sur une méthode GD. Les résultats de la simulation montrent effectivement moins de fluctuations sur la tension. Comparée à un contrôleur PID seul, la méthode proposée permet un pilotage sans oscillations de la commande en pression d'entrée.

[Rezazadeh, Askarzadeh & Sedighizadeh \(2011\)](#) ont présenté une régulation de la tension d'une pile PEMFC de 5 kW via le débit de méthane. Un modèle de reformage du méthane est intégré pour la production d'hydrogène. Le contrôleur est basé sur un réseau de neurones RBF inverse et un contrôleur PID pour générer le signal de commande. La stabilité est assurée par une analyse au sens de Lyapunov et les poids du modèle RBF sont ajustés par une loi adaptative. Les perturbations interviennent sur le courant avec des variations de 70 à 90 A. Sous des conditions opératoires normales, la consigne de 53 V est correctement respectée. Le temps de réponse de la régulation est de l'ordre de 10 s. De faibles dépassements et

oscillations acceptables sont visibles sur le suivi de consigne. Un deuxième scénario est testé et montre une robustesse satisfaisante avec une variance des résultats de 1%, en présence d'un bruit blanc présentant un écart type de 0,2% sur le courant.

Une situation de dégradation d'un auxiliaire a été réalisée la même année par [Ragb, Jones, Yu & Barry Gomm \(2011\)](#) pour la régulation avec rejet de perturbations de la stœchiométrie en oxygène via la tension du compresseur. Le contrôleur est conçu avec la même structure que celle décrite précédemment, c'est-à-dire la combinaison d'un réseau de neurones RBF et d'un contrôleur PID. Lorsqu'une erreur résiduelle apparaît la sortie du contrôleur PID augmente, les poids du modèle RBF sont alors ajustés, ils sont obtenus à chaque itération par une méthode RLS. L'efficacité du contrôleur adaptatif est éprouvée dans deux situations, une perte de gain de 30 % du compresseur et une perturbation sur la charge en courant. Les résultats de la simulation montrent la capacité du contrôleur proposé à fournir approximativement la même performance pour un système sain et un auxiliaire défectueux. Quelques faibles dépassements sont constatés avec une amplitude maximale de  $0,25 \lambda_{O_2}$  pour une consigne de stœchiométrie en oxygène fixée à  $2 \lambda_{O_2}$ . De plus, le temps de réponse de la régulation n'est que de quelques secondes.

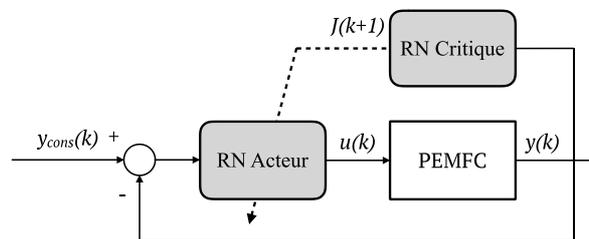
Les articles précédents soulignent la contribution du contrôleur hybride sur le lissage de courbes dans le suivi de trajectoire et dans les variables de commande, cette caractéristique induit une amélioration de la stabilité du système. Récemment, la même structure a été utilisée pour la régulation angulaire d'un actionneur pneumatique, pour un muscle artificiel. [Son, Kien & Anh \(2017\)](#) ont implémenté un réseau de neurones de type ARX et un contrôleur PID. Les poids des neurones sont ajustés hors ligne avec un algorithme ED, les taux d'apprentissage sont ensuite ajustés en ligne selon une méthode de logique floue. Comparée à un contrôleur PID, la méthode proposée rejette l'erreur en régime permanent, tout en permettant une meilleure adaptabilité et précision de contrôle.

La structure hybride offre des performances intéressantes sur la PEMFC. Le contrôleur traditionnel statique agit comme un contrôleur robuste. En effet, le contrôleur traditionnel est spécifique à un état du système. Lors de l'apparition d'un défaut ou d'une perturbation inconnue, il existe alors un risque d'erreur de position permanente. Quoiqu'il en soit, il existe un réel intérêt d'implémenter des méthodes de gestion pour l'ajustement des algorithmes d'optimisation. Elles améliorent de manière évidente la précision et l'adaptabilité de cette structure de contrôle.

#### **2.4.4 Contrôleur neuronal adaptatif par programmation dynamique**

La programmation dynamique adaptative (« Adaptive Dynamic Programming » ou ADP) est une méthode itérative pour résoudre les problèmes complexes non linéaires avec une stratégie de contrôle optimal. Comme décrit sur la [Figure 20](#), la méthode est basée sur le concept de récompense/renforcement pour déterminer progressivement la commande optimale. Ainsi, un modèle RN acteur est chargé d'estimer la commande, tandis qu'un modèle RN critique estime le coût futur. Il s'agit d'anticiper les actions prise par le modèle acteur et d'adapter en conséquence les poids de ce dernier.

Almeida & Simoes (2005) ont proposé une régulation de la tension de pile PEMFC par la pression des gaz réactifs. Bien que l'approche mise en place dans cette étude se base sur la minimisation d'une fonction coût calculée, elle n'emploie pas de modèle RN critique. Deux réseaux de neurones sont utilisés dans cette structure de contrôle, un contrôleur et un prévisionneur. La méthode développée est basée sur un réseau de neurones de type ordinateur arithmétique de modèle cérébelleuse paramétrique (« parametric Cerebellar Model Arithmetic Computer »). Ce modèle comporte trois couches d'association, une couche d'entrée floue, une couche de mémoire longue représentée par des équations paramétriques et une couche de mémoire courte en sortie. Une solution pour éviter les minimums locaux est proposée en deux parties. La première est un apprentissage hors ligne des poids à long terme basé sur les entrées-sorties d'un contrôleur PID, il s'agit ici des coefficients utilisés pour la couche paramétrique. Cette technique d'apprentissage permet de contourner la période incompressible à l'initialisation des paramètres du modèle. Deuxièmement, l'adaptation en ligne n'a lieu que sur les poids à court terme. Les tensions mesurée et prédite de la pile sont utilisées par la fonction coût afin d'ajuster les poids du contrôleur par une méthode GD. Le contrôleur proposé est comparé à un PID. Une situation de perturbations en courant entre deux niveaux 0 et 22,5 A est mise en place. Les résultats de simulation montrent un net avantage pour l'algorithme proposé, qui permet une réduction progressive de l'erreur de position, alors que le contrôleur PID présente une erreur résiduelle permanente. L'erreur de position quadratique obtenue en utilisant le contrôleur PID est de 0,99 V et celle obtenue à partir de la méthode proposée est de 0,24 V. Par ailleurs, le contrôleur PID est le plus rapide des deux.



**Figure 20** Structure de contrôle par programmation dynamique neuronale

Une étude utilisant l'approche ADP est proposée par Bo & Zhang (2018) pour un contrôle de la concentration d'oxygène dissous dans les procédés de traitement des eaux usées. La dégradation de la matière organique est fortement non linéaire et possède d'importantes incertitudes, représentées notamment par des paramètres variant au cours du temps. Le système est également soumis à des perturbations climatiques provenant de l'extérieur. La structure de contrôle est basée sur trois modèles ESN qui possèdent chacun un rôle défini, un acteur, un prévisionniste et un critique. Les poids des modèles ESN sont ajustés en ligne suivant une méthode RLS. Dans des conditions normales de fonctionnement et dans les premières itérations, le contrôleur proposé nécessite 2 jours pour se stabiliser, d'importants dépassements sont observés avec une amplitude maximale de  $0,15 \text{ g/m}^3$  pour une concentration en oxygène de  $2 \text{ g/m}^3$ . Il devient à la suite de cette période, plus performant qu'un contrôleur PID qui induit des fluctuations périodiques. Dans des conditions de pluie ou de tempête, la méthode proposée

présente une stabilisation satisfaisante de la consigne, alors que le contrôleur PID en est incapable et fluctue énormément jusqu'à diverger.

Ces dernières années des méthodes de programmation dynamique basées sur les réseaux de neurones à apprentissage profonds, offrant de meilleures adaptations et convergences ont été décrites (Wu and Wang, 2018). En effet, la combinaison de la programmation dynamique et de réseau de neurones autorise une grande polyvalence, flexibilité et robustesse d'opérations. Cependant, elle nécessite un effort de calcul plus important. De plus, cette structure de contrôle requiert un système stable au démarrage du contrôle, afin de pouvoir initialiser ses paramètres. Il existe tout de même plusieurs approches de la programmation dynamique permettant de surmonter cette contrainte, notamment par l'utilisation des dérivées partielles au lieu de variables.

### 2.4.5 Contrôleur neuronal adaptatif proportionnel intégral dérivé

Le régulateur traditionnel PID est sans aucun doute le contrôleur le plus utilisé dans l'industrie (Visioli, 2012). Sur la base d'une erreur de position, une loi de contrôle (1) délivre un signal de correction au système. Cette méthode nécessite le réglage de trois paramètres : un terme proportionnel  $k_p$ , un terme intégral  $k_i$  et un terme dérivé  $k_d$ . Traditionnellement, les méthodes d'essais et erreurs, manuels ou heuristiques (Kishnani et al., 2014) sont adoptés pour leurs réglages. Cependant ces procédures doivent être répétées à chaque point de fonctionnement et à chaque changement dynamique du système. Pour remédier à cette situation, certaines méthodes auto réglables sont étudiées dans la littérature (Narvekar and Upadhye, 2016), telles que la logique floue ou le réseau de neurones.

$$u_{pid}(t) = k_p e(t) + k_i \int_0^t e(\tau) d\tau + k_d \frac{d(e(t))}{dt} \quad (1)$$

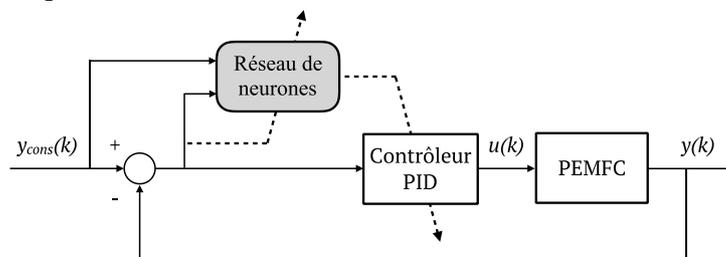
Une approche pour ajuster les paramètres du régulateur PID par l'algorithme généralisé de variance minimale (« Generalized Minimum Variance » ou GMV) a été réalisée par Lebreton et al. (2016) et Damour et al. (2014). Les auteurs ont proposé d'améliorer la résilience de l'alimentation en oxygène en mettant en œuvre un contrôleur PID à réglage automatique. Un réseau de neurones de type ARX est établi pour obtenir les dynamiques du système et utilisé pour l'estimation future de la stœchiométrie en oxygène. Les poids des neurones sont ajustés hors ligne à partir d'une base de données. Les coefficients du contrôleur PID sont déterminés en ligne en deux étapes. Les paramètres du réseau de neurones sont extraits et linéarisés à l'aide du développement de Taylor. Cela permet d'appréhender la dynamique du système. Ensuite, un algorithme de GMV est utilisé pour minimiser une fonction coût afin de déterminer les coefficients PID. Le contrôleur proposé est testé selon deux scénarios, une condition de fonctionnement sain et une condition de défaillance du contrôleur de débit. La défaillance est simulée par une perte de 200 sccm. Les résultats expérimentaux montrent une bonne performance avec le contrôleur proposé par rapport à un contrôleur PID classique, les erreurs relatives moyennes (« Mean Relative Error ») passent de +140 % à +30 %. Sur l'ensemble des résultats, l'erreur globale diminue de 50 % à 20 %. En condition de défaillance, il est observé une erreur constante de 15 % avec le contrôleur PID traditionnel, ce qui n'est pas le cas avec la

méthode proposée. Dans un autre article, [Lebreton et al. \(2015\)](#) ont combiné ce contrôleur avec une stratégie AFTC. Un module de diagnostic des défauts et un mécanisme de reconfiguration pour la consigne sont mis en place. Dans cette étude, la validité du contrôleur est confirmée sous des conditions de noyage et d'assèchement.

La matrice jacobienne est également utilisée pour l'adaptation des paramètres PID. Récemment, [Xu, Yan & Ji \(2016\)](#) ont mis en place une régulation avec rejet de perturbation en tension d'une pile SOFC. La variable de commande mise en place est le débit d'hydrogène. Le contrôleur est un PID auto-adaptatif contraint basé sur un modèle RBF. Le modèle RBF est utilisé pour estimer l'information jacobienne, tandis que les paramètres PID sont ajustés par une méthode GD. Le contrôleur développé est comparé avec un contrôleur PID traditionnel. La méthode proposée obtient un temps de réponse plus court sur les changements de courant de 280 à 300 A, mais induit néanmoins de légers dépassements et oscillations durant les phases transitoires.

Un autre moyen d'adaptation des paramètres PID est directement basé sur la sortie du modèle neuronal. [Sedighizadeh & Rezazadeh \(2007\)](#) ont proposé un asservissement de puissance d'une pile PEMFC de 1 kW via les pressions d'entrées anodique et cathodique. Les auteurs ont développé un modèle réseau de neurones de type ondelettes avec un filtre IIR, dont la sortie est directement utilisée pour l'adaptation d'un contrôleur PI. Deux modèles sont utilisés, un pour l'adaptation en gain du paramètre  $k_p$  et l'autre pour l'adaptation en gain du paramètre  $k_i$ . La consigne de puissance varie entre 0,8 et 1 par unité, le contrôleur mis en place propose un suivi de consigne efficace par rapport à un contrôleur inverse de type ondelette, dont le temps de convergence est très lent. De petites fluctuations sont présentes dans les périodes stationnaires, et le temps de réponse à 5% de la consigne de l'asservissement est de quelques secondes.

Dans un autre article, les mêmes auteurs [Sedighizadeh & Rezazadeh \(2010\)](#) ont proposé un asservissement avec rejet de perturbations de la puissance d'une pile PEMFC à partir de l'humidité relative de l'hydrogène. Le contrôleur est une combinaison d'un réseau de neurones de type « wavelet » avec filtre IIR et d'un contrôleur PID. Ici, le réseau de neurones apporte la dynamique du système. Puis, cette dynamique est utilisée par des lois adaptatives basées sur la méthode GD pour déterminer les paramètres PID. Le contrôleur est soumis à une situation de bruit blanc. Le contrôleur proposé démontre des capacités robustes et rapides en suivi de trajectoire. Certains dépassements et oscillations sont présents sur le signal de puissance, ce qui peut s'expliquer par le choix de la variable de commande.



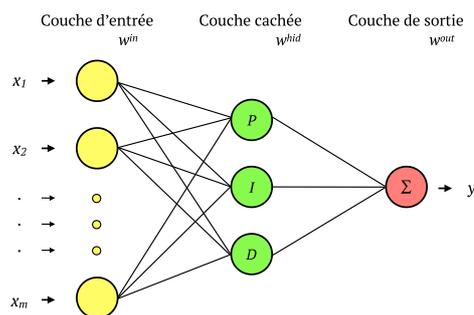
**Figure 21** Structure de contrôle PID neuronale

Comme le montre la [Figure 21](#), les paramètres PID peuvent également être directement estimés par un modèle neuronal. Une approche directe a été entreprise par [Guoai, Shuhai,](#)

Qihong, Liyan & Lin (2010) pour développer l'asservissement de la tension d'une pile PEMFC d'une puissance de 60 kW à partir de la pression en air. Le contrôleur est un PID neuronal auto réglable basée sur le modèle de type Elman. Deux réseaux de neurones sont implémentés dans deux temporalités différentes,  $t$  et  $t + 1$ . L'identificateur neuronal est utilisé pour estimer la pression future en air et un contrôleur neuronal est utilisé pour estimer les paramètres PID. La prévision de la pression est utilisée pour adapter le contrôleur neuronal, ce qui permet d'anticiper l'influence de la commande et d'adapter judicieusement le contrôleur PID. Tous les poids neuronaux sont ajustés par l'algorithme BP. Les résultats de la simulation montrent un ajustement en temps réel des paramètres PID. Le signal de commande est stable et le suivi de consigne est correctement respecté.

Il existe des variantes de cette structure de commande, notamment par l'ajout de contraintes sur le signal de commande. Ji, Xu & Liu (2016) ont récemment proposé un asservissement de la tension d'une pile SOFC en présence de perturbations à partir du débit d'hydrogène. Un module de contrainte sert à limiter le débit d'entrée afin de protéger les composants et les actionneurs. Un modèle RBF est utilisé pour estimer les paramètres PID, ses poids sont ajustés par une méthode GD. Un algorithme basé sur un théorème de convergence asymptotique est implémenté pour sélectionner le taux d'apprentissage approprié, sa stabilité est aussi éprouvée au sens de Lyapunov. Le contrôleur est testé en présence de perturbations de courant entre des niveaux de 280 à 300 A. Le module de contrainte permet de réduire les dépassements pour les hautes puissances, mais également en régime transitoire.

Huang, Li & Sun (2018) ont récemment réalisé une étude AFTC pour un véhicule spatial. Dans des conditions normales atmosphériques, le véhicule est régulé par un contrôleur PID statique. Lorsqu'un défaut est identifié par le module de diagnostic, tel qu'une défaillance actionneur, les paramètres PID sont estimés par un modèle RBF. Les paramètres du modèle RBF sont ajustés par une méthode GD. La convergence et la stabilité du contrôleur sont analysées au sens de Lyapunov. Les résultats de simulation montrent une diminution des dépassements par la méthode proposée par rapport à un contrôleur PID.



**Figure 22** Réseau de neurones imitant le contrôleur PID

Le réseau de neurones peut également simuler directement le comportement d'un contrôleur PID. Comme le montre la Figure 22, cette structure neuronale multicouche se compose de trois neurones cachés. Chaque nœud correspondant à un paramètre PID avec un coefficient neuronal spécifique. La couche de sortie est composée d'une sommation unique qui délivre directement la loi de commande. Les entrées sont les erreurs de position comme un

contrôleur PID. Cette méthode a permis à [Li, Wang & Dai \(2006\)](#) d'obtenir une régulation de la température d'une PEMFC transportable d'une puissance de 12 W. La température du système est contrôlée par la chauffe des gaz d'alimentation. Les paramètres PID varient au cours du temps, et les poids neuronaux sont adaptés à partir de l'erreur de position via une méthode GD. Les résultats expérimentaux montrent moins de dépassement lors du suivi de consigne et une meilleure stabilité comparée à un contrôleur PID. Cependant, la dynamique de réponse est plus lente et le contrôleur PID permet d'atteindre la température de consigne avec une minute d'avance.

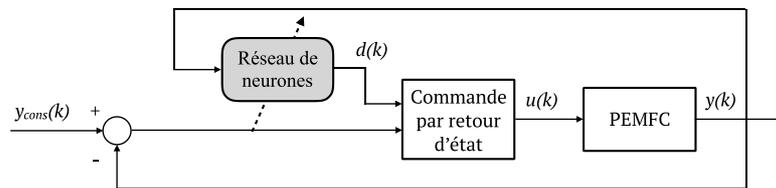
Une approche différente permet un compromis entre robustesse et rapidité d'adaptation. Récemment, [Zribi, Chtourou & Djemel \(2015\)](#) ont proposé d'utiliser la même structure que celle décrite précédemment pour la régulation d'un procédé thermique non linéaire. Pour accélérer le dynamisme de l'adaptation des paramètres du contrôleur PID, un coefficient de gain est implémenté. De cette façon, le contrôleur se dote d'un dynamisme variable et propose ainsi un meilleur rejet de perturbations et une meilleure performance en suivi de consigne. Les dépassements sont également atténués au maximum.

Un contrôleur PID mal optimisé aura tendance à générer des dépassements ou alors un temps de convergence lent. Présentée dans les articles précédents, la structure adaptative PID neuronale offre des performances intéressantes, une convergence rapide avec une atténuation des dépassements, tout en restant simple à mettre en œuvre. Il a également l'avantage d'avoir été validé sur des défaillances auxiliaires, et en présence des défauts de noyage et d'assèchement. Le modèle neuronal permet une grande flexibilité des trois paramètres, qu'ils soient adaptés directement ou non. Pour protéger le système, des modules de contraintes peuvent être implémentés tout en maintenant de bonnes performances. L'utilisation de la matrice jacobienne avec une structure de doubles réseaux de neurones permet de réduire de manière importante les dépassements et d'anticiper la réponse du système face aux commandes. Enfin une analyse de stabilité peut être entreprise au sens de Lyapunov.

#### **2.4.6 Contrôleur neuronal adaptatif par retour d'état**

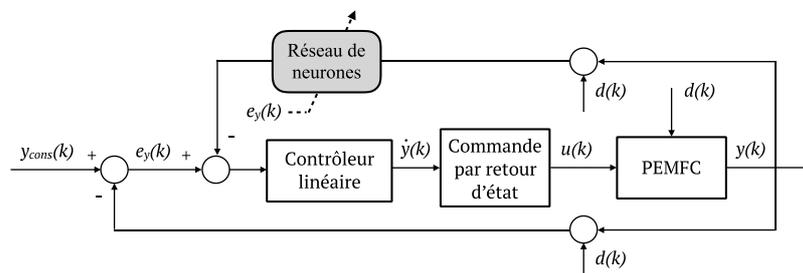
La régulation par retour d'état permet de définir une loi de commande à partir d'un modèle physique dynamique. Elle nécessite l'existence d'équations caractéristiques et la possibilité de quantifier des variables d'états au moyen de capteurs, d'observateurs ou d'estimateurs. Une analyse préliminaire est faite sur l'observabilité et la commandabilité du système étudié avant de procéder à la conception du contrôleur. Un processus de linéarisation est mis en place pour simplifier la complexité du modèle comportemental. Elle se base sur une combinaison linéaire pondérée des termes d'entrées et de sorties présentant des non-linéarités dans le système ([Henson and Seborg, 1996](#)). La transformation d'un système non linéaire en un système linéaire équivalent permet d'appliquer les techniques de contrôle linéaire. Puis, une transformation inverse est réalisée pour retourner dans l'espace d'origine. Une connaissance des états du système est nécessaire pour calculer la commande; cependant, certains termes d'incertitudes, tels que les variations entre la conception et la fabrication, la distribution de

température (Noorkami et al., 2014), les perturbations ou les dégradations, peuvent être estimés par des estimateurs, tels que les réseaux de neurones.



**Figure 23** Structure de contrôle par retour d'état neuronale

Une première approche pour la régulation stœchiométrique en oxygène d'une pile PEMFC a été proposée par Zhang, Pan, Quan, Chen & Shi (2006). Présentée à la Figure 23, la conception du contrôleur est basée sur l'association d'un contrôleur par retour d'état et un modèle ML pour la prévision de la tension de pile. Le modèle linéaire utilisé est obtenu par linéarisation d'un modèle dynamique du neuvième ordre (Pukrushpan et al., 2004). Les poids neuronaux sont ajustés par une méthode BP. Les résultats de la simulation, en présence de perturbations en courant entre 30 et 120 A, montrent un temps de réponse rapide de l'ordre de la seconde et un suivi de consigne efficace. Quelques dépassements en stœchiométrie pour une consigne de  $2 \lambda_{O_2}$  sont présents dès les premiers paliers de courant, mais restent de faibles amplitudes  $0,05 \lambda_{O_2}$ . Elles sont ensuite totalement atténuées sur les paliers de courant suivants.



**Figure 24** Structure de contrôle par retour d'état neuronale avec contrôleur linéaire

Abbaspour, Khalilnejad & Chen (2016) ont récemment mis au point une régulation de la différence de pression anodique et cathodique afin d'éviter la dégradation physique de la membrane. Le contrôleur par retour d'état classique diverge en présence de dynamiques inconnues ou de perturbations. Le réseau de neurones de type ML apporte la réduction de ces déviations en adaptant l'erreur de position utilisée par le contrôleur par retour d'état. Les poids neuronaux sont ajustés suivant une méthode GD. Cette approche qui est décrite sur la Figure 24 permet de compenser les non-linéarités et de réduire les erreurs statiques. Les éléments inconnus (les pressions partielles en hydrogène et en oxygène) sont estimés par un contrôleur linéaire, ici un contrôleur PI. Trois scénarios de test sont mis en place dans la simulation, un système en condition saine, une perturbation dans les pressions d'entrées, et enfin l'intégration d'incertitude dans l'état du système. Le contrôleur adaptatif proposé est comparé avec un contrôleur PI. En condition initiale avec une consigne de pression anodique et cathodique de 3 atm, le contrôleur proposé permet d'effacer les dépassements qui sont présents lorsqu'on utilise

un contrôleur linéaire. En présence de perturbations, le contrôleur neuronal permet de compenser efficacement les changements de courant. En présence d'incertitudes inconnues, le contrôleur neuronal permet une réduction d'oscillations de 20 % sur la pression anodique et de 40 % sur la pression cathodique. Dans ce dernier scénario, le contrôleur PI diverge et montre une incapacité à réguler la pression cathodique.

Dans un article plus récent, les auteurs [Abbaspour, Yen, Forouzannezhad & Sargolzaei \(2019\)](#) proposent d'inclure le contrôleur dans une stratégie FTC avec diagnostic du défaut. La variable à contrôler reste la différence de pression par le biais des valves d'entrées. Deux défauts auxiliaires sont considérés dans cette étude, un défaut compresseur et un défaut sur les valves de sorties. Les résultats en mode Hardware-In-the-Loop montrent une efficacité du modèle neuronale à moduler les signaux de commandes pour éliminer les dépassements et les erreurs statiques qui sont présents sur les résultats avec un contrôleur classique. Les temps de réponse aux perturbations sont mesurés à 0,5 sec avec le contrôleur proposé. La stabilité de la stratégie FTC est analysée au sens de Lyapunov.

Le modèle neuronal flou suscite un grand intérêt dans la littérature, notamment dans la recherche d'atténuation des dépassements. [Mumtaz et al. \(2018\)](#) ont récemment proposé un suivi de puissance maximale pour un système photovoltaïque. Le système étudié est un réseau électrique connecté à des sources d'énergie et d'appoints, telles qu'une batterie, un électrolyseur ou une PEMFC d'une puissance de 260 kW. Un réseau de neurones à six couches est utilisé pour l'estimation des variables inconnues du vecteur d'état, tandis que ses paramètres sont ajustés par la méthode GD. Le contrôleur proposé est comparé à plusieurs contrôleurs traditionnels, notamment un contrôleur PID adaptatif. Les résultats de la simulation montrent de meilleures performances avec le contrôleur proposé avec une erreur en régime permanent de 2,5 kW et des dépassements de 1 %, tandis que les autres contrôleurs atteignent des erreurs de 19,7-105 kW et des dépassements de 5 à 60 %.

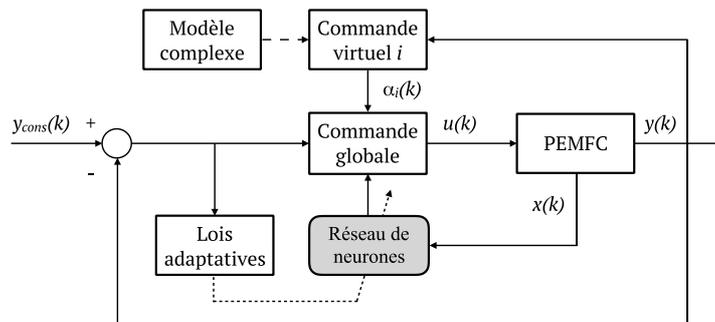
Le contrôleur par retour d'état équipé de capteurs est un outil correcteur très performant, mais nécessite un coût financier plus élevé. L'implémentation des réseaux de neurones pour l'estimation de variables représente une solution viable. L'utilisation de modèle avancé, tel que le modèle de type flou, semble apporter de meilleures performances qu'un modèle RN classique.

#### **2.4.7 Contrôleur neuronal adaptatif par rétrogradation**

Le contrôleur par rétrogradation (« backstepping » ou BS) est basé sur le principe de décomposition d'un système complexe d'ordre  $n$  en une succession de sous-systèmes réduits d'ordre 1. Chaque sous-système est résolu par une fonction candidate de Lyapunov d'où découle une loi de commande. À partir d'un sous-système stable connu, un traitement récursif stabilise les autres sous-systèmes de la chaîne d'intégrateurs un par un. Enfin, tous les pseudo-contrôleurs sont intégrés pour récupérer la loi de contrôle globale. Comme le décrit la [Figure 25](#), les modèles neuronaux sont utilisés pour leur capacité d'approximation des fonctions non linéaires, des variables du système qui ne peuvent être mesurées ou même de variables inconnues, ce qui permet de simplifier la conception du contrôleur. [Depature, Lhomme, Sicard,](#)

Bouscayrol & Boulon (2017) ont effectué une comparaison du contrôleur par rétrogradation sans réseau de neurones à un contrôleur inverse pour une régulation de vitesse d'un véhicule électrique alimenté par une PEMFC d'une puissance de 1.2 kW. Le contrôleur par rétrogradation est construit sur la base d'un modèle du second ordre, et le contrôleur inverse est déduit d'une représentation macroscopique énergétique. Les résultats de la comparaison montrent que l'approche par rétrogradation induit des dépassements plus faibles pendant les phases d'accélération, ce qui se traduit par une meilleure performance de suivi de consigne.

Une seule étude utilisant cette structure de contrôle est proposée par Li, Chen, Cai & Zhang (2011) pour la régulation stœchiométrique en oxygène via la tension du compresseur. Premièrement, une méthode de développement en série de Taylor est utilisée pour linéariser le modèle du troisième ordre non linéaire. Puis, le contrôleur est conçu à l'aide de procédures de rétrogradation sur le modèle linéarisé. Un filtre linéaire, basé sur la méthode de contrôle de surface dynamique, est proposé pour éviter les dérivées de chaque fonction candidate de Lyapunov. Le débit d'entrée en oxygène est estimé à l'aide d'un modèle RBF à partir des pressions d'entrée et de la vitesse de rotation du compresseur. Les paramètres du modèle RBF (fonctions gaussiennes et poids neuronaux) sont adaptés sur la base de lois adaptatives basées sur la méthode de projection en zone morte (« dead-zone projection »). Une analyse de stabilité théorique au sens de Lyapunov est effectuée pour garantir la précision du suivi de consigne. Le contrôleur proposé est comparé à un contrôleur par rétroaction et à un contrôleur PID sous une série de courant de 100 à 270 A. Comparé à un contrôleur PID, la méthode proposée élimine les oscillations et les dépassements présents lors des changements de courant. La régulation induit un temps de réponse plus court et une stabilisation à partir de 0,07 s alors qu'un contrôleur PID nécessite plus que 0,30 s.



**Figure 25** Structure de contrôle par rétrogradation neuronale

Jing & Yang (2018) ont récemment développé une stratégie FTC adaptative aux défauts actionneurs. L'originalité de cette étude est la prise en compte d'un nombre infini de défaillances de capteurs et la contrainte des signaux de commandes. De plus le retard pur du système est intégré dans la conception du contrôleur. Un modèle RBF est utilisé pour l'estimation de variables non mesurées. Les résultats de simulation montrent la capacité effective de compenser le retard inconnu du système et des défauts actionneurs.

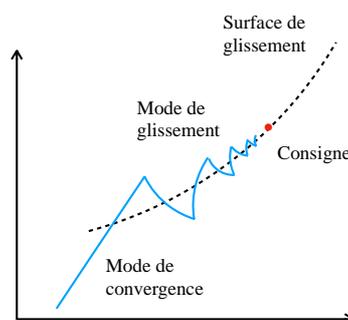
Une approche innovante a été proposée par Dai et al. (2019) pour les systèmes non linéaires, elle consiste en un contrôleur hybride qui combine les signaux de commandes d'un

contrôleur BS et d'un contrôleur ADP basé RN. Le premier objectif est de réaliser un contrôle adaptatif aux défauts par l'estimation des perturbations et l'ajustement en ligne des paramètres de la loi de commande BS. Le second objectif est d'utiliser le contrôle neuronal afin d'assurer une régulation optimale, quel que soit le point de fonctionnement. La solution proposée a été testée en simulation en situation de pertes partielles des actionneurs.

Cette structure de contrôle est très répandue dans la littérature et donne de très bons résultats. Le contrôleur par rétrogradation est bien adapté à la régulation des gaz d'entrée pour les piles à combustible, surpassant la plupart des méthodes conventionnelles. Les avantages sont nombreux, tels que la garantie d'une stabilité globale ou l'utilisation d'un modèle neuronal pour l'estimation de la dynamique du système. La contribution du modèle neuronal comme estimateur offre une solution simple pour obtenir les variables non mesurées. L'estimateur permet de réduire le phénomène d'oscillations et augmenter la précision du contrôle. Des essais d'expérimentation avec des conditions de défaut permettraient de tester ce contrôleur et d'évaluer davantage les performances.

#### 2.4.8 Contrôleur neuronal adaptatif par mode glissant

L'approche de contrôle par mode glissant est caractérisée par un ensemble de lois de commande rétroactive et d'une loi de commutation. La loi de commande se décompose en deux termes, ce processus est décrit sur la [Figure 26](#). Le premier est le mode de convergence, où l'objectif est de contraindre asymptotiquement le système à partir d'une condition initiale quelconque, à atteindre une fonction donnée avec une dynamique de convergence. Une fois que la consigne est atteinte dans une limite donnée, le deuxième terme, le mode de glissement s'assure du suivi de consigne. Selon que l'erreur de position est positive ou négative, un signal de commande discontinue est appliqué. De cette manière, le contrôleur est robuste aux perturbations, aux incertitudes du système et garantit une convergence temporelle finit. Cependant, ces avantages sont au détriment du phénomène de réticence (« chattering ») autour de la consigne, et au phénomène de dépassement qui peut être important. La pile à combustible et les actionneurs sont des organes sensibles aux oscillations ([Kunusch et al., 2012](#)), le contrôle par mode glissant n'est donc pas une méthode systématique pour le contrôle du système. Pourtant, des méthodes existent pour réduire ces phénomènes, tels que la logique floue ([Nagarale et al., 2007](#)) ou la mise en œuvre d'observateurs ([Lee and Utkin, 2007](#)).



**Figure 26** Principe de correction par mode glissant

Les méthodes utilisant ce contrôleur pour une application PEMFC dans la littérature n'utilisent pas de réseau de neurones. Ces études seront tout de même abordées brièvement dans cette partie. [Laghrouche, Harmouche, Ahmed & Chitour \(2014\)](#) ont développé un asservissement avec rejet de perturbations sur la stœchiométrie en oxygène afin de réduire la consommation électrique de l'ensemble du système. L'application est testée sur un modèle pile de 33kW. En envisageant une commande par mode glissant d'ordre supérieur (« high order sliding mode »), l'étude vise à réduire les oscillations autour de la consigne. Un modèle du 3<sup>e</sup> ordre est utilisé pour la construction des lois de commande. Les deux termes du mode glissant sont pondérés par des gains adaptatifs. Ils sont construits sur la base d'équation différentielle ordinaire dont la fonction inconnue est une fonction homogène au sens de Lyapunov. Le contrôleur adaptatif proposé est comparé à un contrôleur robuste. Le courant de la pile varie entre 150 et 400 A, ce qui provoque des variations en stœchiométrie entre les paliers de 1,3 à 2,9  $\lambda_{O_2}$ . De faibles oscillations et dépassements sont clairement visibles sur la méthode proposée. Malgré tout, l'adaptation aux incertitudes et la faisabilité de la méthode sont tout de même confirmées.

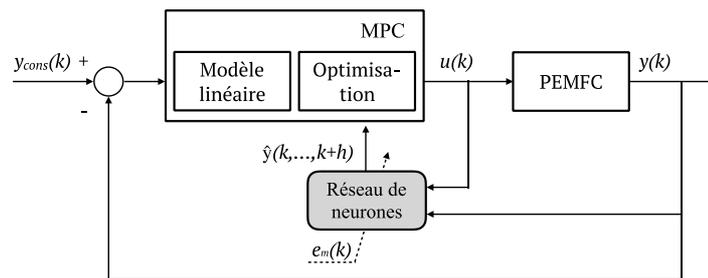
Dans un autre article, [Matraji, Ahmed, Laghrouche & Wack \(2015\)](#) ont proposé des scénarios de tests similaires à l'étude précédente pour évaluer les performances d'une approche mode glissant super tension (« super twisting sliding mode »). L'objectif étant d'ajuster les paramètres de gains afin de contraindre l'état du système à converger plus rapidement sur l'état stable. La structure de contrôle est sous une forme en cascade comprenant deux boucles dynamiques. Une boucle externe pour définir la consigne du compresseur par l'estimation de la stœchiométrie en oxygène et une boucle interne pour définir le courant du compresseur à partir de l'erreur de vitesse angulaire. La régulation en présence de perturbations en courant de charge montre un suivi de consigne avec des oscillations bien moins importantes. Néanmoins, la constante de temps de la régulation est bien plus importante qu'un contrôleur robuste.

Un asservissement de température avec rejet de perturbations est effectué par [Fang, et al. \(2017\)](#). Le modèle prend en compte les retards purs des actionneurs et la dynamique thermique entre l'entrée et la sortie de la pile. Un filtre de Kalman est implémenté pour l'estimation de température non mesurée. Et enfin, dans le but de réduire le phénomène de réticence, un filtre passe-bas est appliqué sur la commande. Les perturbations testées sont le courant de charge qui varie entre les niveaux de 30 et 130 A, et la température du liquide de refroidissement en entrée de pile qui chute de 61 à 50 °C. Les résultats d'expérimentations sur un système PEMFC de 10 kW montrent la capacité de la méthode proposée à stabiliser la température en sortie de pile. Une erreur de  $\pm 1$  °C est présente avec la méthode proposée, alors qu'une erreur de  $\pm 3$  °C est présente avec un contrôleur PI.

L'approche par mode glissant est une approche de pure régulation d'un système tout en étant insensible aux incertitudes et perturbations. Le modèle réseau de neurones est très répandu en littérature pour l'estimation de gains ([Yin et al., 2017](#)), de variables non mesurées ([Nguyen et al., 2018](#)), mais également pour la compensation de perturbations ([Lee et al., 2004](#)). Ce sont des voies qui peuvent être explorées.

### 2.4.9 Contrôleur neuronal adaptatif par commande prédictive

Le contrôleur par commande prédictive (« Model Predictive Control » ou MPC) neuronale, tout comme le contrôleur par mode glissant neuronal, est une approche qui reste peu utilisée dans la littérature de la pile PEMFC. Sa structure est présentée à la Figure 27. Le contrôleur MPC s'appuie sur un modèle dynamique du système, il s'agit le plus souvent d'un modèle empirique obtenue par linéarisation du système. Le contrôleur est composé d'un processus d'optimisation basé sur un critère qui prend en compte les états futurs du système, il s'agit donc d'un contrôle par anticipation. Il intègre implicitement les contraintes en limitant la plage de fonctionnement des commandes lors des premières itérations.



**Figure 27** Structure de contrôle par MPC neuronale

Un contrôleur adaptatif MPC avec estimateur neuronal est proposé par [Bao, Ouyang & Yi \(2006\)](#). Le modèle neuronal identifié de type ARX pour la prévision, il est ajusté en ligne suivant une méthode BP. L'objectif de l'étude numérique est d'assurer la stœchiométrie cathodique à  $2 \lambda_{O_2}$  et une différence de pression de 0,2 bar entre l'anode (+0,2) et la cathode. Le contrôle est effectué dans une situation de courant variable et la commande est la pression d'entrée cathodique. Le contrôleur proposé permet un temps de convergence à 5 % de la consigne plus rapide qu'un contrôleur PI (2 s à <1 s). Les oscillations et dépassements sont néanmoins plus importants (+/- 0,2 bar sur 3 bar). Ces effets se reflètent sur la différence de pression où les amplitudes des dépassements sont moins importantes avec la méthode proposée.

Une application en AFTC sur une pile DMFC a été effectuée par [Keller, Ding, Müller & Stolten \(2017\)](#). À chaque itération, une linéarisation est réalisée à partir d'un modèle non linéaire et des entrées-sorties du système. Un observateur est développé sur un modèle semi-empirique pour obtenir la prévision du débit en gaz réactif. Le contrôleur est configuré sur un horizon de prévision à 250 ms et un horizon de contrôle de 50 ms. Des coefficients dynamiques et des contraintes sont imposés suivant le défaut encouru. Les résultats montrent des performances globalement satisfaisantes.

Une récente étude comparative considère les temps de calcul pour la prévision des états futurs. [Wong et al. \(2018\)](#) ont démontrés que le temps d'itération d'un RN de type ML à 1000 neurones caché (1,17 ms) n'est pas supérieur à un observateur traditionnel basé sur une méthode itérative d'optimisation Runge-Kutta (1,55 ms).

[Sadeghassadi et al. \(2018\)](#) ont proposé une structure MPC neuronale pour le contrôle de la concentration d'oxygène dissous dans les procédés de traitement des eaux usées. Un modèle de type ARX avec un apprentissage par RLS est utilisé pour la prévision d'états. Le

contrôleur est testé en présence de perturbations extérieures et affiche de meilleures performances comparées à un contrôleur PI traditionnel. Une stabilité au sens de Lyapunov est réalisée pour la boucle de contrôle.

Une approche originale propose de remplacer directement le contrôleur MPC par un modèle neuronal (Mohamed et al., 2019). Il s'agit de réaliser en d'autres mots une structure de contrôle par modèle de rétroaction.

L'approche MPC neuronale reste actuellement en cours de développement dans le domaine PEMFC. La prise en compte des états futurs sur un horizon fixe est un véritable atout dans un objectif de contrôle optimal où les modèles physiques restent difficiles à appréhender. Des actions prises à un instant  $t$  peuvent avoir des répercussions non immédiates, mais visibles au fil du temps. L'estimation sur plusieurs temps est ici une capacité supplémentaire qui peut être profitable aux situations de défauts à dynamiques longues.

## 2.5 Synthèse et discussion sur l'état de l'art

Après avoir détaillé les différentes méthodes de la littérature, des tableaux de synthèses regroupant les approches et les performances sont donnés dans cette section. Parmi les approches entreprises pour le contrôle de la PEMFC, plusieurs scénarios de tests communs peuvent être identifiés comme suit :

- Suivi de consigne (Abbaspour et al., 2016; Almeida and Simoes, 2005; Bao et al., 2006; Li et al., 2009, 2011; Rakhtala et al., 2011; Rezazadeh et al., 2011; Sanchez et al., 2010, 2014; Zhang et al., 2006).
- Régulation (Dong et al., 2003; Guoai et al., 2010; Li et al., 2006; Sedighizadeh and Rezazadeh, 2007; Sun et al., 2005).
- Régulation avec rejet de perturbations (Abbaspour et al., 2016; Sedighizadeh and Rezazadeh, 2010).
- Suivi de consigne en présence de défauts auxiliaires (Abbaspour et al., 2019; Damour et al., 2014; Lebreton et al., 2016; Ragb et al., 2011).
- Atténuation de défauts système (Lebreton et al., 2015).

### 2.5.1 Tableaux de synthèses sur l'état de l'art

Le [Tableau 12](#) résume l'ensemble des approches. Les résultats en contrôle de stœchiométrie, de tension, de différence de pression, et de température sont respectivement résumés sur les [Tableau 13](#), [Tableau 14](#), [Tableau 16](#) et [Tableau 15](#).

**Tableau 12** Synthésation des structures de contrôles adaptatifs neuronaux appliquées pour la pile PEMFC

Structure de contrôle	Application	Période de calcul	Type de réseau de neurones	Entrée(s) du réseau de neurones	Sortie(s) du réseau de neurones	Méthode d'adaptation	Consigne (et perturbations)
Modèle inverse	Stœchiométrie en oxygène via la tension du compresseur <a href="#">Li et al. (2009)</a>	-	Logique floue récurrente	Consigne en débit d' air de sortie pile (t ; t-1)	Tension du compresseur	Paramètres du modèle RF par GD	$\lambda_{O_2} = 2$ (0,1-0,3 A/cm <sup>2</sup> )
Modèle de réaction	Puissance via humidité de l' hydrogène <a href="#">Sedighzadeh &amp; Rezazadeh (2010)</a> Stœchiométrie en oxygène via la tension du compresseur <a href="#">Sánchez et al. (2010, 2014)</a>	0,002 s	Ondelettes avec filtre IRR B-Spline	Consigne en puissance unitaire Erreur stœchiométrique en oxygène	Humidité relative de l' hydrogène Tension du compresseur	Poids neuronaux par LS Poids neuronaux par GD	P = 0,5-1 pu (bruit blanc) $\lambda_{O_2} = 2$ (100-300 A)
Hybride	Température pile via les débits de gaz et du refroidissement <a href="#">Dong et al. (2003)</a> Température de pile via les débits de gaz <a href="#">Sun et al. (2005)</a> Tension via pression d' entrée en air <a href="#">Rakhtala et al. (2011)</a> Tension par débit de méthane <a href="#">Rezazadeh et al. (2011)</a>	2 s 2 s 2 s	Logique floue Logique floue ML RBF	Erreur de température (e(k) ; $\Delta e_i(k)$ ) Erreur de température (e(k) ; $\Delta e_i(k)$ ) Consigne en tension Consigne en tension	Débits d' hydrogène, d' oxygène et du liquide caloporteur Débits d' hydrogène et d' oxygène Pression d' entrée en air Débit de méthane	Poids neuronaux par BP Poids neuronaux par BP Poids neuronaux par GD Poids neuronaux par des lois adaptatives Poids neuronaux par RLS	T = 80 °C T = 80 °C V = 57 V (18-33 A) V = 53 V (70-90 A, Bruit blanc 1%) $\lambda_{O_2} = 2$ (100-300 A, perte compresseur 30 %)
Programmation dynamique	Tension via les pressions d' entrées des gaz <a href="#">Almeida et al. (2005)</a>	-	CMAC	Courant de charge (t) Tension compresseur, Tension pile, puissance, stœchiométrie en oxygène (t-1) Erreur en tension	Pressions d' entrées d' hydrogène et d' oxygène	Poids neuronaux par GD	V = 24-28 V (5-25 A)
Proportionnel intégral dérivé	Stœchiométrie en oxygène via le débit d' entrée <a href="#">Lebreton et al. (2016)</a> <a href="#">Lebreton et al. (2015)</a> <a href="#">Damour et al. (2014)</a>	3 s	ARX	Stœchiométrie en oxygène (t-1) Débit en oxygène (t-1)	Stœchiométrie en oxygène (t)	Paramètres PID par GMV	$\lambda_{O_2} = 2-5$ (15-25 A, perte contrôleur de débit -200 sccm)

*Passer à la page suivante*

**Tableau 12** Synthésation des structures de contrôles adaptatifs neuronaux appliquées pour la pile PEMFC (Suite)

Structure de contrôle	Application	Période de calcul	Type de réseau de neurones	Entrée(s) du réseau de neurones	Sortie(s) du réseau de neurones	Méthode d'adaptation	Consigne (et perturbations)
Proportionnel intégral dérivé	Puissance par les pressions d' entrées Sedighizadeh & Rezazadeh (2007) Sedighizadeh & Rezazadeh (2010)	-	Ondelettes avec filtre IIR	Pressions d' entrées des gaz	Coefficients de gains pour les paramètres PI	Poids neuronaux par LS	P = 0,8-1 pu
	Tension via pression d' entrée en air Guoai et al. (2010)	-	Elman	Tension Débit en air Température de l' air Pression en air (t+1)	Pression en air (t+1) Paramètres PID (t)	Poids neuronaux par BP	V = 0,25-1 V et (A = 20-100 %)
Retour d' état	Température par la chauffé des gaz Li et al. (2006) Stœchiométrie en oxygène via la tension du compresseur Zhang et al. (2006) Différence de pression à la membrane via les pressions anodique et cathodique Abbaspour et al. (2016) Abbaspour et al. (2019)	-	ML-PID ML ML	Consigne en température Température de pile Courant (t) Débits des gaz (t) Pressions d' entrées des gaz Différence de pression à la membrane	Températures de chauffé anode et cathode Tension de pile (t+1) Compensation de la commande	Poids neuronaux par GID Poids neuronaux par BP Poids neuronaux par loi sigmoïdale	T = 40 °C $\lambda_{O_2} = 2$ d : 25-140 A P = 3 atm O <sub>2</sub> et H <sub>2</sub> (P = 250-3200 W et incertitudes paramétriques)
Rétrogradation	Stœchiométrie en oxygène via la tension du compresseur Li et al. (2011)	-	RBF	Pression d' entrée des gaz. Vitesse du compresseur.	Fonction non affine représentant la dynamique du sous-système d' alimentation.	Poids neuronaux par projection en zone morte	$\lambda_{O_2} = 2$ (100-270 A)
Commande prédictive	Stœchiométrie en oxygène, la pression d' entrée cathodique et la différence de pression à la membrane Bao et al. (2006)	0,01 s	ARX	Sorties précédentes + tension régulateur de contre-pression, tension du moteur et tension régulateur de pression	Prévisions futures : débit du compresseur, pressions, tension du stack, puissance nette	Paramètres neuronaux par BP	$\lambda_{O_2} = 2$ , P <sub>ca,in</sub> = 2,6-3,2 bar et $\Delta P_{an/ca} = 0,2$ bar (250-300 A)

**Tableau 13** Récapitulatif des structures de contrôles adaptatifs neuronaux appliqués au contrôle de stoechiométrie

Contrôle de stoechiométrie	
<b>Inverse</b>	<p><b>Résultats de l' étude</b> Convergence plus rapide qu' un PI. Diminution de l' amplitude transitoire. Pas de dépassements ni d' oscillations. Stabilise le rendement du compresseur (72-76 %).</p> <p>Li et al. (2009)</p>
<b>Rétroaction</b>	<p><b>Résultats des études</b> Atténuation des dépassements comparés à un PI. Suppression des erreurs de positions permanentes comparées à un modèle inverse.</p> <p>Sánchez et al. (2010, 2014)</p>
<b>Hybride</b>	<p><b>Résultats de l' étude</b> Possède les mêmes performances de suivi de consigne en situation de système sain ou défaillant.</p> <p>Ragb et al. (2011)</p>
<b>PID</b>	<p><b>Résultats de l' étude</b> Effacement de l' erreur constante en situation de défaut auxiliaire comparé à un PID. Moins d' erreurs qu' un PID traditionnel (MRE de 13.71 à 1.35).</p> <p>Lebreton et al.(2016, 2015) ;Damour et al. (2014)</p>
<b>Retour d' état</b>	<p><b>Résultats de l' étude</b> Temps de réponse rapide. Bonne précision du contrôleur.</p> <p>Zhang et al. (2006)</p>
<b>Rétrogradation</b>	<p><b>Résultats de l' étude</b> Effacement des oscillations et dépassement comparés à un PID.</p>
<b>MPC</b>	<p><b>Résultats de l' étude</b> Temps de convergence à 5 % plus rapide qu' un PI.</p> <p>Bao et al. (2006)</p>
<b>Observations</b>	<p>Stabilité non assurée.</p>
<b>Observations</b>	<p>Faibles oscillations aux premières itérations. Stabilité non assurée.</p>
<b>Observations</b>	<p>Faibles dépassements. Temps de réponse de quelques secondes.</p>
<b>Observations</b>	<p>Stabilité non assurée. Réseau de neurones figé.</p>
<b>Observations</b>	<p>Stabilité non assurée. Très faibles dépassements.</p>
<b>Observations</b>	<p>Stabilité du contrôleur assurée. Temps de réponse très court comparé au PID (0.07s à 0.30 s).</p>
<b>Observations</b>	<p>Présences d' oscillations comparée à un PI. Stabilité non assurée.</p>

**Tableau 14** Récapitulatif des structures de contrôles adaptatifs neuronaux appliqués au contrôle de tension

Contrôle de tension			
<b>Inverse</b>		<b>Hybride</b>	
<p><b>Résultats de l'étude</b></p> <p>Suivi de consigne équivalent sous un fonctionnement normal ou perturbé par bruit blanc.</p> <p><b>Observations</b></p> <p>Forts dépassements et oscillations. Stabilité non assurée.</p>	<p><b>Résultats des études</b></p> <p>Bonne robustesse (variance de 1 % sur un bruit blanc réglé sur un écart-type de 0.2 %). Moins de fluctuations comparées à un PID. Commande plus fluide par rapport à un PID.</p> <p><b>Observations</b></p> <p>Temps de réponse de l'ordre de 10s.</p>	<p><b>Programme</b></p> <p><b>Résultats de l'étude</b></p> <p>Réduction progressive de l'erreur de position comparée au PID qui maintient une erreur permanente (MSE 0.99V à 0.24 V).</p> <p><b>Observations</b></p> <p>Temps de réponse du PID plus rapide.</p>	<p style="text-align: center;"><b>PID</b></p> <p><b>Résultats des études</b></p> <p>Signal de commande stable. Suivi de consigne satisfaisant. Temps de réponse plus rapide qu'un contrôleur inverse. Robuste au bruit blanc.</p> <p><b>Observations</b></p> <p>Fluctuations dans le transitoire. Stabilité non assurée.</p>

**Tableau 15** Récapitulatif des structures de contrôles adaptatifs neuronaux appliqués au contrôle de température

Contrôle de température	
<b>Rétroaction</b>	<b>PID</b>
<p><b>Résultats de l'étude</b></p> <p>Peu de fluctuation dans la période transitoire. Contrôle fluide des différents débits. Convergence rapide.</p> <p><b>Observations</b></p> <p>Stabilité non assurée.</p>	<p><b>Résultats de l'étude</b></p> <p>Moins de dépassements et d'oscillations comparés à un PID.</p> <p><b>Observations</b></p> <p>Temps de réponse inférieur à un PID. Stabilité non assurée.</p>

**Tableau 16** Récapitulatif de la structure de contrôle adaptatif neuronale appliqué au contrôle de pression

Contrôle de pression	
<b>Retour d'état</b>	<b>MPC</b>
<p><b>Résultats de l'étude</b></p> <p>Effacement des dépassements comparé à un PI. Compense efficacement les perturbations comparées à un PI qui diverge. Réduit les oscillations en présence d'incertitudes (20 % pression anode, 40 % pression cathode). Applicable en temps réel.</p> <p><b>Observations</b></p> <p>Stabilité assurée.</p>	<p><b>Résultats de l'étude</b></p> <p>Temps de convergence à 5 % plus rapide comparé à un PI. Dépassements ponctuels moins importants comparés à un PI.</p> <p><b>Observations</b></p> <p>Oscillations plus importantes comparées à un PI. Stabilité non assurée.</p>

## 2.5.2 Discussion sur l'état de l'art

Un large éventail de structures de contrôle et de mécanismes adaptatifs a été mis en œuvre pour la PEMFC, cette diversité permet une analyse pour sélectionner les outils les plus pertinents. Quatre variables de contrôle sont couramment utilisées : la stœchiométrie en oxygène, la puissance de la pile, la température et la différence de pression à la membrane.

Le contrôle sur le débit de gaz implique des actions rapides pour desservir efficacement la consommation en réactifs. Le but étant de réduire au minimum les durées des phases de sous-alimentation qui détériore la membrane. Il en va de même pour l'excès d'évacuation d'eau due à une exposition prolongée en fort débit. Le meilleur moyen d'y parvenir est l'approche par rétrogradation qui offre un temps de réponse très faible, tout en étant robuste aux perturbations de courant. Elle limite également fortement les oscillations qui peuvent apparaître dans les périodes transitoires, et assure une stabilité asymptotique de par sa construction. Pour la prise en compte de perturbations plus complexes, l'approche neuronale PID ou neuronale hybride ont déjà fait leurs preuves en situation de pertes de gain du compresseur, de pertes de gain du contrôleur de débit ou encore en situation de noyage ou d'assèchement.

La génération d'eau est localisée à la cathode, ainsi, la stœchiométrie cathodique fait figure d'acteur principal dans les stratégies de gestion d'eau. Le débit étant étroitement lié à la pression, la pression anodique doit suivre les variations de pressions cathodiques. Ceci afin de garder une différence de pression nulle à la membrane, limitant ainsi les stresses mécaniques et par la même occasion les instabilités sur le signal de tension. Une approche par retour d'état présente de bonnes performances que ce soit en situation de perturbations inconnues ou d'incertitudes paramétriques. Le réseau de neurones est utilisé ici comme compensateur, il permet d'anticiper les actions prises par le contrôleur. La méthode montre des capacités d'effacement de dépassement et affiche une adaptation effective où les poids neuronaux convergent après chaque perturbation.

Les mêmes besoins sont transposables pour une application en puissance. Les approches neuronales PID et hybride présentent ici aussi de bonnes performances sur le pilotage des pressions d'entrées. Les commandes ne présentent pas d'oscillations, les temps de réponse sont acceptables et la régulation est robuste aux perturbations qui peuvent être générées les capteurs de pressions sensibles.

Le contrôle de la température est un élément important dans le fonctionnement des piles à combustible. La température des vapeurs d'eau, des conduites d'alimentation ou encore de la pile fait partie des facteurs influençant le contenu en eau de la membrane, les réactions chimiques et toute la gestion en eau du système. Les contrôles adaptatifs neuronaux des PEMFC sont très peu rapportés dans la littérature, seuls quelques tests en démarrage ont été effectués. Le contrôleur neuronal PID présente le meilleur suivi de consigne pour des courants élevés avec des dépassements relativement faibles. Pour des courants faibles, c'est l'approche inverse qui donne de bons résultats.

Pour améliorer les performances et les capacités d'adaptation, certains développements peuvent être envisagés. Tout d'abord, l'approche par rétrogradation avec l'intégration d'estimateur ou d'observateur pour les situations de défauts système. Les études sur le mode glissant neuronal ont aussi montré que ces méthodes pouvaient être explorées. Concernant la

l'adaptabilité, l'algorithme par logique floue semble être le plus appropriée pour la détermination des paramètres d'apprentissage. La méthode peut être appliquée sur les coefficients PID ou dans le cadre des apprentissages neuronaux. Les contrôleurs ayant des capacités prédictifs, anticipateurs présentent également des avantages non négligeables afin de limiter l'amplitude des déviations. L'association de réseau de neurones avancés tels que les architectures de hautes dimensions ou de structures profondes présentent des opportunités nouvelles à expérimenter. Néanmoins, ces approches de contrôle doivent respecter, dans toutes les situations, certaines obligations :

- L'estimation de la commande optimale avec un temps de réponse en adéquation avec la nature des défauts système. Le but étant de garantir un temps de convergence sur la consigne cohérent avec la nature du défaut à atténuer.
- La mise en place de mécanisme d'actualisation des paramètres neuronaux en ligne et en temps réel. Les temps d'opérations doivent prendre en compte les retards purs des composants, c'est-à-dire la chaîne de transport de l'information. Ils ne doivent pas rajouter de retard supplémentaire.
- Une optimisation des réseaux de neurones, ou la justification des valeurs d'hyperparamètres.
- Garantir et maintenir une stabilité de la boucle de contrôle, quels que soient le point de fonctionnement et les perturbations, ou du moins définir une plage de fonctionnement.

## 2.6 Choix de la structure de contrôle

Le principe de sélection s'appuie sur la définition d'une série de critères permettant d'évaluer par l'intermédiaire d'une note le degré de satisfaction d'une solution (Roland, 2011). La solution recherchée dans cette étude est la structure de contrôle neuronal adaptative.

### 2.6.1 Définitions et pondérations des critères de sélection

Deux classes de critères sont mises en place dans cette étude. Des critères objectifs qui s'appuient sur la possibilité de quantifier parfaitement la solution, et des critères subjectifs qui dépendent du niveau de connaissance de la solution. Les critères de choix d'implantation du contrôle neuronal adaptatif sont les suivantes :

– **Critères objectifs :**

- C1 : L'originalité scientifique, le potentiel novateur
- C2 : L'absence de modèle physique
- C3 : La place du réseau de neurones, le nombre mis en place
- C4 : L'anticipation du contrôleur, l'intégration de données futures
- C5 : L'absence de préapprentissage

– **Critères subjectifs :**

- C6 : Les performances immédiates
- C7 : Les performances de contrôle
- C8 : Le minimum d'effort de calcul
- C9 : La simplicité d'intervention, de mise à jour par l'utilisateur

Tous les critères n'ayant pas la même importance, une valorisation de ces derniers par un coefficient  $k$  est entreprise. Ce qui permet de pondérer les notes obtenues par critère. Les critères objectifs ont naturellement une pondération plus importante que les critères subjectifs. Il devient alors possible de noter les solutions en faisant la somme de l'ensemble des notes obtenues résultant des différents critères d'évaluation. Cela donne lieu à des métriques, des longueurs mesurables dans un espace donné. Un classement des solutions est alors effectué et il ne sera retenu que la ou les solutions obtenant les meilleurs scores. Les barèmes de notation et de pondération sont donnés au [Tableau 17](#).

Valorisation $k$ affectée aux différents critères $C_i$		Intérêt $j$ de la solution au regard des critères $C_i$	
Peu important	1	Satisfaisant	1
Important	2	Bonne	2
Assez important	3	Très bonne	3
Très important	4	Excellent	4
Vital	5		

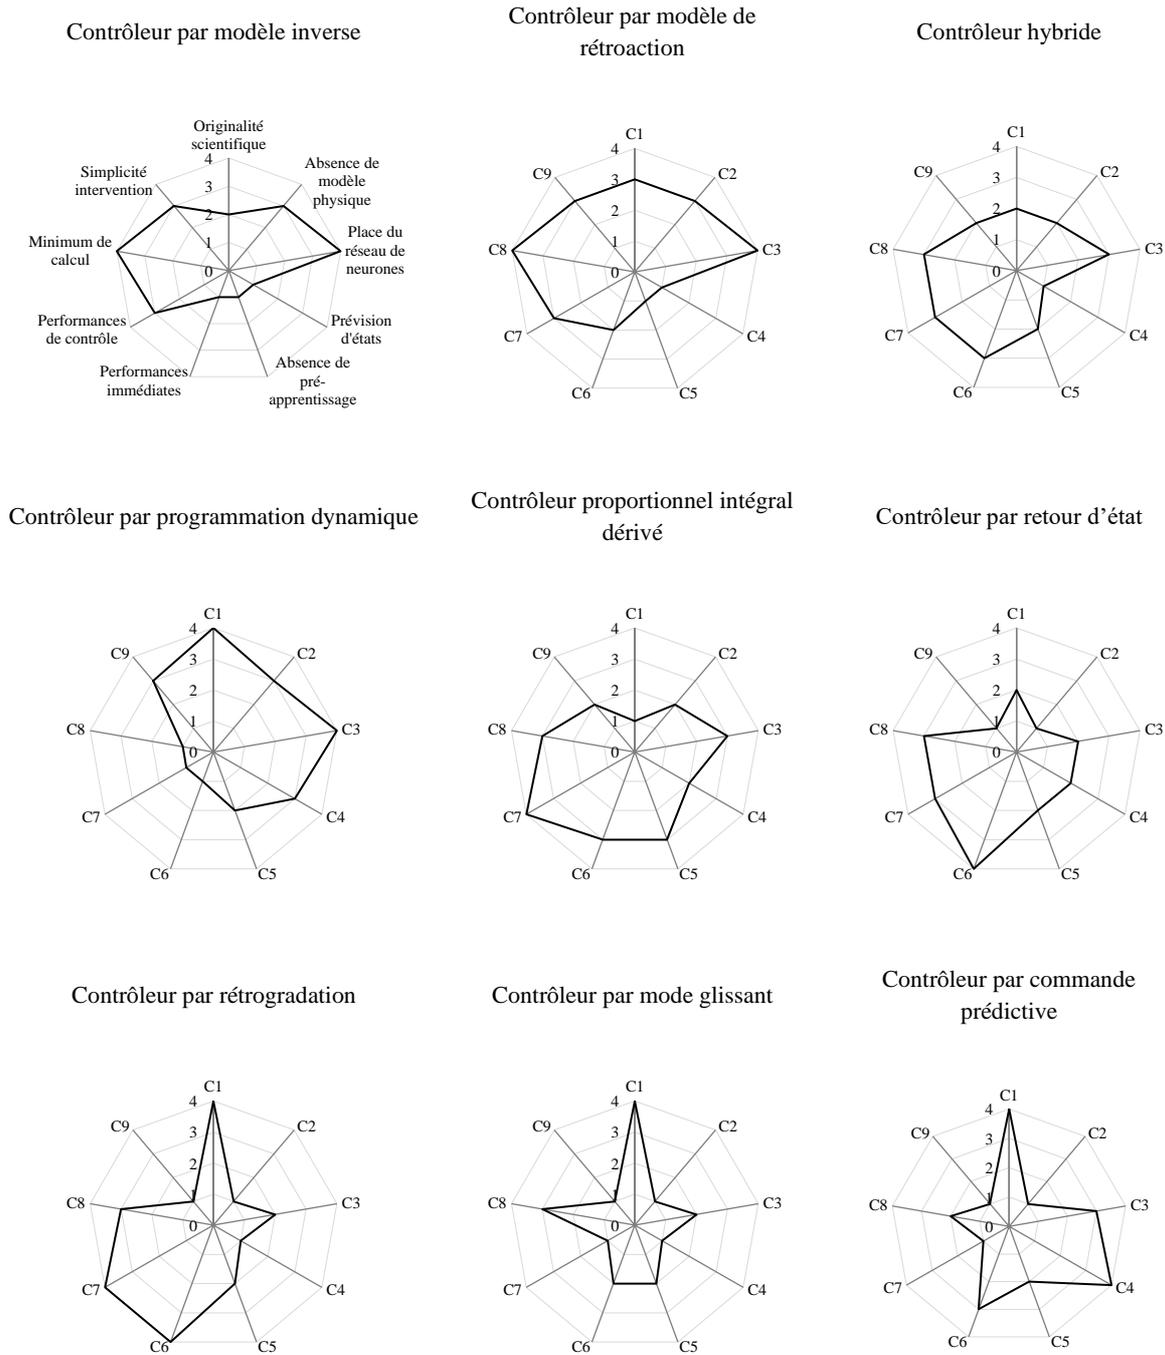
**Tableau 17** Barèmes de notation et de pondération pour le choix de la structure de contrôle

## 2.6.2 Justification de la valorisation des solutions

La valorisation des critères est justifiée ci-dessous :

- C1** Les travaux doivent s'inscrire dans une originalité scientifique  $\Rightarrow 5$
- C2** Ce critère est primordial pour obtenir une capacité de généricité du contrôleur  $\Rightarrow 4$
- C3** La place du RN doit être importante dans l'obtention de la commande  $\Rightarrow 4$
- C4** La capacité d'anticipation permet de compenser les retards possibles  $\Rightarrow 3$
- C5** De même que le critère C2, la nécessité de préapprentissage est un frein à la capacité de généricité du contrôleur. Une sauvegarde des données en ligne et un apprentissage en ligne est tout de même envisageable.  $\Rightarrow 3$
- C6** Un compromis est nécessaire entre le contrôle clé en main et l'adaptabilité  $\Rightarrow 2$
- C7** Les différents résultats de la littérature au regard des besoins sont à prendre en considération  $\Rightarrow 2$
- C8** Sous une perspective d'intégration mobile, le calcul doit rester raisonnable  $\Rightarrow 2$
- C9** La possibilité d'intervention, de maintenance du contrôleur apporte un réel confort dans son utilisation  $\Rightarrow 1$

Une valeur est donnée à chaque solution technique et critère associé, la méthodologie et les justifications de ces derniers sont données dans l'[Annexe B](#). Pour visualiser les appréciations sans pondérations, des diagrammes de Kiviat sont établis en [Figure 28](#) pour faciliter leurs représentations.



**Figure 28** Diagrammes de Kiviati des contrôleurs au regard des critères de sélection

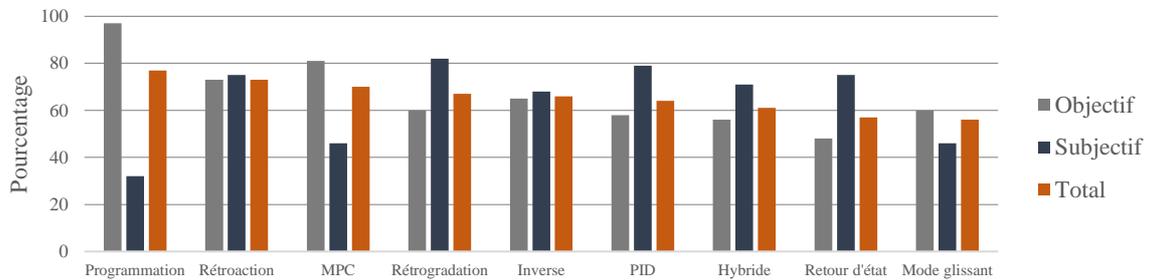
### 2.6.3 Notation des structures de contrôles

Les diagrammes de Kiviati permettent l'analyse de plusieurs solutions, suivant plusieurs caractéristiques quantifiables. Une normalisation suivant l'importance donnée est attribuée à chaque caractéristique afin d'obtenir des niveaux comparables. Ces diagrammes avec deux classes de critères peuvent être analysés de la manière suivante. Les cinq axes à droite, les critères objectifs révèlent la pertinence de deux approches, le contrôleur par modèle de rétroaction et le contrôleur par programmation dynamique. Les quatre axes à gauche, les

critères subjectifs, révèlent la pertinence de trois approches, le contrôleur PID, le contrôleur par retour d'état et le contrôleur par rétrogradation. En associant les critères par une pondération spécifique, la notation des solutions devient celle présentée au [Tableau 18](#).

		Inverse		Rétro		Hybride		DP		PID		Etat		BS		SMC		MPC		Max	Total			
Objectif	Ci	k	j	Note	j	Note	j	Note	j	Note	j	Note	j	Note	j	Note	j	Note	j	Note				
	C1	5	2	10	3	15	2	10	4	20	1	5	2	10	4	20	4	20	4	20	4	20	20	
C2	4	3	12	3	12	2	8	3	12	2	8	1	4	1	4	1	4	1	4	1	4	12		
C3	4	3	12	3	12	2	8	4	16	2	8	1	4	1	4	1	4	2	8	3	12	12		
C4	3	1	3	1	3	1	3	3	9	2	6	2	6	1	3	1	3	4	12	3	9	9		
C5	3	1	3	1	3	2	6	1	3	3	9	2	6	2	6	2	6	2	6	2	6	9	9	
Total objectif				40			45			35			60			36			30			37		
				65			73			56			97			58			48			60		
																						62	Pts	
																						100	%	
Subjectif	C6	2	1	2	2	4	3	6	1	2	3	6	4	8	4	8	2	4	3	6	4	8		
	C7	2	3	6	3	6	3	6	1	2	4	8	3	6	4	8	1	2	1	2	4	8	8	
C8	2	4	8	4	8	3	6	1	2	3	6	3	6	3	6	3	6	2	4	4	8	8		
C9	1	3	3	3	3	2	2	3	3	2	2	1	1	1	1	1	1	1	1	1	4	4		
Total subjectif				19			21			20			9			22			21			23		
				68			75			71			32			79			75			82		
																						13	Pts	
																						13	%	
																						46		
																						46		
Total objectif + subjectif				59			66			55			69			58			51			60		
				66			73			61			77			64			57			67		
																						90	Pts	
																						100	%	

**Tableau 18** Tableau de notations des structures de contrôles

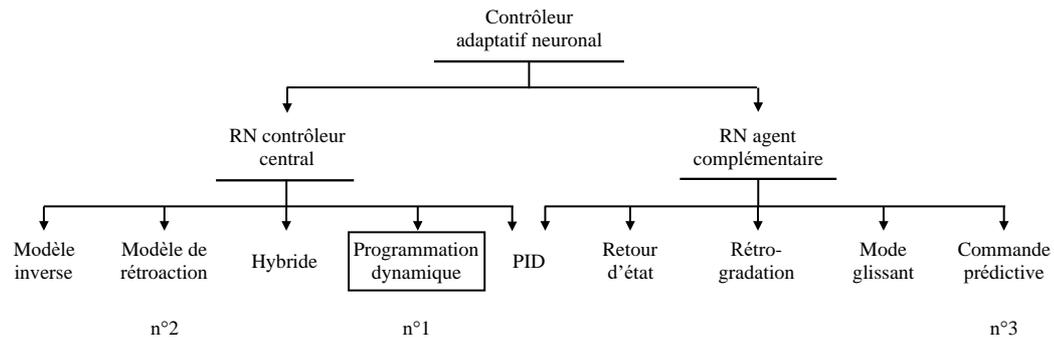


**Figure 29** Classement des structures de contrôle au regard des critères de sélection

Comme illustré sur la [Figure 29](#), sept structures dépassent les 60 % de la dimension maximale et deux d'entre elles atteignent même les 70 %. Il s'agit du contrôleur par modèle de rétroaction et du contrôleur par programmation dynamique.

### Structure de contrôle sélectionnée.

Dans le cadre de notre étude, l'approche retenue est la programmation dynamique. En effet, la possibilité d'avoir trois réseaux de neurones avec chacun un rôle différent, le faible niveau de développement sur l'application de la PEMFC et l'intégration d'un modèle de prévision pilotée donnée font partie des arguments en sa faveur. Une attention particulière sera apportée sur l'effort de calcul et le temps de convergence de cette structure de contrôle.



**Figure 30** Choix de la structure de contrôle à adopter

Le contrôleur par programmation dynamique nécessite trois modèles réseau de neurones pour l'obtention du signal de commande : une estimation du signal de commande, une estimation de l'état futur, et une estimation d'un critère de coût. Le même type de modèle sera employé pour les trois rôles afin d'uniformiser le processus d'estimation et d'optimisation.

## Conclusion

Le contrôleur par programmation dynamique a été choisi suivant différents critères de sélection et niveaux de pondérations. L'approche offre la possibilité d'obtenir la commande optimale tout en octroyant une capacité d'anticipation par le biais d'une prévision d'état du système. Le tout étant exclusivement obtenu par l'utilisation des réseaux de neurones.

Dans un souci de généricité, la définition des réseaux de neurones du contrôleur doit être maintenant automatisée. Cela passe obligatoirement par l'utilisation d'outils d'optimisations. Plusieurs idées ont pu émerger de par les différentes lectures. Tout d'abord la préférence d'un réseau de neurones à dimension temporelle pour s'accorder à la temporalité du système PEMFC, de ses actionneurs et de ses capteurs. Ensuite, le choix évident d'un algorithme d'apprentissage offrant une stabilité et une convergence globale garanties. À la suite de cela, les défauts et leurs effets multilatéraux seront considérés dans la conception du contrôleur.

Le chapitre suivant est consacré à la conception de la structure de contrôle adaptative aux états de santé du système. La première partie est consacrée à la théorie et aux différentes méthodes de la structure ADP. À ce titre, plusieurs choix seront réalisés. La seconde partie est construite sur l'étude approfondie du modèle réseau de neurones, les choix d'implémentations, et pour terminer la définition des cibles d'apprentissage. La troisième section est consacrée à la considération des défauts. La dernière partie aborde les études de stabilités et les conditions nécessaires au bon fonctionnement du contrôleur.

# CHAPITRE 3

## L'ELABORATION DU CONTROLEUR ADAPTATIF AUX ETATS DE SANTE DE LA PILE

### Sommaire

---

<b>3.1</b>	<b>Théorie de la programmation dynamique</b> .....	<b>65</b>
3.1.1	Principe d'optimalité.....	65
3.1.2	Différentes structures de programmation dynamique.....	67
3.1.3	Ajustement prospectif ou rétrospectif du modèle critique.....	68
<b>3.2</b>	<b>Estimation des fonctions inconnues</b> .....	<b>69</b>
3.2.1	Évaluation des modèles neuronaux.....	69
3.2.2	Analyse des hyperparamètres du modèle ESN.....	74
3.2.3	Logique floue pour le réglage en ligne des coefficients d'apprentissage.....	78
<b>3.3</b>	<b>Programmation dynamique adaptative aux défauts du système</b> .....	<b>83</b>
3.3.1	Interférence des signaux de commandes.....	83
3.3.2	Banque de contrôleurs adaptatifs dans la stratégie AFTC.....	84
<b>3.4</b>	<b>Structure de contrôle ADP et sorties cibles d'apprentissages</b> .....	<b>85</b>
3.4.1	Structure de contrôle ADP basé HDP.....	85
3.4.2	Apprentissages des modèles ESN.....	86
<b>3.5</b>	<b>Algorithme du contrôle ADP</b> .....	<b>88</b>
<b>3.6</b>	<b>Études de stabilité et de convergence de la stratégie de contrôle</b> .....	<b>88</b>
3.6.1	Stabilité du contrôleur ADP basé HDP.....	89
3.6.2	Stabilité et convergence globale du modèle ESN.....	90

---

## Introduction

Les besoins de contrôle, les actionneurs et les différentes commandes pour le système PEMFC ont été énoncés. La structure de contrôle neuronale par programmation dynamique a ensuite été adoptée. Il est maintenant légitime de se poser des questions sur le type de réseau de neurones à implémenter, les hyperparamètres à optimiser et enfin les interactions du contrôleur au travers de la stratégie AFTC.

Ce chapitre débute par la théorie de la programmation dynamique et des différentes approches existantes. La deuxième section évalue plusieurs modèles neuronaux pour sélectionner le meilleur modèle à mettre en place dans le contrôleur ADP. La troisième section est consacrée au développement de la méthodologie d'adaptation aux états de santé, il s'agit de relier le contrôleur aux autres modules de la stratégie de contrôle globale. Le chapitre se termine ensuite par les analyses de la stabilité et de la convergence d'apprentissage.

### 3.1 Théorie de la programmation dynamique

La programmation dynamique repose sur une idée fondamentale qui est le principe d'optimalité. Il s'agit de la décomposition en étages multiples d'un problème global en plusieurs sous-problèmes dont la résolution est locale.

**Théorème 2.** Le principe d'optimalité (Bellman, 1954)

Une politique optimale a la propriété que, quels que soient l'état initial et les décisions initiales, les décisions restantes doivent constituer une politique optimale vis-à-vis de l'état résultant des premières décisions.

Dans le cas de système à retard (Fan and Theodorou, 2016), ce principe d'optimalité doit considérer une fenêtre historique incluant l'information du retard, ainsi, la commande est dépendante de plusieurs entrées et sorties, soit  $u(t) = (x(t), x(t - \tau_x), u(t), u(t - \tau_u))$ .

#### 3.1.1 Principe d'optimalité

Soit un système non linéaire à retards multiples répondant à la dynamique suivante (Lin and Hwang, 1996) :

$$\frac{dx}{dt} = f(x(t), x(t - \tau_x), u(t), u(t - \tau_u), t), \quad 0 \geq t \geq \tau_{x,u} \quad (2)$$

où  $x(t) = [x_1(t), x_2(t), \dots, x_n(t)]^T \in \mathbb{R}^n$  est un vecteur d'état,  $u(t) = [u_1(t), u_2(t), \dots, u_m(t)]^T \in \mathbb{R}^m$  est le vecteur de commande,  $\tau_x$  et  $\tau_u$  sont les retards purs inconnus sur l'état du système et l'application de la commande. La fonction représentant les dynamiques du système  $f(x(t), x(t - \tau_x), u(t), u(t - \tau_u))$  est définie sur un ensemble  $\Omega_x \subseteq \mathbb{R}^n$ , dont  $f(0,0,0,0) = 0$  à partir d'un état initial  $x(0) = x_0$ . Pour un critère de performance donné (Pham, 2007), l'objectif est de prendre les meilleures décisions  $u(t)$  afin de minimiser

les coûts. Une fonction coût cumulative est ainsi associée au système pour quantifier les performances :

$$J(t) = \int_0^{\infty} U(x(t), u(t)) dt \quad (3)$$

$U(x(t), u(t))$  est la fonction utilitaire ("utility function") appelée également la fonction de renforcement, sa forme est généralement de nature quadratique.

Un signal de commande idéal  $u^*(t)$  dont l'objectif est de minimiser l'erreur cumulative  $J(t)$  est obtenue de la manière suivante :

$$u^*(t) = \arg \min_{u(t)} \{J(x(t), u(t))\} \quad (4)$$

La fonction coût optimale cumulative correspondante à la commande idéale est définie comme suit :

$$J^*(t) = \min_{u(t)} \{J(x(t), u(t))\} \quad (5)$$

Conformément au principe d'optimalité de Bellman, si un contrôleur est optimal entre  $t$  et un horizon  $T$  pour une condition initiale  $x(t)$ , alors il est aussi optimal entre  $t + 1$  et  $T$ , avec la condition initiale  $x(t + 1)$  pour un temps  $t + 1 > t$ . Cependant, l'ensemble des points compris entre  $t$  et l'horizon  $T$  ne sont pas connus. Or, l'optimalité supposerait d'avoir l'ensemble des valeurs de coût. Pour résoudre ce problème, la résolution globale est réduite à une échelle locale. Ainsi, l'horizon  $T$  est portée sur l'instant suivant  $t + 1$ , et la même opération est effectuée sur le critère de coût global. La fonction coût cumulative peut ainsi s'écrire de la manière suivante :

$$J(t) = \int_0^{t+1} U(x(t), u(t)) dt + \gamma \int_{t+1}^T U(x(t), u(t)) dt \quad (6)$$

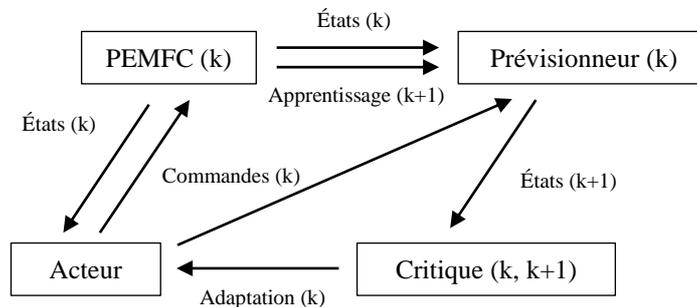
$$J^*(t) = \min_{u(t)} \{U(x(t), u(t)) + \gamma \hat{J}(\hat{x}(t + 1), \hat{u}(t + 1))\} \quad (7)$$

où  $\gamma$  est le coefficient d'actualisation ("discount factor") respectant le domaine  $0 < \gamma \leq 1$  et  $\hat{J}(t + 1)$  est le coût futur estimé. Le coefficient  $\gamma$  vise à pondérer le coût futur estimé dans la fonction coût cumulative. La commande idéale peut ainsi se formuler comme suit :

$$u^*(t) = \arg \min_{u(t)} \{U(x(t), u(t)) + \gamma \hat{J}(\hat{x}(t + 1), \hat{u}(t + 1))\} \quad (8)$$

Cette commande est obtenue à la condition que la valeur inconnue qui est le coût au temps suivant  $\hat{J}(t + 1)$  soit disponible. Pour obtenir cette information inconnue, un processus d'estimation de valeurs futures est mis en place, ici nous utiliserons des modèles neuronaux. Plus précisément, un modèle acteur fournit la commande optimale, un modèle prévisionneur fournit la réponse du système à cette nouvelle commande, et enfin un critique évalue ce nouvel état. Le modèle RN fonctionne à l'aide de données échantillonnées, l'approche de la programmation dynamique sera donc de nature discrète avec des périodes d'échantillonnages  $k$ .

Au sein de la littérature, plusieurs processus de résolution de problèmes de programmation dynamiques ont été proposés sur la base de structures critique adaptative, dont le principe général est présenté sur la Figure 31.



**Figure 31** L'approche critique adaptative

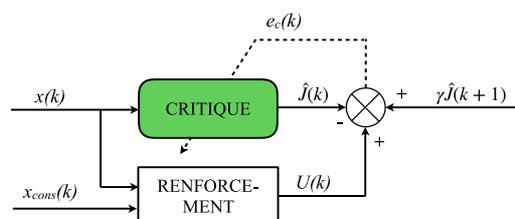
En termes d'influence et de précision, le modèle prévisionneur est le plus important, car il cherche à prévoir le comportement du système face aux commandes prises. De plus, cette prévision est utilisée par les autres modèles. Ses cibles d'apprentissage sont accessibles à l'instant  $k+1$ . Vient ensuite le modèle critique qui calcule les coûts présent et futur  $J(k), J(k+1)$ . Ses cibles d'apprentissage sont calculées par le signal de renforcement. Cette fonction apporte à la structure de contrôle l'information de la consigne à respecter. Le modèle acteur est ensuite corrigé à partir des informations recueillies sur les modèles précédents.

### 3.1.2 Différentes structures de programmation dynamique

Werbos (1977) propose deux méthodes progressives pour la résolution des problèmes de ADP à l'aide de modèles neuronaux : la méthode heuristique (« Heuristic Dynamic Programming » ou HDP) et la méthode duale (« Dual heuristic Dynamic Programming » ou DHP).

#### Programmation dynamique heuristique

La méthode HDP consiste à obtenir, par le modèle critique, la génération d'une fonction coût  $\hat{J}(x(k))$  qui vérifie l'équation suivante :  $U(x(k)) + \gamma\hat{J}(x(k+1)) - \hat{J}(x(k)) = 0$ . Relativement simple à mettre en œuvre, elle propose une première résolution aux problèmes ADP.



**Figure 32** La méthode HDP

### Programmation dynamique heuristique double

Au lieu d'estimer la fonction coût  $\hat{J}(x(t))$ , l'approche DHP s'intéresse aux dérivées partielles. La méthode DHP est ainsi mieux adaptée pour un contrôle en régime transitoire (Werbos, 1977). Le modèle critique doit alors vérifier l'équation suivante :  $\frac{\partial J^*(x(k))}{\partial x(k)} - \frac{\partial U(k)}{\partial x(k)} - \gamma \frac{\partial J^*(x(k+1))}{\partial x(k)} = 0$ . L'opération d'apprentissage est ici plus lourde par rapport à l'opération d'apprentissage de la méthode HDP, car elle nécessite la rétropropagation d'intégrateurs.

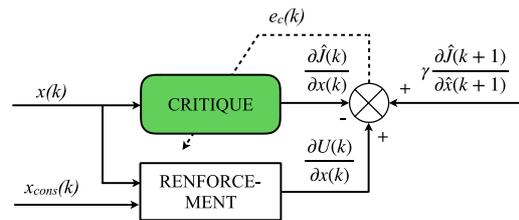


Figure 33 La méthode DHP

### Programmation dynamique heuristique double globale

Une autre approche combine l'association des deux méthodes précédentes, il s'agit de la dynamique heuristique double globale (« Global Dual Heuristic dynamic Programming » ou GDHP). La sortie du modèle critique se compose de deux éléments, la fonction coût et sa dérivée. Cette troisième configuration apporte de meilleurs résultats comparés aux deux approches précédentes, au détriment d'un effort de calcul plus conséquent.

#### 3.1.3 Ajustement prospectif ou rétrospectif du modèle critique

L'estimation de la fonction coût aux instants  $k$  et  $k + 1$  est obtenue par un unique modèle critique. Ce modèle est donc utilisé deux fois lors de l'exécution de la boucle de contrôle. Son apprentissage peut être obtenu de deux manières différentes :

##### Apprentissage prospectif

L'approche prospective consiste à ajuster le modèle neuronal critique en fonction de l'estimation du coût futur. Un coefficient d'horizon  $\gamma$  est alors appliqué sur l'estimation  $J^*(k + 1)$  pour pondérer son incertitude.

$$J^*(x(k)) \approx U(k) + \gamma J^*(x(k+1)) \quad (9)$$

##### Apprentissage rétrospectif

L'approche rétrospective est quant à elle le processus inverse où l'ajustement du modèle neuronal critique est effectué en fonction de l'estimation  $J^*(k)$ . Cette approche

présente moins d'incertitude que la précédente, car la cible ne contient que des informations aux instants  $k$ .

$$J^*(x(k+1)) \approx \frac{U(k) + J^*(x(k))}{\gamma} \quad (10)$$

Dans une vision du contrôle prédictif, l'approche prospective est la plus adaptée, car elle considère les prévisions et leurs coûts dans l'estimation de la commande à chaque instant  $k$ .

Pour de premiers essais, nous adopterons la programmation dynamique heuristique couplée à un apprentissage prospectif du modèle critique.

## 3.2 Estimation des fonctions inconnues

### 3.2.1 Évaluation des modèles neuronaux

Il s'agit dans un premier temps d'évaluer plusieurs types de modèles neuronaux afin de déterminer le plus apte à l'estimation des fonctions de contrôleur ADP. Un total de six réseaux de neurones est évalué dans l'étude proposée :

- deux modèles standards, ML et RBF,
- deux modèles temporels, TD et ARX,
- et deux modèles mémoriels récurrents, ESN et LSTM.

La base de données utilisée a été élaborée sur un banc d'essai PEMFC de type monocellule d'une puissance maximale de 50W. Les perturbations présentes dans cette base de données sont dues à la variation de la stœchiométrie en oxygène sur différents paliers de courant. Les modèles neuronaux sont configurés en multi-entrées et en mono-sortie. Les entrées et sorties sont données dans le [Tableau 19](#). L'évolution de la tension aux bornes de la pile reflète la dynamique du système, elle est utilisée comme sortie cible pour l'apprentissage. Une représentation des variables de la base de données est disponible à la [Figure 34](#). La base comprend 5 752 échantillons avec une période d'échantillonnage de 4 secondes, soit près de 6 heures de mesures. Il s'agit d'une base de données typique utilisée pour une application de diagnostic par résidus via un modèle comportemental, elle est issue des campagnes d'expérimentations de [Dijoux \(2019\)](#).

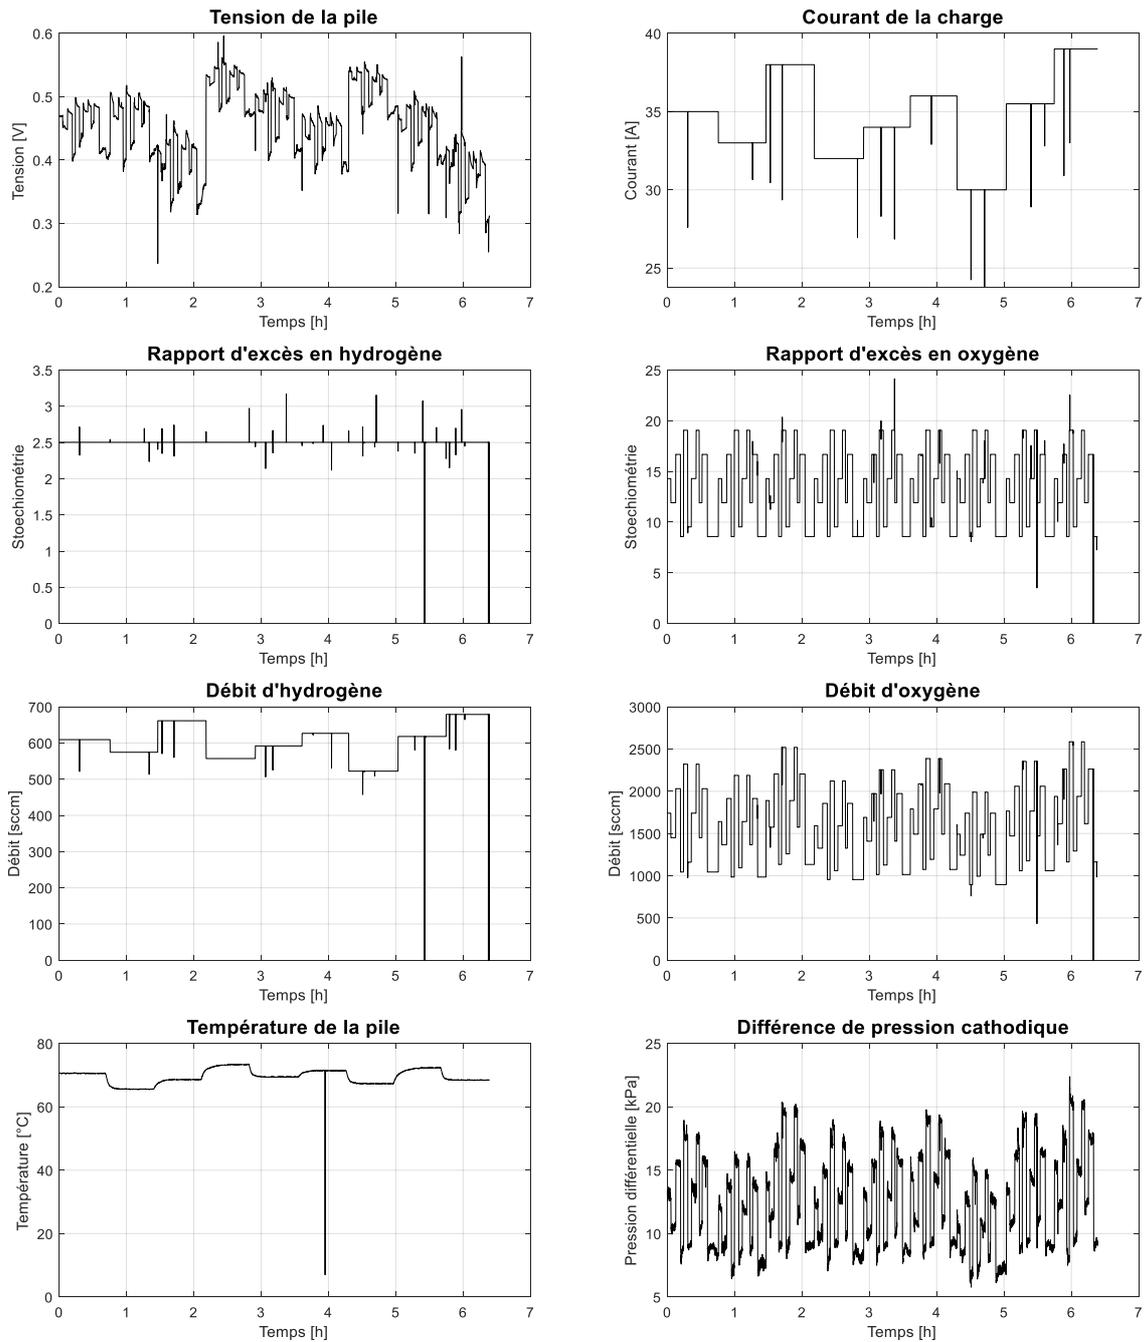
**Tableau 19** Entrées et sortie pour la comparaison des modèles de neurones

	Variables d'entrées		Variable de sortie
$q_{H_2,in}(k)$	Le débit d'entrée d'hydrogène	$V_{fc}(k+1)$	La tension de pile
$q_{O_2,in}(k)$	Le débit d'entrée d'oxygène		

Les modèles sont identifiés dans une situation en temps réel, par conséquent une seule séquence de données n'est disponible qu'à la fois. Une méthode de validation croisée ne peut donc être mise en place, nous effectuons ici un apprentissage en ligne pour une application de prévision. Le critère d'erreur MAPE est calculé sur l'ensemble des prévisions recueillies des modèles. L'algorithme de la descente du gradient (55) est utilisé pour l'ajustement des poids

neuronaux de l'ensemble des modèles RN. L'erreur normalisée en pourcentage MAPE (« Mean Absolute Percentage Error ») facilite la lecture de la performance du modèle et permet de traiter les résidus de modélisation en valeurs absolues, ce qui évite les compensations de résidus. Son équation est donnée ci-dessous :

$$MAPE = \frac{100}{n} \sum_i^n \left| \frac{y - y^*}{y} \right| \quad (11)$$



**Figure 34** Base de données utilisée pour l'évaluation des modèles neuronaux

Plusieurs cycles d'apprentissage BP peuvent être menés sur une même séquence de données. Cette approche permet de réduire l'erreur de modélisation au fil des cycles. Dans notre application en ligne, un seul cycle d'apprentissage BP est réalisé à chaque période d'échantillonnage. Les hyperparamètres des différents réseaux de neurones testés sont uniformisés et sont présentés au [Tableau 20](#).

Les modèles TD et ARX sont réglés sur une fenêtre d'entrées de 3 échantillons, cette valeur est obtenue par essais-erreurs. Pour ces deux modèles, à chaque échantillon, il existe donc 10 entrées (i) qui sont les suivantes :  $[biais, q_{H_2,in}(k), q_{H_2,in}(k-1), q_{H_2,in}(k-2), q_{O_2,in}(k), q_{O_2,in}(k-1), q_{O_2,in}(k-2), V(k), V(k-1), V(k-2)]$ , et 1 sortie (o) qui est la suivante :  $V(k+1)$ . Un biais unitaire est ajouté comme entrée des modèles afin que la fonction d'activation ne passe pas à l'origine à chaque itération, cela permet d'améliorer les performances de modélisation. Ce terme a la même fonction que l'ordonnée à l'origine dans une loi de régression.

En pratique, le nombre de neurones doit être proche de la valeur i/o et inférieur au double de sa valeur. Nous choisissons une valeur moyenne de 10 neurones pour tous les modèles. Pour le modèle ESN, la connectivité du réservoir carré est réglée à 0,1, il s'agit donc d'une sélection unique de 10 % de neurones actifs. Son réservoir est généré initialement sur une matrice de taille 10x10, puis 90 % des neurones sont mises à 0. La matrice interne ne reçoit aucun traitement ou vérification supplémentaire.

Les fonctions gaussiennes du modèle RBF sont centrées sur l'origine et possèdent toutes la même largeur unitaire.

Les données d'entrées de tous les modèles sont mises à l'échelle en fonction de leurs ordres de grandeur afin d'obtenir des valeurs normalisées inférieures à 1, et ainsi éviter une possible saturation des fonctions d'activations.

**Tableau 20** Configurations des réseaux de neurones évalués

Hyperparamètres	ML	RBF	TD	ARX	ESN	LSTM
Neurones (actifs)	10 (10)	10 (10)	10 (10)	10 (10)	100 (10)	10 (10)
Taux d'apprentissage	0,5	0,5	0,5	0,5	0,5	0,5
Fonction d'activation	tanh	gaussian	tanh	tanh	tanh	tanh + sigmoid
Couche cachée	1	1	1	1	1	1
Autres		Centre(s) : 0 Largeur(s) : 1	Fenêtre : 3 échantillons	Fenêtre : 3 échantillons	Taux de fuite : 0,5 Connectivité : 0,1	

Le temps de calcul moyen d'une itération, comprenant le calcul de la sortie d'un modèle et l'ajustement de ces poids, est donné au [Tableau 21](#). Le modèle LSTM fait intervenir dans le cas présent 160 vecteurs de poids  $((4 \times n_{entrées})|_{"U_{F,I,C,O"}} + 4|_{"W_{F,I,C,O}}) \times n_{neurones}$ , ce qui explique un temps de calcul conséquent.

**Tableau 21** Temps de calcul moyen d'une itération par modèle

Modèle	ML	RBF	TD	ARX	ESN	LSTM
Temps [ms]	0,159	0,158	0,182	0,192	0,070	95,57

Dans une approche de contrôle par ADP où plusieurs réseaux de neurones sont exécutés, il est préférable d'adopter l'architecture la plus rapide. Ici, le modèle ESN présente le plus faible temps de calcul, soit  $70 \mu s$ . Le contrôleur ADP nécessite 4 exécutions du modèle ESN, par conséquent, obtenir une commande nécessiterait un temps minimum de  $t_{cmd} \approx 0,3 ms$ . Ce temps incompressible est compatible avec les temps des réponses des différents actionneurs identifiés au [Chapitre 1](#). Néanmoins, pour l'obtention d'une commande, il ne permet pas de répondre aux défauts possédant une dynamique rapide, tel le court-circuit.

Les métriques de prévisions avec la base de données complète sont données dans le [Tableau 22](#). Plusieurs essais ont été nécessaires, la raison vient de la génération aléatoire des poids neuronaux qui peuvent engendrer des modèles non fonctionnels. Une vingtaine de tests sont reportés ici, un plus grand nombre d'essais ont été effectués, mais n'apportent pas d'informations supplémentaires. La visualisation graphique des erreurs MAPE est donnée à la [Figure 35](#). Dans ce tableau, un modèle divergeant est représenté par un vide [ ]. Ces divergences s'expliquent par la génération aléatoire des poids lors de l'initialisation des modèles, ces générations peuvent créer des combinaisons non convergentes, où l'erreur d'estimation est très élevée. Aucun schéma de vérification ou de correction n'est effectué sur l'ensemble des modèles. Aucune génération pseudo-aléatoire n'est mise en place, chaque essai génère une combinaison de poids unique.

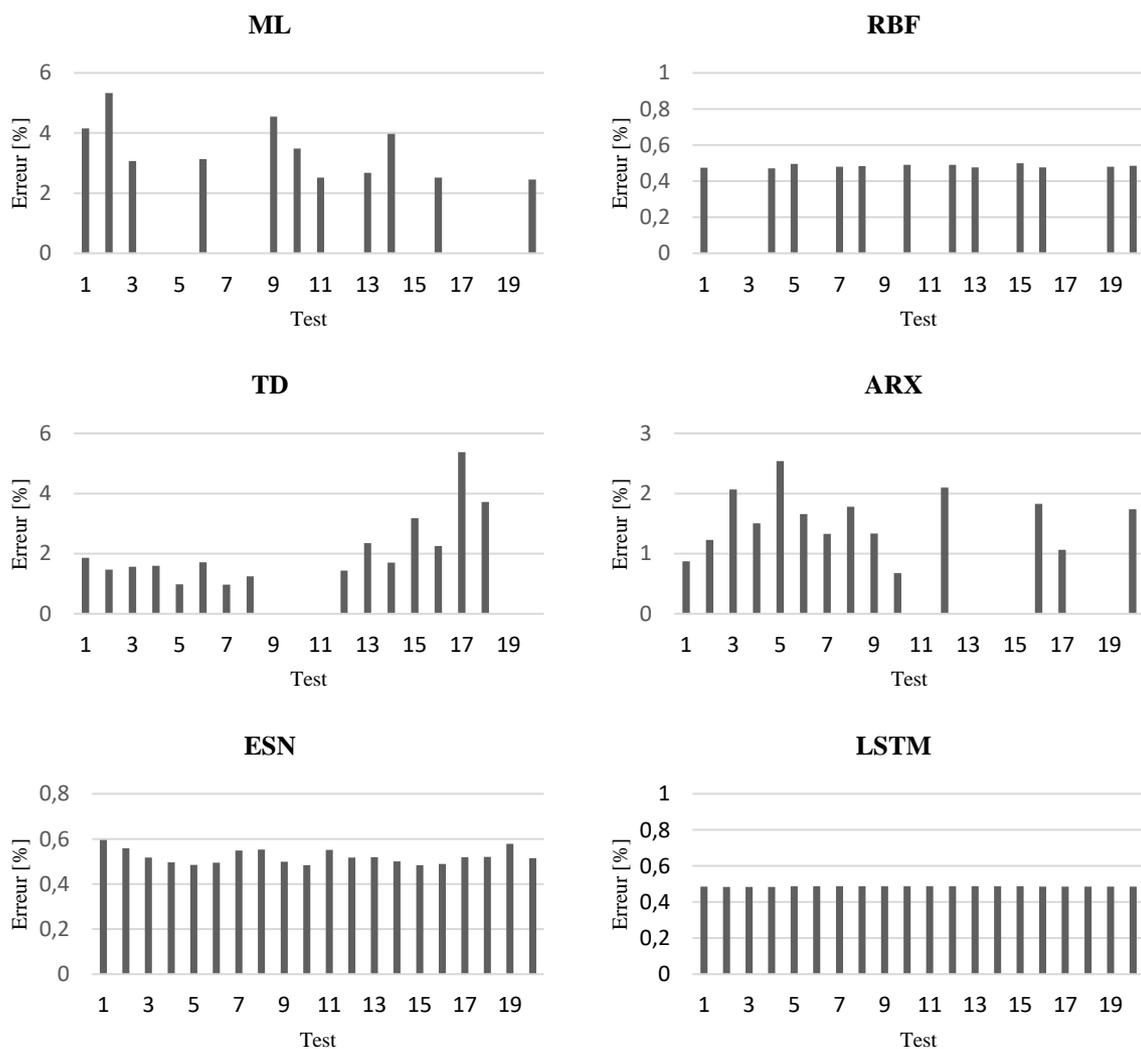
**Tableau 22** Performances MAPE des modèles au cours de plusieurs tests

Essai n°	ML	RBF	TD	ARX	ESN	LSTM
1	4,158	0,475	1,86	0,871	0,595	0,48483
2	5,328		1,473	1,227	0,559	0,48417
3	3,066		1,564	2,064	0,517	0,48405
4		0,471	1,591	1,506	0,496	0,48397
5		0,495	0,981	2,537	0,485	0,48672
6	3,137		1,715	1,660	0,495	0,48681
7		0,479	0,968	1,330	0,549	0,48677
8		0,483	1,243	1,778	0,553	0,48679
9	4,55			1,334	0,499	0,48673
10	3,482	0,49		0,676	0,483	0,48681
11	2,513				0,551	0,48679
12		0,49	1,439	2,097	0,517	0,48679
13	2,679	0,476	2,344		0,518	0,48679
14	3,968		1,705		0,500	0,48677
15		0,499	3,175		0,483	0,48681
16	2,515	0,477	2,255	1,828	0,489	0,48586
17			5,376	1,063	0,518	0,48565

18			3,723	0,520	0,48552
19		0,479		0,578	0,48551
20	2,458	0,486	1,740	0,514	0,48559

Les minimums d'erreurs sont obtenus par le modèle RBF, suivi par le modèle LSTM, ESN, ARX, TD et ML. En termes de stabilité et dans un scénario sans optimisation structurale, les modèles ESN et LSTM se montrent plus consistants à chaque test de modélisation. La raison principale vient de l'initialisation de valeurs nulle de leurs matrices d'états. Cette initialisation permet au processus d'apprentissage d'ajuster avec plus d'efficacité les poids neuronaux. Le modèle ESN est tout de même le plus adapté à une approche en ligne, en effet, il présente un temps de calcul bien inférieur aux autres modèles tout en présentant une précision satisfaisante.

Les modèles RN autres que ESN sont également testés sur une configuration de 100 neurones actifs. Cette configuration n'est profitable qu'aux modèles ML et ARX qui obtiennent des performances équivalentes au modèle ESN. Malgré tout, ces modèles restent divergeant sur une proportion équivalente d'essais.



**Figure 35** Résultats des tests de calcul des différents modèles

Compte tenu de la fonction de performances et des temps de calcul, le modèle neuronal ESN est adopté pour la modélisation des fonctions inconnues du contrôleur ADP. L'étape suivante concerne les hyperparamètres de ce modèle.

### 3.2.2 Analyse des hyperparamètres du modèle ESN

Le modèle ESN contient plusieurs hyperparamètres. Pour répondre à un objectif de généralité, nous proposons une méthode systématique pour les définir. Une étude de sensibilité est menée sur ces hyperparamètres pour comprendre la contribution possible de chacun sur l'erreur de modélisation. Pour cela, nous reprenons la base de données et l'application de prévision en tension précédentes. Tout d'abord, une liste exhaustive des hyperparamètres est dressée ci-dessous :

- Les hyperparamètres correspondant aux entrées et aux sorties :
  1.  $n_{in}$  le **nombre d'entrées**
  2.  $n_{out}$  le **nombre de sorties**
  
- En fonction de l'amplitude des entrées et des sorties, des coefficients de mise à l'échelle, de normalisation ou de standardisation sont à appliquer. Ce processus limite le phénomène de saturation des fonctions d'activations, le phénomène de perte d'information et la divergence du modèle. Quelle que soit la loi de normalisation employée, les hyperparamètres correspondants sont les suivants :
  3.  $c_{in}$  les **coefficients appliqués aux entrées**
  4.  $c_{out}$  les **coefficients appliqués aux cibles** de l'apprentissage
  
- Les hyperparamètres se rapportant à la structure du réservoir interne sont les suivants :
  5.  $n_{Deep}$  le **nombre de réservoirs** dans le modèle,
  6.  $n_{Res}$  le **nombre de neurones** dans un réservoir,
  7.  $C_o^l$  la **connectivité** du réservoir ou les connectivités des réservoirs,
  8.  $\alpha^l$  le(s) **taux de fuite(s)**, voir équation (43),
  9.  $\rho(W^{res})$  le(s) **rayon(s) spectral(s)**, en mathématiques le rayon spectral défini un cercle centré sur l'origine contenant toutes les valeurs propres du réservoir de neurones. Soit la plus grande valeur absolue de ses valeurs propres. Il exprime la manière dont chaque valeur non nulle reste persistante au cours des itérations et peut décrire ainsi le comportement dynamique du réservoir.
  
- Pour terminer, l'apprentissage fait intervenir un hyperparamètre spécifique :
  10.  $\eta$  le **taux d'apprentissage**.

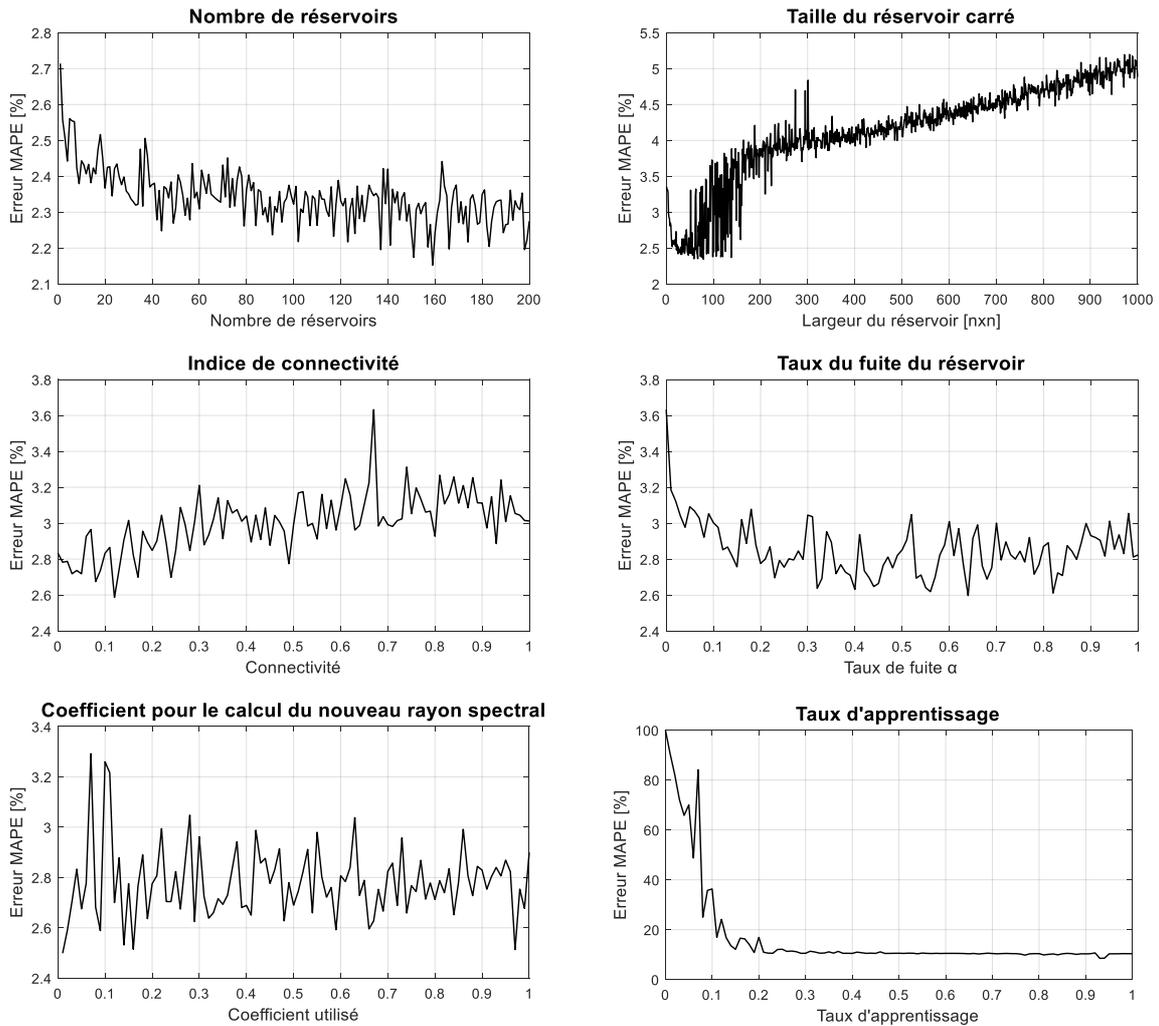
Un total de dix hyperparamètres sont donc présents pour la définition d'un modèle ESN. En pratique, les hyperparamètres de 1 à 4 relèvent des données utilisées, par conséquent, seuls les coefficients de 5 à 10 sont concernés par une optimisation.

Une méthode commune « One-At-Time » est mise en place. Un hyperparamètre est fixé tandis que les autres varient au cours des itérations. La limite de cette méthode réside dans le manque d'exploration dans les plages de variation. En effet, les valeurs fixes imposent un unique point d'observation pour l'hyperparamètre qui est analysé. L'apprentissage est réalisé par une méthode des moindres carrés récursifs. Cette méthode est couramment utilisée en expérimentation, car elle apporte une plus grande stabilité comparée à la méthode de la descente du gradient. Pour éviter de se limiter sur une configuration de poids neuronaux unique, aucune génération pseudo-aléatoire n'est effectuée. Les plages de variations des hyperparamètres sont données au [Tableau 23](#), les valeurs fixes sont reprises de l'application précédente et correspondent aux configurations les plus utilisées dans la littérature.

**Tableau 23** Plages de variation des hyperparamètres

	<b>Variables d'entrées</b>	<b>Plage de variation</b>	<b>Valeur fixe</b>
<i>nDeep</i>	Nombre de réservoirs	1 – 200	1
<i>nRes</i>	Taille du réservoir [nxn]	[1x1] – [1000x1000]	[10x10]
<i>Co</i>	Connectivité	0 – 1,00	0,10
$\alpha$	Taux de fuite	0 – 1,000	0,500
$\rho(W^{res})$	Rayon spectral	0,001 – 1,000	1,000
$\eta$	Taux d'apprentissage	0 – 1,000	0,500

Les erreurs moyennes MAPE sur la prévision de la tension en fonction des hyperparamètres sont présentées au sein de la [Figure 36](#).



**Figure 36** Influence des hyperparamètres sur la précision (MAPE) de modélisation en tension

On observe que les influences des hyperparamètres pour une application de prévision de la tension ne sont pas importantes, elles varient de 2,5% à 5% (sauf pour le taux d'apprentissage). Nous avons déployé ici la méthodologie d'essais-erreurs sur un modèle simple de prévision de la tension aux bornes de la pile. Au regard des précisions, une optimisation des hypermètres n'est pas forcément nécessaire pour cette application, mais nous permet d'étudier les hyperparamètres. Cependant, une optimisation automatique pourrait être pertinente pour déterminer de manière optimale les hyperparamètres des modèles acteur et critique qui constituent la structure du contrôleur ADP.

Le plus grand contributeur ① à la précision du modèle est le taux d'apprentissage avec une variation de près de 90 %. Son influence est certaine, puisqu'elle régit directement l'apprentissage du modèle.

Le deuxième contributeur ② est le nombre de neurones. Sa modification en ligne implique la définition d'une nouvelle structure du modèle. Son optimisation doit s'exécuter en parallèle pour conserver le fonctionnement des modèles ESN exécutés en ligne. Le cas de la

Figure 36 indique quatre phases dynamiques : une diminution de l'erreur de modélisation entre 1 et 100 neurones, un minimum d'erreur entre 100 et 1k neurones, une augmentation de l'erreur de modélisation entre 1k et 100k neurones avec beaucoup de variations, puis une erreur qui ne cesse d'augmenter passer les 100k neurones. Le phénomène de sur-apprentissage apparaît dès le seuil des 1k neurones.

Le troisième contributeur ③ est le taux de fuite du réservoir. Pour l'exemple présenté, un taux de fuite entre 0,2 et 0,8 est à privilégier. En observant l'équation (43) disponible dans l'Annexe A.1, nous remarquons que le taux de fuite régule la proportion des entrées à l'instant  $k$  et la proportion des états internes précédents dans le calcul d'une sortie ESN. Un taux de fuite à 0 signifie que la sortie dépend uniquement des états précédents, et inversement un taux de fuite à 1 signifie que la sortie dépend uniquement des entrées du modèle à l'instant  $k$ . Dans notre exemple, pour obtenir les meilleurs résultats de prévision, la sortie du modèle nécessite en proportion plus ou moins égale des entrées à l'instant  $k$ , mais également des états précédents.

Le quatrième contributeur ④ et le non moins important est le rayon spectral. Il s'agit d'un coefficient de pondération qui intervient sur l'amplitude des valeurs non nulles du réservoir. L'objectif est d'obtenir un réservoir répondant à la capacité de réaliser des échos, c'est-à-dire ayant une propriété de réflexion de l'information jusqu'à son évanouissement. Le non-respect de cette propriété aurait pour conséquence un réservoir divergent, et par conséquent la génération de sorties incorrectes. Pour réaliser cette propriété, les poids du réservoir initialisé sont divisés par le rayon spectral calculé ou imposé comme dans notre exemple. On observe ici que des pondérations inférieures à 0,2, qui produisent ici des matrices dont le nouveau rayon spectral est supérieur à 1 engendrent des modèles plus instables. Une forme répondant aux modèles ESN à multi réservoirs est définie de la manière suivante (Gallicchio et al., 2018b):

**Théorème 3.** La propriété d'échométrie<sup>1</sup> du réservoir

Considérant un ESN profond dont la dynamique est donnée par des fonctions de transition d'états et un réservoir  $W^{res(l)}$  dont les poids sont générés aléatoirement à partir d'une distribution uniforme entre  $[-1, 1]$ . Alors la propriété d'échométrie du réservoir existe si :

$$\max \rho \left( (1 - \alpha^{(l)})I + \alpha^{(l)}W^{res(l)} \right) = \max \rho^{(l)} < 1 \quad (12)$$

En considérant le Théorème 3, le rayon spectral devient une variable dépendante du taux de fuite. Une étape de vérification est implémentée à chaque changement de ce taux de fuite. Si la condition ci-dessous n'est pas respectée, une mise à l'échelle des poids du réservoir est effectuée par une estimation de la pondération appropriée.

Le cinquième contributeur ⑤ est la connectivité du réservoir. Une tendance est perceptible malgré les générations aléatoires. Cette tendance rejoint les conclusions de la

<sup>1</sup> Echométrie : Science, Art de faire des échos ; de faire des bâtiments, dont la disposition, et surtout celle des voûtes, forme des échos, *Dictionnaire de Trévoux*, 1740.

littérature (Lukoševičius, 2012) : les faibles valeurs 0,1 sont à privilégier au lieu d'un réservoir entièrement connecté. Cet hyperparamètre sera donc fixé sur la valeur de 0,1.

Le sixième contributeur ⑥ est le nombre de réservoirs cachés. Tout comme le nombre de neurones, une modification de ce coefficient implique une modification structurelle du modèle. Cette modification engendre une optimisation supplémentaire de chacun des réservoirs, puisque chaque réservoir possède ses propres hyperparamètres  $C_0$ ,  $\alpha$  et  $\lambda$ . Par conséquent, il serait intéressant de déterminer le nombre de réservoir caché en début d'optimisation et de le fixer. Pour l'exemple présenté, le minimum d'erreur est obtenu avec un nombre de 100 réservoirs cachés. Une phase d'optimisation avec une telle structure prendrait un temps conséquent et n'est pas envisageable pour une application en ligne. Cet hyperparamètre pourra être fixé à 1 pour nos tests de contrôle.

Le [Tableau 24](#) regroupe les résultats précédents qui ont conduit à régler les hyperparamètres des modèles ESN pour l'application du contrôleur ADP.

**Tableau 24** Synthèse sur l'optimisation des hyperparamètres pour un modèle de prévision ESN en tension

	<b>Variables d'entrées</b>	<b>Valeurs optimales</b>
$n_{in}$	Nombre d'entrées	3
$n_{out}$	Nombres de sorties	1
$c_{in}$	Coefficients pour les entrées	[1; $1e^{-3}$ ; $1e^{-3}$ ]
$c_{out}$	Coefficient pour les cibles	1
$n_{Deep}$	Nombre de réservoirs	1
$n_{Res}$	Nombre de neurones	900 ou [30x30]
$C_0$	Connectivité	0,1
$\alpha$	Taux de fuite	0,5
$\rho(W^{res})$	Rayon spectral	Calculé en fonction du réservoir généré
$\eta$	Taux d'apprentissage	0,3 ou variable en fonction de l'erreur de modélisation

Ces informations sont valables pour la mise en place d'un modèle de prévision en tension. Nous formulons l'hypothèse que ces hyperparamètres restent acceptables pour les modèles acteur et critique.

### 3.2.3 Logique floue pour le réglage en ligne des coefficients d'apprentissage

Le taux d'apprentissage quantifie le gain d'ajustement des poids neuronaux. À chaque instant  $t$  l'ajustement des poids est obtenu en fonction de l'erreur de modélisation et du taux d'apprentissage. Un taux important apporte un ajustement fort et rapide. À l'inverse, un taux faible garantit une absence de dépassement, mais apporte une convergence lente. Son réglage

dépend donc de l'erreur de modélisation et de la variation en précision de la modélisation. Une conduite adéquate de ce paramètre est par conséquent la clé pour un apprentissage optimal du réseau de neurones.

La logique floue est un outil décisionnel qui vise à formaliser des procédés graduels basés sur des combinaisons véritables. La méthodologie se construit en plusieurs étapes. Tout d'abord, les variables retenues pour les entrées et sorties sont présentées au [Tableau 25](#).

**Tableau 25** Entrées et sortie de la méthode de logique floue

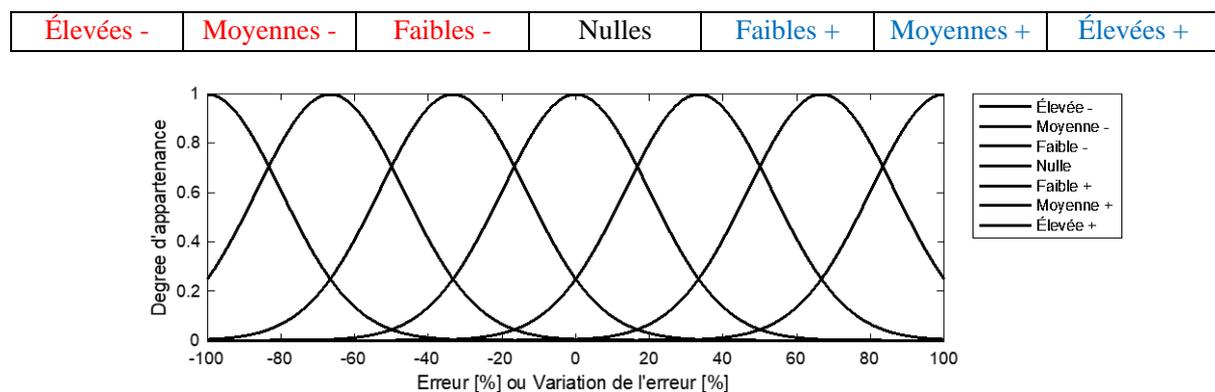
Variables d'entrées		Variable de sortie	
$e_m$	L'erreur de modélisation	$\eta$	Le taux d'apprentissage
$\Delta e_m$	La variation de l'erreur de modélisation		

L'erreur de modélisation et sa variation sont notées entre  $[-100,100]$  et e taux d'apprentissage est contraint entre  $[0,1]$ . Les erreurs sont calculées sur une métrique en pourcentage MPE (« Mean Percentage Error »). L'opération en nombres absolus n'est pas prise en compte dans la détermination de l'erreur pour conserver les signes positifs et négatifs. Ce critère est calculé de la manière suivante :

$$MPE = \frac{100}{n} \sum_i^n \frac{y - y^*}{y} \quad (13)$$

### Partitionnement des domaines de fonctionnement des entrées et des sorties

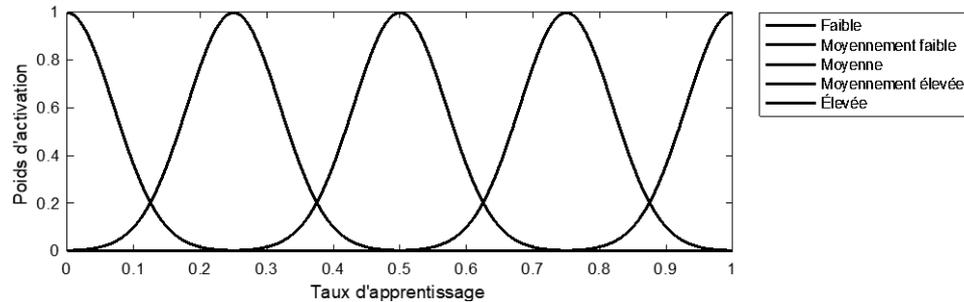
La première étape de construction de la méthode est le partitionnement des entrées et des sorties. Pour la méthode de logique floue, il s'agit de diviser les plages de fonctionnement des entrées et sorties en plusieurs fonctions d'appartenance. Nous choisissons un total de 7 fonctions d'appartenance  $A$  pour les entrées, elles sont présentées à la [Figure 37](#).



**Figure 37** Fonctions d'appartenance associées à l'erreur et à sa variation pour le processus de fuzzification

La sortie sera divisée en 5 fonctions d'appartenance  $D$  comme le décrit la [Figure 38](#).

Faibles	Moyennement faibles	Moyennes	Moyennement élevées	Élevées
D1	D2	D3	D4	D5

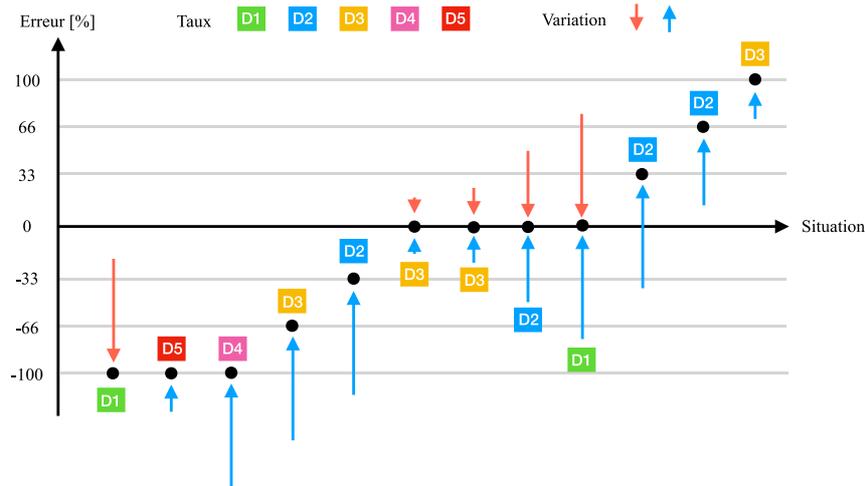


**Figure 38** Fonctions d'appartenance associées au taux d'apprentissage pour le processus de défuzzification

Le nombre de sept fonctions en entrées apporte une certaine précision, un certain lissage dans le processus de calcul. Le nombre de cinq fonctions en sortie permet de mieux partitionner le domaine de définition du taux d'apprentissage. Le taux d'apprentissage s'apparente à une loi log-normale, des fonctions de type gaussiennes (40) sont donc adoptées pour la phase de défuzzification, mais également pour la phase de fuzzification. Ces fonctions gaussiennes traduisent une tendance moyenne. Des fonctions trapézoïdales ou sigmoïdales traduiraient respectivement des tendances faibles ou des tendances fortes. Les fonctions gaussiennes sont définies avec une largeur importante afin de participer au lissage des tendances.

### Définition des règles floues

La seconde étape de construction de la méthode est la définition des règles floues  $i$  proposées sur la base de l'expertise, elles sont présentées dans le [Tableau 26](#). Le prédicat de ces règles est basé sur une combinaison de propositions et d'opérateurs logiques. Les propositions sont illustrées sur la [Figure 39](#). Durant cette étude, des règles de type *Mamdani* sont utilisées pour l'obtention des conclusions par ensemble flou. Le [Tableau 26](#) regroupe les règles floues.



**Figure 39** Visualisation de combinaisons véritables, de 1 à 12

- ① Si l'erreur est élevée négativement, et que sa variation est élevée négativement, il aura donc tendance à diverger, alors le taux d'apprentissage doit être faible.
- ② Si l'erreur est élevée négativement, et que sa variation est faible positivement, alors le taux d'apprentissage peut être élevé.
- ③ Si l'erreur est élevée négativement, et que sa variation est forte positivement, alors le taux d'apprentissage peut être moyennement élevé.
- ④ Si l'erreur est moyennement négative, et que sa variation reste forte positivement, alors le taux d'apprentissage peut être moyen.
- ⑤ Si l'erreur est faible négativement, et que sa variation reste forte positive, alors le taux d'apprentissage doit être faible.
- ⑥ Si l'erreur est nulle, et que sa variation est nulle, alors le taux d'apprentissage reste sur une valeur moyenne pour se tenir prêt à toute éventualité.
- ⑦ - ⑨ Si l'erreur est nulle, et que sa variation est non nulle, alors le taux d'apprentissage doit être inversement proportionnel à cette dernière.
- ⑩ Si l'erreur est faible positivement, et que sa variation est élevée positivement, alors le taux d'apprentissage peut être réduit à être moyennement faible.
- ⑪ Si l'erreur est moyennement positive, et que sa variation est moyennement positive, alors le taux d'apprentissage reste moyennement faible.
- ⑫ Si l'erreur est élevée positivement, et que sa variation est faible positivement, alors le taux d'apprentissage peut être moyen.

**Tableau 26** Zones d'action des règles floues et de leurs recouvrements

	ET $\Delta_{e_m}$	Élevée	Moyenne	Faible	Nulle	Faible	Moyenne	Élevée
SI $e_m$	ALORS $\lambda$	-	-	-		+	+	+
Élevée -		D1		D3		D5		D4
Moyenne -			D2					D3
Faible -		D2						D2
Nulle		D1	D2	D3	D3	D3	D2	D1
Faible +		D2						D2
Moyenne +		D3					D2	
Élevée +		D4		D5		D3		D1

### Phase de fuzzification

La phase de fuzzification est le passage d'un ensemble réel à un ensemble flou. Il se déroule par le cycle de calcul des entrées  $e_m$  et  $\Delta_{e_m}$  au regard des fonctions d'appartenance  $A$  caractérisant chaque ensemble flou. Cela permet d'obtenir différents degrés d'appartenance  $0 \leq \mu_{A_i}(x) \leq 1$ . Toutes les règles floues définies précédemment (si  $e_m$  ET  $\Delta_{e_m}$  ALORS  $\lambda$ ) sont ensuite exécutées, l'opérateur logique « ET » est traduit en choisissant le minimum entre les degrés de vérité des propositions (Chevrie and Guély, 1998).

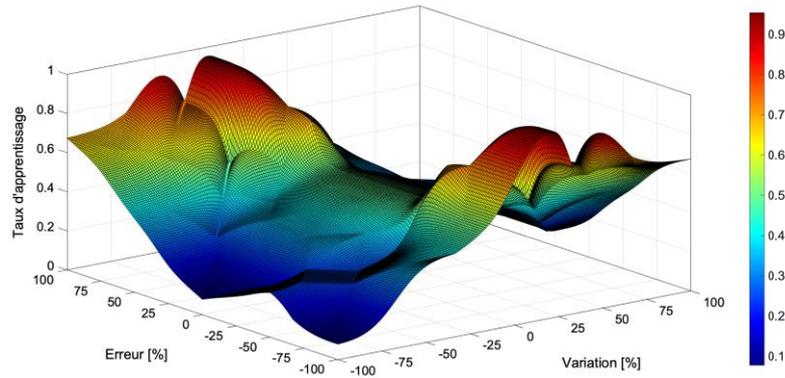
### Phase d'inférence

Les degrés d'appartenance à chaque espace flou sont maintenant connus pour l'erreur et la variation de l'erreur. Ainsi, des conclusions à partir de ces règles peuvent être formulées. Pour ce faire, une phase d'inférence est mise en place, une opération de conjonction des éléments de la prémisse est effectuée pour obtenir le degré de vérité à une règle floue  $v_i = \mu_{A_1^i}(x_1) \wedge \dots \wedge \mu_{A_j^i}(x_j)$ . Il s'agit de récupérer les positions maximales relatives à chaque espace flou de sortie  $D$ .

### Phase de défuzzification

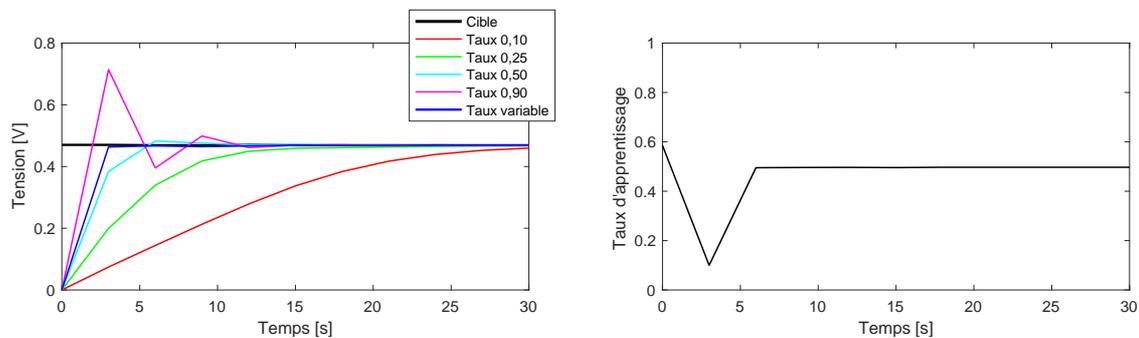
À la suite de cela, une phase de défuzzification permet le retour à un ensemble réel. Une opération d'agrégation est utilisée pour assembler les poids des ensembles flous définis précédemment  $v_i$ . Pour terminer, un calcul de barycentre permet de déduire la valeur du taux d'apprentissage adéquat.

Une surface floue peut être obtenue en exécutant l'ensemble du domaine de fonctionnement des entrées. Ainsi, nous pouvons obtenir le taux d'apprentissage idéal en fonction des règles floues  $i$  employées et des entrées  $e_m$  et  $\Delta_{e_m}$ . La surface floue est représentée sur la Figure 40.



**Figure 40** Surface floue relative au taux d'apprentissage

Un exemple d'application sur une cible d'apprentissage (0,47 V) est donné à la [Figure 41](#). L'ajustement automatique du taux d'apprentissage par la méthode logique floue apporte un réel compromis entre temps de réponse et dépassement.



**Figure 41** Application de la logique floue sur le taux d'apprentissage

En utilisation pratique, on utilise directement la surface floue pour le calcul du taux d'apprentissage.

### 3.3 Programmation dynamique adaptative aux défauts du système

#### 3.3.1 Interférence des signaux de commandes

L'objectif est de déterminer les contraintes de sécurité, visant à ne pas amplifier tout défaut installé. En effet, un maintien de consigne peut être qualifié de néfaste s'il amplifie directement un défaut ou s'il interagit conflictuellement avec une autre variable capable d'influencer le défaut. Pour ce faire, nous construisons une matrice d'interférence qualitative entre le type de contrôle et les défauts de noyage et d'assèchement. Cette matrice est représentée au [Tableau 27](#). Ce travail de synthèse est possible en utilisant les arbres de défaillances et les graphes de structure.

Les interactions possibles lors de l'apparition des défauts sont notées en rouge, ceux intervenants lors de l'atténuation sont notés en bleu, et les variables sensibles sont notées par

un encadrement. Au regard des résultats, seul la boucle de régulation en différence de pression à la membrane est possiblement sensible au défaut de noyage. Les autres boucles de régulations, en débit, en humidité et en température, sont quant à eux les variables d'actions pour l'apparition et le recouvrement des défauts.

**Tableau 27** Matrice d'interférence entre les variables de commandes et les variables spécifiques au défaut de noyage et d'assèchement de la membrane

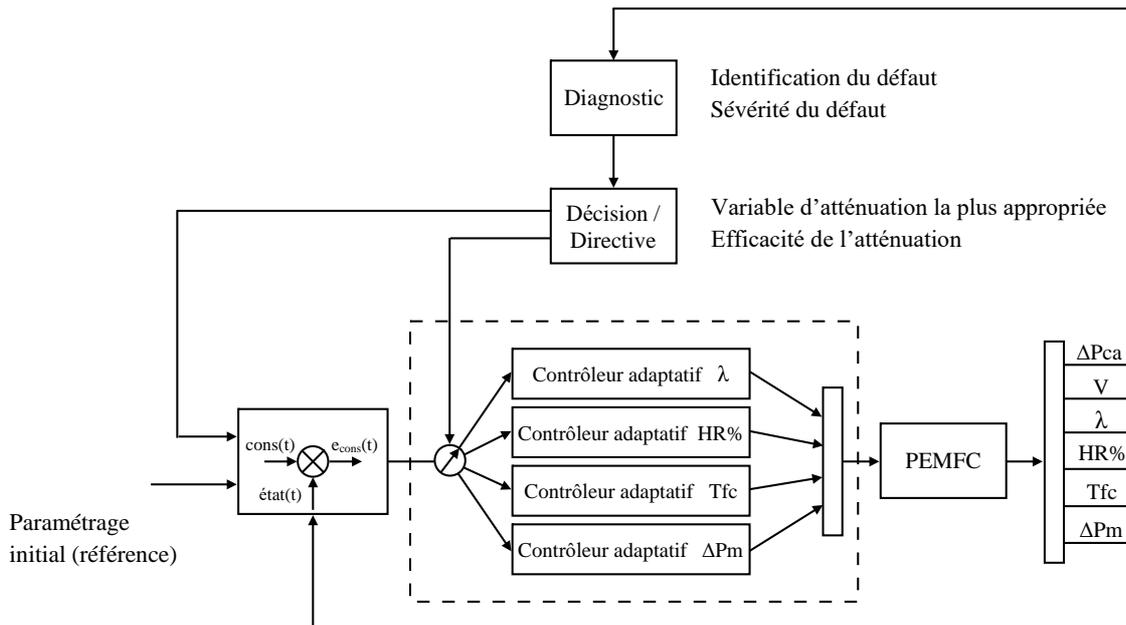
Variables à contrôler	Variables de commande	Variables influençant l'état de santé					
Stœchiométrie en hydrogène $\lambda_{H_2}$	$q_{H_2,in}$						
Stœchiométrie en oxygène $\lambda_{O_2}$	$q_{O_2,in}$						
Humidité relative anodique $HR_{an} \%$		$q_{H_2O,an,in}$	$T_{ballon}$	$T_{canal}$			
Humidité relative cathodique $HR_{ca} \%$		$q_{H_2O,ca,in}$	$T_{ballon}$	$T_{canal}$			
Température de la pile $T_{fc}$					$P_{heater}$	$q_{coolant}$	$w_{fan}$
Différence de pression $\Delta p_{an,ca}$						$P_{an,in}/P_{ca,in}$	$P_{an,out}/P_{ca,out}$

### 3.3.2 Banque de contrôleurs adaptatifs dans la stratégie AFTC

Les résultats de [Wu & Zhou \(2016\)](#) indiquent l'incapacité des contrôleurs par retour d'état configurés pour un fonctionnement nominal du système d'assurer un suivi de consigne correct en situation de défaut. Pour corriger cela, l'étude propose une banque de contrôleur suivant chaque cas de figure. Le module de diagnostic implémenté dans cette étude oriente le choix contrôleur adéquat face à une situation spécifique.

L'approche ici est différente vu la capacité d'adaptation du contrôleur et la présence du module de décision. Le système PEMFC en boucle fermée fait appel à plusieurs contrôleurs adaptatifs, chaque contrôleur agit sur une variable spécifique (stœchiométrie, humidité relative, température, ou différence de pression à la membrane). Lors de la détection d'un défaut par le module de diagnostic, le module de décision, ou directive, active le processus d'atténuation en déterminant et en calculant la consigne correctrice. Le graphique de principe est donné à la [Figure 42](#).

Le paramétrage initial sert au démarrage du système PEMFC. Pour les défauts de noyage et d'assèchement, le module de diagnostic est basé sur les mesures de différence de pression cathodique et de tension. Le module de diagnostic permet ainsi l'identification de la présence d'un défaut et son degré de sévérité. Le module de décision intègre ces informations et fournit une analyse. Au regard de l'occurrence du défaut, de sa sévérité, et des variables d'atténuation, le module de décision identifier la variable correctrice et son incrémentation positive ou négative. L'amplitude de l'incrémentaion est liée à l'efficacité d'atténuation demandée. Pour notre cas d'étude, nous considérons que la direction d'incrémentaion et l'efficacité de l'atténuation sont connues et sont fournies par le module de décision. Pour les tests de simulation et d'expérimentation, ces informations seront données arbitrairement.



**Figure 42** Diagramme fonctionnel du contrôleur adaptatif aux états de santé dans la stratégie AFTC

### 3.4 Structure de contrôle ADP et sorties cibles d'apprentissages

#### 3.4.1 Structure de contrôle ADP basé HDP

Nous rappelons les choix effectués précédemment. Compte tenu de la prise en compte des défauts et du choix du modèle neuronal, la structure ADP adoptée est de type HDP couplé à des modèles ESN. L'approche HDP présente un effort de calcul contenu, car une seule sortie est estimée. Le modèle ESN intègre des états mémoriels et une sortie récurrente ce qui contribue à la modélisation des dynamiques du système. De plus, il s'agit d'un modèle neuronal dont les ajustements lors de l'apprentissage ne concernent que la matrice de sortie. Le temps de calcul est par conséquent relativement court  $0,70 \mu s$ . L'approche s'accompagne d'un apprentissage prospectif pour le modèle critique, il s'agit d'un apprentissage basé sur des sorties prédites sur un horizon de prédiction.

Le diagramme du contrôle retenu est présenté à la [Figure 43](#). Les erreurs de modélisations utilisées pour l'apprentissage des trois modèles sont données à la suite du diagramme. Le signal d'entrée  $d(k)$  du modèle prévisionneur fait référence à toutes les perturbations mesurables. En l'occurrence, il peut s'agir ici du signal de courant de charge ou de la stœchiométrie. La sortie du modèle acteur est ajouté à la commande précédente. Puis, des contraintes de sécurité sont considérées en fonction des plages de fonctionnement des actionneurs.

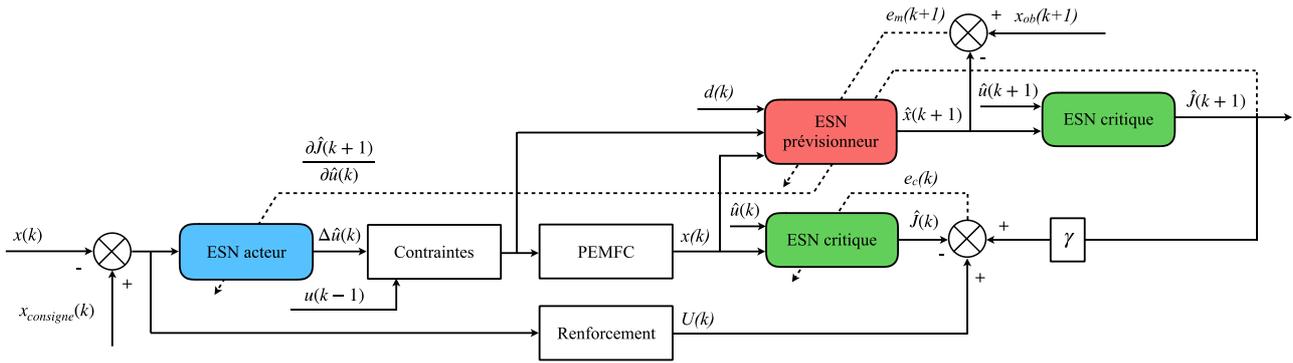


Figure 43 Structure de contrôle adaptative par programmation dynamique

### 3.4.2 Apprentissages des modèles ESN

#### Modèle prévisionneur

Le modèle prévisionneur a le rôle d'anticiper l'influence de la commande calculée par ESN acteur sur la variable contrôler. Cette prévision sert à l'ajustement des modèles ESN acteur et critique. Le terme  $d(k+1)$  correspond à la perturbation future, dans nos essais cette entrée est considérée en simulation puisqu'elle est connue, mais elle n'est pas considérée en expérimentation. Les entrées et sorties de ce modèle sont les suivantes :

	Entrées	Sorties
<b>Prévisionneur</b>	1 $\hat{u}(k)$ $x(k)$ $d(k+1)$	$\hat{x}(k+1)$

L'erreur de modélisation utilisée dans l'apprentissage de ce modèle est la suivante :

$$e_{prev}(k) = x(k) - \hat{x}(k-1) \quad (14)$$

où  $x$  correspond à l'état du système observé et  $\hat{x}$  correspond à la sortie du module à l'instant précédent. La valeur réelle n'étant pas disponible à l'instant  $t$ , nous prenons en considération l'instant précédent. L'apprentissage du modèle prévisionneur aura par conséquent un temps de retard.

#### Modèle critique

Le modèle critique a le rôle d'estimer le coût présent et futur du signal de renforcement, ce modèle est utilisé deux fois. Les modèles acteur et critique qui sont utilisés pour l'estimation des valeurs futures voient en entrée une compensation d'état par l'erreur de modélisation du modèle prévisionneur. Cette compensation permet de contrebalancer, dans une certaine mesure, le retard d'apprentissage du modèle prévisionneur dans l'algorithme du contrôleur. Les entrées et sorties de ce modèle sont les suivants :

	Entrées	Sorties
<b>Critique</b>	1 $x(k)$ $\hat{u}(k) = \hat{u}(k-1) + \Delta\hat{u}(k)$	$\hat{f}(k)$
<b>Critique 1</b>	1 $\hat{x}(k+1) + e_{prev}(k)$ $\hat{u}(k+1) = \hat{u}(k) + \Delta\hat{u}(k+1)$	$\hat{f}(k+1)$

On adopte l'approche prospective pour l'ajustement du modèle critique :

$$\hat{f}(x(k)) - U(k) - \gamma\hat{f}(x(k+1)) = 0 \quad (15)$$

L'erreur de modélisation correspondante est la suivante :

$$e_c(k) = U(k) + \gamma\hat{f}(x(k+1)) - \hat{f}(x(k)) \quad (16)$$

### Modèle acteur

Le modèle acteur a le rôle de fournir la commande pour le contrôle. Les entrées et sorties de ce modèle sont les suivants :

	Entrées	Sorties
<b>Acteur</b>	1 $x_{cons}(k) - x(k)$	$\Delta\hat{u}(k)$
<b>Acteur 1</b>	1 $x_{cons}(k) - (\hat{x}(k+1) + e_{prev}(k))$	$\Delta\hat{u}(k+1)$

La commande à l'instant future est déterminée de la manière suivante :

$$u(k) = u(k-1) - \zeta \frac{\partial J(k)}{\partial u(k)} \quad (17)$$

où  $0 < \zeta \leq 1$  est le coefficient d'atténuation de la commande. L'erreur de modélisation correspondante est de cette forme :

$$e_a(k) = -\zeta \frac{\partial J(k)}{\partial u(k)} - \Delta\hat{u}(k+1) \quad (18)$$

où  $\Delta\hat{u}(k+1)$  est une estimation obtenue par le modèle à partir de la prévision  $\hat{x}(k+1)$ . L'information jacobienne est obtenue de la manière suivante :

$$\frac{\partial J(k)}{\partial u(k)} = \frac{\partial U(k)}{\partial u(k)} + \gamma \frac{\partial \hat{f}(k+1)}{\partial u(k)} \quad (19)$$

où  $U(k)$  et  $u(k)$  sont des éléments connus. La donnée jacobienne future  $\partial J(k+1)/\partial u(k)$  est obtenue sur la règle de la dérivation en chaîne :

$$\frac{\partial J(k+1)}{\partial u(k)} = \frac{\partial J(k+1)}{\partial x(k+1)} \frac{\partial x(k+1)}{\partial u(k)} \quad (20)$$

On récupère les matrices des modèles ESN et on effectue la dérivée de la fonction d'activation pour obtenir les termes de la dérivation en chaîne :

$$\frac{\partial J(k+1)}{\partial x(k+1)} = W_c^{out}(k) f'_c(W_c^{res}(k)) W_c^{in} \quad (21)$$

$$\frac{\partial x(k+1)}{\partial u(k)} = W_p^{out}(k) f'_p(W_p^{res}(k)) W_p^{in} \quad (22)$$

où  $f'_{c,m}$  est la dérivée de la fonction d'activation des neurones.

### 3.5 Algorithme du contrôle ADP

L'algorithme utilisé pour la mise en place du contrôle par programmation dynamique heuristique est le suivant :

---

#### Algorithme 1 Contrôleur ADP

---

```

1  Définir les hyperparamètres des modèles ESN acteur, prévisionneur et critique
2  Initialiser les modèles ESN acteur, prévisionneur et critique
3  Vérification du caractère échoïque des modèles
4  Initialiser :  $i = 0$ 
5  Définir le temps de contrôle :  $N_{run}$ 
6  Tant que  $i < N_{run}$ 
7      Acquisition de l'état système :  $x(k)$ 
8      Estimation du taux d'apprentissage :  $\eta_p(k)$ 
9      Ajustement des poids du modèle prévisionneur :  $e_p(k)$ 
10     Calcul du signal de renforcement :  $U(k)$ 
11     Estimation du coût du contrôle :  $J^*(k)$ 
12     Estimation de la commande :  $u^*(k)$ 
13     Prévion de l'état système futur :  $x^*(k+1)$ 
14     Prévion de la commande future :  $u^*(k+1)$ 
15     Prévion du coût du contrôle futur :  $J^*(k+1)$ 
16     Estimation du taux d'apprentissage :  $\eta_c(k)$ 
17     Ajustement des poids du modèle critique par apprentissage prospectif :  $e_c(k)$ 
18     Estimation du taux d'apprentissage :  $\eta_a(k)$ 
19     Ajustement des poids de l'acteur par l'information jacobienne :  $e_a(k)$ 
20     Sauvegarde des paramètres
21     Incrémentation  $i = i + 1$ 
22 Fin tant que  $i < N_{run}$ 

```

---

### 3.6 Études de stabilité et de convergence de la stratégie de contrôle

Les études de stabilité et de convergence étant développées dans la littérature (Bo and Zhang, 2018; Z. Huang et al., 2018; Kumar et al., 2017; Yildiz et al., 2012), elles seront reprises

dans cette section. Parmi les travaux disponibles, certains concernent le contrôle ADP et d'autres le modèle ESN. Les conditions et les domaines de validités seront énoncés, puis ils seront pris en considération dans notre algorithme de contrôle.

### 3.6.1 Stabilité du contrôleur ADP basé HDP

L'utilisation en ligne du contrôleur ADP et de son apprentissage par renforcement fait que la question de stabilité est fondamentale. L'analyse de la stabilité au sens de Lyapunov est l'approche couramment adoptée pour cette tâche. [Huang et al. \(2018\)](#) ont récemment analysé les domaines de stabilité du contrôleur ADP suivant la nature de la fonction de renforcement. Les conditions pour le respect de la stabilité du contrôle sont extraites de cette étude.

Pour une **erreur de contrôle sous une forme quadratique**  $e(k) = U^T(k)U(k)R[X(k)]$ , où  $X = (X_1, X_2, \dots, X_k)$  rassemble tous les vecteurs d'états,  $U = (U_1, U_2, \dots, U_k)$  rassemble toutes les commandes et  $R(k)$  est une matrice définie positive. La fonction candidate de Lyapunov est définie comme suit :

$$V(t) = \sum_{k=t+1}^m \zeta^{k-t-1} (U^T(k)U(k)R[X(k)]) \quad (23)$$

où  $m$  est un horizon du contrôle optimal et  $0 < \zeta \leq 1$  est le coefficient d'atténuation précédemment défini. La dérivée de la fonction candidate est construite à partir du théorème de l'encadrement autour de valeurs minimales et maximales. Ces bornes sont définies suivant la valeur minimale et maximale de la matrice  $R(k)$ . La résolution de la dérivée indique une valeur négative, ce qui démontre l'existence d'une boucle de contrôle ADP asymptotiquement stable au sens de Lyapunov. Le contrôle est alors asymptotiquement stable et converge si la condition (25) est respectée :

$$\dot{V}_{max}(k) = - \sum_{j=1}^n \frac{1}{2} \left\| \frac{x(k+1) - x_{cible}(k+1)}{x_{max}(k+1)} \right\|^2 \quad (24)$$

$$\dot{V}(k) \leq \dot{V}_{max}(k) < 0 \quad (25)$$

où  $x_{max}$  représente la valeur maximale de l'ensemble des états jusqu'au temps  $k+1$ .

Pour une **erreur de contrôle sous forme résiduelle absolue**, la fonction candidate de Lyapunov est définie comme suit :

$$V(t) = \sum_{k=t+1}^m \zeta^{k-t-1} \left( \frac{1}{2} \left| \sum_{j=1}^n \frac{x_j(k) - x_j^*(k)}{x_{min,j}(k)} \right| \right) \quad (26)$$

où  $x_{min}$  est le minimum des états connus du système. Le contrôle est alors asymptotiquement stable et converge si la condition (28) est respectée :

$$\dot{V}_{max}(t) = - \left( \frac{1}{2} \left| \sum_{j=1}^n \frac{x_j(t+1) - x_j^*(t+1)}{x_{max,j(t+1)}} \right| \right) \quad (27)$$

$$\dot{V}(t) \leq \dot{V}_{max}(t) < 0 \quad (28)$$

### 3.6.2 Stabilité et convergence globale du modèle ESN

Depuis la définition de [Jaeger \(2000\)](#), de nombreuses publications ont pour objet la recherche d'éléments supplémentaires pour définir au mieux et de manière pratique un modèle ESN viable, stable et performant. Nous avons sélectionné les analyses les plus pertinentes au regard de notre problématique de contrôle.

#### – Étude de stabilité du réservoir ESN

Dans l'objectif de prouver la propriété échoïque du réservoir de neurones, le critère matriciel de Schur peut être employé pour le modèle ESN en complément de la condition se référant au rayon spectral.

**Définition 1.** Le critère matriciel de Schur appliqué au modèle ESN

On suppose une matrice de poids  $W^{res} \in \mathbb{R}^{N \times N}$  générée aléatoirement intervenant dans le calcul du modèle ESN et de condition  $\rho(W^{res}) < 1$ . S'il existe une matrice diagonale définie positive  $P_s > 0$  telle que  $W^{resT} P_s W^{res} - P_s$  est définie négative, alors la propriété échoïque du modèle ESN est garantie quel que soit les entrées du réservoir.

La preuve de la [Définition 1](#) est apportée dans les travaux de [Yildiz, Jaeger & Kielbel \(2012\)](#), où la résolution est réalisée à l'aide de la théorie de Lyapunov. Le critère matriciel de Schur permet de déterminer que toutes les racines du réservoir sont de modules inférieurs à 1, auquel cas, nous pouvons considérer que le réservoir possède un caractère échoïque et que la structure du modèle ESN restera stable au cours du temps. Ainsi, lors de l'initialisation et de l'optimisation du modèle, le critère matriciel de Schur sera vérifié afin de s'assurer de la stabilité du réservoir.

#### – Étude de convergence de l'apprentissage par les moindres carrés et descente du gradient

Pour un algorithme d'apprentissage utilisant la méthode des **moindres carrés récurrents**, soit  $W^{out*}$  les poids idéaux de la matrice de sortie, la sortie du modèle ESN à l'instant  $k$  est alors donnée par :

$$y_{cible}(k) = x^T(k) W^{out*}(k) \quad (29)$$

L'erreur entre les poids idéaux et les poids réels est donnée comme suit :

$$\tilde{W}^{out}(k) = W^{out*}(k) - W^{out}(k) \quad (30)$$

À partir d'une analyse aux limites réalisée par [Bo & Zhang \(2018\)](#) sur les modèles ESN, il a été démontré que les poids  $W^{out}(k)$  tendent vers les poids idéaux  $W^{out*}(k)$  en temps infini.

$$\lim_{k \rightarrow \infty} W^{out}(k) = W^{out*}(k) \quad (31)$$

L'ajustement de la matrice de sortie est défini comme ci-dessous à la condition que le taux d'apprentissage soit borné  $0 < \eta < 1$  :

$$W^{out}(k+1) = W^{out}(k) + \eta \frac{P(k)x(k)e(k)}{1 - x^T(k)P(k)x(k)} \quad (32)$$

où  $P$  est la matrice de covariance de l'erreur d'estimation. La matrice de covariance de l'erreur d'estimation  $P(k)$  est donnée de la manière suivante :

$$\begin{aligned} P(k) &= [P^{-1}(k-1) + x^T(k)x(k)]^{-1} \\ &= P(k-1) - \frac{P(k-1)x(k)x^T(k)P(k-1)}{1 + x^T(k)P(k-1)x(k)} \end{aligned} \quad (33)$$

$P(k) \in \mathbb{R}^{n \times n}$  est initialisée sur une matrice unitaire.

Pour un algorithme d'apprentissage utilisant la méthode de la **descente du gradient**, [Kumar et al. \(2017\)](#) propose une analyse de stabilité au sens de Lyapunov pour l'équation d'ajustement des poids. La fonction candidate de Lyapunov est de nature quadratique :

$$V(k) = \frac{1}{2} \left[ (e(k))^2 + (W^{out}(k))^2 \right] > 0 \quad (34)$$

La stabilité asymptotique de l'apprentissage est établie pour la condition suivante :

$$\Delta V(k) = V(k+1) - V(k) \leq 0 \quad (35)$$

L'unique solution de l'équation ci-dessus est bien notée  $\Delta W_{out}(k) \leq 0$ , ce qui nous permet d'obtenir un minimum global par la forme suivante :

$$W^{out}(k+1) = W^{out}(k) + \eta \frac{W^{out}(k) + e(k) \frac{\partial e(k)}{\partial W^{out}(k)}}{1 + \left( \frac{\partial e(k)}{\partial W^{out}(k)} \right)^2} \quad (36)$$

## Conclusion

La consistance de différents modèles neuronaux a été éprouvée, de même que leurs vitesses d'exécutions pour une application en temps réel. Le modèle ESN est celui qui a été retenu comme structure neuronale pour les modèles acteur, prévisionneur et critique. Parmi tous les modèles temporels testés, il présente le plus faible temps d'exécution ( $70 \mu s$ ). Ce temps est compatible avec la dynamique des actionneurs de la pile, le défaut de noyage et le défaut d'assèchement de la membrane. Nous retenons également le contrôleur par programmation dynamique heuristique avec apprentissage prospectif du modèle critique. Le

choix de la stratégie AFTC au niveau du contrôleur a été justifié. L'atténuation des défauts est réalisée par la mise en œuvre d'un ensemble de contrôleurs en aval du module de décision. Nous remarquons que seule la boucle de régulation en différence de pression est directement influencée par le défaut de noyage. Deux analyses de stabilités ont été adoptées. La stabilité au sens de Lyapunov sert à l'analyse du contrôleur, tandis que, le critère matriciel de Schur est employé pour le caractère échoïque des modèles ESN. De plus, certains coefficients sont contraints pour assurer la convergence de l'apprentissage des modèles ESN.

Les deux chapitres suivants concernent la mise en œuvre du contrôleur et à l'analyse des résultats de contrôle.

# Chapitre 4

## TEST DE LA PROCEDURE DE CONTROLE ADAPTATIF EN SIMULATION

### Sommaire

---

<b>4.1</b>	<b>Dispositif de simulation et le modèle cœur de pile</b> .....	<b>94</b>
4.1.1	Modèle PEMFC, les variables de contrôles et de commandes .....	95
4.1.2	Scénarios de tests et les mises en conditions de défauts .....	95
<b>4.2</b>	<b>Les contrôleurs et leurs paramétrages</b> .....	<b>98</b>
4.2.1	Contrôleur PID .....	98
4.2.2	Contrôleur par programmation dynamique heuristique .....	99
4.2.3	Le temps de calcul des contrôleurs .....	100
<b>4.3</b>	<b>Résultats de simulation obtenus sur un empilement de cellules</b> .....	<b>101</b>
4.3.1	Suivi de consigne stœchiométrique en fonctionnement sain – Scénario S1.1 ...	101
4.3.2	Régulation avec rejet de perturbation en condition de fonctionnement sain – Scénario S1.2.....	104
4.3.3	Régulation en présence du défaut de noyage – Scénario S2 .....	106
4.3.4	Suivi de consigne en présence du défaut d’assèchement de la membrane – Scénario S3.....	108
<b>4.4</b>	<b>Analyse et interaction des modèles neuronaux</b> .....	<b>110</b>
<b>4.5</b>	<b>Synthèse et discussion sur les résultats de simulation</b> .....	<b>113</b>

---

## Introduction

L'objectif de ce chapitre est de démontrer la faisabilité de l'algorithme de contrôle en simulation. Celle-ci repose sur un modèle du système PEMFC capable de reproduire un fonctionnement nominal, mais également un fonctionnement en présence de certains défauts système. Le modèle que nous utiliserons est celui de Pukrushpan ([Pukrushpan, 2003](#)).

Une étape préalable à l'implémentation en ligne et aux tests expérimentaux est l'évaluation des performances et du comportement du régulateur en simulation. La simulation offre une flexibilité et un degré d'observation qui serait difficile et coûteux à réaliser en expérimentation. Cette étape est fondamentale avant le test de l'algorithme en ligne. Notamment, l'analyse de l'apprentissage des réseaux de neurones permettra d'identifier les possibles perturbations ou interférences résultant de l'interdépendance des modèles ESN au sein de la stratégie ADP.

Un modèle dynamique PEMFC avec défauts a été sélectionné en première partie. Le modèle est détaillé dans l'[Annexe B](#). Pour les comparaisons avec le régulateur ADP nous utilisons un régulateur PID dont les coefficients sont optimisés. La deuxième partie présente les résultats de suivi de consigne et de régulation. La troisième partie donne les résultats obtenus en présence de défauts ou de perturbations extérieurs. Enfin, la dernière partie donne les résultats des analyses de stabilité et de convergence.

### 4.1 Dispositif de simulation et le modèle cœur de pile

Une synthèse des modèles dynamiques de la littérature est dressée afin de lister les travaux de modélisation compatibles avec notre cas d'étude. Cette liste de modèles n'est pas exhaustive, les modèles présentés dans le [Tableau 28](#) prennent en compte les défauts et défaillances du système PEMFC. Ils sont tous supposés observables et contrôlables du point de vue des états du système. Le domaine de fonctionnement des modèles est précisé à partir des conditions de fonctionnements opératoires.

**Tableau 28** Synthèse des modèles PEMFC avec défauts

Modèles physiques	PEMFC	Défaut/Défaillance	T [°C]	HR [%]	Pressions	Débit réactif / autre
<a href="#">(Abdollahzadeh et al., 2018)</a>	25 cm <sup>2</sup>	Empoisonnement anodique	65 – 80	50 – 100	0,11 – 0,15	$\lambda = 2$ pour 25 A / 10 – 20 ppm CO
<a href="#">(Wu and Zhou, 2016)</a>	381 x 280 cm <sup>2</sup>	Noyage cathodique, Assèchement	60 – 70	50 – 100	1,5 – 3 MPa	$\lambda = 2$ pour 150 – 200 A
<a href="#">(Zhai et al., 2012)</a>	72 x 54 cm <sup>2</sup>	Noyage anodique / Purge anodique				Courant max 30 A
<a href="#">(Bakhtiar et al., 2012)</a>	448 x 200 cm <sup>2</sup>	Noyage cathodique, Assèchement	40 – 60	18,5 – 50	0,1 MPa	0,08 m <sup>3</sup> .s <sup>-1</sup>
<a href="#">(Liu et al., 2006)</a>	1 x 5 cm <sup>2</sup>	Noyage GDL cathode	70	90	0,2 MPa	0,10 – 0,20 L.min <sup>-1</sup>

Modèles circuit équivalent	PEMFC	Défaut/Défaillance	T [°C]	HR [%]	Pressions	Débit réactif / autre
(Giner-Sanz et al., 2014)	20 x 58 cm <sup>2</sup>	Court-circuit électrique, Franchissement H <sub>2</sub>	50		0,1 Mpa	2 – 8 NL.min <sup>-1</sup>
(Hernandez et al., 2010)	20 cellules	Noyage cathodique, Assèchement / Dégradation membrane	50		0,1 – 0,15 MPa	$\lambda = 2 – 4$ pour 17 – 40 A
(Gebregergis et al., 2008)	1 x 10 cm <sup>2</sup>	Noyage GDL cathode, Assèchement	40+		6,7 kPa	100 cm <sup>3</sup> .min <sup>-1</sup>

Au regard des modèles présentés, le modèle PEMFC avec défauts retenu est celui qui est développé dans les travaux de [Wu & Zhou \(2016\)](#). Ce choix a été opéré en considérant le domaine de fonctionnement, la dimension de pile et la disponibilité des coefficients paramétriques. Ce modèle PEMFC a également été éprouvé dans une simulation de stratégie AFTC.

#### 4.1.1 Modèle PEMFC, les variables de contrôles et de commandes

Le modèle approché du cœur de pile PEMFC est détaillé dans l'[Annexe B](#). Il s'agit d'un empilement de 381 cellules. Plusieurs hypothèses permettent sa simplification. La dynamique du modèle étant établie sur les dynamiques fluidiques, la simulation du système PEMFC est réalisée avec une période d'échantillonnage de 2 ms. Les simulations sont effectuées sous le logiciel *MATLAB*<sup>®</sup>. Ce modèle est généralement employé pour la régulation de la tension de la pile et la différence de pression à la membrane.

$$[y_1; y_2] = [V; \Delta P_{mbr}]$$

La différence de pression à la membrane est obtenue par la différence entre la somme des pressions partielles anodique et cathodique ( $\Delta P_{mbr} = P_{ca} - P_{an}$ ). La tension de la pile étant une variable indicatrice de l'état de santé de la pile, il paraît peu pertinent de la réguler dans la stratégie AFTC. La tension délivrée est modulée par les auxiliaires électriques en aval de pile. Nous adopterons comme variables à contrôler, la stœchiométrie en oxygène, la différence de pression à la membrane et la température de la pile.

$$[y_1; y_2; y_3] = [\lambda_{O_2}; \Delta P_{mbr}; T_{fc}]$$

Les variables de commande sont la pression d'air en entrée  $p_{a,in}$  en Pa, la pression d'hydrogène en entrée  $p_{H_2,in}$  en Pa et le débit du liquide de refroidissement  $W_{coolant}$  en kg/s.

$$[u_1; u_2; u_3] = [p_{air,in}; p_{H_2,in}; W_{coolant}]$$

#### 4.1.2 Scénarios de tests et les mises en conditions de défauts

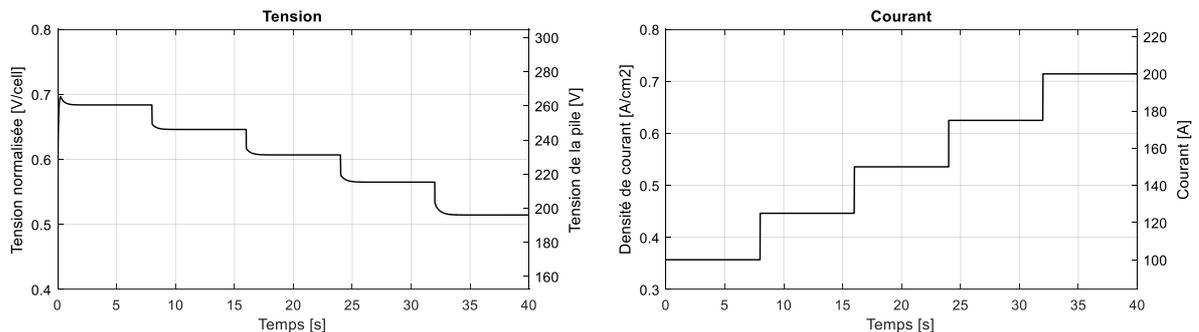
Les paramètres opératoires de la simulation sont détaillés dans le [Tableau 29](#).

**Tableau 29** Condition de fonctionnement en mode sain et en présence de défauts pour la simulation

Variables	Normal S1	Noyage S2	Assèchement S3
Courant [A]	100 – 200	200	175
Pression d'entrée à l'anode $t(0)$ [Pa]	150 000	150 000	150 000
Pression d'entrée à la cathode $t(0)$ [Pa]	200 000	200 000	200 000
Température pile [°C]	60	60	60 – 70
Température ambiante [°C]	25	25	25
Humidité relative hydrogène [%]	100	100	100
Humidité relative air [%]	80	100 + condensation	50
Eau injectée à la cathode [kg/s]	0,002	0,002 – 0,01	0

### Scénarios S1.1 et S1.2 : Fonctionnement nominal

Le comportement du système en conditions de fonctionnement opératoires nominales est donné ci-dessous. Des paliers entre 100 et 200 A sont réalisés sous des pressions absolues d'entrées de 1,5 bar en hydrogène pur et de 2,0 bar en air ambiant. La température de la pile est ici réglée à 60°C par un contrôleur PID. L'humidité relative est fixée à 1 pour l'anode et 0,5 pour la cathode.

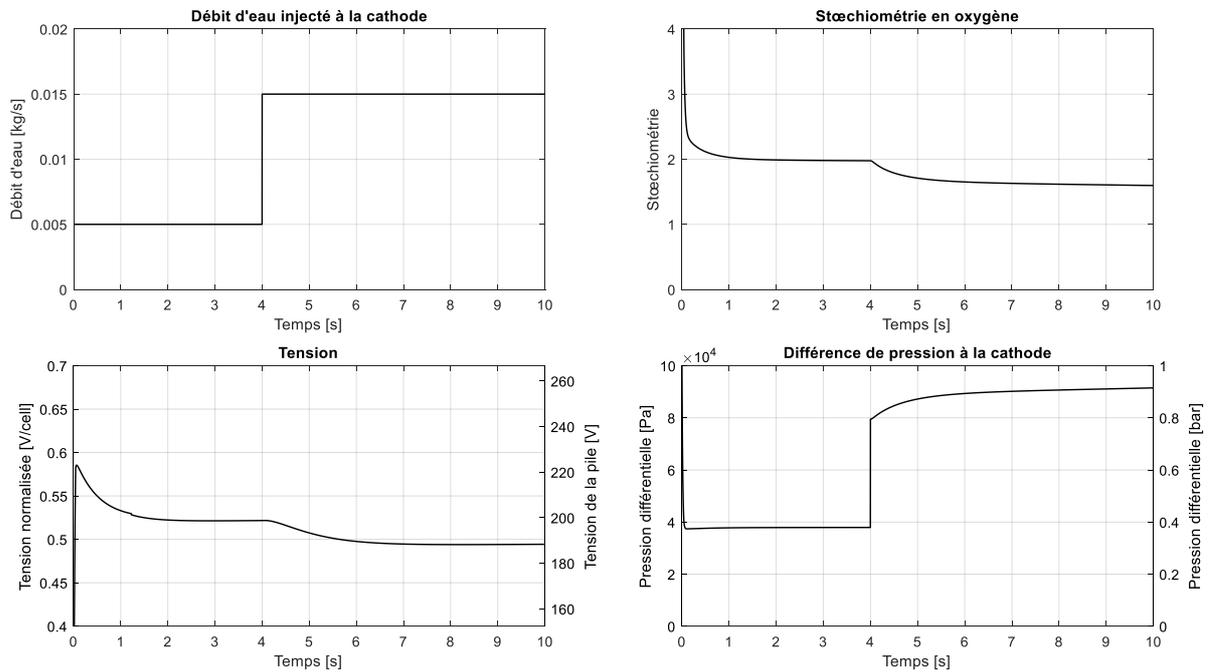
**Figure 44** Dynamiques du modèle PEMFC sur un fonctionnement nominal sans régulation

Deux tests sont réalisés sur un fonctionnement sain. Le **Scénario S1.1** est un suivi de consigne de la stœchiométrie en oxygène. Pour ce test, l'entrée  $d(k+1)$  du modèle prévisionneur pour le contrôleur ADP n'est pas pris en compte. Le **Scénario S1.2** est une régulation des trois variables de contrôle  $y_1, y_2, y_3$  en présence de perturbations en courant.

### Scénario S2 : Défaut de noyage des canaux de distribution cathodique

Le défaut de noyage est interprété à la cathode par une augmentation du débit d'eau injecté  $W_{v_{inj,ca}}$  par le biais des buses d'injection, il s'agit ici d'une augmentation fixée à 0,010 kg/s. L'humidité relative à la cathode augmente, la vapeur d'eau arrive à saturation et l'eau se condense. L'eau liquide occupe alors la chambre cathodique et vient diminuer la quantité en réactif pour un volume physique donné. La conséquence est une baisse de la tension et une augmentation de la différence de pression entrée-sortie à la cathode. Le point de fonctionnement

en courant est fixé à 200 A, soit une densité de  $0,71 \text{ A/cm}^2$ . Les courbes de la [Figure 45](#) représentent la réponse du système PEMFC en présence du défaut de noyage.



**Figure 45** Dynamiques du modèle PEMFC en présence d'un défaut de noyage sans régulation

### Scénario S3 : Défaut d'assèchement de la membrane

Le défaut d'assèchement de la membrane est généré par une diminution du débit du liquide de refroidissement  $W_{cool}$ , elle est réduite de  $0,20 \text{ kg/s}$ . La régulation de la température est désactivée pendant la simulation de ce défaut. La température de la pile est initialement stabilisée à partir d'un débit de refroidissement donné, lors de la diminution de ce débit la température augmente. Cette augmentation entraîne alors une évaporation de l'eau contenue dans la pile et à la membrane. La cinétique de la perte en eau étant ici prépondérante aux réactions catalytiques, la hausse de la température n'augmente pas temporairement la tension de la pile. Elle a plutôt pour conséquence une forte baisse de la tension et une légère augmentation de la différence de pression cathodique. La défaillance de fonctionnement sur la circulation du liquide de refroidissement intervient ici à 3 secondes du point de démarrage. Le point de fonctionnement en courant est fixé à 175 A, soit une densité de  $0,62 \text{ A/cm}^2$ . Les courbes suivantes représentent la variation des différentes variables en situation de défaut d'assèchement de la membrane. Les courbes de la [Figure 46](#) représentent la réponse du système PEMFC en présence du défaut de noyage.

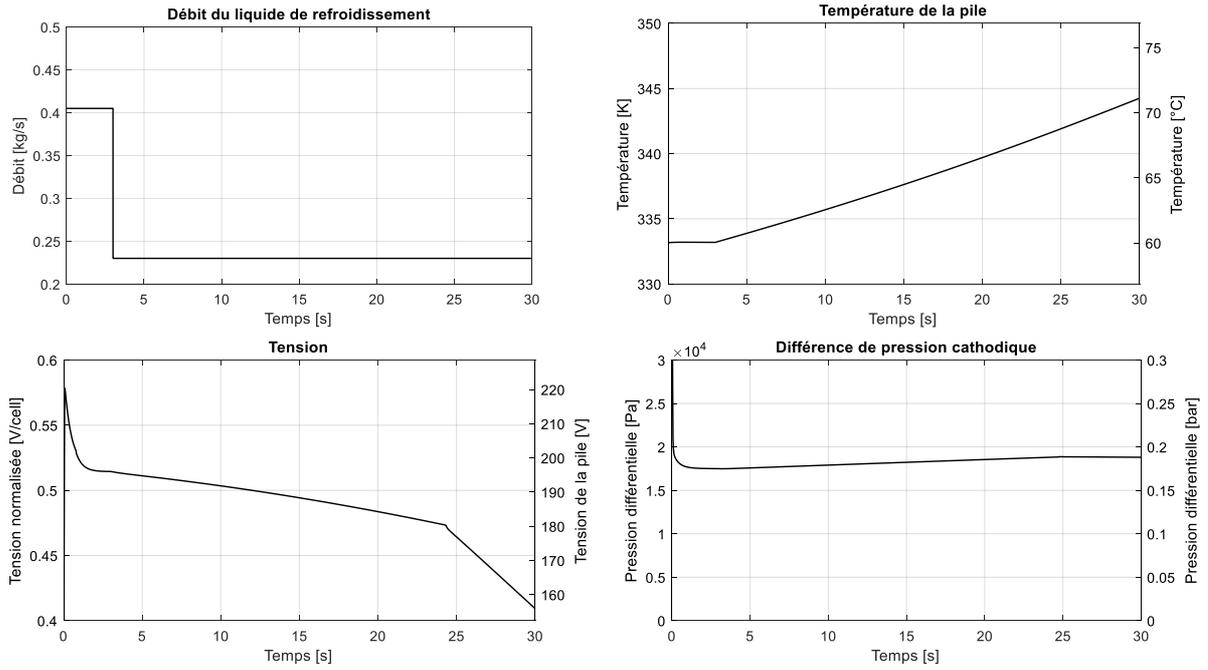


Figure 46 Dynamiques du modèle PEMFC sur un défaut d'assèchement sans régulation

## 4.2 Les contrôleurs et leurs paramétrages

Le contrôleur PID est utilisé pendant l'étude en simulation afin de réaliser une comparaison de performances avec le contrôleur ADP développé. Les contrôleurs sont évalués à partir d'un critère d'erreur quadratique moyen (« Root Mean Square Error » ou RMSE) écrit sous la forme suivante :

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^N (\text{état}_i - \text{consigne}_i)^2}{N}} \quad (37)$$

où  $N$  représente le nombre d'échantillons. Cette métrique est choisie pour pouvoir quantifier l'erreur suivant la variable à réguler.

### 4.2.1 Contrôleur PID

Trois contrôleurs PID en temps discret sont employés pour les signaux de commandes. Les paramètres utilisés pour la définition de ces contrôleurs sont déterminés par la méthode heuristique Ziegler–Nichols :

Contrôleur	Sorties	$kP$	$kI$	$kD$
PID 1	$u_1 = p_{an,in}$	0,015	2,41	0,60
PID 2	$u_2 = p_{ca,in}$	1100	301,5	75,37
PID 3	$u_3 = W_{coolant}$	2,4	96	24

### 4.2.2 Contrôleur par programmation dynamique heuristique

Le contrôleur ADP utilisé en simulation est de type multi-variable. Le modèle acteur fournit les variations des signaux de commande. Cette approche offre deux avantages, un temps de calcul plus faible que l'utilisation de plusieurs contrôleurs ADP, et un même réservoir dynamique ce qui signifie une même stabilité au cours du temps. Chaque test de suivi de consigne ou de régulation est effectué indépendamment, les modèles ESN sont initialisés à chaque fois.

Nous rappelons que les variables à contrôler sont  $[y_1; y_2; y_3] = [\lambda_{O_2}; \Delta P_{mbr}; T_{fc}]$  et les variables de commandes sont  $[u_1; u_2; u_3] = [p_{a,in}; p_{H_2,in}; W_{coolant}]$ . Les entrées et les sorties des modèles ESN sont détaillées dans le [Tableau 30](#).

**Tableau 30** Entrées et sorties des modèles ESN en simulation

	Acteur	Acteur 1	Prévisionneur	Critique	Critique 1
<b>Entrées</b>	1	1	1	1	1
	$e_{\lambda_{O_2}}(k)$	$\lambda_{O_2_{cons}}(k)$	$\lambda_{O_2}(k)$	$\lambda_{O_2}(k)$	$\hat{\lambda}_{O_2}(k+1)$
	$e_{\Delta P_m}(k)$	$-(\hat{\lambda}_{O_2}(k+1)$ $+ e_{prev,\lambda_{O_2}}(k))$	$\Delta P_m(k)$	$\Delta P_m(k)$	$+ e_{prev,\lambda_{O_2}}(k)$
	$e_{T_{fc}}(k)$	$\Delta P_{m_{cons}}(k)$ $-(\Delta \hat{P}_m(k+1)$ $+ e_{prev,\Delta P_m}(k))$	$T_{fc}(k)$	$T_{fc}(k)$	$\hat{\Delta P}_m(k+1)$ $+ e_{prev,\Delta P_m}(k)$
		$T_{fc_{cons}}(k)$ $-(\hat{T}_{fc}(k+1)$ $+ e_{prev,T_{fc}}(k))$	$\hat{P}_{an,in}(k)$	$\hat{P}_{an,in}(k)$	$\hat{T}_{fc}(k+1)$ $+ e_{prev,T_{fc}}(k)$
			$\hat{P}_{ca,in}(k)$	$\hat{P}_{ca,in}(k)$	
			$\hat{W}_{coolant}(k)$	$\hat{W}_{coolant}(k)$	$\hat{P}_{an,in}(k+1)$
			$I_{st}(k+1)$ ou $\lambda_{O_2}(k+1)$		$\hat{P}_{ca,in}(k+1)$
					$\hat{W}_{coolant}(k+1)$
<b>Sorties</b>	$\Delta \hat{P}_{an,in}(k)$	$\Delta P_{an,in}(k+1)$	$\hat{\lambda}_{O_2}(k+1)$	$J_{O_2}(k)$	$J_{O_2}(k+1)$
	$\Delta \hat{P}_{ca,in}(k)$	$\Delta P_{ca,in}(k+1)$	$\hat{\Delta P}_m(k+1)$	$J_{\Delta P_m}(k)$	$J_{\Delta P_m}(k+1)$
	$\Delta \hat{W}_{coolant}(k)$	$\Delta W_{coolant}(k+1)$	$\hat{T}_{fc}(k+1)$	$J_{\Delta T_{fc}}(k)$	$J_{\Delta T_{fc}}(k+1)$

Les entrées et sorties du module de renforcement sont les suivants :

Signal de renforcement U(k)	
<b>Entrées</b>	$[e_{\lambda_{O_2}}(k); e_{\Delta P_m}(k); e_{T_{fc}}(k)]$
<b>Sorties</b>	$[U_{O_2}(t); U_{\Delta P_m}(t); U_{\Delta T_{fc}}(k)]$

Il existe trois signaux jacobien et trois sorties cibles pour le modèle critique, donc autant de coefficients ADP. Tous les coefficients d'atténuation  $\zeta$  et d'actualisation  $\gamma$  possèdent la même amplitude de 0,3. L'apprentissage des modèles ESN est réalisé à partir de méthodes de descente du gradient. Les signaux de renforcement sont mis à l'échelle pour obtenir des valeurs

entre 0 et 1. La même opération est effectuée sur les entrées et les cibles d'apprentissage des modèles ESN. À partir de l'étude des hyperparamètres effectuée au chapitre précédent et en supposant qu'elle satisfait les modèles neuronaux acteur et critique, les trois modèles ESN acteur, prévisionneur et critique sont configurés de la manière suivante :

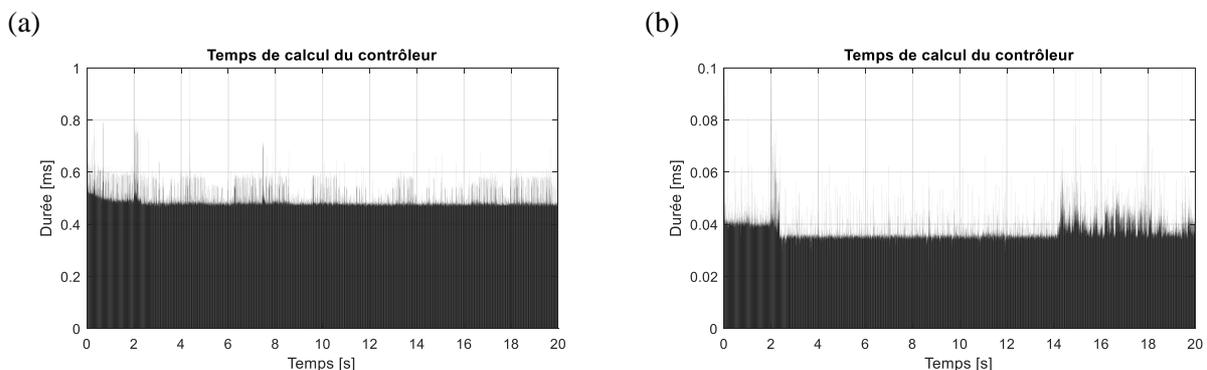
**Tableau 31** Configuration des hyperparamètres du contrôleur ADP en simulation

	$nDeep$	$nRes$	$C_o$	$\alpha$	$\eta$	$\zeta$	$\gamma$
Acteur, prévisionneur et critique	1	30	0,1	0,5	0,3		
Coefficients ADP						0,3	0,3

La fonction de renforcement est une erreur résiduelle absolue. Ce choix permet d'appliquer la fonction candidate de Lyapunov correspondante et d'évaluer dans le même temps la stabilité du contrôleur au cours du temps. La sortie de la fonction de renforcement est normalisée linéairement entre 0 et 1, les entrées et les sorties des modèles sont également normalisées par la même méthode.

### 4.2.3 Le temps de calcul des contrôleurs

La Figure 47 montre les temps de calcul des contrôleurs multi-variables, seul le scénario S1 est présenté, les temps de calcul sont équivalents, quel que soit le scénario mis en œuvre.



**Figure 47** Comparaison des temps de calcul des contrôleurs durant la simulation.

a) programmation dynamique b) contrôleur PID

Le contrôleur PID est le plus rapide. Le contrôleur ADP nécessite une période moyenne de 0,5 ms pour le calcul d'une itération. En considérant une marge d'erreur, avec un temps de calcul 10 fois supérieur, le contrôleur ADP est applicable avec les systèmes dont le temps d'échantillonnage est supérieur à 5 ms. Ce temps de calcul est obtenu dans un processus de contrôle sans optimisation des hyperparamètres. Ainsi, la mise en place d'une méthodologie incluant une optimisation des hyperparamètres impliquerait un temps de calcul plus important. La boucle de contrôle est cadencée à 5 ms pour tous les contrôleurs. La méthode de logique floue n'est pas employée en simulation. En effet, suite à plusieurs essais, nous observons qu'un

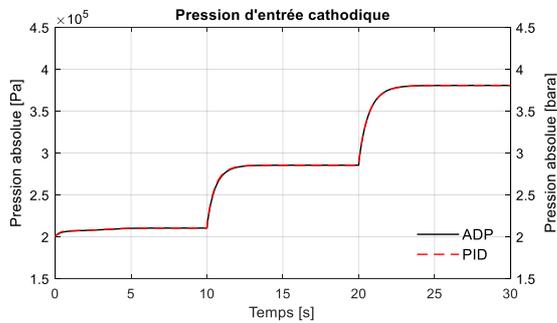
taux d'apprentissage fixé à 0,3 suffit à obtenir des convergences d'apprentissage satisfaisantes en simulation.

### 4.3 Résultats de simulation obtenus sur un empilement de cellules

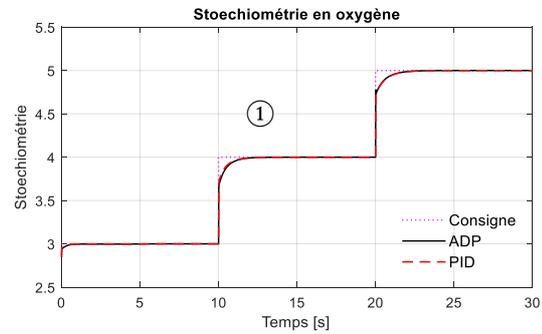
#### 4.3.1 Suivi de consigne stœchiométrique en fonctionnement sain – Scénario S1.1

Les consignes sont les suivantes :  $[\lambda_{O_2}; \Delta P_{mbr}; T_{fc}] = [\{3, 4, 5\}; 0 Pa; 60 ^\circ C]$  et le courant de charge est fixé à 150 A. La réponse du système PEMFC pour le scénario S1.1 est donnée à la Figure 48.

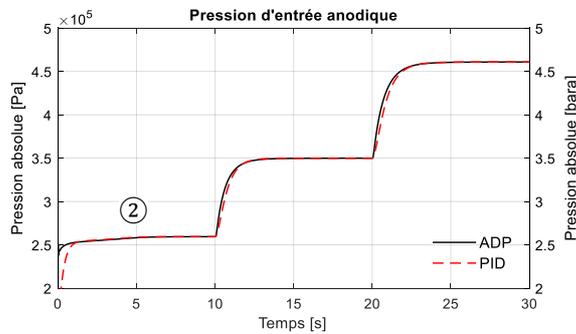
(a) Commandes



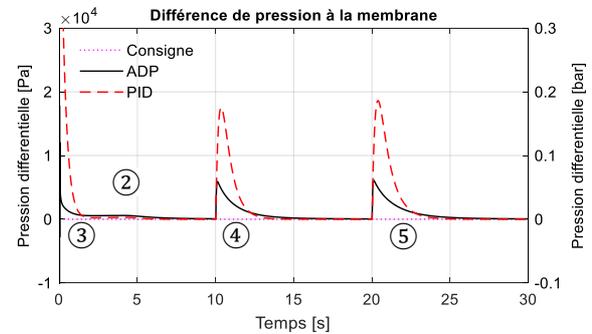
(a) Variables à contrôler



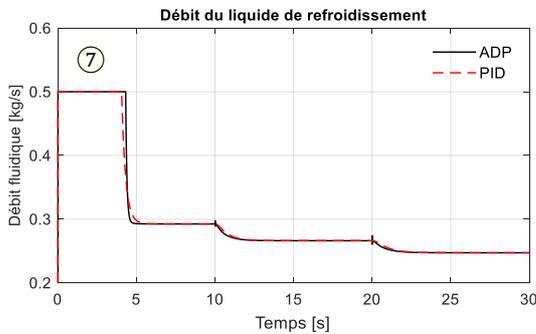
(b) Commandes



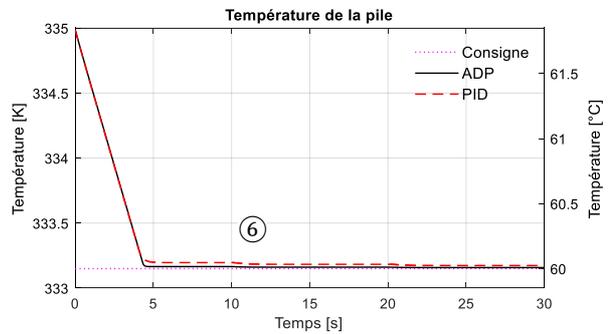
(b) Variables à contrôler



(c) Commandes



(c) Variables à contrôler



**Figure 48** Réponse du système PEMFC durant le suivi de consigne stœchiométrique – Scénario S1.1. a) Contrôle en stœchiométrie b) Contrôle en différence de pression à la membrane c) Contrôle en température

### Observations du suivi de consigne stœchiométrique – Scénario S1.1

- Les erreurs obtenues sont les suivants :

	$RMSE_{\lambda_{O_2}}$	$RMSE_{\Delta P_{membrane}}$	$RMSE_{T_{fc}}$
ADP	0,0477	1 775,2 Pa	0,4054 K
PID	0,0436	6 258,9 Pa	0,4053 K

- ① Le contrôle de stœchiométrie en oxygène est équivalent entre le contrôleur PID et le contrôleur proposé.
- ② Une erreur de position est remarquable avec le contrôleur ADP sur la différence de pression à la membrane, son amplitude est de 0,02 bar. À première vue, il ne semble pas avoir de différence entre l'amplitude des pressions d'entrées calculées par les deux contrôleurs. Il existe tout de même une faible différence, la pression d'entrée anodique calculée par le contrôleur ADP est plus faible de 700 Pa.
- Suite aux changements de stœchiométrie aux points ③④⑤, le contrôleur PID induit des déviations en différence de pression deux fois plus élevée que le contrôleur ADP. La déviation initiale au démarrage du contrôle est la même pour les deux contrôleurs. Les amplitudes sont données ci-dessous :

	③	④	⑤
ADP	0,6 bar	0,065 bar	0,068 bar
PID	0,6 bar	0,175 bar	0,185 bar

- La pente de convergence sur la consigne est plus rapide avec le contrôleur PID.
- Les temps d'établissement du régime permanent sont plus rapides avec le contrôleur PID, les valeurs sont données ci-dessous :

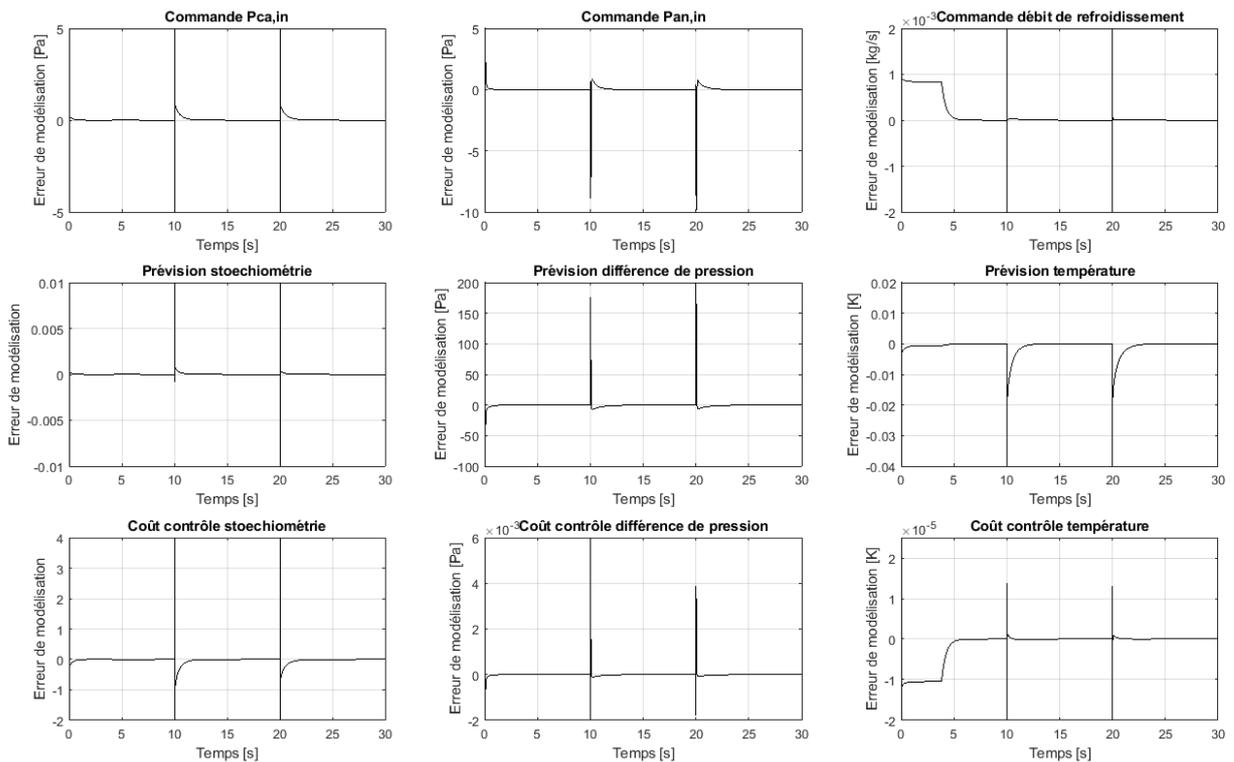
	③	④	⑤
ADP	7,88 s	6,15 s	6,23 s
PID	5,03 s	3,31 s	4,07 s

- Concernant le contrôleur PID, une erreur statique est observée sur la température ⑥, son amplitude est de 0,1-0,2 K ce qui reste négligeable.
- En début de contrôle au point ⑦, le débit du liquide de refroidissement calculé par les deux contrôleurs dépasse la limite fixée à 0,5 kg/s, ce qui enclenche le processus de contrainte.
- De manière générale, aucun dépassement de consigne ou d'oscillation n'est observé.

### Analyses du suivi de consigne stœchiométrique – Scénario S1.1

Les deux contrôleurs sont satisfaisants sur le test effectué. Les contrôles de stœchiométrie et de température sont équivalents. Pour le contrôle de la différence de pression, le contrôleur ADP présente une plus faible déviation que le contrôleur PID, sa capacité d'anticipation permet de réduire fortement l'erreur de trainage. Malgré tout, le contrôleur PID est ici le plus rapide pour atteindre la consigne voulue. Le contrôleur ADP présente une convergence à la consigne plus douce. Ce phénomène est à lier au signal de renforcement qui reçoit une normalisation linéaire. Lorsque l'erreur de position est faible, le signal de renforcement l'est encore plus. Il serait alors intéressant de combiner la normalisation du signal de renforcement avec un processus de modulation dans le but de conserver une erreur avec une amplitude suffisamment grande afin de diminuer plus fortement l'erreur de trainage et améliorer ainsi les performances de régulation. Une telle méthode pourrait impliquer l'apparition de dépassements sur le suivi de consigne.

La Figure 49 présente les erreurs de modélisation des trois modèles ESN. Nous rappelons que le taux d'apprentissage de l'ensemble est fixé à 0,3.



**Figure 49** Erreurs de modélisation des modèles ESN durant le suivi de consigne – Scénario S1.1

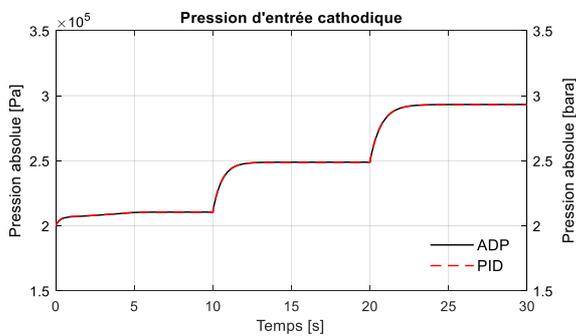
De fortes fluctuations sont présentes lors des changements dynamiques, on observe aussi que toutes les erreurs de modélisation convergent vers zéro. Ce qui démontre de l'efficacité des apprentissages effectués. L'ensemble des modèles et apprentissages réalisés en simulation remplissent correctement leurs objectifs d'estimation et de prévision pour le contrôleur ADP.

Les erreurs de modélisation des modèles ESN lors des tests de simulation suivants présentes les mêmes dynamiques et n'apportent pas d'informations supplémentaires, ils ne seront pas présentés dans ce manuscrit.

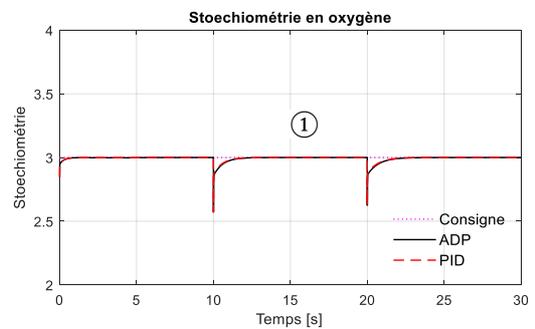
### 4.3.2 Régulation avec rejet de perturbation en condition de fonctionnement sain – Scénario S1.2

Il s'agit maintenant d'opérer une régulation multiple avec rejet de perturbation en courant. Les consignes sont fixes et prennent les valeurs suivantes  $[\lambda_{O_2}; \Delta P_{mbr}; T_{fc}] = [3; 0 Pa; 60^\circ C]$ . La perturbation est maintenant le courant de la charge qui varie par paliers  $I_{st} = \{150 A, 175 A, 200 A\}$ . La réponse du système en présence des perturbations en courant est donnée à la Figure 50.

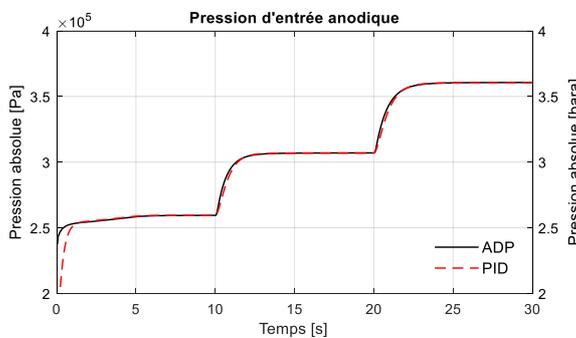
(a) Commandes



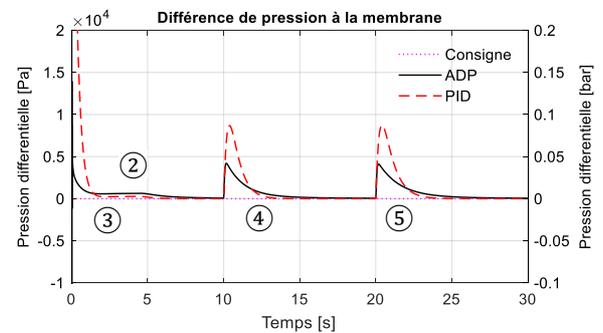
Variable à contrôler



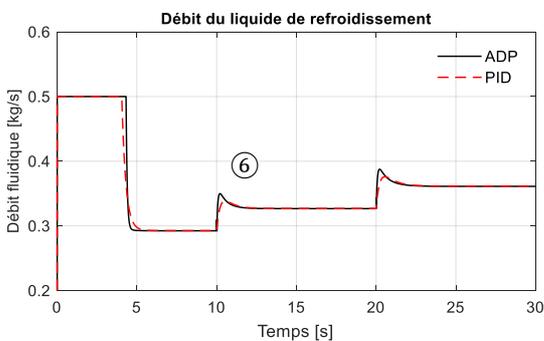
(b) Commandes



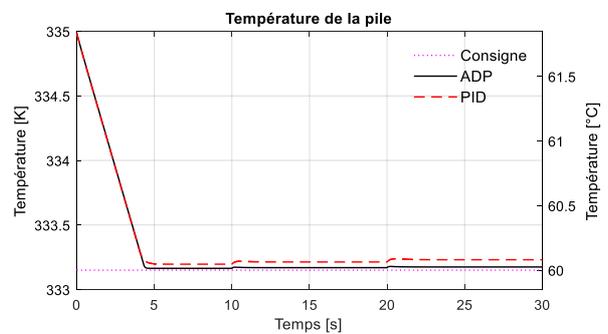
Variable à contrôler



(c) Commandes



Variable à contrôler



**Figure 50** Réponse du système PEMFC en présence des perturbations en courant – Scénario S1.2. a) Contrôle en stœchiométrie b) Contrôle en différence de pression à la membrane c) Contrôle en température

### Observations de la régulation avec rejet de perturbations – Scénario S1.2

- Les erreurs obtenues sont les suivants :

	$RMSE_{\lambda_{O_2}}$	$RMSE_{\Delta P_{membrane}}$	$RMSE_{T_{fc}}$
ADP	0,0236	1 548,0 Pa	0,4056 K
PID	0,0206	5 220,2 Pa	0,4090 K

- ① La régulation en stœchiométrie reste équivalente avec les deux contrôleurs.
- Les déviations ponctuelles en stœchiométrie provoquées par les perturbations ont une amplitude maximale de  $-0,4 \lambda_{O_2}$ . En phase transitoire, l'erreur de position à une amplitude maximale de  $-0,1 \lambda_{O_2}$ .
- ② De même qu'au test précédent, le contrôleur ADP présente une erreur statique (600 Pa) pour le premier palier (150 A) sur la différence de pression. Au bout de 5 secondes, la variable à contrôler se remet à converger sur la valeur nulle.
- Pour le contrôle de différence de pression, le contrôleur ADP induit une déviation réduite de moitié par rapport au contrôleur PID. Les amplitudes sont les suivantes :

	③	④	⑤
ADP	0,6 bar	0,42 bar	0,41 bar
PID	0,6 bar	0,86 bar	0,82 bar

- Les temps d'établissement du régime permanent pour la différence de pression sont les suivants :

	③	④	⑤
ADP	8,25 s	5,61 s	6,33 s
PID	5,02 s	2,96 s	3,95 s

- ⑥ Une erreur statique de 0,1 à 0,2 K (0,05 à 0,1 °C) est remarquable pour le contrôle de température avec le contrôleur PID, ces erreurs de positions sont négligeables. En phase statique, les commandes de débit du liquide de refroidissement calculées par les deux contrôleurs ne sont pas équivalentes, une différence dans le débit de refroidissement de 0,2 g/s persiste.
- ⑥ La régulation en température par le contrôleur ADP est plus efficace.
- De manière générale, aucun dépassement de consigne ou d'oscillation n'est observés.

### Analyses de la régulation avec rejet de perturbations – Scénario S1.2

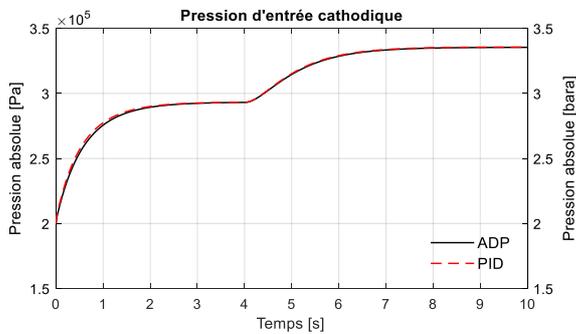
L'augmentation de la densité de courant augmente la température, par conséquent la dynamique de température est ici différente. Le contrôleur ADP se montre plus performant en

présence de cette perturbation que le contrôleur PID. La capacité de prévision du contrôleur ADP permet d'anticiper davantage l'action des commandes et de diminuer ainsi les déviations et par conséquent les erreurs de positions. On observe une réduction de la déviation deux fois plus faible avec le contrôleur proposé. On observe toujours une erreur statique sur le premier palier en régime permanent. Tous les modèles ESN sont initialisés en ligne et le contrôleur ne converge efficacement qu'à la deuxième perturbation. Ces contrôleurs nécessitent un certain nombre de données avant de converger effectivement, ceci est dû à la capacité d'apprentissage des modèles ESN.

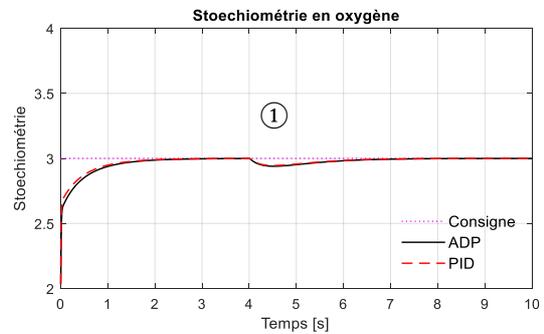
### 4.3.3 Régulation en présence du défaut de noyage – Scénario S2

Le système PEMFC est maintenant mis en condition de noyage sous une charge de 200 A, l'augmentation du débit d'eau injectée cathodique à lieu à 4 secondes.

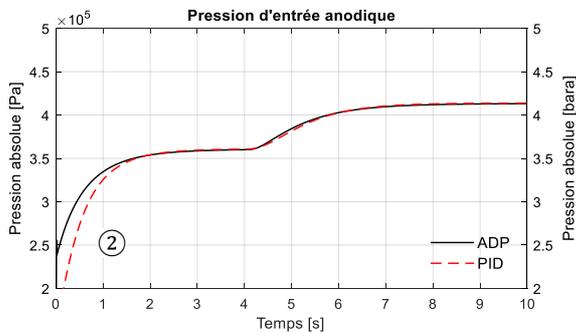
(a) Commandes



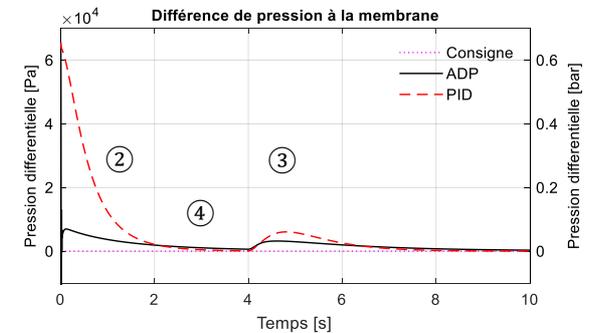
Variable à contrôler



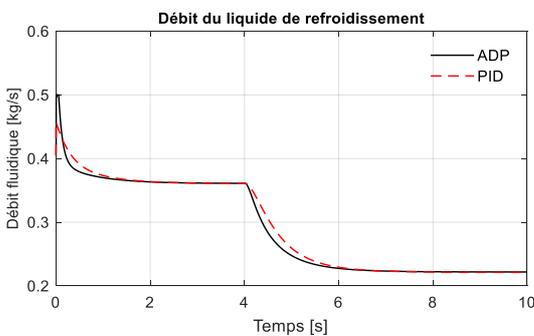
(b) Commandes



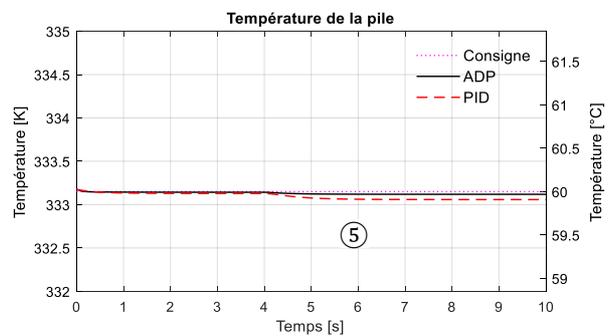
Variable à contrôler



(c) Commandes



Variable à contrôler



**Figure 51** Réponse du système PEMFC en présence du défaut de noyage – Scénario S2. a) Contrôle en stoechiométrie b) Contrôle en différence de pression à la membrane c) Contrôle en température

### Observations de la régulation en présence du défaut de noyage – Scénario S2

- Les erreurs obtenues sont les suivants :

	$RMSE_{\lambda_{O_2}}$	$RMSE_{\Delta P_{membrane}}$	$RMSE_{T_{fc}}$
ADP	0,0734	3 093,5 Pa	0,0227 K
PID	0,0622	12 585 Pa	0,0664 K

- ① La régulation en stœchiométrie est équivalente entre les deux contrôleurs.
- Pour le contrôle en différence de pression, le contrôleur PID induit des erreurs de positions importantes par rapport au contrôleur ADP. La déviation au point ② correspond au début du contrôle. La déviation au point ③ correspond à augmentation d'eau injectée à la cathode. Les amplitudes de ces déviations sont données ci-dessous :

	②	③
ADP	+ 0,65 bar	+ 0,033 bar
PID	+ 0,65 bar	+ 0,06 bar

- ④ Sur le contrôle en différence de pression, à la première déviation, avec le contrôleur ADP, le modèle PEMFC ne converge pas totalement sur la consigne nulle. Une faible erreur statique d'une amplitude de + 500 Pa persiste toujours au bout de 4 secondes. Avec le contrôleur PID, le système converge plus rapidement vers la consigne nulle. On a observé lors des tests précédents que cette erreur statique après les 5 secondes de régulation. Les temps d'établissement du régime permanent pour la différence de pression sont les suivants :

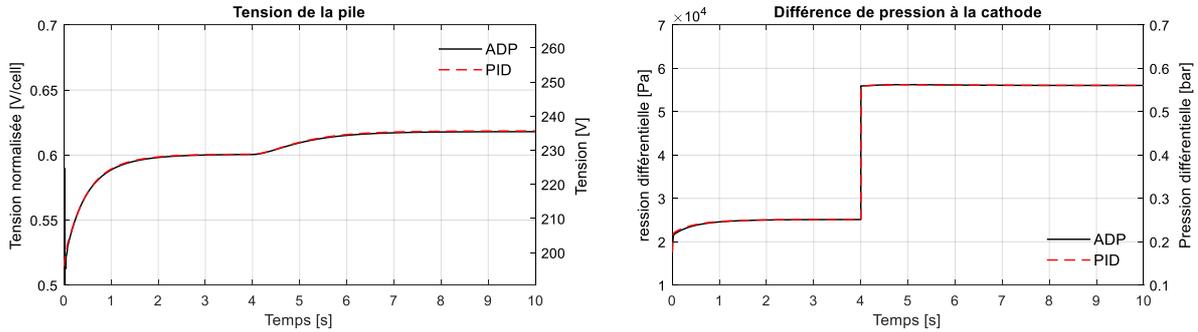
	②	③
ADP	4 s	5 s
PID	3 s	3,57 s

- ⑤ Le contrôleur PID présente une erreur statique sur le contrôle en température.
- De manière générale, aucun dépassement de consigne ou d'oscillations n'est observés.

### Analyses de la régulation en présence du défaut de noyage – Scénario S2

On observe toujours un phénomène récurrent d'erreur statique lors du début de contrôle avec le contrôleur proposé. L'injection d'eau supplémentaire influe sur la différence de pression à la cathode et ces perturbations se retrouvent sur le signal de la différence de pression à la membrane. Le contrôleur PID permet une régulation rapide, mais avec des différences de pression fortes, à l'inverse le contrôleur ADP offre une régulation plus lente, mais des

déviations plus faibles. Le contrôleur ADP est ici plus efficace pour maintenir l'équilibre de pressions à la membrane.

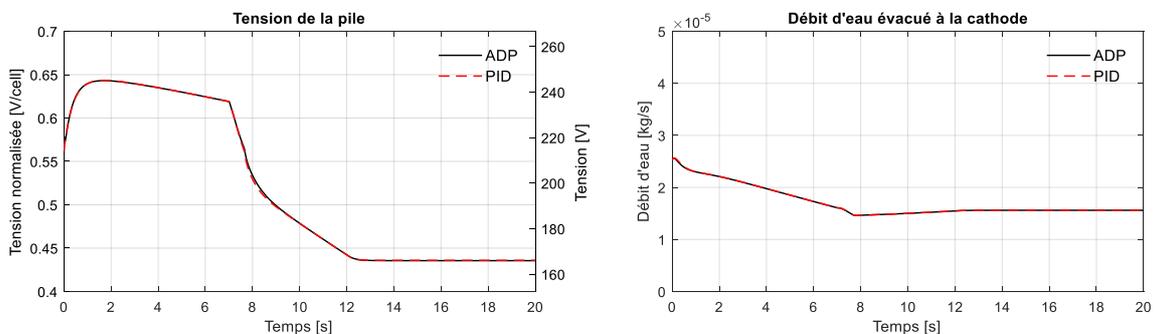


**Figure 52** Réponse du système PEMFC aux différents contrôleurs durant S2

L'eau injectée à la cathode provoque une augmentation de la différence de pression à la cathode et une diminution en stœchiométrie. La régulation en stœchiométrie se met alors en place, ce qui a pour conséquence une augmentation de la pression d'entrée cathodique et donc une amélioration de la tension de la pile. Dans cette configuration de pile, et avec ce type de régulation, le résidu de tension ne peut être utilisé pour diagnostiquer un défaut de noyage.

#### 4.3.4 Suivi de consigne en présence du défaut d'assèchement de la membrane – Scénario S3

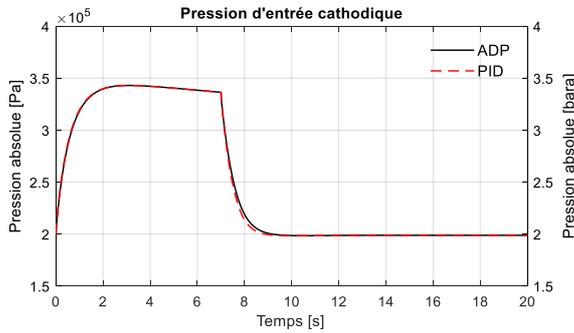
Le système est maintenant mis en condition de défaut d'assèchement de la membrane. La température est réglée pour une augmentation de  $T_{st} = \{60\text{ °C}, 70\text{ °C}\}$ . Afin d'éviter d'amplifier le défaut, un changement de stœchiométrie en oxygène de  $\lambda_{O_2} = \{4, 2.5\}$  est entrepris pour réduire la perte en eau. Cette action correctrice est simulée, car les modules de diagnostic et de décision ne sont pas modélisés. La température augmente dès le début du contrôle, la tension de la pile chute suivant le scénario S3 est donnée à la Figure 45. Le changement stœchiométrique intervenant à 4 secondes permet de freiner l'évacuation de l'eau et par conséquent l'assèchement de la membrane. La tension de la pile se stabilise ensuite au lieu de diminuer graduellement.



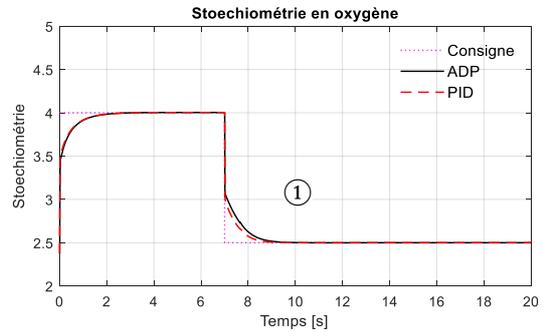
**Figure 53** Réponse du système PEMFC en présence du défaut d'assèchement de la membrane – Scénario S3

La réponse du système durant l'apparition et l'atténuation du défaut d'assèchement est donnée à la Figure 54.

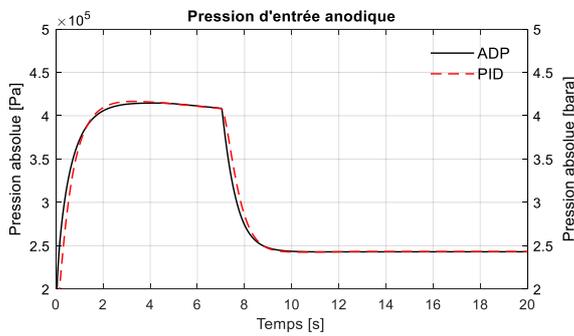
(a) Commandes



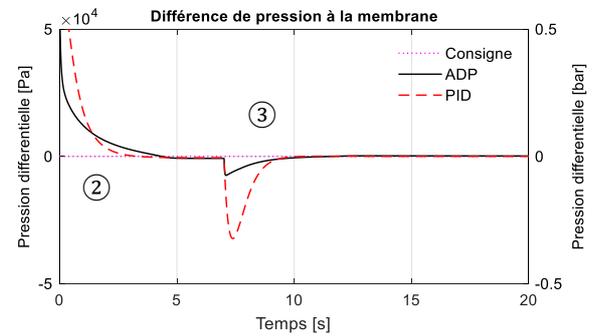
Variable à contrôler



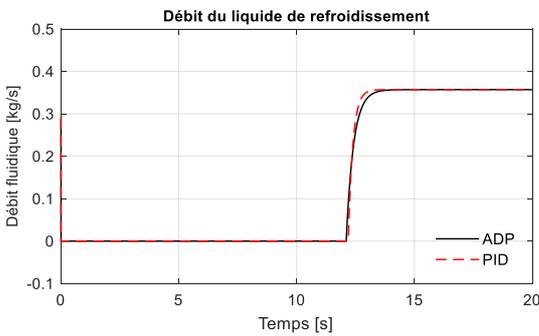
(b) Commandes



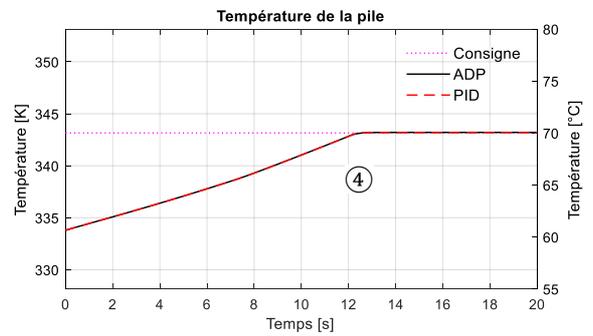
Variable à contrôler



(c) Commandes



Variable à contrôler



**Figure 54** Réponse du système PEMFC en présence du défaut d'assèchement de la membrane – Scénario S3. a) Contrôle en stœchiométrie b) Contrôle en différence de pression à la membrane c) Contrôle en température

**Observations du suivi de consigne en présence du défaut d'assèchement de la membrane – Scénario S3**

- Les erreurs obtenues sont les suivants :

	$RMSE_{\lambda_{O_2}}$	$RMSE_{\Delta P_{membrane}}$	$RMSE_{T_{fc}}$
ADP	0,1105	5 732,4 Pa	4,4821 K
PID	0,0925	12 176 Pa	4,4819 K

- La régulation en stœchiométrie est équivalente pour les deux contrôleurs. Un léger avantage en termes de précision est à remarquer pour le contrôleur PID au point ①.
- La déviation au point ② est le début du contrôle. La déviation au point ③ est provoquée par le changement de stœchiométrie en oxygène. Les temps d'établissement du régime permanent pour la différence de pression sont les suivants :

	②	③
ADP	4,7 s	5,7 s
PID	3,6 s	4,7 s

- Lors du changement en stœchiométrie, le contrôleur ADP présente une déviation nettement inférieure que le contrôleur PID. Les amplitudes des déviations sont les suivantes :

	②	③
ADP	6 bar	-0,07 bar
PID	6 bar	-0,32 bar

- ④ La régulation en température des deux contrôleurs est équivalente.
- Aucun dépassement de consigne ou d'oscillations n'est observé.

### Analyses du suivi de consigne en présence du défaut d'assèchement de la membrane – Scénario S3

Les contrôleurs sont robustes à l'augmentation en température. Le changement de stœchiométrie permet de stabiliser la chute de tension. Cette action modifie la pression d'entrée anodique et la différence de pression à la membrane, le contrôleur ADP présente ici une précision plus performante que le contrôleur PID. On remarque dans ce scénario que le contrôleur proposé permet d'obtenir une déviation quatre fois plus faible que le contrôleur PID. L'écart de performances entre les deux contrôleurs est plus importants dans une situation de défaut.

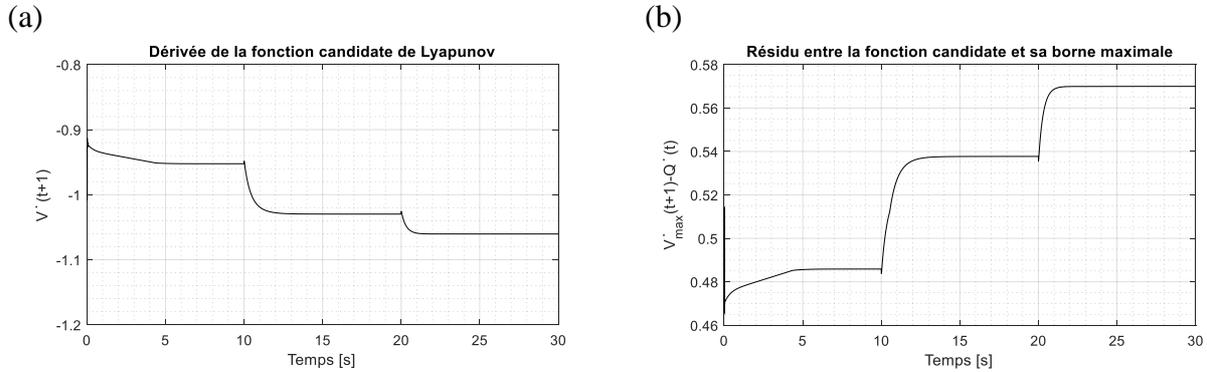
## 4.4 Analyse et interaction des modèles neuronaux

Dans cette section nous proposons d'analyser la stabilité du contrôleur proposé. Pour y parvenir, nous abordons la stabilité du contrôleur puis la convergence des modèles ESN.

### Stabilité du contrôleur au sens de Lyapunov

La stabilité du contrôleur ADP au sens de Lyapunov est donnée à la [Figure 55](#), seul le scénario 1 est présenté avec le contrôle stœchiométrique en oxygène. La dérivée de la fonction

candidate (26) est strictement négative. De plus, elle est correctement bornée par sa limite maximale de stabilité  $\dot{V}_{max}(t) - \dot{V}(t) \geq 0$ . Par conséquent, le contrôleur ADP utilisé pour le scénario 1 est asymptotiquement stable et convergent. Ce même résultat est observable pour l'ensemble des tests effectués en simulation.



**Figure 55** Analyse de la stabilité au sens de Lyapunov. a) dérivée de la fonction candidate de Lyapunov b) résidu entre la fonction candidate et sa borne maximale

### Caractère échoïque des réservoirs

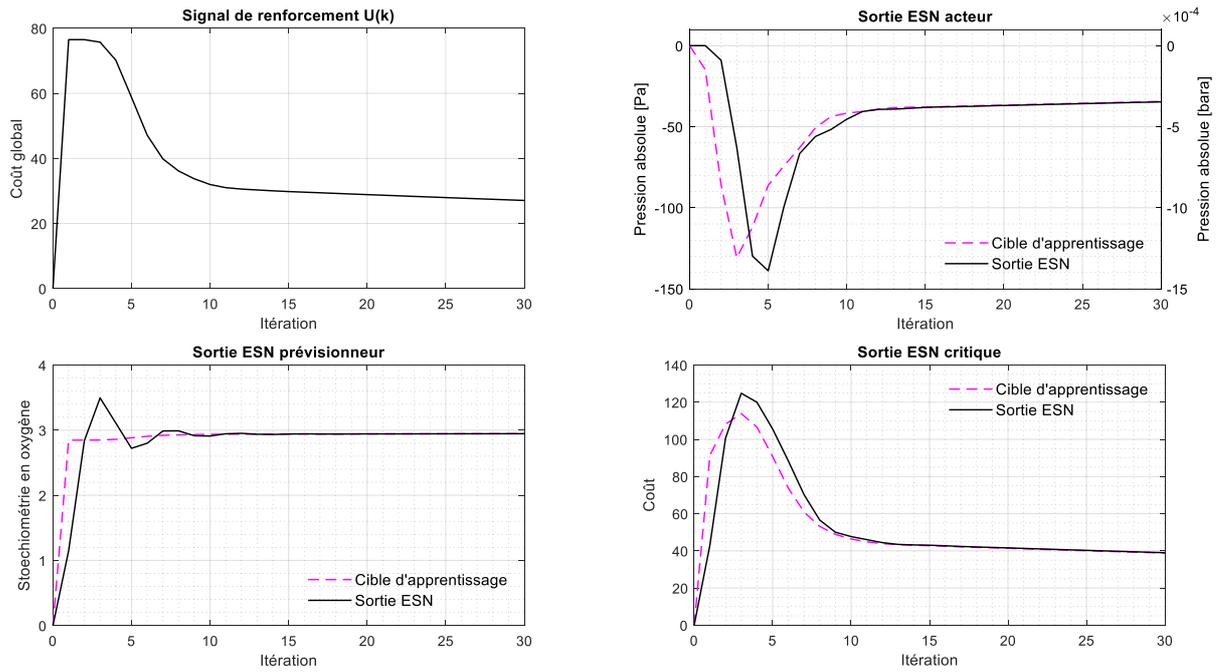
Les indices d'échométrie des modèles ESN sont donnés au [Tableau 32](#). Chaque réservoir est généré aléatoirement, et leur capacité échoïque est alors estimée. Si un réservoir ne répond pas à la condition voulue, l'étape de génération aléatoire est renouvelée jusqu'au respect de la condition. Sur l'ensemble des générations aléatoires, tous les réservoirs ont répondu favorablement à la condition de fonctionnement  $\max \rho^{(l)} < 1$ .

**Tableau 32** Indices d'échométrie des modèles ESN lors des 3 scénarios de simulation

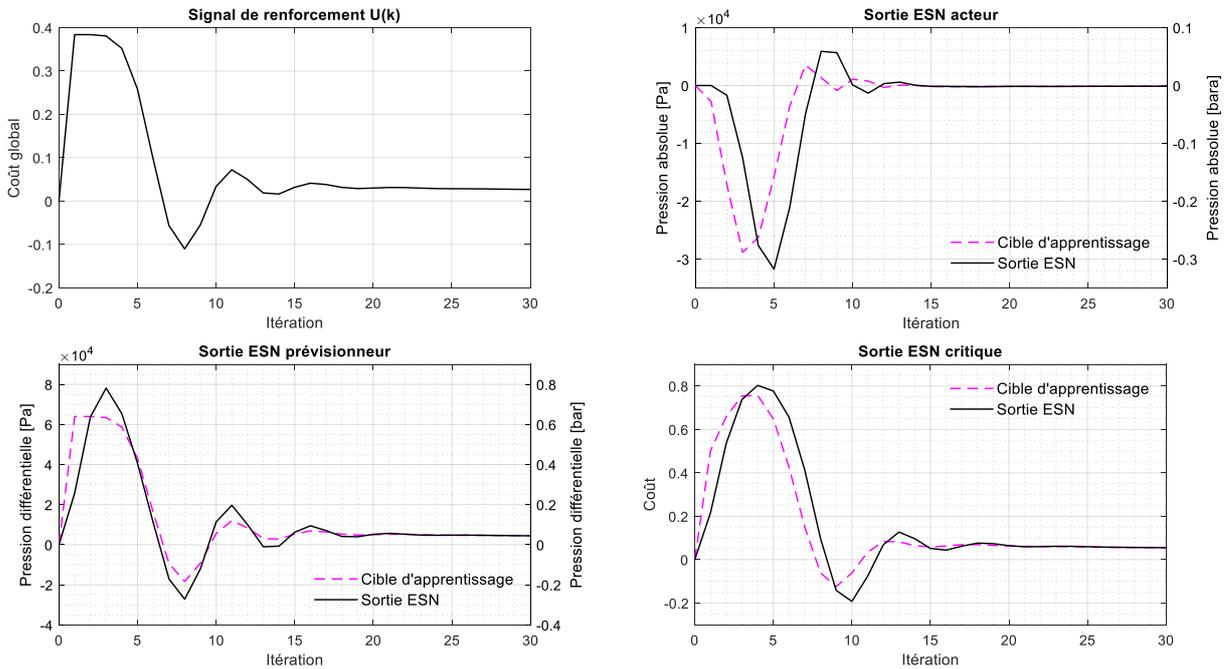
Modèle	Scénario 1.1 suivi sain	Scénario 1.2 régulation sain	Scénario 2 noyage	Scénario 3 assèchement
Acteur	0,4441	0,5619	0,4383	0,5832
Prévisionneur	0,5424	0,4947	0,4788	0,4564
Critique	0,5898	0,4421	0,6246	0,5785

### Convergence de l'apprentissage des modèles ESN

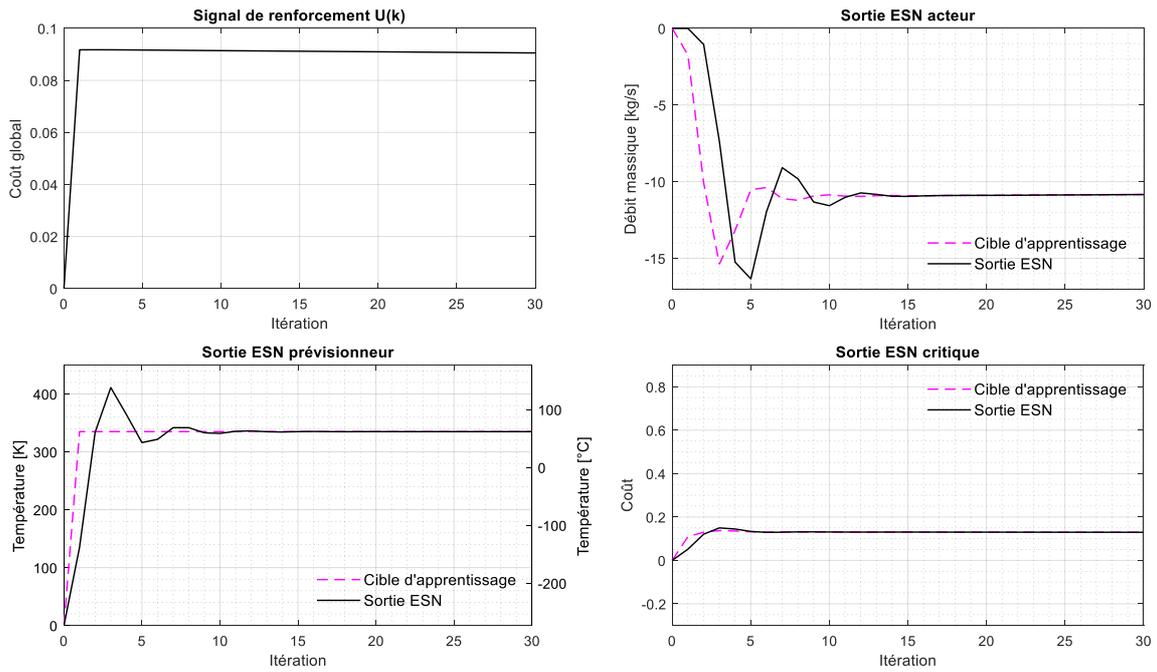
L'apprentissage est observé pour l'ensemble des 3 variables à contrôler. Les sorties et erreurs de modélisation des modèles sont présentées à la [Figure 56](#), [Figure 57](#) et [Figure 58](#). Les 3 modèles ESN sont configurés avec un même coefficient d'apprentissage fixé à la valeur de 0,3. La convergence du modèle est obtenue après chaque perturbation au bout de 10 à 15 itérations, aucun des processus d'apprentissage n'entraîne de divergence. On observe un décalage lors des premières itérations, il s'agit d'une conséquence du processus de rétropropagation.



**Figure 56** Sorties et cibles pour l'apprentissage des modèles ESN lors du suivi de consigne – Scénario S1 (30 premières itérations). Cas du contrôle de la stœchiométrie.



**Figure 57** Sorties et cibles pour l'apprentissage des modèles ESN lors du suivi de consigne – Scénario S1 (30 premières itérations). Cas du contrôle de la différence de pression.



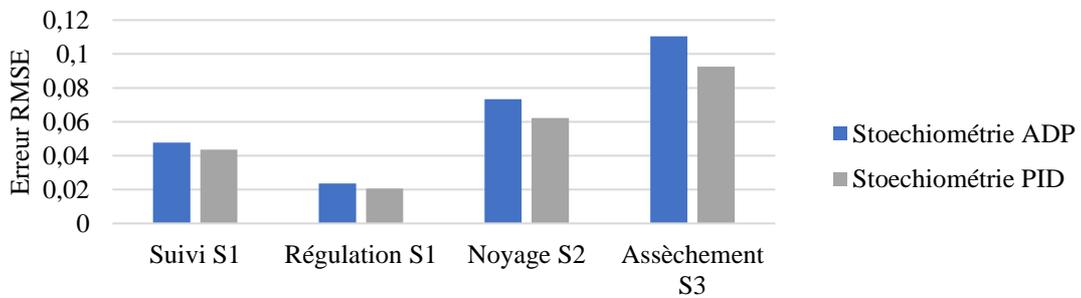
**Figure 58** Sorties et cibles pour l'apprentissage des modèles ESN lors du suivi de consigne – Scénario S1 (30 premières itérations). Cas du contrôle de la température.

**Le critère matriciel de Schur des réservoirs ESN**

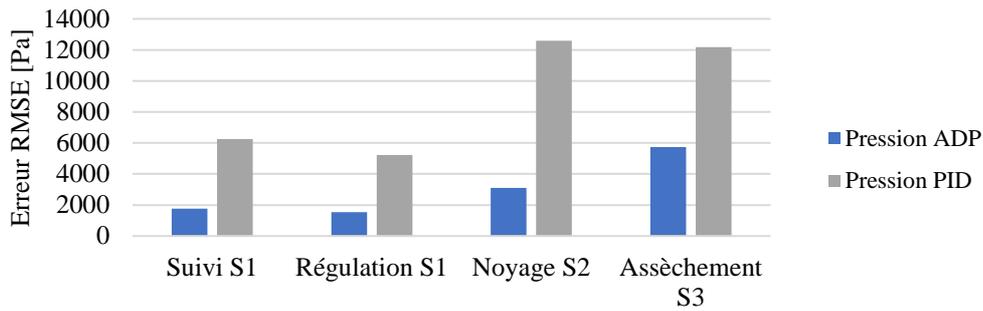
La recherche du critère matricielle de Schur des réservoirs de neurones est résolue numériquement à l'aide d'une boîte à outils permettant la résolution d'inéquation matricielle linéaire disponible sous *Matlab*<sup>®</sup> (*LMI*). Elle permet de résoudre rapidement l'inéquation de la Définition en fournissant la matrice symétrique positive  $P_S > 0$ , dans le cas où elle existe. Dans notre cas d'étude, tous les réservoirs présentent une matrice  $P_S$  existante, les matrices  $W^{res}$  peuvent ainsi tous être considérés comme étant diagonalement stable au sens de Schur.

**4.5 Synthèse et discussion sur les résultats de simulation**

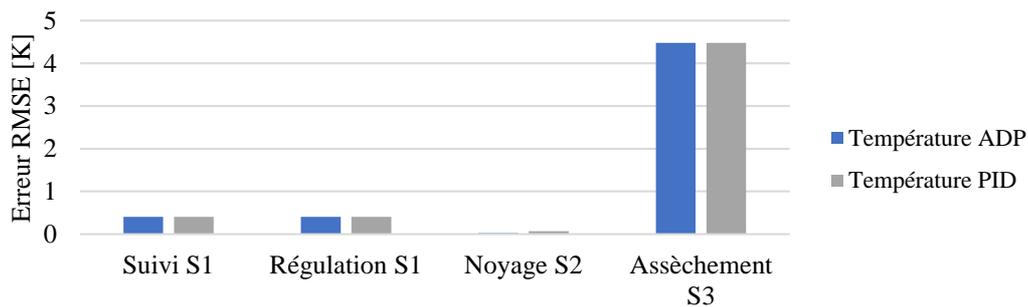
Un ensemble d'histogrammes résumant les performances des contrôleurs est donnée ci-dessous :



**Figure 59** Histogramme résumant les performances de simulation lors du contrôle de la stœchiométrie



**Figure 60** Histogramme résumant les performances de simulation lors du contrôle de la différence de pression à la membrane



**Figure 61** Histogramme résumant les performances de simulation lors du contrôle de la température

Le régulateur ADP développé présente des résultats très satisfaisants, en suivi de consigne et en rejet de perturbation. La comparaison avec le contrôleur de référence PID montre des différences de dynamique propre au contrôleur ADP. On remarque deux caractères propres à la méthode proposée. En effet, le contrôleur ADP implique des erreurs de positions plus faibles que le contrôleur PID, sa capacité d'anticipation permet de réduire fortement les déviations de consigne lors des rejets de perturbations. Cependant au fil des itérations, la réduction progressive des signaux de renforcement nuit au temps de réponse du contrôleur. Pour le contrôleur ADP, les temps d'établissement en régime permanent dépendent fortement de la nature du signal de renforcement. Les tests réalisés ici avec un signal de renforcement résiduel ont montré des performances intéressantes et prometteuses. Nous observons également une possibilité d'améliorer les performances de régulation dès l'apparition de la deuxième perturbation. Pour une mise en œuvre en ligne, où le contrôleur est continuellement actif, cette contrainte peut être négligeable.

L'étude de stabilité et de convergence apporte des réponses sur le fonctionnement et les états internes des modèles ESN. L'analyse par la fonction candidate de Lyapunov montre un contrôle asymptotiquement stable et l'analyse par la matrice diagonale prouve la stabilité des réservoirs de neurones. De plus, le processus de vérification du caractère échoïque du réservoir permet d'écarter, dès la génération des modèles, tout réservoir potentiellement divergeant.

Le cas d'étude qui a été réalisé en simulation présente plusieurs limites. Tout d'abord, le modèle ne peut représenter toutes les caractéristiques et phénoménologies liées à l'apparition

d'un défaut. Les hyperparamètres des modèles ESN et du contrôleur ADP ont été choisis sur la base des analyses effectuées au chapitre précédent. Or, ces analyses ont été conduites dans le cadre d'une application de prévision en tension. Par conséquent, les courbes pour les hyperparamètres ne peuvent être exploitées que pour le modèle de prévision, et non pour les modèles acteur ou critique. La simulation a été réalisée avec une période d'échantillonnage très faible, ce qui n'est pas réalisable en ligne. Même si le contrôleur ADP présente des performances intéressantes par rapport au contrôleur PID, on observe qu'il nécessite 10 à 15 itérations pour la convergence des modèles. Un test en ligne de toute cette méthodologie va nécessiter l'utilisation de la logique floue pour accélérer la convergence des modèles neuronaux.

## Conclusion

La simulation a permis de montrer la pertinence du contrôleur ADP pour le contrôle du système PEMFC. La régulation multi-variable avec rejet de perturbations fonctionne pour les trois 3 cas scénarios : fonctionnement sain, présence du défaut de noyage et présence du défaut d'assèchement. La comparaison avec le contrôleur de référence PID montre des résultats prometteurs pour l'expérimentation. De plus, les analyses de stabilité et de convergence montrent d'un fonctionnement viable des différents modèles ESN.

Cependant, plusieurs limites ont également été mises en lumière. L'apprentissage nécessite plusieurs itérations afin d'éliminer complètement l'erreur de modélisation. Par ailleurs, le contrôleur proposé possède un temps de réponse plus long, malgré une réduction plus efficace des déviations. Afin d'améliorer les résultats, l'intégration de coefficients variables pour le signal de renforcement et les taux d'apprentissages semblent être des pistes intéressantes.

La prochaine étape est l'expérimentation réelle du contrôleur ADP sur un banc d'essai. Le contrôleur proposé sera soumis à des tests en ligne et en temps réel. Le banc d'essai possédant une configuration différente de celle étudiée en simulation, le contrôleur sera ainsi éprouvé sur des variables, des commandes et des dynamiques différentes. L'expérimentation sera aussi un moyen d'analyser l'influence des retards purs des différents capteurs et actionneurs sur le contrôleur ADP.

# Chapitre 5

## LA VALIDATION DU CONTROLEUR ADAPTATIF PAR L'EXPERIMENTATION

### Sommaire

---

<b>5.1</b>	<b>Dispositif expérimental</b> .....	<b>117</b>
5.1.1	Banc d'essai et pile à combustible à disposition.....	117
5.1.2	Communication entre capteurs et actionneurs .....	118
<b>5.2</b>	<b>Scénarios de tests et les mises en conditions de défauts</b> .....	<b>119</b>
5.2.1	Variables de contrôle .....	119
5.2.2	Conditions de fonctionnement en mode sain et en présence de défauts .....	122
<b>5.3</b>	<b>La configuration du contrôleur ADP</b> .....	<b>126</b>
<b>5.4</b>	<b>Résultats d'expérimentations obtenus sur la mono-cellule</b> .....	<b>127</b>
5.4.1	Capacités d'apprentissage et d'adaptation – Scénario S1.1.....	127
5.4.2	Régulation avec rejet de perturbation stœchiométrique sous forme de paliers croissant – Scénario S1.2 .....	129
5.4.3	Régulation avec rejet de perturbation stœchiométrique avec de forts paliers – Scénario S1.3 .....	132
5.4.4	Régulation avec rejet de perturbations stœchiométrique sous forme de paliers rapides – Scénarios S1.4 .....	135
5.4.5	Régulation en présence du défaut de noyage – Scénario S2.....	138
5.4.6	Régulation en présence du défaut d'assèchement de la membrane – Scénario S3 142	
<b>5.5</b>	<b>Analyse des résultats d'expérimentations</b> .....	<b>147</b>

---

## Introduction

La validation expérimentale a pour objectif de confirmer ou non la pertinence de l'approche neuronale adaptative développée pour des problématiques de contrôle tolérant aux défauts. Pour cela, le système sera mis en condition de défaut de noyage et d'assèchement. Le système sera aussi soumis à des perturbations extérieures, il s'agit ici des niveaux de courant et des purges en eau à la cathode.

Le système pile à combustible présent au laboratoire est une monocellule et les auxiliaires disponibles ont une orientation de développement et de recherche. Par conséquent, les variables à contrôler et les variables de commandes seront différentes de celles considérées en simulation.

Ce chapitre débute par une présentation du dispositif expérimental, cette section présente le synoptique du banc d'essai, de la monocellule et des moyens de communication. La deuxième partie est consacrée aux différents scénarios de tests qui sont mis en place pour un fonctionnement sain et un fonctionnement en présence de défauts. La troisième partie est consacrée aux résultats de contrôle. La dernière partie est une synthèse et analyse des résultats.

### 5.1 Dispositif expérimental

#### 5.1.1 Banc d'essai et pile à combustible à disposition

Le banc d'essai regroupant tous les organes auxiliaires nécessaires au fonctionnement de la pile provient de la société *Fuel Cell Technologies* FCT. Il s'agit d'un banc expérimental dédié à des applications de recherches scientifiques.



**Figure 62** Banc d'essai FCT du laboratoire LE2P avec sa monocellule

La pile à combustible est une monocellule de  $50 \text{ cm}^2$ , le système est couplé à une alimentation en hydrogène/oxygène/air/azote. Ces gaz d'entrées proviennent de bouteilles

commerciales. Le contrôle de la charge est réalisé électroniquement et peut atteindre une puissance maximale de 1,8 kW. En pratique, nous nous limitons à une densité de courant de charge de 1 A/cm<sup>2</sup>. Les composants internes au banc d'essais sont présentés sur la Figure 63.

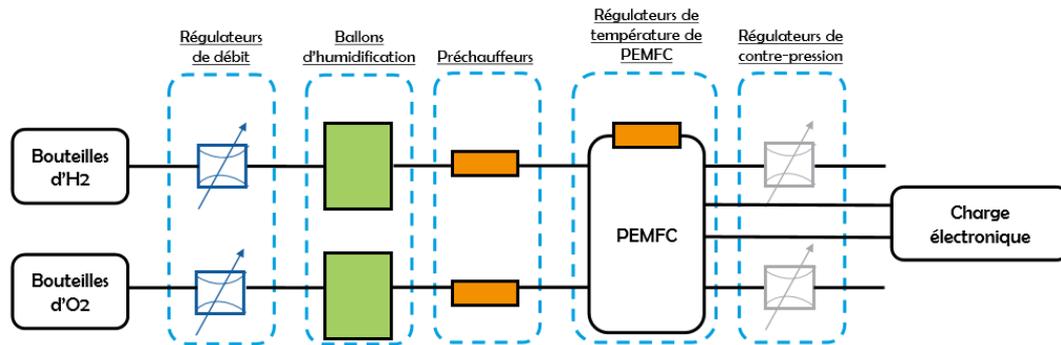


Figure 63 Synoptique du banc d'essai (Dijoux, 2019)

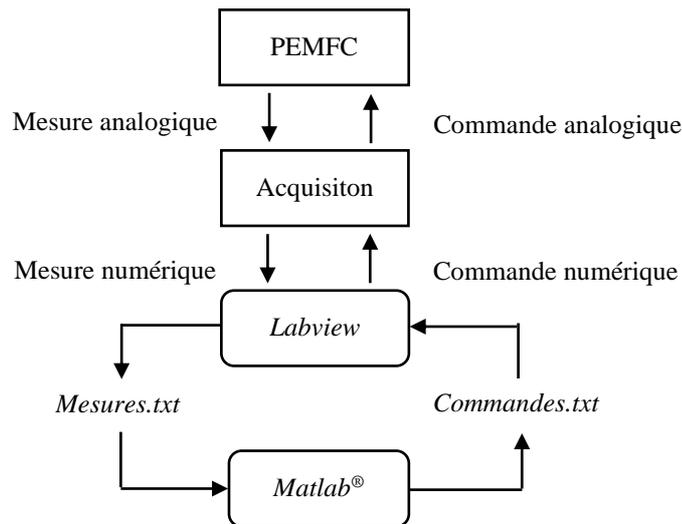
Le contrôle de l'humidité relative est obtenu par la température de point de rosée entre la température des ballons d'humidification et des préchauffeurs. Les débits sont régulés par des contrôleurs de débit massique, et les pressions sont régulées par des régulateurs de contre-pression. L'alimentation en gaz réactif (en amont des MFC) est réglée sur une pression comprise entre 1 et 2 bar. Les composants du banc d'essai sont donnés au Tableau 33.

Tableau 33 Organes majeurs du banc d'essai et du système PEMFC

Type	Modèle constructeur	Spécifications
MEA	1 x Ion Power N117	50 cm <sup>2</sup> - 7,1x7,1 cm – 2 mg/cm <sup>2</sup> PtC (60%)
MFC	2 x MKS Instrument 1179A	Temps de réponse : 2s Précision ± 1%
Régulateur de température	1 x Love Controls Series 16A 1 x Love Controls Series 32DZ	
Régulateur de contre-pression	2 x 20812BP Fairchild	p <sub>max</sub> = 17 bar Précision : 1% à 7 bar
Transducteur électropneumatique	2 x MSP-300100P4N1 2 x TT7800-705	Précision : 1% Répétabilité : 0,1 % de la pression max
Charge électronique	1 x N3300A	

### 5.1.2 Communication entre capteurs et actionneurs

Les interactions homme-machine sont opérées par le biais d'un dispositif d'acquisition de données (*Labjack U12*) et d'un ordinateur. L'interface graphique permettant l'observation et l'opération du banc d'essai est disponible sous *Labview*. Le contrôleur est développé sous *Matlab*<sup>®</sup>, la mise en place du contrôleur (hyperparamètre, lecture des mesures, écriture des commandes, initialisation, consignes, etc) est effectuée par une seconde interface graphique. Les mesures et les commandes sont stockées dans des fichiers texte (.txt) qui regroupent toutes les informations utiles à chaque période d'échantillonnage. Le schéma de communication est donné ci-dessous :



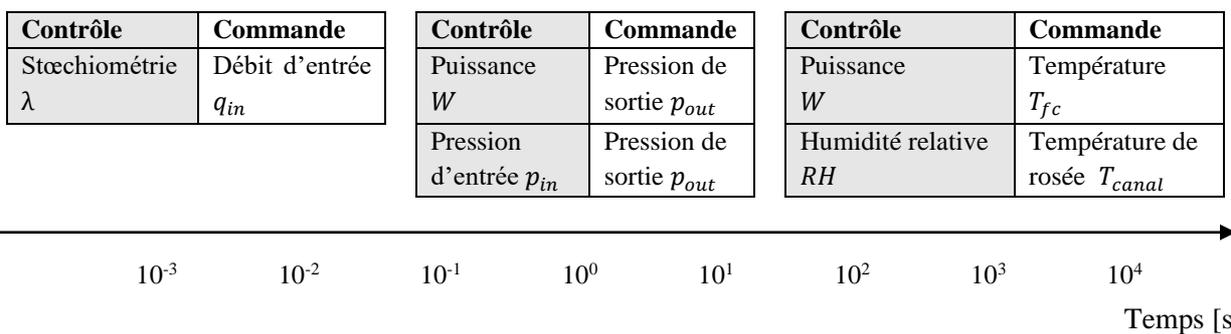
**Figure 64** Schéma de communication du banc d'essai du laboratoire

Dû à des contraintes liées au banc d'essai expérimental, la période d'échantillonnage minimale est de 4 secondes. L'acquisition des mesures et l'envoi de commande à haute fréquence restent possibles par le développement d'outils et de matériels externe au banc d'essai.

## 5.2 Scénarios de tests et les mises en conditions de défauts

### 5.2.1 Variables de contrôle

Au regard des auxiliaires disponibles, plusieurs contrôles peuvent être mis en place, ils sont présentés à la [Figure 65](#) où la variable à contrôler est régulée par la variable de commande spécifique. Cependant, plusieurs contraintes et événements imprévus lors de la phase d'expérimentation nous ont conduits à limiter les contrôles à mettre en œuvre.



**Figure 65** Régulations possibles sur le banc FCT

Les régulations de stœchiométries via le débit ne sont pas possibles. En effet, le temps de réponse du régulateur de débit MFC est inférieur à la période d'échantillonnage, par conséquent, nous ne pouvons pas observer les phases transitoires du débit. Ainsi, nous supposons que la régulation du débit est parfaitement assurée par l'actionneur MFC.

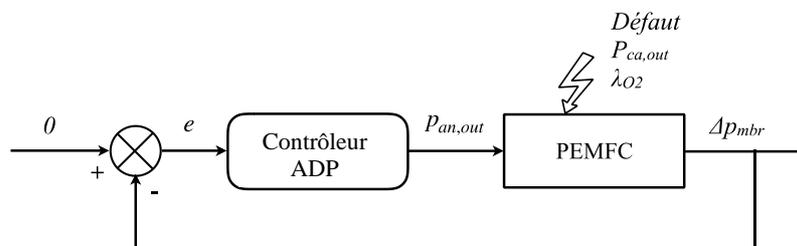
Les régulations en température ne sont pas ici envisageables. Un dysfonctionnement matériel est apparu sur le système de refroidissement de la pile. La température est uniquement régulée par le système de chauffe par cartouche chauffante et n'est plus refroidie par la ventilation. Il est donc difficile de manipuler les baisses de température. Le système de refroidissement étant défectueux la régulation en température présentera des oscillations importantes, ce qui peut affecter nos résultats.

La différence de pression à la membrane est ici difficilement mesurable vu l'absence de capteur de pression à la membrane. Une solution consiste à estimer cette variable par la moyenne des pressions de sortie et d'entrée. Afin d'obtenir des valeurs proches des valeurs réelles, nous considérerons la différence de pression à l'entrée de la membrane, puisqu'elle est directement mesurée par les transducteurs de haute-pressions. De plus, il s'agit de la localisation où le risque de déformation de la membrane est le plus élevé. La photographie, à la [Figure 66](#), est un exemple typique d'un déchirement brutal par une différence de pression supérieure à 1 bar. On peut observer la conduite d'entrée et le début des canaux de distribution sous la MEA.



**Figure 66** Photographie d'une destruction de la MEA à l'entrée de la monocellule

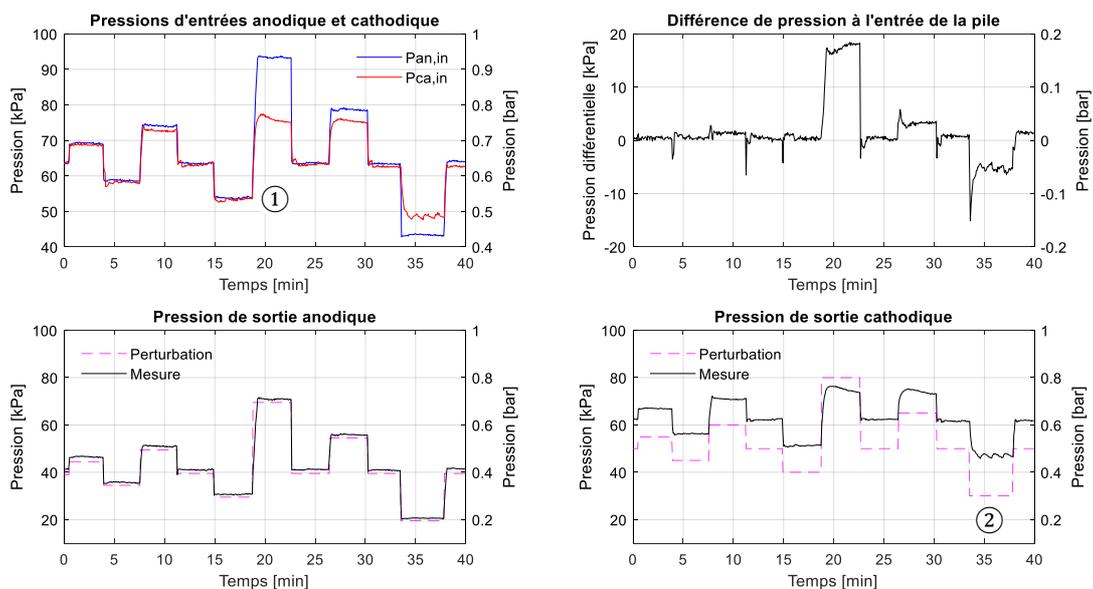
En fonction de ces différentes contraintes, le schéma de contrôle choisi est par conséquent celui présenté ci-dessous, la variable à contrôler est la différence de pression à l'entrée de la pile  $y_1 = \Delta P_{mbr,in}$ . Les variables de commandes et actionneurs pour sa mise en œuvre sont respectivement les pressions de sorties et les régulateurs de contre-pression. Nous choisissons de ne considérer que la pression de sortie anodique comme variable de commande  $u_1 = P_{ca,out}$ , la pression de sortie cathodique recevra une consigne fixe en fonction des besoins d'évacuation en eau.



**Figure 67** Schéma de contrôle pour l'expérimentation

Nous considérerons trois types de perturbations, la stœchiométrie en oxygène, la pression de sortie cathodique et les purges en eau, et deux types de défauts, le défaut de noyage et le défaut d'assèchement de la membrane.

De plus, le contrôleur ADP devra s'accommoder des différentes boucles fermées internes associées aux actionneurs. En effet, les régulateurs de contre-pression (BPR) et les régulateurs de débit massiques intègrent leurs propres contrôleurs PID. Le contrôleur statique du BPR est conçu pour une plage de fonctionnement avec une précision spécifique de  $\pm 1\%$  à  $7 \text{ bar}$ . Le système PEMFC ne fonctionnant pas à cette pression, les précisions des contrôleurs PID statiques internes risquent d'être fortement dégradées. Pour observer ce changement de précision, nous mettons en place un **Scénario S0** sur lequel nous appliquons une perturbation équivalente sur les pressions de sorties. Pour un courant fixe de  $20 \text{ A}$ , nous plaçons le système sur une consigne nulle pour la différence de pression à l'entrée de la pile. Nous appliquons ensuite la perturbation directement sur les BPR. La réponse de la pile au scénario S0 est donnée à la [Figure 68](#).



**Figure 68** Réponse de la pile en présence de perturbation sous forme de créneaux équivalents sur les pressions de sortie anodique et cathodique – Scénario S0

Au démarrage de l'observation, la différence de pression à l'entrée de la pile est nulle. La pression de sortie anodique est réglée sur  $39 \text{ kPa}$  (avec une mesure à  $41,2 \text{ kPa}$ ) et la pression de sortie cathodique est réglée sur  $50 \text{ kPa}$  (avec une mesure à  $62,3 \text{ kPa}$ ). On observe une forte erreur statique induite par le BPR cathodique. A l'inverse, le BPR anodique présente une précision satisfaisante. Au point ①, lorsque la perturbation devient plus importante sur une valeur de  $80 \text{ kPa}$ , la précision du BPR cathodique s'améliore. Cependant, la différence de pression à l'entrée de la pile n'est plus nulle, elle présente alors une différence de pression importante proche de  $20 \text{ kPa}$ .

Sur une faible perturbation au point ②, on observe des fluctuations dans la mesure de la pression de sortie cathodique et une baisse de la précision du BPR. On en déduit que sur une

faible pression à 30 kPa, le BPR induit des oscillations d'une période de 1 min sur la pression de sortie cathodique.

### 5.2.2 Conditions de fonctionnement en mode sain et en présence de défauts

Les paramètres opératoires de l'expérimentation sont détaillés dans le [Tableau 34](#).

**Tableau 34** Condition de fonctionnement en mode sain et en présence de défauts pour l'expérimentation

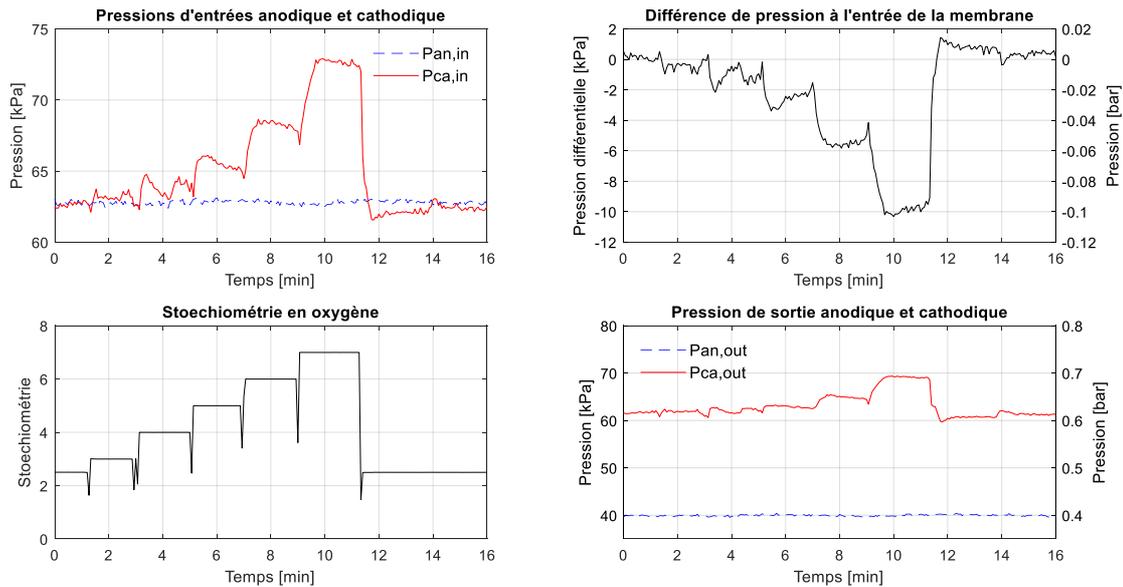
Variables	Normal S1	Noyage S2	Assèchement S3
Courant [A]	20	30	20
Stœchiométrie anodique	2	2.5	2
Stœchiométrie cathodique	2,5 - 10	3	10
Température pile [°C]	70	55	80
Température conduite cathodique [°C]	70	55	80
Température ballon cathodique[°C]	62	70	63
Humidité relative de l'oxygène [%]	70	100 + condensation	50
Consigne pression sortie cathode [kPa]	50	30	50

#### Scénarios S1.1, S1.2, S1.3 et S1.4 : Fonctionnement en mode sain

Quatre tests sont réalisés sur un fonctionnement de la pile en mode sain.

Le test au **Scénario S1.1** a pour but d'observer l'apprentissage et le potentiel d'amélioration du contrôleur face à la répétition d'une perturbation. La perturbation est un palier répétitif de 50 à 55 kPa qui est imposé sur la pression de sortie cathodique. Pour maintenir l'équilibre à l'entrée de la pile, le contrôleur ADP doit alors réguler la pression de sortie anodique en conséquence.

Le test au **Scénario S1.2** est une régulation en présence d'une perturbation sur le débit d'entrée. La pression de sortie cathodique reste fixée à 50 kPa. Pour éviter de réaliser des changements brusques en courant, nous choisissons de modifier la stœchiométrie. La perturbation finale reste la même et engendre une modification du débit d'entrée cathodique et par conséquent de la pression d'entrée cathodique. La perturbation est sous forme de créneaux croissants. La réponse de la pile en présence de perturbations sur la stœchiométrie en oxygène est donnée à la [Figure 69](#).



**Figure 69** Réponse de la pile en présence de perturbation sur la pression d'entrée cathodique sans régulation

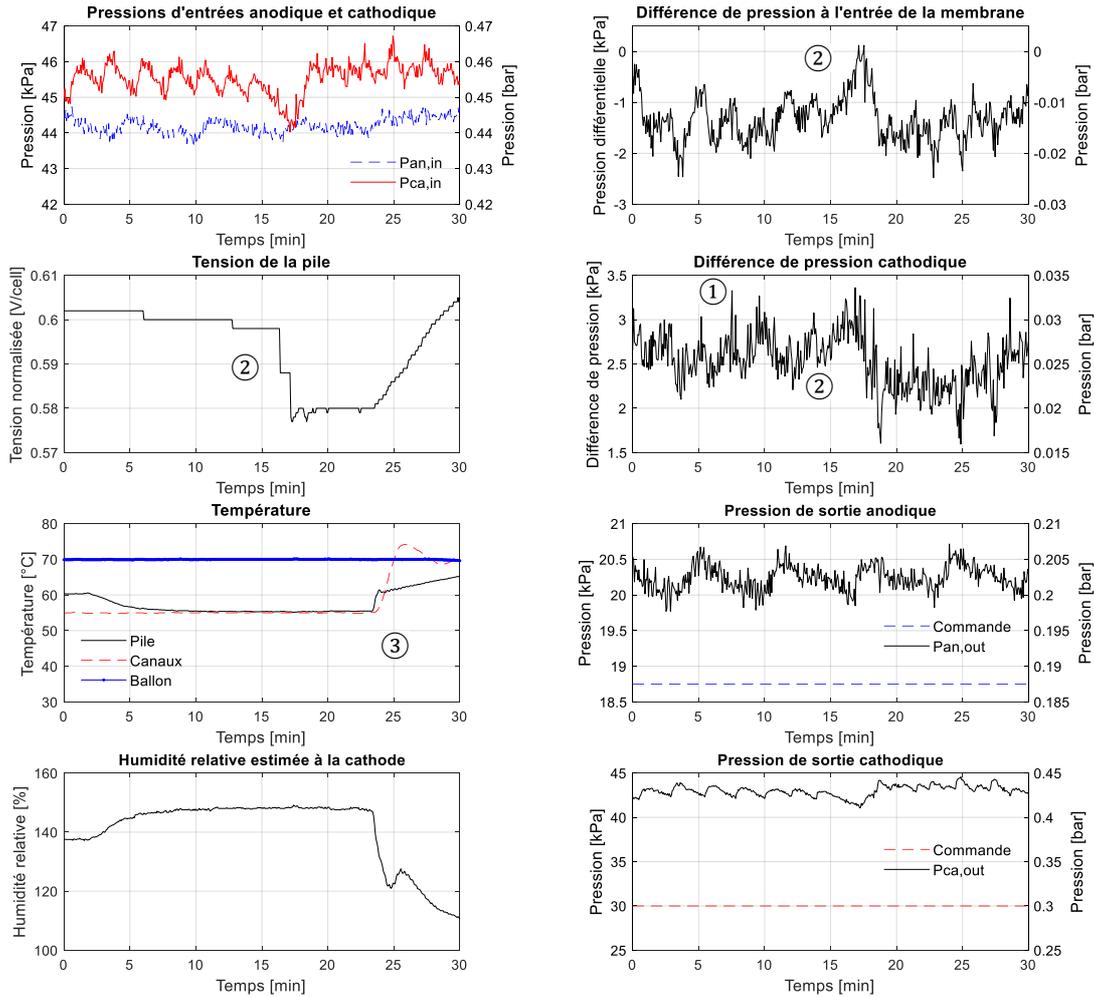
Au début de l'observation, les pressions de sorties sont réglées pour obtenir une différence de pression nulle à l'entrée de la pile. Le changement de stœchiométrie modifie alors cette différence. Les variations de perturbations réalisées engendrent de faibles différences de pression à l'entrée de la pile. Ces variations sont plutôt négligeables dans cette configuration. Pour évaluer notre contrôleur, nous conservons tout de même ce scénario de test. En effet, l'utilisation d'un empilement de cellules à la place d'une monocellule entraînerait des débits plus importants, et par conséquent une perturbation plus importante.

Le test au **Scénario S1.3** est une régulation en présence d'une perturbation en débit d'entrée avec des créneaux de plus fortes amplitudes.

Le test au **Scénario S1.4** est une régulation en présence d'une perturbation en débit d'entrée avec des paliers de perturbation à temps court afin d'observer l'aptitude du contrôleur dans des situations de perturbations transitoires.

### Scénario S2 : Fonctionnement en présence du défaut de noyage

Le défaut de noyage est identifié par une chute de la tension et la présence de motifs triangulaire dans la différence de pression cathodique. Ces motifs traduisent l'accumulation d'eau et son évacuation à la cathode. La réponse de la pile en présence du défaut de noyage est donnée à la [Figure 70](#).



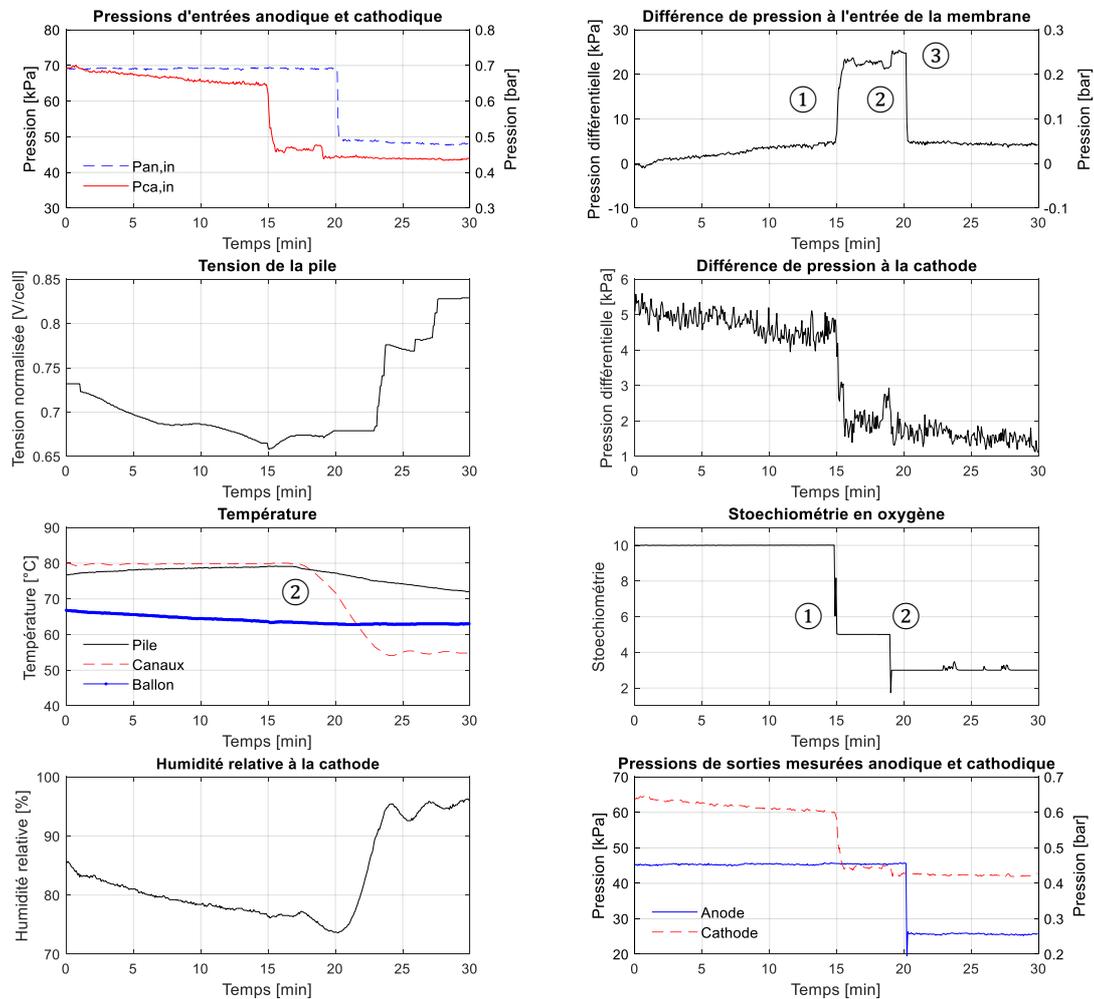
**Figure 70** Réponse de la pile en présence du défaut de noyage sans régulation

Dans les 15 premières minutes, la tension diminue de 0,602 V à 0,577 V soit une perte de 0,025 V. La différence de pression cathodique présente des motifs réguliers ① d'une amplitude de 0,5 kPa. Au début de l'observation, les pressions des sorties sont réglées pour obtenir une différence de pression nulle à l'entrée de la pile. Cependant, la différence de pression à l'entrée de la membrane présente rapidement des variations suite à la présence du défaut. Les fluctuations sont faibles, de l'ordre de 2,5 kPa, mais elles permettront d'évaluer le contrôleur sur des signaux à dynamiques rapides et oscillants. Au point ②, une certaine accumulation d'eau à la cathode permet de retrouver la différence de pression nulle à l'entrée de la pile, mais son évacuation vers les 17 minutes modifie la différence de pression à -2 kPa.

Pour l'atténuation du défaut, une décision simulée est prise sur la température de rosée au point ③ afin de diminuer la condensation en eau à l'entrée de la cathode. La température de la pile et des canaux d'alimentation passe alors de 55 °C à 70 °C. Cette action modifie la dynamique des pressions cathodique, la pression d'entrée cathodique devient plus stable entre 20 à 30 min.

### Scénario S3 : Fonctionnement en présence du défaut d'assèchement de la membrane

Le défaut d'assèchement de la membrane est identifié par la chute de tension. La réponse de la pile en présence du défaut d'assèchement de la membrane est donnée à la [Figure 71](#).



**Figure 71** Réponse de la pile en présence du défaut d'assèchement de la membrane sans régulation

Dans les 15 premières minutes, la tension diminue de 0,732 V à 0,665 V soit une perte de 0,067 V. Au début de l'observation, les pressions de sorties sont réglées pour obtenir une différence de pression nulle à l'entrée de la pile. Le défaut d'assèchement de la membrane provoque une différence de pression croissante. La régulation devra donc compenser cette perturbation.

Une première correction simulée est prise à 15 min d'essai, la stoechiométrie en oxygène passe de 10 à 5 au point ① pour atténuer la perte en eau de la cathode. La tension se stabilise alors à 0,673 V. Ce changement de stoechiométrie provoque inévitablement une différence de pression à la membrane plus importante que pendant l'apparition du défaut.

Une deuxième correction intervient à 18 min. Elle se compose d'une diminution de la stœchiométrie d'une valeur de 5 à 3 et d'une modification de la température de rosée. Le refroidissement défectueux et pour limiter le travail élastique de la membrane qui atteint presque les 0,3 bar au point ③, nous diminuons volontairement la pression de sortie anodique.

### 5.3 La configuration du contrôleur ADP

Le contrôleur ADP est maintenant configuré en mono-entrée et mono-sortie. Les entrées et les sorties sont données au [Tableau 35](#). La fonction de renforcement est un critère de nature quadratique qui présente ici une stabilité accrue par rapport à un critère de nature résiduel. Les entrées et sorties sont normalisées entre 0 et 1 par un coefficient en fonction de la grandeur de la variable. En condition réelle, les perturbations étant inconnues elles ne sont pas intégrées dans le modèle prévisionneur. Le critère d'erreur RMSE est utilisé pour mesurer la précision de modélisation des modèles ESN et le coefficient de détermination R2 est utilisé pour quantifier la qualité d'estimation des modèles ESN.

La période d'échantillonnage relativement importante nous autorise à réaliser un apprentissage par cycle. Entre chaque période d'échantillonnage, le processus d'apprentissage effectue 3 cycles d'apprentissage ce qui contribue à diminuer les erreurs de modélisation. De plus, la méthode de logique floue est implémentée en expérimentation pour réguler le processus d'apprentissage. La période d'échantillonnage est relativement importante. L'intérêt de la logique floue est d'ajuster correctement les gains d'apprentissage et de diminuer les temps nécessaires pour les apprentissages.

**Tableau 35** Entrées et sorties des modèles ESN en expérimentation

	ESN Acteur	ESN Acteur 1	ESN Prévisionneur	ESN Critique	ESN Critique 1
<b>Entrées</b>	1	1	1	1	1
	$\Delta P_m(k)$	$\Delta \hat{P}_m(k+1) + e_{prev}(k)$	$\Delta P_m(k)$ $\hat{P}_{an,out}(k)$	$\Delta P_m(k)$ $\hat{P}_{an,out}(k)$	$\Delta \hat{P}_m(k+1) + e_{prev}(k)$ $\hat{P}_{an,out}(k+1)$
<b>Sorties</b>	$\Delta \hat{P}_{an,out}(k)$	$\Delta \hat{P}_{an,out}(k+1)$	$\Delta \hat{P}_m(k+1)$	$J_{\Delta P_m}(k)$	$J_{\Delta P_m}(k+1)$

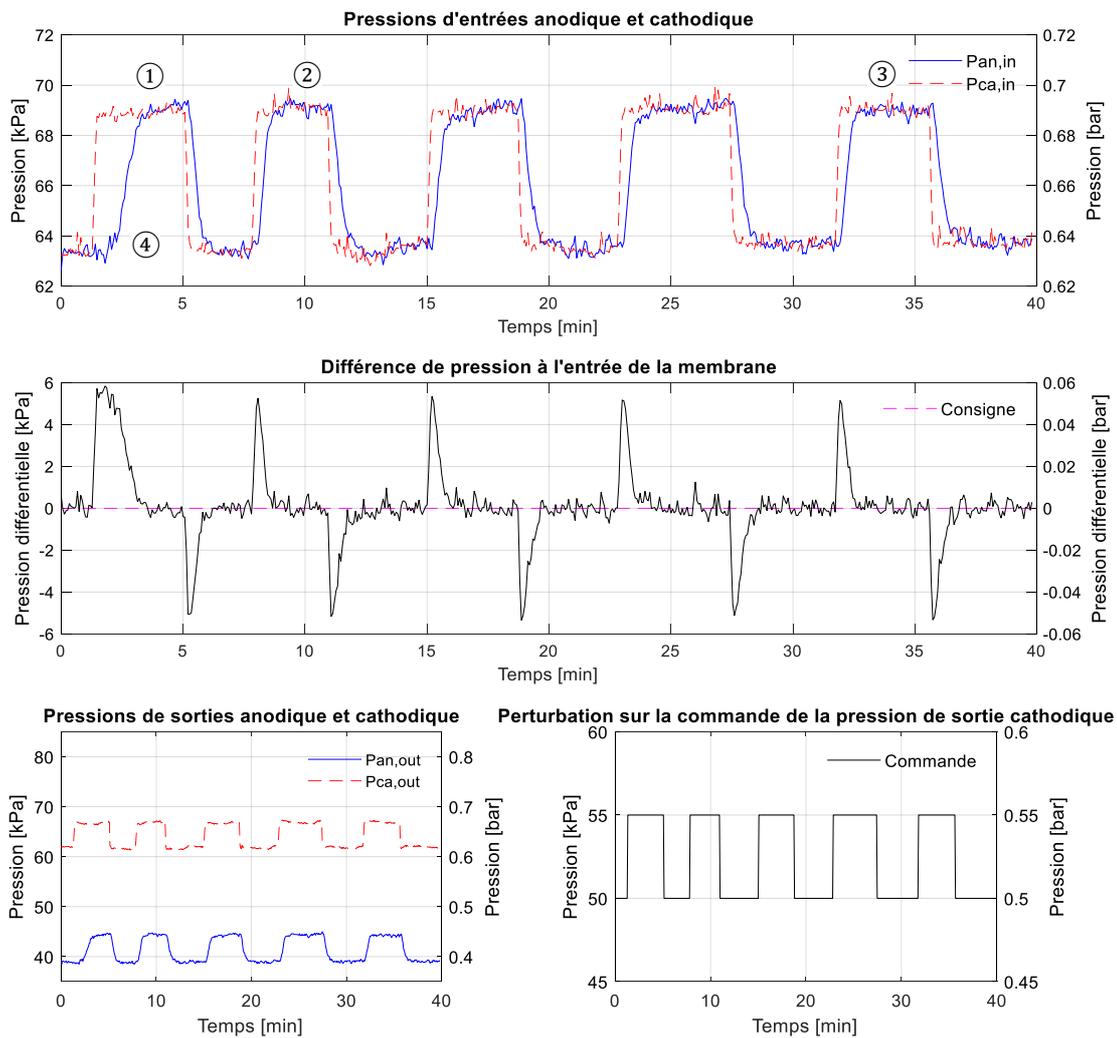
Les entrées et la sortie du module de renforcement sont les suivants :

Renforcement U(k)	
<b>Entrées</b>	$Cons_{\Delta P_m}(k)$ $\Delta P_m(k)$
<b>Sorties</b>	$U_{\Delta P_m}(k)$

## 5.4 Résultats d'expérimentations obtenus sur la monocellule

### 5.4.1 Capacités d'apprentissage et d'adaptation – Scénario S1.1

Nous avons remarqué en simulation que la première convergence à la consigne ne reflète pas les capacités réelles du contrôleur. En effet, la première convergence apparaît après l'initialisation des modèles ESN. Nous proposons dans cette partie d'évaluer les capacités d'apprentissage et d'adaptation du contrôleur face à un événement récurrent. Les résultats de la régulation en présence d'une perturbation récurrente sont présentés sur la [Figure 72](#).



**Figure 72** Réponse du système PEMFC en présence d'une perturbation récurrente – Scénario S1.1

### Observations de la régulation en présence d'une perturbation récurrente – Scénario S1.1

- Les erreurs obtenues sont les suivants :

	$RMSE_{\Delta P_{membrane}}$	$R2_{\Delta P_{membrane}}$
ADP	1,6698 kPa	0,62

- La perturbation qui agit sur la commande en pression de sortie cathodique de 50 à 55 kPa se traduit par une pression mesurée de 61 à 67 kPa. Il s'agit ici de l'erreur statique du BPR.
- Les amplitudes de déviations sont les suivantes :

Palier	①		②		③	
Perturbation	↑	↓	↑	↓	↑	↓
Amplitude [kPa]	5,8	-5,1	5,2	-5,1	5,1	-5,1

- Les temps de convergence à la consigne sont les suivants :

Palier	①		②		③	
Perturbation	↑	↓	↑	↓	↑	↓
Durée [itération]	19 – 49	76 – 93	117 – 130	164 – 177	476 – 489	534 – 547
Temps [s]	120	68	52	52	52	52

- Aucun dépassement de consigne ou d'oscillations n'est observé.

### Analyse de la régulation en présence d'une perturbation récurrente – Scénario S1.1

Une erreur de position est présente pour le suivi de consigne de l'actionneur de contre-pression. Cela s'explique par son utilisation en faible pression, qui par conséquent sort de sa plage de fonctionnement nominale (précision : 1 % à 7 bar). Le contrôleur s'est adapté à cette particularité et assure correctement le suivi de consigne.

Sur la première perturbation au point ①, 30 itérations sont nécessaires pour atteindre la valeur de consigne. Cette valeur est très importante et n'est pas du tout envisageable pour une application telle que la stœchiométrie. La faible valeur du coefficient ADP d'atténuation (0,3) n'est pas suffisamment importante pour la correction immédiate de la commande. La pression d'entrée anodique ne change qu'à partir de 15 itérations au point ④. Augmenter le coefficient d'atténuation permettrait d'accélérer la réponse du contrôleur. La déviation correspondante à la première perturbation est mesurée à 5,8 kPa.

Sur le deuxième palier de perturbation ② et jusqu'à la dernière perturbation ③, les temps pour atteindre la valeur de consigne sont réduits de moitié, soit 57 %. Les déviations sont quant à elles diminuées de 0,7 kPa, soit une baisse de 13 %. On observe que le temps pour atteindre la consigne lors de la première descente et déjà nettement inférieur à celui nécessaire pour atteindre la consigne lors de la première montée.

En conclusion, le contrôleur est capable d'obtenir de meilleurs résultats à partir de la deuxième occurrence d'un évènement. Cependant, la réponse du contrôleur n'est pas réactive

dès la première apparition d'une perturbation. Pour y remédier, une gestion adaptée des paramètres ADP (coefficients d'atténuation et d'actualisation) peut être une piste à explorer.

### 5.4.2 Régulation avec rejet de perturbation stœchiométrique sous forme de paliers croissant – Scénario S1.2

La réponse du système PEMFC en présence de perturbation stœchiométrique sous forme de paliers croissants et décroissants, est donnée à la Figure 73.

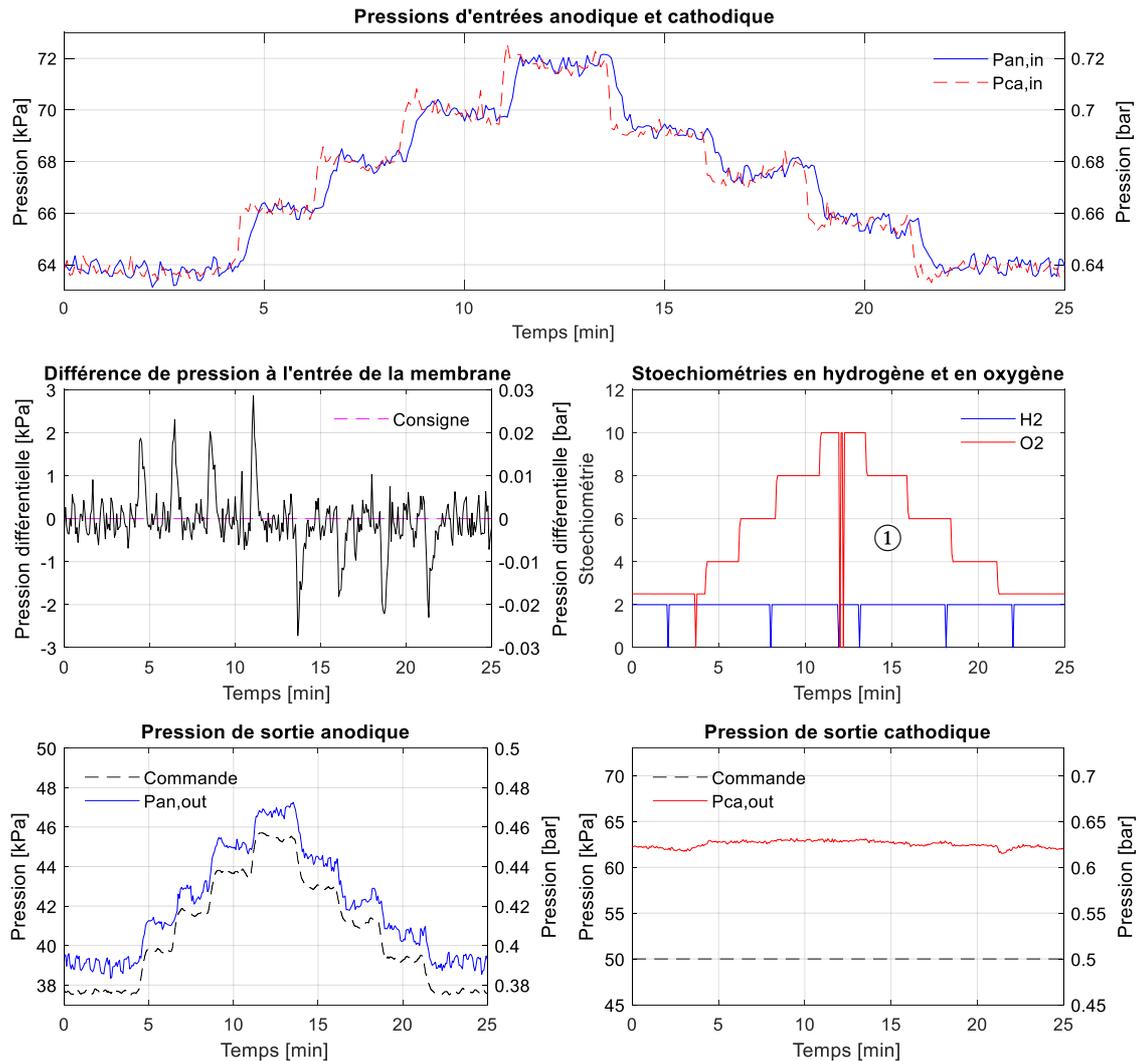


Figure 73 Réponse du système en présence d'une perturbation croissante – Scénario S1.2

#### Observations de la régulation en présence de perturbation croissante – Scénario S1.2

- Les critères d'erreurs sont les suivants :

	$RMSE_{\Delta P_{membrane}}$	$R2_{\Delta P_{membrane}}$
ADP	0,6730 kPa	0,93

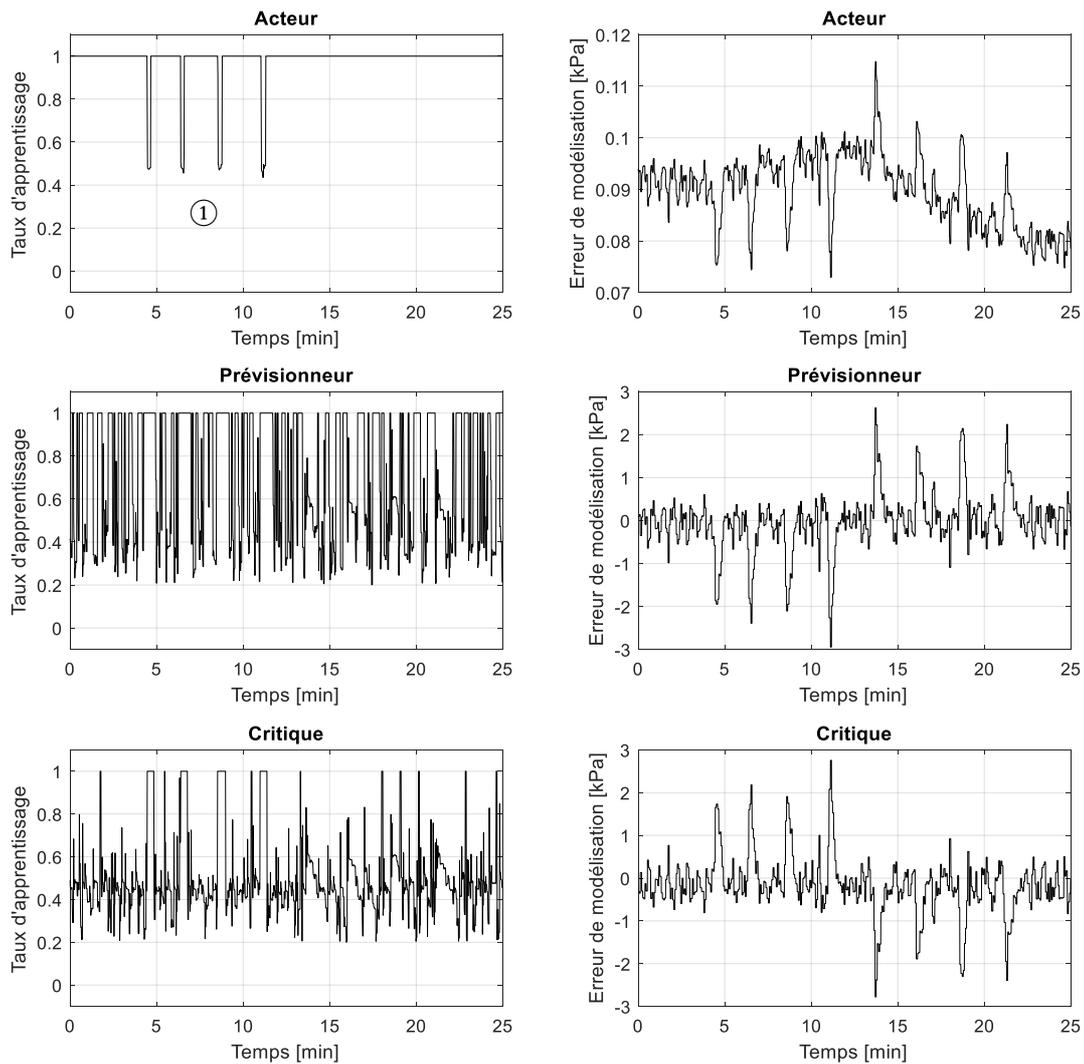
- Les actionneurs de contre-pression présentent également une erreur statique, due au fonctionnement en faible pression.
- La déviation maximale à lieu au passage de la perturbation stœchiométrique entre 8 et 10, elle est mesurée à une amplitude de 3 kPa.
- Les temps de convergence sont tous équivalents et sont mesurés à 9 itérations, soit 36 secondes.
- Sur l'ensemble des paliers de perturbations, la correction n'est effective qu'à partir de la 4<sup>e</sup> itération.
- ① Le fichier d'acquisition présente quelques erreurs de mesures, d'où les stœchiométries nulles.
- Aucun dépassement de consigne ou d'oscillation n'est observé.

### **Analyses de la régulation en présence de perturbation stœchiométrique sous forme de paliers croissants – Scénario S1.2**

La régulation est ici satisfaisante, dans la mesure où les perturbations sont de faibles amplitudes. Cependant, dans une possible application avec un empilement de cellules, les hyperparamètres du contrôleur ADP devront être optimisés davantage pour accélérer le suivi de consigne.

### **Observations des modèles ESN en présence de perturbation stœchiométrique sous forme de paliers croissants – Scénario S1.2**

Les taux d'apprentissage obtenus par la méthode de logique floue et les erreurs résiduelles de modélisation des trois modèles ESN sont donnés à la [Figure 74](#).



**Figure 74** Taux d'apprentissage calculés et erreurs de modélisation des modèles ESN en présence de perturbation stœchiométrique sous forme de paliers croissants – Scénario S1.2

- Les erreurs de modélisation obtenues pour le modèle acteur sont les suivants :

	$RMSE_{acteur}$	$R2_{acteur}$
ADP	0,0901 kPa	0,95

- La moyenne du taux d'apprentissage du modèle acteur est de 0,98.
- Les erreurs de modélisation obtenues pour le modèle prévisionneur sont les suivants :

	$RMSE_{prévisionneur}$	$R2_{prévisionneur}$
ADP	0,7066 kPa	0,82

- La moyenne du taux d'apprentissage du modèle prévisionneur est de 0,69.
- Les erreurs de modélisation obtenues pour le modèle critique sont les suivants :

	$RMSE_{critique}$	$R2_{critique}$
ADP	0,7566 kPa	0,87

- La moyenne du taux d'apprentissage du modèle critique est de 0,48.

### **Analyses des modèles ESN en présence de perturbation stœchiométrique sous forme de paliers croissants – Scénario S1.2**

L'erreur de modélisation du modèle acteur reste persistante tout au long du test et le taux d'apprentissage reste fixé à la valeur unitaire. On observe 4 instants au point ① où le taux d'apprentissage diminue pour atteindre la valeur de 0,5. A ces mêmes instants, l'erreur de modélisation du modèle acteur est la plus faible. L'erreur du modèle acteur est constamment non nulle et indique une correction constante de la commande. On observe tout de même une tendance croissante lors des paliers montants, et une tendance décroissante lors des paliers descendants.

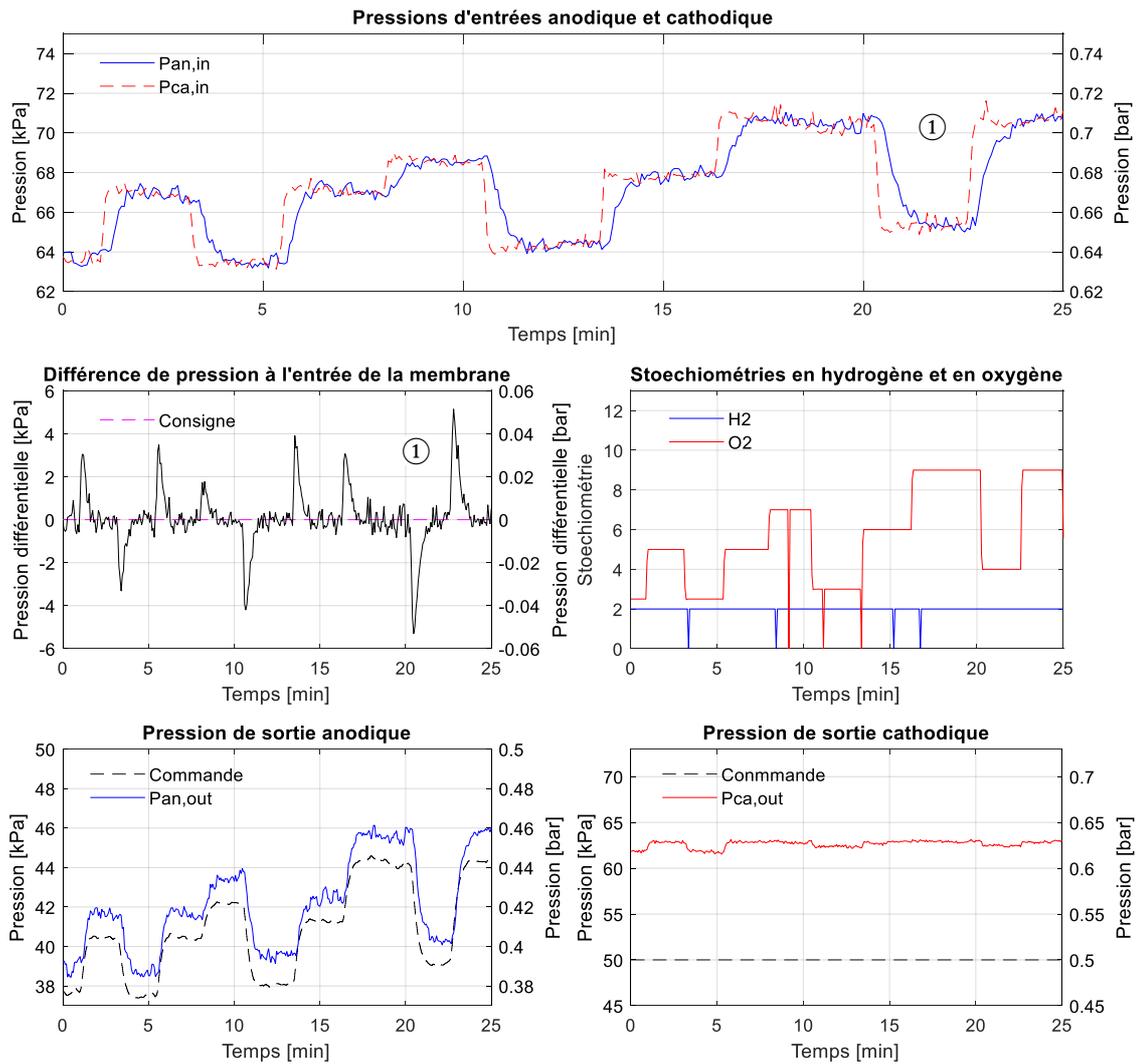
Le modèle prévisionneur est caractérisé par une erreur de modélisation convergente vers 0. Les taux d'apprentissage restent tout de même importants. Les fluctuations autour de la consigne provoquent des changements fréquents du taux d'apprentissage.

Le modèle critique converge également vers 0 et ses variations de taux d'apprentissage restent faibles.

Les processus d'apprentissage fonctionnent correctement et ne présentent pas de divergence. L'application en expérimentation expose l'algorithme de logique floue à des fluctuations et oscillations importantes autour de la consigne. Le taux d'apprentissage fluctue ainsi en conséquence.

### **5.4.3 Régulation avec rejet de perturbation stœchiométrique avec de forts paliers – Scénario S1.3**

La réponse du système en présence de perturbations stœchiométriques importantes est présentée à la [Figure 75](#).



**Figure 75** Réponse du système PEMFC en présence de perturbations stœchiométriques sous forme de paliers importants – Scénario S1.3

### Observations de la régulation en présence de perturbations stœchiométriques sous forme de paliers importants – Scénario S1.3

- Les erreurs obtenues sont les suivantes :

	$RMSE_{\Delta P_{membrane}}$	$R2_{\Delta P_{membrane}}$
ADP	1,2574 kPa	0,74

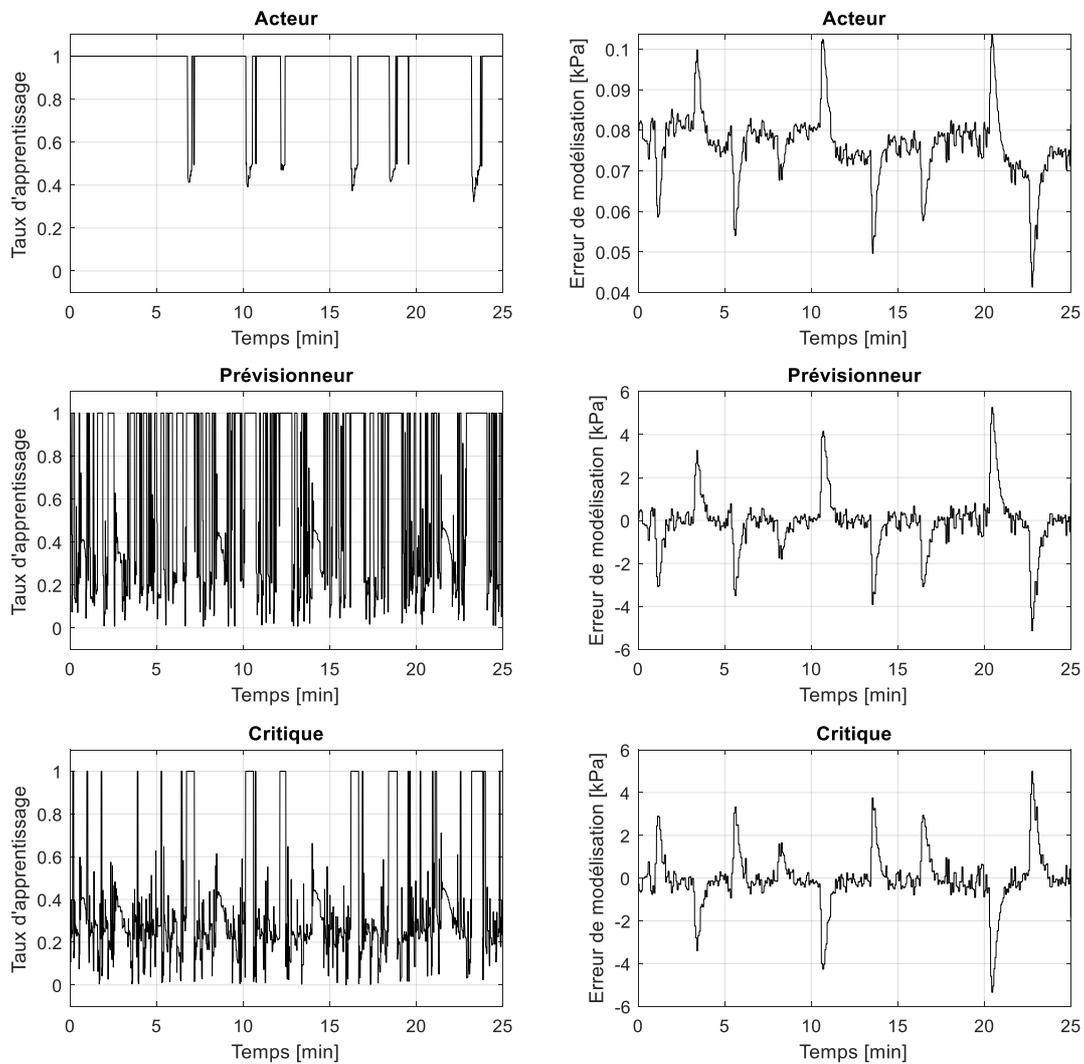
- La déviation maximale ① est enregistrée à 5 kPa pour une variation de stœchiométrie d'une valeur de 4 à 9. Le temps de convergence correspondant est mesuré à 17 itérations, soit 68 secondes.
- Aucun dépassement de consigne ou d'oscillations n'est observé.

### Analyses de la régulation en présence de perturbations stœchiométriques sous forme de paliers importants – Scénario S1.3

Sur des paliers de plus fortes amplitudes, le critère R2 nous indique une moins bonne performance de contrôle comparé au test précédent. Le contrôleur étant conçu par réaction itérative, chaque déviation est caractérisée par l'amplitude de la perturbation. Une perturbation de 7 kPa ①, provoquera à chaque apparition une déviation de même amplitude. Par conséquent, les déviations sont difficilement atténuables sans connaissance de la perturbation future.

### Observations des modèles ESN en présence de perturbations stœchiométriques sous forme de paliers importants – Scénario S1.3

Les taux d'apprentissage obtenus par logique floue et les erreurs résiduelles de modélisation des trois modèles ESN sont donnés à la [Figure 76](#).



**Figure 76** Taux d'apprentissage calculés et erreurs de modélisation des modèles ESN en présence de perturbations stœchiométriques sous forme de paliers importants – Scénario S1.3

- Les erreurs obtenues pour le modèle acteur sont les suivants :

	$RMSE_{acteur}$	$R2_{acteur}$
ADP	0,0765 kPa	0,99

- La moyenne du taux d'apprentissage d'acteur est de 94.
- Les erreurs obtenues pour le modèle prévisionneur sont les suivants :

	$RMSE_{prévisionneur}$	$R2_{prévisionneur}$
ADP	1,2782 kPa	0,73

- La moyenne du taux d'apprentissage du prévisionneur est de 0,61.
- Les erreurs obtenues pour le modèle critique sont les suivants :

	$RMSE_{critique}$	$R2_{critique}$
ADP	1,2611 kPa	0,77

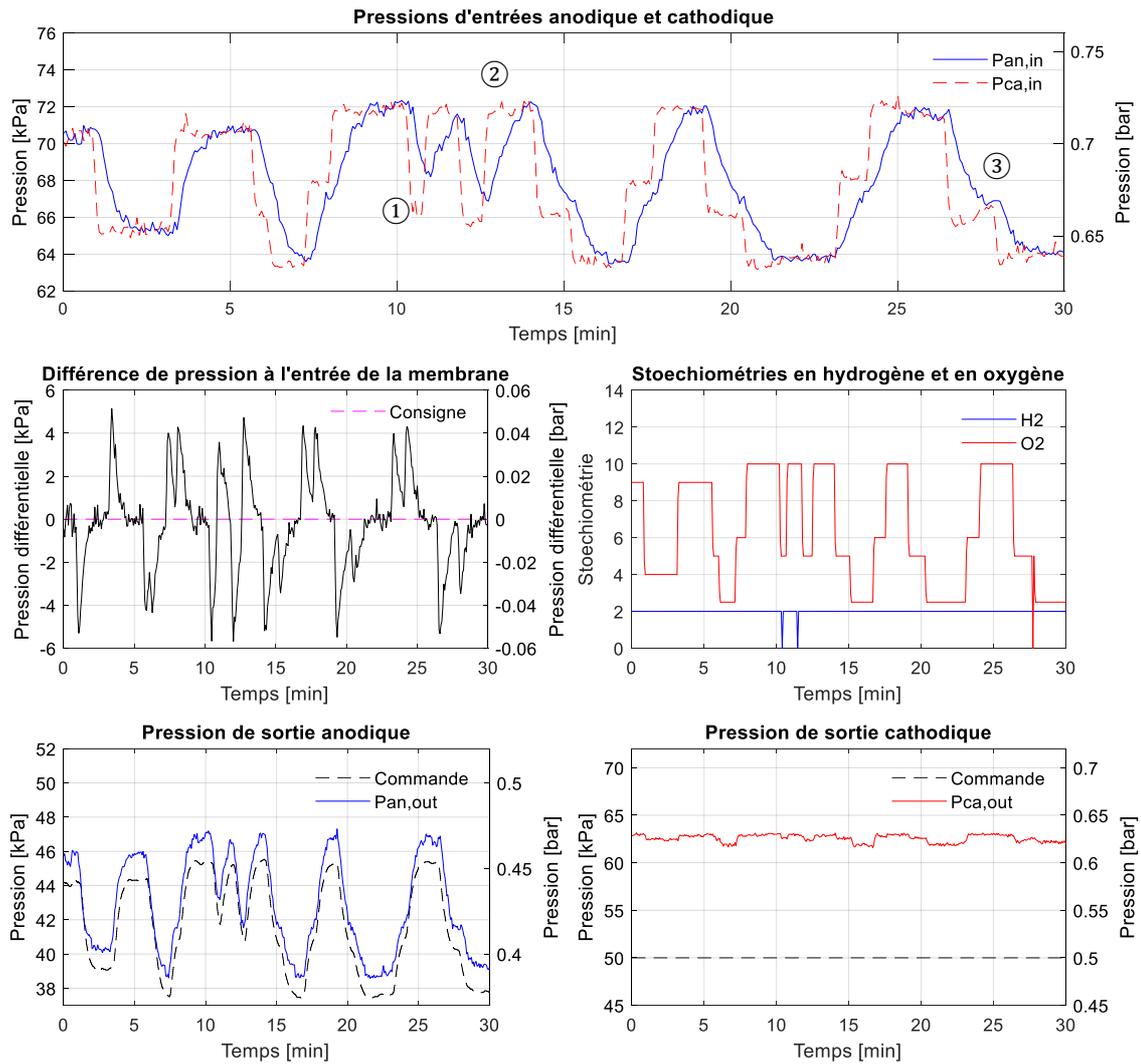
- La moyenne du taux d'apprentissage du critique est de 0,35.

### **Analyses des modèles ESN en présence de perturbations stœchiométriques sous forme de paliers importants – Scénario S1.3**

La performance des modèles prévisionneur et critique sont relativement égaux. Les modèles prévisionneur et critères sont moins performants dans ce scénario. Ce phénomène s'explique par des perturbations stœchiométriques plus importantes, et par conséquent d'un apprentissage plus complexe des modèles.

#### **5.4.4 Régulation avec rejet de perturbations stœchiométrique sous forme de paliers rapides – Scénarios S1.4**

Les résultats obtenus de la régulation en présence de perturbations stœchiométriques sous forme de paliers rapides sont donnés à la [Figure 77](#). L'objectif étant de modifier la stœchiométrie alors que la régulation est encore dans une période transitoire, afin de noter la capacité du contrôleur à contre-réagir.



**Figure 77** Réponse de la pile en présence de perturbation stœchiométrique sous forme de paliers rapides – Scénario S1.4

### Observations de la régulation en présence de perturbation stœchiométrique sous forme de paliers rapides – Scénario S1.4

- Les critères d'erreurs sont les suivants :

	$RMSE_{\Delta P_{membrane}}$	$R2_{\Delta P_{membrane}}$
ADP	2,1487 kPa	0,56

- La double montée rapide de stœchiométrie de 2,5 à 10 au point ① ne permet pas un suivi de consigne en différence de pression.
- ② Aucune divergence du contrôleur n'est observée.
- ③ Dès que le contrôleur atteint sa consigne, la correction est automatiquement stabilisée.

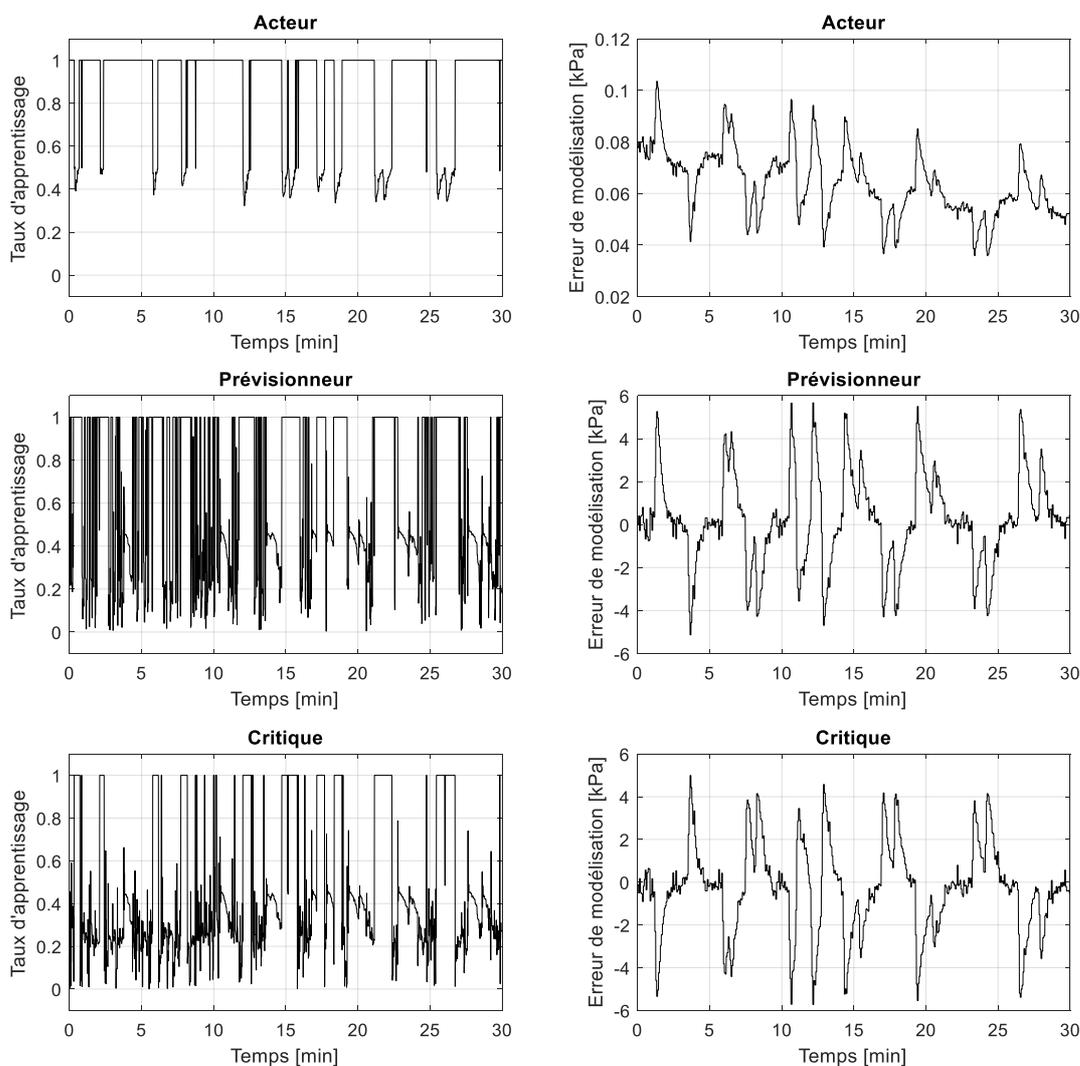
- Aucun dépassement de consigne ou d'oscillations n'est observé

### Analyses de la régulation en présence de perturbation stœchiométrique sous forme de paliers rapides – Scénario S1.4

Les temps nécessaires pour atteindre les consignes et les déviations restent ici aussi très importants. Malgré tout, le contrôleur soumis à des perturbations en période transitoire reste stable et ne présente aucune divergence ou dépassement.

### Observation des modèles ESN en présence de perturbation stœchiométrique sous forme de paliers rapides – Scénario S1.4

Les taux d'apprentissage obtenus par logique floue et les erreurs résiduelles de modélisation des trois modèles ESN sont donnés à la [Figure 78](#).



**Figure 78** Taux d'apprentissage calculés et erreurs de modélisation des modèles ESN en présence de perturbations stœchiométriques sous forme de paliers rapides – Scénario S1.4

- Les erreurs obtenues pour le modèle acteur sont les suivants :

	$RMSE_{acteur}$	$R2_{acteur}$
ADP	0,0651 kPa	0,97

- La moyenne du taux d'apprentissage d'acteur est de 0,87.
- Les erreurs obtenues pour le modèle prévisionneur sont les suivants :

	$RMSE_{prévisionneur}$	$R2_{prévisionneur}$
ADP	2,1218 kPa	0,72

- La moyenne du taux d'apprentissage du prévisionneur est de 0,64.
- Les erreurs obtenues pour le modèle critique sont les suivants :

	$RMSE_{critique}$	$R2_{critique}$
ADP	2,1692 kPa	0,79

- La moyenne du taux d'apprentissage du critique est de 0,46.

### **Analyses des modèles ESN en présence de perturbation stœchiométrique sous forme de paliers rapides – Scénario S1.4**

Les apprentissages de critique et du prévisionneur présentent des erreurs de modélisation plus importantes sous des perturbations en transitoire. Le taux d'apprentissage estimé par la logique floue est plus important avec une moyenne de 0,64 pour le modèle prévisionneur et de 0,46 pour le modèle critique. Le modèle acteur présente quant à lui plusieurs paliers à 0,5 qui coïncident aux instants où la consigne est correctement respectée.

#### **5.4.5 Régulation en présence du défaut de noyage – Scénario S2**

Les conditions opératoires du banc d'essai sont réglées pour l'apparition du défaut de noyage. Le contrôleur est ensuite considéré dès l'identification du défaut. Les résultats du contrôle lors de l'apparition du défaut de noyage sont présentés dans la [Figure 79](#).

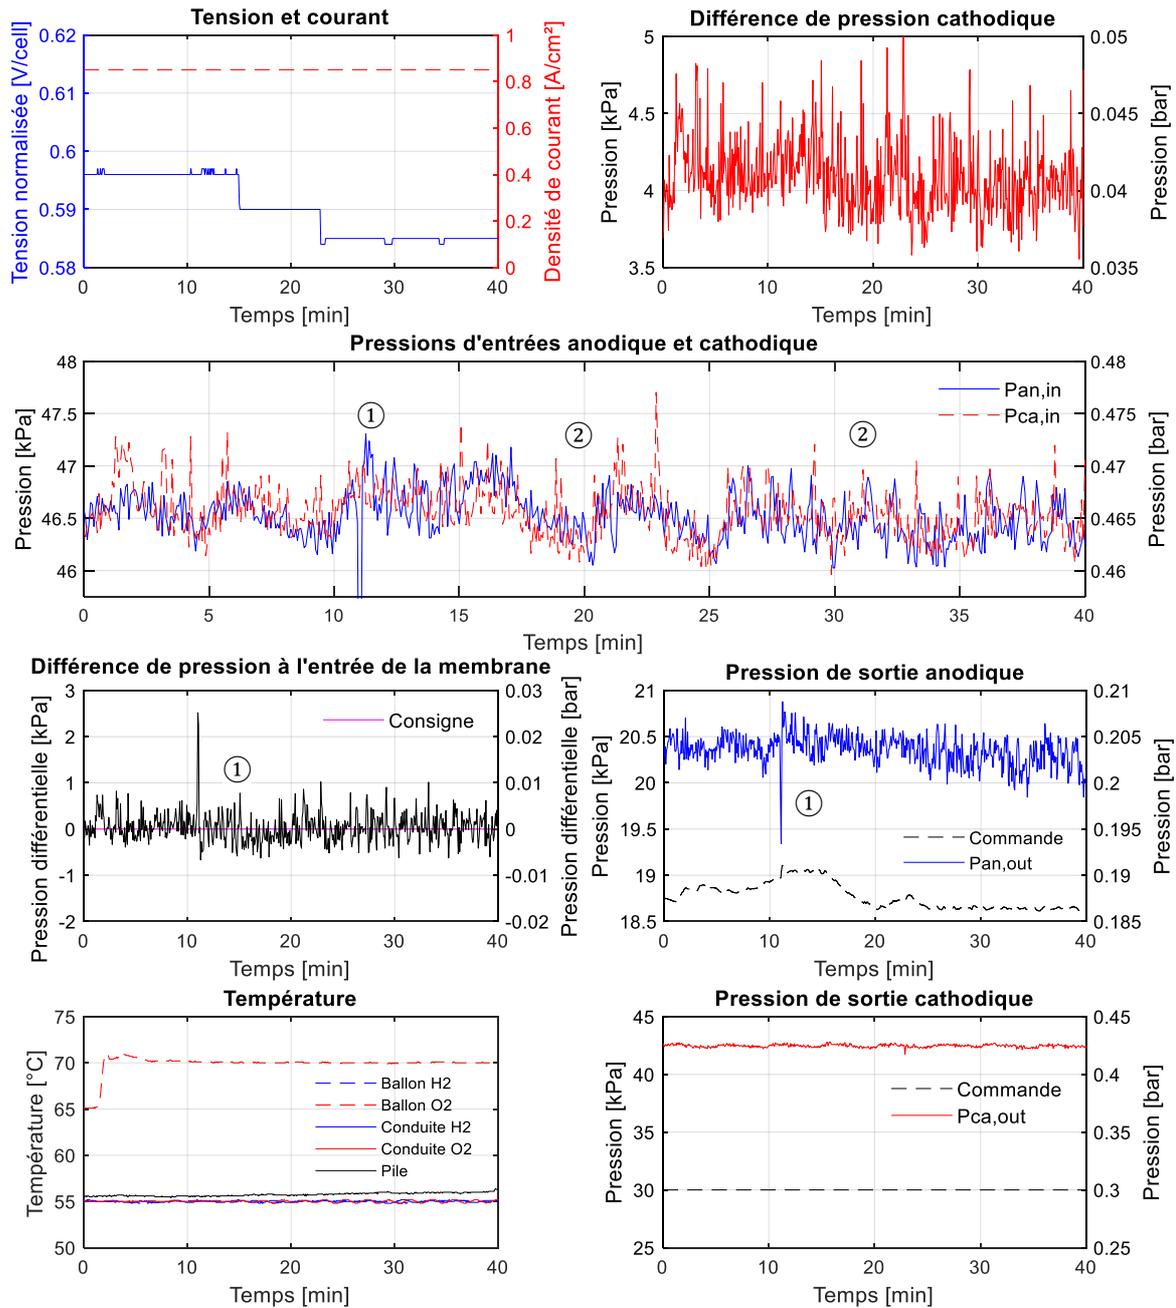


Figure 79 Réponse de la pile en présence du défaut de noyage – Scénario S2

### Observations de la régulation en présence du défaut de noyage – Scénario S2

- Les erreurs obtenues sont les suivantes :

	$RMSE_{\Delta P_{membrane}}$	$R2_{\Delta P_{membrane}}$
ADP	0,3316 kPa	0,7514

- La tension chute de 0,596 V à 0,585 V, soit une variation de 0,011 V. La différence de pression cathodique présente plusieurs sauts croissants et décroissants, résultant des évacuations d'eau au sein des canaux de distribution.
- ① L'actionneur de contre-pression s'ouvre pour évacuer l'excès d'eau des canaux de distribution à l'anode. À la suite de cet évènement, la régulation présente des fluctuations notables.
- ② La suite du contrôle présente également des fluctuations dans la régulation.
  
- Aucun dépassement de consigne ou d'oscillations n'est observé

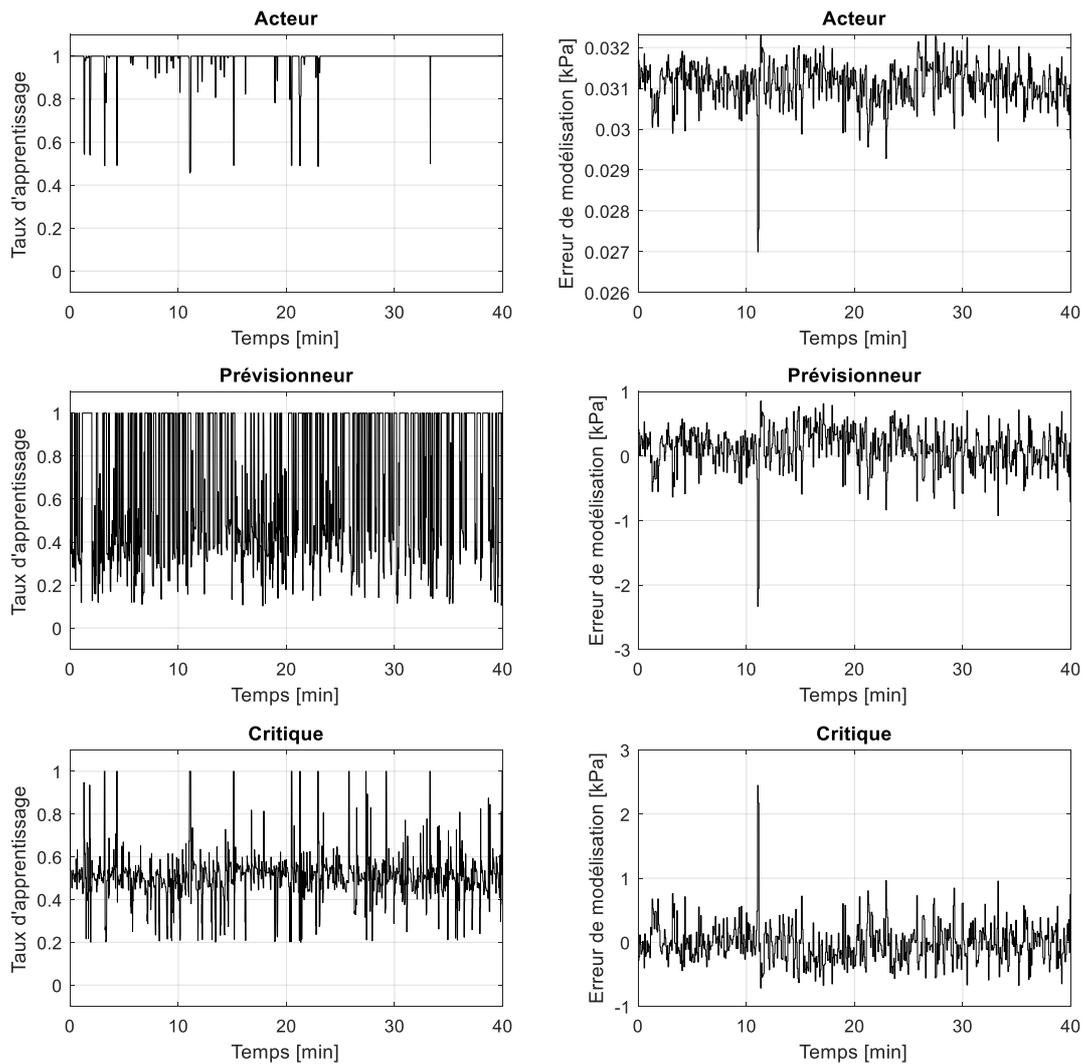
### **Analyses de la régulation en présence du défaut de noyage – Scénario S2**

Le suivi de consigne induit par le contrôleur proposé est satisfaisant malgré l'apparition du défaut. Les fluctuations présentes dans la régulation sont des conséquences directes de l'évacuation en eau à la cathode. Ces perturbations sont parfaitement prises en compte par le contrôleur qui assure un équilibre nul à l'entrée de la pile.

Lors de l'ouverture de la conduite par l'actionneur au point ① la régulation s'est mise à présenter des erreurs plus importantes. La commande reste fixe à cet instant, l'ouverture partielle de la conduite ne vient pas perturber le contrôleur ADP, la commande reste stable au cours du temps.

### **Observations des modèles ESN en présence du défaut de noyage – Scénario S2**

Les taux d'apprentissage obtenus par logique floue et les erreurs résiduelles de modélisation des trois modèles ESN sont donnés à la [Figure 80](#).



**Figure 80** Logique floue et apprentissage des modèles sous l'apparition du défaut de noyage S2

- Les erreurs de modélisation obtenues pour le modèle acteur sont les suivants :

	$RMSE_{acteur}$	$R2_{acteur}$
ADP	0,0311 kPa	0,99

- La moyenne du taux d'apprentissage d'acteur est de 0,98.
- Les erreurs de modélisation obtenues pour le modèle prévisionneur sont les suivants :

	$RMSE_{prévisionneur}$	$R2_{prévisionneur}$
ADP	0,3321 kPa	0,76

- La moyenne du taux d'apprentissage du prévisionneur est de 0,66.
- Les erreurs de modélisation obtenues pour le modèle critique sont les suivants :

	$RMSE_{critique}$	$R2_{critique}$
ADP	0,6048 <i>kPa</i>	0,81

---

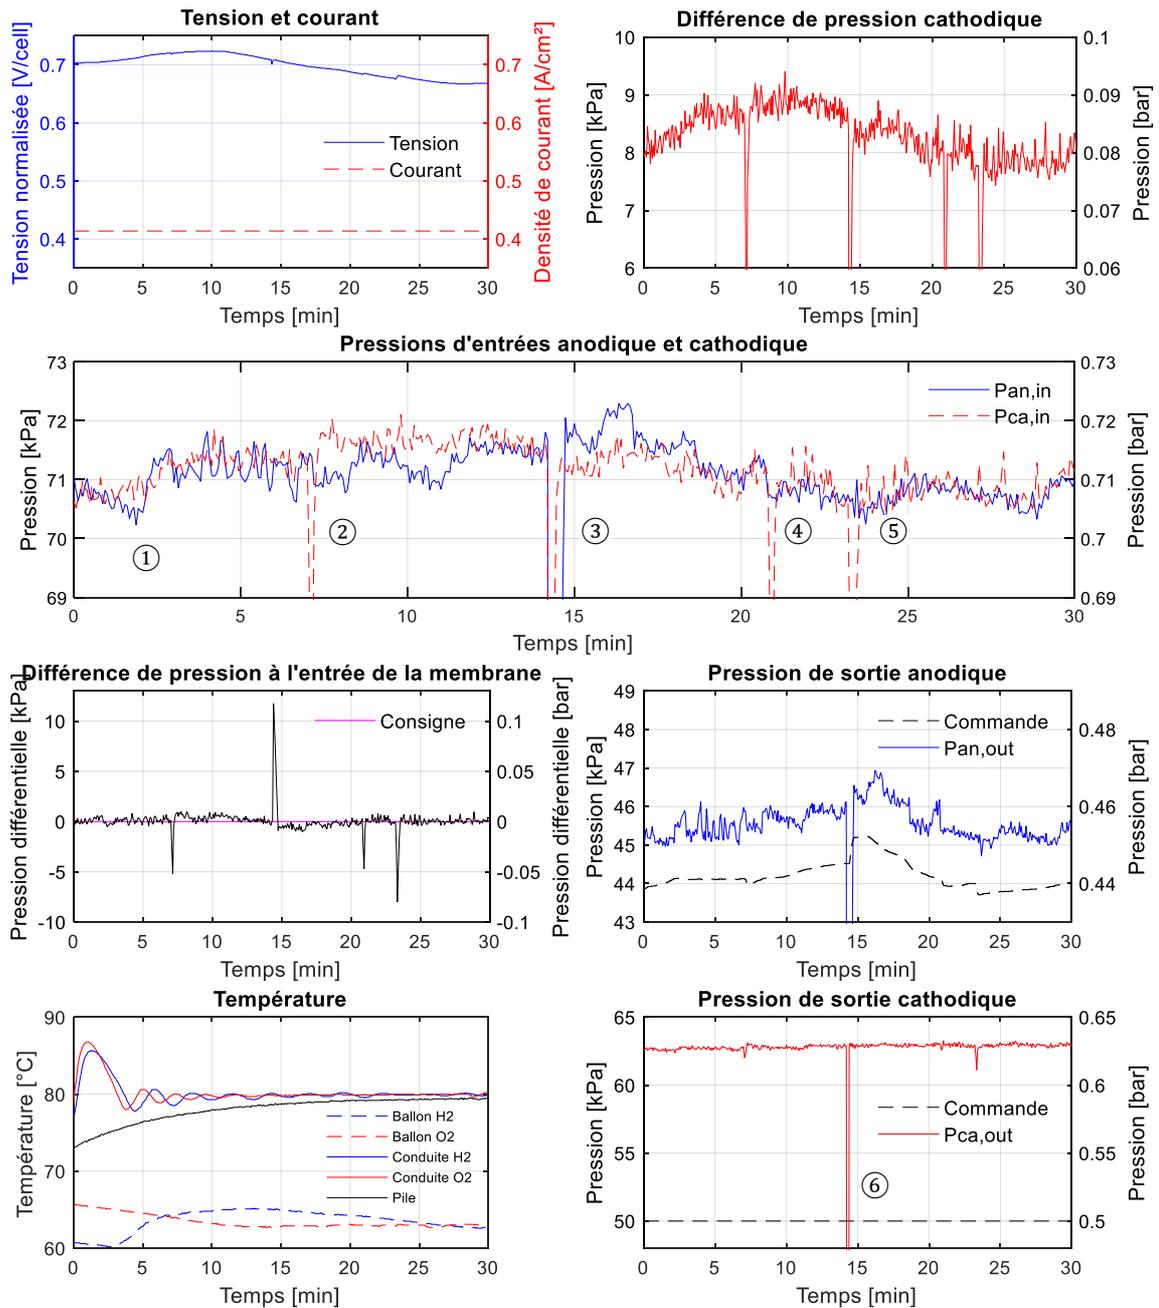
- La moyenne du taux d'apprentissage du critique est de 0,50.

### **Analyses des modèles ESN en présence du défaut de noyage – Scénario S2**

Les fluctuations de régulation autour de la consigne sont plus présentes sous la condition de noyage, ce qui produit un signal de renforcement plus variable, et par conséquent un apprentissage plus complexe des différents modèles ESN.

### **5.4.6 Régulation en présence du défaut d'assèchement de la membrane – Scénario S3**

La régulation en différence de pression à la membrane est mise en place dès la montée en température. Les résultats du contrôle lors de l'apparition du défaut d'assèchement de la membrane sont donnés à la [Figure 81](#).



**Figure 81** Réponse de la pile en présence du défaut d’assèchement de la membrane – Scénario S3

**Observations de la régulation en présence du défaut d’assèchement de la membrane – Scénario S3**

- Les erreurs obtenues sont les suivants :

	$RMSE_{\Delta P_{membrane}}$	$R2_{\Delta P_{membrane}}$
ADP	1,0802 kPa	0,94

- La tension chute de 0,723 V à 0,667 V, soit une variation de 0,056 V. La différence de pression cathodique diminue lors du défaut d'assèchement de la membrane.
- Suite à la montée en température lors des premières minutes, les réactions catalytiques sont nettement améliorées et la tension augmente. Lorsque l'humidité commence à diminuer au niveau de la membrane, la résistivité de la membrane augmente et la tension se met alors à diminuer.
- ① Des déviations plus ou moins importantes sont présentes lors de la montée de tension de la pile.
- ② ③ ④ ⑤ Quatre ouvertures à la cathode sont observées, dont la purge au point ③ qui dégage totalement les canaux de distribution cathodique.
- La température de la pile monte plus lentement que les conduites. La régulation en température des conduites par le contrôleur intégré présente un dépassement et des oscillations marqués.
- ② Suite à la première ouverture à 7,2 min, une erreur de position se présente avec une amplitude de -1 kPa.
- ③ À 14,2 min, le contrôleur présente une erreur de position de +0,87 kPa suite à une ouverture totale.
- Les ouvertures au point ④ à 20,8 min et au point ⑤ à 23,2 min ne provoquent pas d'erreur de position.
- ⑥ Lors de la purge totale, le banc ouvre totalement les deux régulateurs de contre-pression. Pendant ce laps de temps, le banc ne répond plus à la commande fournie par le contrôleur proposé.
- ② ③ ④ ⑤ Les quatre ouvertures durent chacune 3 itérations, soit 12 secondes.
- Un dépassement de la consigne est observé au point ③, il s'agit d'une compensation de la purge.
- Aucune oscillation sur la régulation n'est observée.

### **Analyses de la régulation en présence du défaut d'assèchement de la membrane – Scénario S3**

L'augmentation du débit, et le changement d'humidité relative provoquent des perturbations importantes au niveau de la régulation en position ①. On observe malgré tout, une nette amélioration du contrôleur proposé de 20 à 30 min. Dans cette période, la différence de pression cathodique continue de faire des sauts croissants. L'eau contenue dans la cathode continue à s'évacuer. Il s'agit de la zone où les températures sont également stabilisées. Ce qui laisse à penser à une période présentant moins de changements thermodynamiques.

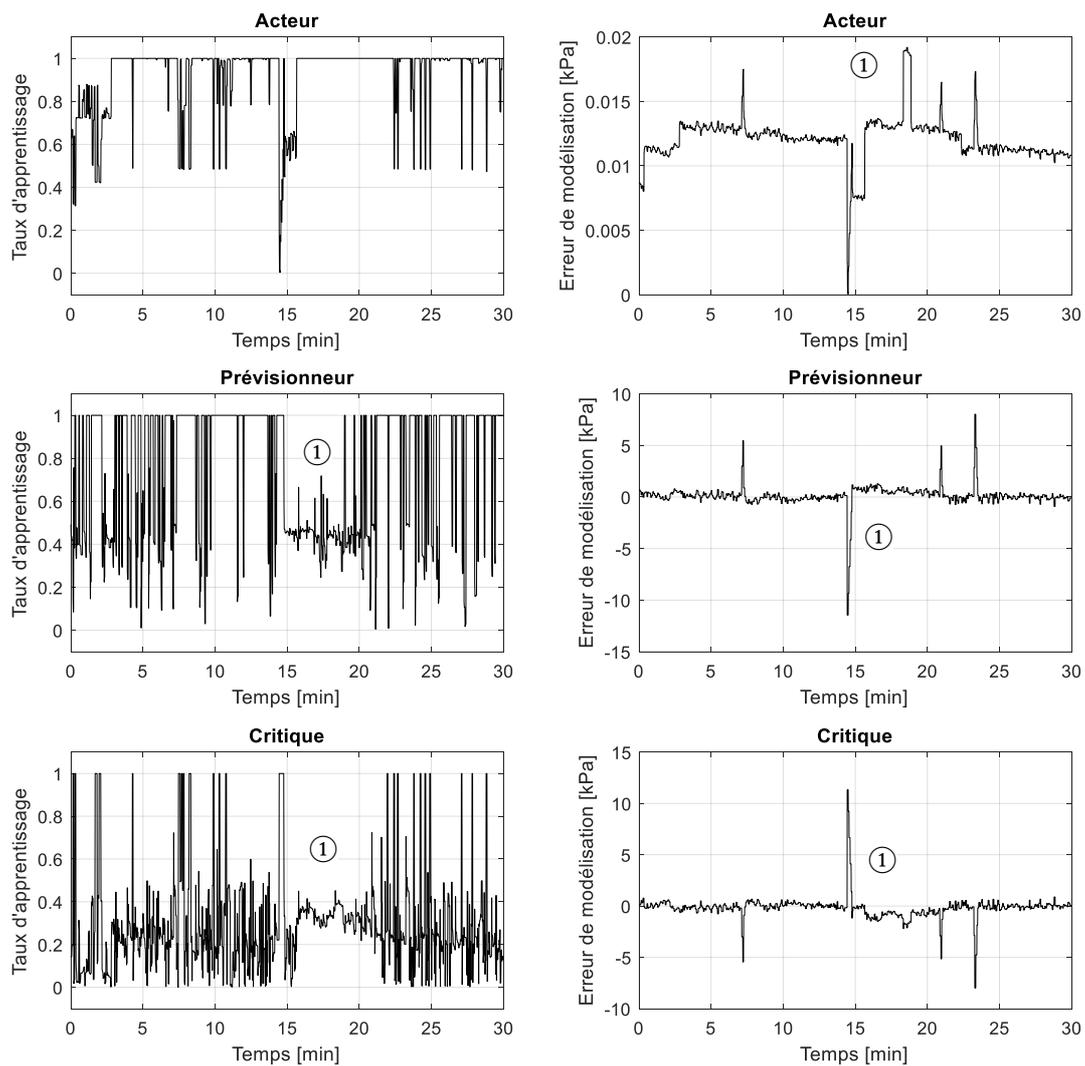
Les deux erreurs statiques et dépassements en ② et ③ ne sont pas négligeables. D'autant que ces erreurs de positions prennent plusieurs minutes à s'effacer complètement. Le premier au point ② nécessite 6,7 minutes pour s'effacer, alors que le deuxième au point ③ nécessite 3,8 minutes pour s'effacer complètement.

L'ouverture à la cathode ⑤ présente une amplitude plus importante que l'ouverture ②, pourtant la régulation ne présente pas de dépassement. L'ouverture ④, bien qu'elle soit de

plus faible amplitude, ne provoque également pas de dépassement. La régulation s'est adaptée à la situation et à ces perturbations. L'utilisation de modèles neuronaux mémorielle présente ici un des intérêts à conserver temporairement les informations des états précédents.

### Observations des modèles ESN en présence du défaut d'assèchement de la membrane – Scénario S3

Les taux d'apprentissage obtenus par logique floue et les erreurs résiduelles de modélisation des trois modèles ESN sont donnés à la Figure 82.



**Figure 82** Logique floue et apprentissage des modèles sous l'apparition du défaut d'assèchement S3

- Les erreurs de modélisation calculées pour le modèle acteur sont les suivants :

	$RMSE_{acteur}$	$R2_{acteur}$
ADP	0,0122 kPa	0,93

- La moyenne du taux d'apprentissage d'acteur est de 0,92.
- Les erreurs de modélisation calculées pour le modèle prévisionneur sont les suivants ;

	$RMSE_{prévisionneur}$	$R2_{prévisionneur}$
ADP	1,0835 <i>kPa</i>	0,78

- La moyenne du taux d'apprentissage du prévisionneur est de 0,73.
- Les erreurs de modélisation calculées pour le modèle critique sont les suivants :

	$RMSE_{critique}$	$R2_{critique}$
ADP	1,1663 <i>kPa</i>	0,83

- La moyenne du taux d'apprentissage du critique est de 0,29.

### Analyses des modèles ESN en présence du défaut d'assèchement de la membrane - Scénario S3

Les évènements d'ouverture à la cathode et les compensations sont clairement observables sur l'ensemble des erreurs de modélisation. Le plus frappant est celui de la deuxième ouverture (③). A cet instant entre 15 et 20 min, le modèle acteur présente une erreur de modélisation faible, le modèle prévisionneur présente une erreur positive et le modèle critique présente une erreur nulle. Si l'erreur du modèle critique est nulle, alors on peut considérer la composante  $\frac{\partial J(k+1)}{\partial x(k+1)}$  de la donnée jacobienne  $\frac{\partial J(k)}{\partial u(k)} = \frac{\partial U(k)}{\partial u(k)} + \gamma \frac{\partial J(k+1)}{\partial u(k)}$  comme étant de faible intensité. Le modèle critique est alors correctement identifié. Malgré cela, si le coefficient d'actualisation reste faible alors l'ajustement du modèle acteur risque d'être proportionnellement faible  $e_a(k) = -\zeta \frac{\partial J(k)}{\partial u(k)} - \Delta \hat{u}(k+1)$ . Dans ce cas de figure, un coefficient d'actualisation plus important (*e.g.*  $> 0,3$ ) permettrait d'ajuster davantage le modèle acteur.

En comparaison des autres tests, on observe que le taux d'apprentissage des modèles critique et prévisionneur se stabilisent entre 15 et 20 min, ces périodes correspondent au moment de la purge cathodique et au phénomène de compensation au point (③). La chute brutale de la différence de pression au point (③) entraîne une forte erreur de modélisation sur les modèles prévisionneur et critique. La méthode de logique floue ajuste alors le taux de fuite pour minimiser les possibles erreurs d'estimation des modèles. Lorsque la consigne est à nouveau respectée, les taux d'apprentissage se remettent à fluctuer dans l'ensemble du domaine [0 1] et les erreurs de modélisations affichent une valeur nulle. La méthode de logique floue appliquée au taux d'apprentissage permet d'adapter l'apprentissage aux différentes situations et contribue à maintenir une erreur de modélisation nulle.

## 5.5 Analyse des résultats d'expérimentations

La configuration des modèles ESN du contrôleur est semblable à l'application de simulation. Trois modifications sont tout de même à souligner. Tout d'abord le signal de renforcement qui est prend une forme quadratique pour améliorer la stabilité en expérimentation. Puis, l'absence de signal de perturbation en entrée de prévisionneur. Cette information est difficilement accessible en expérimentation. La troisième modification est l'utilisation de la logique floue pour réguler l'algorithme d'apprentissage des modèles neuronaux.

Durant la phase d'expérimentation, un total de six scénarios de tests sont mis en œuvre, en condition de fonctionnement sain et en présence de défauts. Les tests sous l'atténuation de défaut n'ont pu être menés et seront effectués dans de prochaines études. La différence de pression à la membrane est la variable à contrôler, et elle est manipulée indirectement par l'intermédiaire des actionneurs de contre-pression. En obstruant la canalisation de sortie, le régulateur de débit massique est contraint d'ouvrir la conduite d'entrée pour respecter la consigne de stœchiométrie, ce qui augmente par conséquent la pression d'entrée. Le contrôleur proposé n'agit que sur la pression de sortie anodique. La pression de sortie cathodique reste fixée.

La répétition d'un événement met en évidence la capacité d'apprentissage du contrôleur proposé. Lors de la deuxième occurrence de perturbation, la régulation présente de meilleurs résultats. Malgré tout, l'apprentissage possède une limite dans le sens où des répétitions supplémentaires n'améliorent pas davantage les performances de contrôle. Sous des paliers rapides, nous n'observons pas d'instabilité ou de divergence de régulation. Lors des perturbations en paliers plus importants, nous observons que les déviations provoquées par les perturbations ne peuvent être atténuées comme en simulation. De plus, le contrôleur nécessite quelques itérations avant d'entreprendre la correction de la consigne. Lorsqu'une erreur de position apparaît, elle est intégrée au modèle acteur et au signal de renforcement. Cependant, plusieurs itérations sont nécessaires à la correction des poids du modèle acteur par l'information jacobienne. Il s'agit sans aucun doute du choix des paramètres ADP, les coefficients d'atténuation et d'actualisation, qui ralentissent l'adaptation du contrôleur ADP. Une sélection optimale de ces paramètres pourrait apporter de meilleurs résultats. Cependant, un risque de dépassements de consigne pourrait apparaître dans le cas où ces coefficients seraient surévalués.

En condition de noyage, l'équilibre des pressions d'entrées est satisfaisant. Une première ouverture de la canalisation de sortie fait apparaître des fluctuations modérées. Ces phénomènes sont provoqués par l'accumulation en eau dans l'actionneur de contre-pression et n'affectent pas le contrôleur. La commande calculée reste stable malgré les bruits capteurs présents sur la mesure de pression d'entrée. Le contrôleur est dans notre application insensible aux fluctuations des capteurs de pressions.

Pour l'apparition du défaut d'assèchement, la montée en température provoque des modifications dynamiques fluidiques qui mettent à mal la régulation lors des premières minutes. Puis des ouvertures partielles et un purge totale cathodiques interviennent comme perturbations pour la boucle de régulation. Le contrôleur génère un dépassement sur la première ouverture

et la purge de la canalisation de sortie. Il s'agit d'une compensation directe à la chute de pression. Ce dépassement nécessite quelques minutes avant d'être totalement effacés. Lors des deux ouvertures suivantes, le contrôleur ne génère plus de dépassements, et l'équilibre des pressions d'entrées se retrouve nettement amélioré. La sortie des modèles prévisionneur et critique est alors stable. Lors de la purge totale cathodique, les erreurs de modélisation deviennent brusquement importantes, malgré tout, la méthode de logique assure une gestion sur les taux d'apprentissage pour éviter toute amplification des erreurs de modélisation.

## **Conclusion**

Après une étape de test en simulation, le régulateur ADP a pu être validé en expérimentation. Certaines contraintes dues à l'expérimentation nous ont conduits à choisir des variables de contrôles et de commandes différentes de celles utilisées en simulation. Le contrôleur ADP s'est adapté à la configuration sans difficulté. Les seules modifications apportées ont été les échelles de normalisation des entrées et des cibles d'apprentissages des trois modèles ESN.

Le contrôleur générique proposé s'est également adapté à la période d'échantillonnage importante de 4 secondes, mais aussi aux régulateurs internes statiques qui possèdent une précision non-linéaire. Les résultats en régulations ont montré des performances très satisfaisantes dans l'ensemble des tests effectués. Notons cependant que dans certains cas, le temps nécessaire pour atteindre la valeur de consigne est important au regard des dynamiques considérées. Pour y remédier, des outils de gestion pour les hyperparamètres ADP peuvent être intégrés et semblent être une piste pertinente pour une continuité des travaux.

# Conclusions générales

Un rappel des fonctions et questions du chapitre 1 est effectué ci-dessous. Les objectifs de cette thèse sont de remplir et de satisfaire la totalité des fonctions d'études. Quant aux questions nous tâcherons d'y répondre dans cette conclusion.

**FP 1** Considérer les états de santé du système dans la définition du contrôleur.

**FP 2** Concevoir une méthode générique pour la définition du contrôleur.

**FT 1** Adopter les réseaux de neurones pour l'estimation de grandeurs inconnues.

**FU 1** Automatiser les processus d'identification des modèles neuronaux.

**FC 1** Assimiler les retards purs tout au long de la chaîne de contrôle.

**Q 1** Quel est l'apport d'un contrôleur adaptatif par rapport à un contrôleur traditionnel ?

**Q 2** Existe-t-il un risque d'intégrité du système dans le cas d'un contrôle adaptatif ?

**Q 3** Comment garantir la stabilité d'un contrôleur en perpétuelle évolution ?

**Q 4** Peut-on s'assurer de la fidélité des résultats entre chaque exécution ?

**Q 5** Peut-on s'assurer de la précision des estimateurs neuronaux ?

**Q 6** Quelles sont les différences entre la simulation et l'expérimentation ?

**Q 7** Peut-il exister des interférences entre l'adaptation du contrôleur et les autres modules de la stratégie ATFC ?

Le perfectionnement de la fiabilité du système PEMFC est un des enjeux pour son développement et son déploiement à grande échelle. En effet, des perturbations de fonctionnement entravent son fonctionnement nominal, et provoquent des diminutions de sa durée de vie. Ces événements, les défauts, apparaissent au cœur du système et provoquent de multi perturbations qui peuvent dégrader, de manière réversible ou irréversible, l'état de santé de la pile. L'objectif entrepris dans cette thèse est de proposer un algorithme contrôleur qui soit de nature générique et adaptative aux états de santé de la pile. Il doit être construit en s'appuyant sur des outils d'estimations neuronales, qui permettent de se passer de modèle physique lors de la conception du contrôleur. Ces outils ont l'avantage de n'utiliser que des données d'acquisitions. Les caractères générique et adaptatif répondent à la capacité de réguler les systèmes possédant des configurations d'auxiliaires différentes, mais également à la compensation des perturbations inconnues et complexes. Ce manuscrit ne considère que les défauts de noyage et d'assèchement de la membrane.

La première tâche fut d'entreprendre un état de l'art en deux parties. Il s'agit par ce processus de dresser le maximum de solutions technique afin d'en sélectionner les plus aptes à développer. La première partie concerne les modèles réseau de neurones, leurs applications, leurs

configurations, mais également leurs optimisations, convergences et stabilité. Le contrôleur neuronal à la tâche première de piloter directement les commandes du système PEMFC. Les études de stabilité et de convergence sont par conséquent indispensables avant tout essai qui pourrait être désastreux. La deuxième partie a été consacrée aux structures contrôleurs adaptatifs de la littérature. Les approches de contrôle, les variables de commandes, les performances de régulation ou d'asservissement, et les types d'adaptation ont été soulignés. Plusieurs carences de la littérature PEMFC ont été remarquées, pour y remédier une recherche exploratrice sur d'autres systèmes a été menée en parallèle. Il en ressort plusieurs pistes de recherches, telles que les algorithmes de gestion d'apprentissage, l'emploi de modèle neuronal avancé (*e.g.* modèles profonds), les analyses de stabilité, ou encore l'intégration d'estimateurs futurs pour l'amélioration des résultats de contrôle.

À partir des solutions retenues dans l'état de l'art, une approche a été sélectionnée suivant plusieurs critères objectifs et subjectifs. Une combinaison entre la programmation dynamique ADP, l'apprentissage par renforcement, et l'outil de réseau de neurones échoïque ESN a été adoptée. Une étude comparative a permis de retenir ce type de modèle neuronal et de répondre aux questions **Q 4** et **Q 5**. Le modèle ESN possède une bonne précision d'estimation, un temps de calcul très faible et une fidélité des résultats entre chaque initialisation. Cette combinaison offre la possibilité de définir un contrôle itératif optimal uniquement à partir des données d'acquisition. Il s'agit par conséquent d'un outil totalement générique qui répond à la fonction principale **FP 2**. Le développement du contrôleur adaptatif a été ensuite réalisé autour de la considération des défauts envisagée, ce qui nous permet de satisfaire la fonction principale **FP 1**. Le contrôleur ADP a été construit en considérant les temps de calcul qui peuvent être conséquents vu l'utilisation de trois modèles à réseaux de neurones. En effet, un modèle acteur estime la correction de la commande, un modèle prévisionneur estime la réponse future du système face à la commande estimée et enfin, un modèle critique estime le coût global futur pour l'ajustement anticipé des modèles ESN. Le total de trois modèles neuronaux remplit pleinement la fonction technique **FT 1**, puisqu'ils s'accordent mutuellement pour réguler le système PEMFC. Un apprentissage prospectif de l'algorithme ADP a été choisi pour considérer la prévision dans l'ajustement de la commande. La logique floue a été mise en place pour la gestion des taux d'apprentissages, la méthode propose d'améliorer le temps de convergence des modèles ESN. Les hyperparamètres du modèle ESN ont été étudiés hors-ligne pour le paramétrage des modèles. Cette approche ne répond pas entièrement à la fonction **FU1**, ce qui laisse place à des perspectives pour faciliter l'usage des modèles neuronaux. La stabilité au sens de Lyapunov est adoptée pour la stabilité du contrôleur, et le critère matriciel de Schur est adoptée pour la stabilité des réservoirs de neurones. Le caractère échoïque des réservoirs est vérifié en phase d'initialisation des poids neuronaux internes. Ces processus de vérification répondent à la question de stabilité **Q 3**.

La démonstration du contrôleur proposé a été menée en simulation sur un modèle connu de la littérature. Ce modèle présente la possibilité d'émuler la phénoménologie des défauts de noyage et d'assèchement de la membrane. Le contrôle est effectué sur des consignes de stœchiométries à la cathode, sur une consigne nulle de différence de pression à la membrane, et enfin une consigne fixe en température. Le contrôleur est configuré en multi-entrées multi-sorties, ce qui permet de diminuer les temps de calcul, mais aussi de partager la même dynamique du

réservoir de neurones échoïque. Le contrôleur ADP est comparé à un contrôleur PID optimisé. Trois scénarios sont mis en place, une condition de fonctionnement sain, une mise en condition de défaut de noyage et une mise en condition de défaut d'assèchement de la membrane. Le contrôleur présente des temps de réponse et des déviations inférieures au contrôleur PID. Aucun dépassement n'est observé sur l'ensemble des résultats. Une contrainte est mise en place sur les commandes et assure l'intégrité du système tout en répondant à la question **Q 2**. Certaines interférences entre le contrôleur et la stratégie AFTC justifiant la question **Q 7** ont été remarquées en condition de noyage. La fonction dérivée candidate de Lyapunov reste négative tout au long du calcul, ce qui justifie de la stabilité du contrôleur. Les matrices de Schur sont identifiables, par conséquent les réservoirs de chaque modèle sont considérés comme stables.

L'expérimentation sur une monocellule a permis de valider le caractère générique du contrôleur. En comparaison au modèle de simulation, les variables de commandes ont été modifiées, la période d'échantillonnage a été contrainte à quatre secondes et la boucle de contrôle a dû intégrer plusieurs actionneurs accompagnés de leurs contrôleurs traditionnels internes. L'intégration des retards d'information pour la fonction contrainte **FC 1** a été nativement réalisée par l'utilisation de modèles neuronaux à mémoire. L'expérimentation a permis de mettre en œuvre la gestion de l'apprentissage des modèles neuronaux par logique floue. En présence d'événements récurrents, l'apprentissage des modèles ESN démontre la capacité du contrôleur à améliorer les résultats dès la deuxième apparition de l'événement. Des répétitions supplémentaires n'apportent cependant pas d'amélioration. En présence de perturbations de faibles amplitudes en pressions à la cathode, la pression contrôlée à l'anode est capable de suivre de manière satisfaisante la valeur de consigne. En présence de perturbations d'amplitudes plus importantes, on constate des déviations et des temps de réponse plus importants. Certains hyperparamètres de l'approche ADP doivent être optimisés pour améliorer les temps de réponses du contrôleur proposée. Il est important de souligner que même en présence de perturbations dans les zones transitoires, le contrôleur proposé reste stable et le système converge sur la valeur de consigne. En condition de noyage, le contrôleur assure correctement l'équilibre à l'entrée de la membrane malgré les fluctuations de pressions provoquées par l'évacuation de l'eau. En condition d'assèchement de la membrane, le contrôleur présente quelques difficultés à maintenir l'équilibre des pressions lors de l'apparition du défaut. Cependant, la précision de régulation est améliorée au cours du temps. Quatre ouvertures intempestives de la cathode sont provoquées par le banc d'essai. Suite aux deux premières ouvertures, le contrôleur compense et génère des dépassements, ces erreurs de positions s'effacent au cours du temps. Lors des deux dernières ouvertures, le contrôleur ne présente plus de dépassements, et on remarque une meilleure précision dans la régulation.

Plusieurs limites à notre étude peuvent être soulignées. Tout d'abord, la sélection du contrôleur est étroitement liée aux critères qui ont été appliqués (place du RN, originalité, etc). Ensuite, le choix du modèle échoïque présente un nombre important d'hyperparamètres. Ces hyperparamètres peuvent difficilement être explicables, d'autant que la configuration de nos modèles n'a été effectuée qu'à partir d'un unique test itératif sous une application de prévision en tension. La simulation effectuée n'a pas pu être correctement validée en expérimentation, ce qui laisse la question **Q 6** partiellement résolue. L'expérimentation ne présente pas de contrôleur

comparateur, il est alors difficile de quantifier les performances de l'approche ADP par rapport à une référence. La question **Q 1** n'est réponde qu'en simulation où le contrôleur ADP présente une meilleure précision par rapport à un contrôleur PID.

# Perspectives

De nombreuses perspectives et continuités à nos travaux peuvent être menées. Elles sont classées en fonction de leurs localisations. Certains points sont détaillés dans les pages suivantes.

Au niveau du contrôleur :

- Des algorithmes d'optimisations peuvent être ajoutés pour l'estimation en ligne des hyperparamètres neuronaux, mais également du contrôleur ADP.
- Également, il existe la possibilité d'améliorer l'apprentissage des modèles ESN par la gestion des coefficients d'apprentissage.
- Ensuite, les approches DHP et GDHP devront être conduites en simulation et en expérimentation afin de les comparer à l'approche HDP.
- Augmenter la portée du modèle prévisionneur, en passant de  $t + 1$  à  $\{t + 1, t + 2, \dots, t + \Delta t\}$  permettrait d'améliorer la prévision et par conséquent l'anticipation du contrôleur.
- De même, d'autres contrôleurs pourront être utilisés comme comparateur afin d'éprouver davantage le contrôleur proposé.
- Le contrôleur doit être soumis à d'autres situations de défauts système.

Au niveau de l'objet d'étude :

- Il serait intéressant de valider le contrôleur adaptatif sur une configuration d'auxiliaire différente, voire un système PEMFC d'une puissance différente.
- Sur ce même niveau, le contrôleur doit être validé sur d'autres variables de commandes. L'utilisation de la pression d'entrée en simulation, et de la contre-pression en expérimentation démontre d'une certaine genericité du contrôleur proposé. Malgré tout, des essais en expérimentation sur des variables différentes sont nécessaires.

Au niveau de la stratégie AFTC :

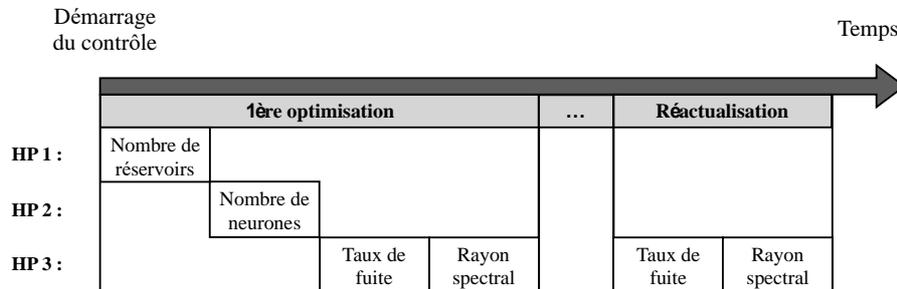
- Le contrôleur devra être éprouvé en présence réelle des modules de diagnostic et de décision. L'objectif serait d'analyser les différentes interactions entre modules AFTC et d'identifier les contributions de chacun des modules.

Au niveau industriel :

- Le contrôleur ADP pour la pile à combustible peut être embarqué pour une utilisation prête à l'emploi. En effet, son caractère générique autorise la mise en place d'une telle application. Pour y parvenir, de plus amples études sur les charges de calculs doivent être menées.

## Optimisation des hyperparamètres neuronaux

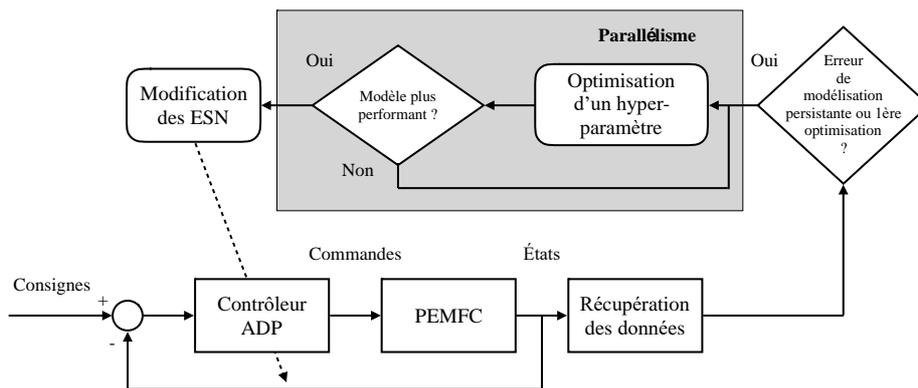
Pour une optimisation et réactualisation des hyperparamètres neuronaux, nous pouvons concevoir une approche semblable à celle indiquée sur la [Figure 83](#).



**Figure 83** Ordre d'optimisation et de réactualisation

Une fois que le nombre de réservoir est optimisé la démarche d'optimisation est conduite sur le nombre de neurones, puis sur le taux de fuite, et enfin la vérification systématique du rayon spectral. Le taux de fuite représente la dynamique récurrente du réservoir, c'est pourquoi cette hyperparamètre est réactualisée au cours du temps. Le nombre de réservoirs et le nombre de neurones sont des hyperparamètres dont les optimisations pourraient être lourds en charge de calculs, ainsi, ils resteraient fixés une fois la première optimisation effectuée.

La modification en ligne d'un coefficient dont la contribution à l'erreur de modélisation est incertaine ne peut être envisageable. Ainsi, le choix peut être portée sur l'exécution en parallèle d'un modèle candidat, comme l'illustre la [Figure 84](#).



**Figure 84** Diagramme d'optimisation des hyperparamètres

Si la cible de l'apprentissage n'est pas atteinte au bout d'un horizon prédéfini, la boucle en parallèle est mise en exécution et un algorithme d'optimisation s'exécute pour rechercher une meilleure configuration des hyperparamètres. Si la nouvelle configuration des modèles neuronaux obtient de meilleures performances que la configuration en place, alors, les caractéristiques des modèles donneurs sont transférées aux modèles en ligne.

## Optimisation des hyperparamètres ADP

L'optimisation des hyperparamètres du contrôleur ADP devra dépendre des situations de contrôles, telles qu'une erreur statique, un temps d'établissement à la consigne trop important ou encore un dépassement pour une compensation de perturbation. L'amplification des coefficients d'atténuation et d'actualisations, ou la modulation du signal de renforcement ne peuvent être réalisées si les sorties des modèles acteur, prévisionneur et critique présentent de fortes erreurs de modélisation. L'utilisation de la méthode de logique floue pour les hyperparamètres ADP en sus des taux d'apprentissage peut être une solution envisageable.

L'algorithme du contrôleur ADP pourrait donc être mis à jour et incorporer des fonctions supplémentaires.

### Algorithme 2 Contrôleur ADP avec algorithmes d'optimisation pour les hyperparamètres

```

0  Initialiser les modèles ESN acteur, prévisionneur et critique
1  Initialiser :  $i = 0$ 
2  Définir le temps de contrôle :  $N_{run}$ 
3  Définir les plages des HP
4  Définir le temps d'optimisation des HP :  $N_{HP}$ 
5  Tant que  $i < N_{run}$ 
6    Acquisition de l'état système :  $x(k)$ 
7    Calcul logique floue pour le modèle prévisionneur :  $\eta_m(k)$ 
8    Ajustement des poids du modèle prévisionneur :  $e_m(k)$ 
9    Calcul du signal de renforcement :  $U(k)$ 
10   Si ( $U(k) > \varepsilon_{contrôle}$ )
11     Si Nouveaux HP
12       Modification des HP
13     Fin si Nouveaux HP
14     Estimation de la commande :  $\hat{x}(k)$ 
15     Estimation du coût du contrôle :  $\hat{J}(k)$ 
16     Prédiction de l'état système futur :  $\hat{x}(k+1)$ 
17     Prédiction de la commande future :  $\hat{u}(k+1)$ 
18     Prédiction du coût du contrôle futur :  $\hat{J}(k+1)$ 
19     Calcul logique floue pour l'actualisation :  $\gamma(k)$ 
20     Calcul logique floue pour le critique :  $\eta_m(k)$ 
21     Ajustement des poids de critique :  $e_c(k)$ 
22     Calcul logique floue pour l'atténuation :  $\zeta(k)$ 
23     Calcul logique floue pour l'acteur :  $\eta_m(k)$ 
24     Ajustement des poids de l'acteur :  $e_a(k)$ 
25   Fin si ( $U(k) > \varepsilon_{contrôle}$  ou  $e_{a,p,c} > \varepsilon_{a,p,c}$ )
26   Incrémentation  $i = i + 1$ 
27 Fin tant que  $i < N_{run}$ 

```

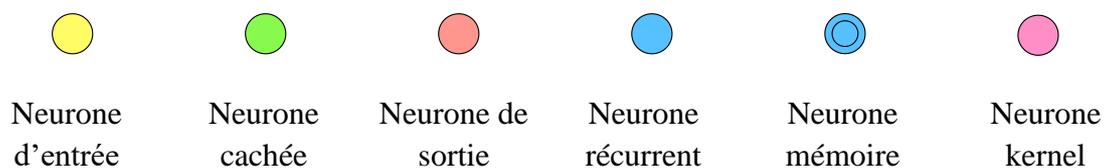


# Annexe A1 Les structures des réseaux de neurones

La fonction d'activation et la connexion pondérée sont deux morphèmes qui forment le concept de réseau neuro-mimétique, il s'agit de la transmission d'un signal électrique dynamique. Pour cela, quatre éléments communs composent le neurone biologique et le concept neuro-mimétique :

- Les dendrites sont les récepteurs de l'information. Au fil des expériences, elles développent une structure arborescente hétérogène qui finit par définir la connectivité propre du neurone, et du réseau de neurones. C'est également à cet endroit que des liaisons de rétroaction se construisent, ainsi que la pondération des interconnexions.
- Les synapses sont les zones de contact fonctionnelles entre les neurones. Suivant la nature de l'information, elles peuvent être excitatrices ou inhibitrices de l'information.
- Le corps cellulaire ou soma, est un élément post-synaptique qui réalise la sommation de toutes les entrées  $x_i(t)$ .
- L'axone est une fibre nerveuse en sortie du neurone. Elle renferme la fonction d'activation  $f(\sum x_i(t))$  et transmet l'information à un autre neurone dès le franchissement d'un seuil par la sommation.

Afin d'améliorer la lisibilité des structures neuronales, une légende des différents neurones est définie ci-dessous. Cette visualisation provient des travaux de Fjodor van Veen de l'institut Asimov (2017).



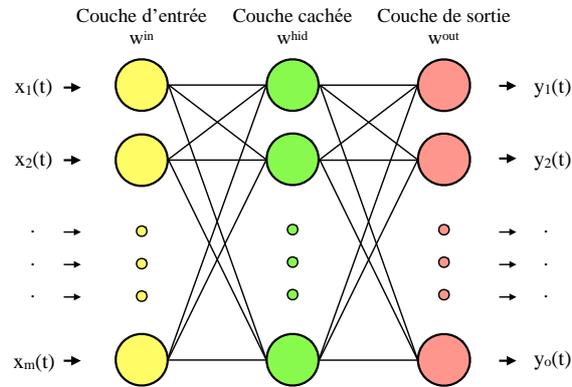
**Figure 85** Les principaux types de neurones

Les neurones récurrents possèdent, en plus de leurs entrées, une information temporelle de leurs états précédents. Cette caractéristique leur confère une aptitude équivalente à une mémoire volatile qui est mise à jour à chaque présentation de nouvelles entrées. Ces neurones sont soumis à d'importantes pertes d'informations temporelles. L'intégration de l'état précédent n'affecte que l'état futur, ce qui implique la perte progressive des informations anciennes au cours du temps.

Comparés aux neurones récurrents, les neurones de mémoire (« Long Short-Term Memory cells » ou neurone LSTM) possèdent en plus, des entrées et des sorties, des informations temporelles sur leurs états. Le calcul de ce neurone implique donc trois flux d'arrivées : les entrées, les états et les sorties. Ces flux ou portes (« gate ») sont gérés par des paramètres mémoriels, des coefficients avec une intensité comprise entre 0 et 1 qui permettent de réguler l'arrivée des informations.

### Modèle perceptron multicouches

Le modèle multicouches (« Multi-Layers » ou ML) est le plus emblématique des modèles neuronaux, en particulier le modèle à trois couches qui est visible sur la [Figure 86](#). Il est utilisé dans la plupart des applications possédant des variables à multi-entrées multi-sorties.



**Figure 86** Réseau de neurones à trois couches

Un modèle multicouche profond correspond à une structure ayant plusieurs couches cachées. Tous les neurones, appelés également nœuds, possèdent une fonction d'activation et sont interconnectés entre eux. Les nœuds de la couche d'entrée possèdent une fonction d'activation de type identitaire. Un nœud de la couche cachée se calcule comme suit :

$$h_n^l = f \left( \sum_{i=1}^m w_i^{in} x_i + \text{biais} \right) \quad (38)$$

où  $x_i$  représente les entrées du neurone,  $h_n$  la sortie d'un neurone,  $n$  est un neurone (ou nœud de calcul),  $f$  est la fonction d'activation,  $l$  est le nombre de couches cachées,  $m$  est le nombre de nœuds d'entrée,  $w_i$  est le poids de la connexion et le *biais* est unitaire. Cette opération est répétée pour chaque  $n$  nœud caché afin d'obtenir le vecteur de la couche cachée  $h_n^l = (h_1, h_2, \dots, h_n)$ . Puis, la couche de sortie est calculée de la même façon :

$$y_o = f \left( \sum_{i=1}^n w_i^{out} h_n^l + \text{biais} \right) \quad (39)$$

Où  $y_o$  est la sortie du réseau et  $o$  est le nombre de nœuds de sortie. Tous les poids des connexions  $w^{in}$ ,  $w^{hid}$  et  $w^{out}$  sont les éléments ajustés durant la phase d'apprentissage.

### Modèle à fonctions de base radiales

Couramment utilisé dans les applications de contrôle, le réseau à fonction de base radiale (« Radial Basis Fonction » ou RBF) est une variante du modèle ML. La différence majeure réside dans ses fonctions d'activation de type gaussienne. Une forme commune à sa fonction d'activation est la suivante :

$$f_{gauss}(x) = \frac{1}{\sigma_n \sqrt{2\pi}} e^{-\frac{(x_i - \mu_n)^2}{2\sigma_n^2}} \quad (40)$$

où  $\mu$  est l'espérance mathématique et  $\sigma$  est l'écart type. Ces deux paramètres s'ajoutent à la liste des paramètres à optimiser au même titre que les poids neuronaux.

### Modèle convolutif

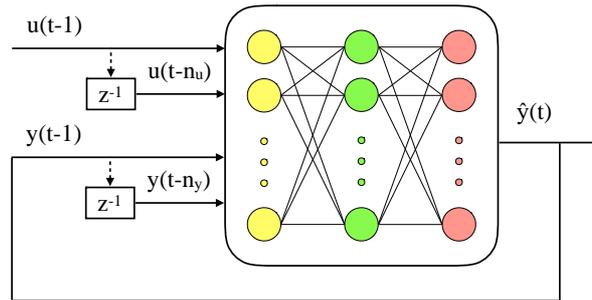
Le modèle neuronal convolutif (Fukushima, 1979) et notamment les modèles convolutif profonds font figure de modèle élite dans les applications de classifications. Un prétraitement sur les données est appliqué par l'intermédiaire de nœuds de type noyau (« kernel ») en couche d'entrée. Ils font intervenir un procédé de filtrage, permettant de simplifier les données d'entrées en ne gardant que les informations pertinentes. Le filtre est appliqué sur les données d'entrées par une opération de convolution. D'autres paramètres s'ajoutent ainsi à la phase d'optimisation, tels que le nombre de filtres, le type de filtre et la fenêtre de convolution.

### Modèle autorégressif

La modélisation considérant des écarts temporels a été impulsée dès 1989 pour faire face aux délais et retards existants dans les systèmes. Une approche pour la considération des dépendances à long terme est construite sur une structure appelée autorégressive à entrées exogènes (« Auto Regressive with eXogenous input » ou ARX) (Lin et al., 1996). Un tel modèle est défini de la manière suivante :

$$y(t) = f_{ARX} \begin{bmatrix} u(t - n_u), \dots, u(t - 1) \\ y(t - n_y), \dots, y(t - 1) \\ d(t - n_d), \dots, d(t - 1) \end{bmatrix} \quad (41)$$

où  $f_{ARX}$  est une fonction non linéaire,  $d$  représente les perturbations,  $n_{u,y,d}$  est respectivement la grandeur maximale du retard des entrées, sorties et des perturbations.



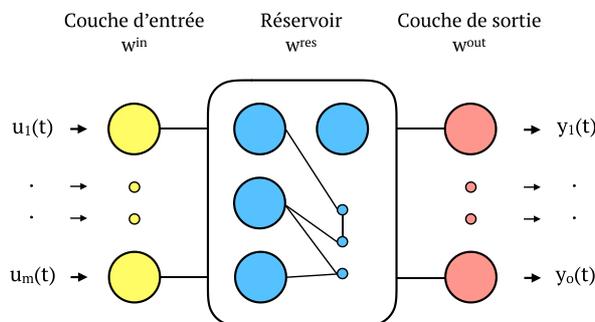
**Figure 87** Réseau de neurones de type ARX

Comme le suggère la [Figure 87](#), la structure neuronale ARX ne diffère pas complètement du modèle ML. Ce sont les entrées qui acquièrent une dimension plus grande par la mise en boucle des valeurs d'entrée et de sorties précédentes. De cette manière, les données d'entrées et de sorties sont associées à une grandeur temporelle améliorant la captation de la dynamique du système. La fenêtre d'entrée est un paramètre qui s'ajoute aux poids neuronaux.

Le modèle à retard temporel (« Time Delay NN » ou TD NN) appartient à la même classe que le modèle ARX, celui des modèles à retard considérant une fenêtre d'entrées. La différence entre les deux structures est l'absence de fenêtre en entrée de modèle.

### Modèle à réservoir

Le modèle à réservoir de type « Echo State Network » ou ESN ([Jaeger, 2000](#)), diffère des structures précédentes par un processus atypique. Il est fondé sur le principe que la seule adaptation de la couche de sortie suffit à réduire l'erreur de modélisation. En effet, un modèle possédant plusieurs couches cachées et des fonctions  $\tanh(x)$  fait intervenir des phénomènes d'évanouissement du gradient (« vanishing gradient ») de l'erreur de modélisation. La première couche reçoit une adaptation plus importante par rapport aux autres. Ainsi l'approche par ESN contribue d'autant à accélérer la phase d'apprentissage. Le modèle ESN est également équipé d'un réservoir de neurones récurrents parsemé fixe comme couche cachée et d'une couche d'entrée aléatoire.



**Figure 88** Réseau de neurones de type ESN

Illustré sur la [Figure 88](#), le calcul de son réservoir récurrent est donné comme suit :

$$\tilde{x}(k) = f(W^{in}u(k) + W^{res}x(k-1) + W^{back}y(k-1)) \quad (42)$$

$$x(k) = (1 - \alpha)x(k-1) + \alpha\tilde{x}(k) \quad (43)$$

où  $x(n) \in \mathbb{R}^n$  est le vecteur d'état du réservoir,  $\tilde{x}(n) \in \mathbb{R}^n$  est la mise à jour du vecteur d'état du réservoir et  $\alpha$  est le taux de fuite, un coefficient de mémoire. La sortie du modèle est calculée comme suit :

$$y(k) = W^{out}[x(k), u(k), y(k-1)] \quad (44)$$

Si plusieurs réservoirs sont présents, les fonctions de transfert d'états sont alors différenciées entre le premier et les autres réservoirs. Pour le premier réservoir, les fonctions sont données de la manière suivante (Gallicchio et al., 2018a) :

$$\tilde{x}^{(1)}(k) = f(W^{in}u(k) + W^{res,(1)}x^{(1)}(k-1) + W^{back}y(k-1)) \quad (45)$$

$$x^{(1)}(k) = (1 - \alpha^{(1)})x^{(1)}(k-1) + \alpha^{(1)}\tilde{x}^{(1)}(k) \quad (46)$$

Les activités des autres réservoirs sont ensuite données de la manière suivante :

$$\tilde{x}^{(l)}(k) = f(W^{out,(l)}x^{(l-1)}(k) + W^{res,(l)}x^{(l)}(k-1)) \quad (47)$$

$$x^{(l)}(k) = (1 - \alpha^{(l)})x^{(l)}(k-1) + \alpha^{(l)}\tilde{x}^{(l)}(k) \quad (48)$$

Le calcul de la sortie d'un modèle à réservoir profond conserve la même forme, seule la matrice de sortie prend une dimension plus importante  $W_{out} \in \mathbb{R}^{o \times (l \times n)}$ .

### Modèle à mémoire court et long terme

Le modèle composé de neurones LSTM est une des structures privilégiées dans le traitement de séries de données possédant des intervalles ou retards temporels. Comme le modèle à réservoir, il possède la capacité à conserver l'information de son état dynamique au cours du temps. Cette information n'est pas conservée au niveau de la couche cachée, mais au sein de chaque unité de calcul. Pour cela, trois portes de régulation de l'information sont associées aux signaux précédents d'entrées, d'états et de sorties. La structure d'un neurone unitaire LSTM est définie comme suit :

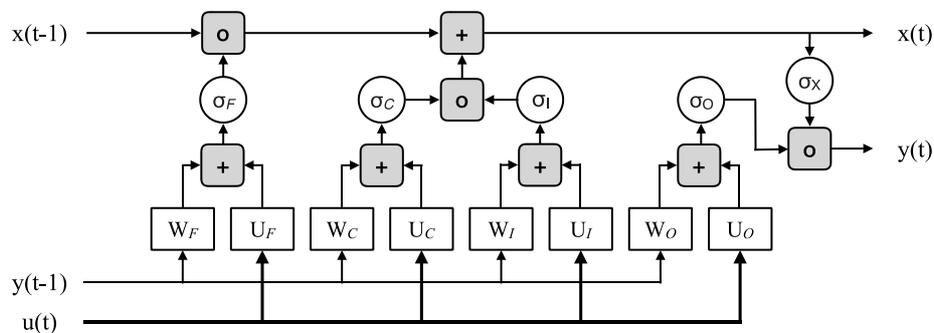


Figure 89 Réseau de neurones de type LSTM

Les équations régissant ce neurone sont données ci-dessous, tout d'abord, le signal de sortie :

$$y(t) = O(t) \times \sigma_x(x(t)) \quad (49)$$

Le signal de sortie de la porte de récurrence est donné par l'équation suivante :

$$O(t) = \sigma_o(U_o u(t) + W_o y(t-1) + b_o) \quad (50)$$

L'état du réseau est calculé de la manière suivante :

$$x(t) = F(t) \times x(t-1) + I(t) \times C(t) \quad (51)$$

Le signal de sortie de la porte d'oubli est calculé comme ceci :

$$F(t) = \sigma_F(U_F u(t) + W_F x(t) + b_f) \quad (52)$$

Enfin, le signal de sortie de la porte des entrées est obtenu par cette équation :

$$I(t) = \sigma_I(U_I u(t) + W_I x(t) + b_i) \quad (53)$$

Les paramètres et hyperparamètres d'un tel modèle sont les suivants :  $\sigma_{F,I,C,O,X}$  sont les fonctions d'activations,  $U_{F,I,C,O} \in \mathbb{R}^{u \times n}$  sont les poids de dimension  $n$  associés aux entrées  $u$ ,  $W_{F,I,C,O} \in \mathbb{R}^{[u \times n],[u \times n],[u \times n],[o \times n]}$  sont les poids associés au signal de récurrence des entrées, des états et des sorties,  $x(t) \in \mathbb{R}^{u \times n}$  est l'état dynamique du réseau et  $b_{o,f,i}$  sont les biais des différentes portes de régulations.

# Annexe A2 Les algorithmes d'optimisations

## A2.1 L'optimisation des paramètres

### Descente du gradient

La descente du gradient (« Gradient Descent » ou GD) est une méthode itérative de minimisation du premier ordre. Suivant un gradient négatif, l'algorithme dirige le modèle à atteindre un minima de la fonction coût. La fonction coût couramment utilisée est de la forme quadratique suivante :

$$J(k) = \frac{1}{2} \sum_{i=1}^o (cible^i - estimé^i)^2 \quad (54)$$

L'amplitude et le sens des ajustements sont obtenus par la direction opposée du gradient :

$$w(k + 1) = w(k) + \Delta w \quad (55)$$

$$\Delta w = -\eta \frac{\partial J}{\partial w_j} \quad (56)$$

où  $\eta$  est un taux d'apprentissage qui pondère l'amplitude de l'ajustement. L'apprentissage par rétropropagation (« Back Propagation » ou BP) est une technique d'évaluation et d'ajustement de paramètres qui se décompose en deux étapes. La première étape est une passe en avant de la base d'apprentissage afin d'obtenir la contribution à l'erreur de chaque neurone. La deuxième étape est une passe en arrière afin d'ajuster chaque couche de neurones suivant leurs contributions. L'apprentissage peut être répété plusieurs fois sur un même jeu de données suivant un nombre de cycles prédéfini, cette opération permet d'affiner l'ajustement des paramètres.

La descente du gradient incrémentale (appelée également DG stochastique) est une variante adaptée à l'application en ligne, où l'ajustement a lieu à chaque itération. Ainsi l'erreur de modélisation est immédiatement prise en compte. Cette approche directe fait apparaître un phénomène d'instabilité autour de la cible d'apprentissage. Pour corriger cela, une sélection appropriée du taux d'apprentissage et la mise en place d'une récurrence du gradient permettent d'améliorer la stabilisation de l'apprentissage.

### Moindres carrés récurrents

La méthode des moindres carrés (“Least Square” ou LS) est une approche de régression linéaire globale. Dans une situation idéale, supposant la connaissance des poids neuronaux parfaits et l’intégralité d’un jeu de données  $N$ , un cycle de calcul est obtenu de la manière suivante :

$$Y_{cible}(N) = W^{out}(N)X(N) \quad (57)$$

où  $Y_{cible}(N) = [y(1), y(2), \dots, y(N)] \in \mathbb{R}^{m \times N}$  sont les sorties cibles et  $X(N) = [x(1), x(2), \dots, x(N)]^T \in \mathbb{R}^{N \times o}$  sont l’ensemble des activités de la couche cachée. Si la couche de sortie est idéale, la solution au problème d’optimisation peut être résolue par une approche quadratique :

$$W^{out*}(N) = \underset{W(N)}{\operatorname{argmin}} S(W(N)) \quad (58)$$

où  $W^{out*}(N)$  est l’estimation de la matrice de sortie idéale,  $\operatorname{argmin}$  se réfère aux arguments obtenant le minimum de la fonction et  $S(W) = \|Y(N) - XW\|^2$  est la fonction objective. Les poids neuronaux sont alors obtenus par la résolution de l’équation inverse :

$$\begin{aligned} W^{out*}(N) &= Y_{cible}(N)X(N)P(N) \\ P(N) &= (X(N)X^T(N))^{-1} \end{aligned} \quad (59)$$

où  $P(N)$  est une matrice de covariance de l’erreur d’estimation et l’opération  $X^T$  est la transposée de  $X$ . Cette méthode hors-ligne permet l’estimation d’une couche de sortie idéale.

L’opération matricielle  $XX^T$  est quelque peu coûteuse en charges de calcul. Pour la mise en place d’une approche en ligne une estimation de celle-ci est possible. Ce qui amène à la méthode des moindres carrés récurrents (« Recursive Least Square » ou RLS). Cette méthode locale est construite sur la dérivation de la méthode LS. Sa démonstration a été faite dans les travaux de [Bo & Zhang \(2018\)](#). La matrice de sortie est donc de la forme suivante :

$$W^{out}(k) = W^{out}(k-1) + \frac{P(k)x(k)e(k)}{1 - x^T(k)P(k)x(k)} \quad (60)$$

La matrice de covariance de l’erreur d’estimation  $P(k)$  est donnée de la manière suivante :

$$\begin{aligned} P(k) &= [P^{-1}(k-1) + x^T(k)x(k)]^{-1} \\ &= P(k-1) \frac{P(k-1)x(k)x^T(k)P(k-1)}{1 + x^T(k)P(k-1)x(k)} \end{aligned} \quad (61)$$

$P(k) \in \mathbb{R}^{n \times n}$  est initialisée sur une matrice zéro.

### Évolution génétique

L’évolution génétique est basée sur une méthode d’échantillonnage probabiliste qui consiste à la génération aléatoire d’une population et à une sélection rigoureuse de candidats acceptables. Plusieurs itérations interviennent dans le processus, également nommées générations. Située dans un espace restreint, la première génération aléatoire permet de balayer

statistiquement l'ensemble des solutions par une population de candidats  $P_{gen} = (W^1, W^2, \dots, W^{ca})$  avec  $W^{ca} \in \mathbb{R}^{1 \times o}$ . À la suite de cela, les meilleurs candidats fournissant les meilleurs résultats sont retenus. Un croisement des poids neuronaux et une mutation de ces candidats sont ensuite effectués. Des candidats aléatoires supplémentaires peuvent être rajoutés à cet instant pour explorer l'espace des possibles. Une nouvelle population est ainsi obtenue, les candidats sont à nouveau évalués, et ainsi de suite jusqu'à l'obtention d'un candidat satisfaisant à un critère défini.

## A2.2 L'optimisation des hyperparamètres

La méthode essais-erreurs est longtemps restée la seule approche pour optimiser les hyperparamètres. Une boucle est mise en place au niveau extérieur de la boucle d'apprentissage et permettait l'observation de l'influence de ces derniers. Or, seul le concepteur développait les connaissances requises pour le choix de ces valeurs.

### Recherche itérative, essais-erreurs en ligne

Semblable à la méthode hors ligne d'essais-erreurs, une approche itérative a été menée sur le contrôle non linéaire par [Jia, Li, Wang & Ding \(2016\)](#). La méthode consiste à évaluer la performance d'un modèle « Extreme Learning Machine » ou ELM, et d'augmenter un par un le nombre de neurones contenus dans sa couche cachée, jusqu'à la satisfaction d'une condition de précision  $\|f(t) - f_{cons}\| < \epsilon$ , avec comme distance  $\epsilon > 0$ . Le modèle ELM s'apprête bien à cette démarche, elle ne possède qu'une seule couche cachée et les poids des connexions sont générés aléatoirement. Une particularité est à noter, lors de l'expansion unitaire de la couche cachée le processus d'ajustement des poids neuronaux est contraint à être mis en pause le temps d'une itération.

### Recherche quadrillée aléatoire

L'algorithme quadrillé aléatoire est semblable à l'algorithme génétique hormis l'absence de croisement et de mutations des candidats. Comme exemple, une optimisation à deux hyperparamètres permet de tester différentes combinaisons réparties sur l'espace en deux dimensions jusqu'à l'obtention d'une tendance. L'avantage de cette méthode est de pouvoir quantifier la prépondérance de chacun de ces deux hyperparamètres. Les recherches aléatoires et itératives sont les plus gourmandes en efforts de calcul, ils sont à privilégier par rapport aux méthodes suivantes si la situation ne fait intervenir que peu d'hyperparamètres.

### Optimisation bayésienne

L'optimisation bayésienne (« Bayesian Optimization ») est une approche probabiliste basée sur l'inférence bayésienne via la connaissance historique des événements précédents. Sur un espace borné, des observations dispersées sont utilisées pour déterminer la distribution de probabilité des points inconnus. Cette distribution est obtenue par une régression et un processus gaussien, en d'autres mots, par l'estimation d'une valeur moyenne et de la dispersion

de l'écart-type autour de cette moyenne. Une fonction d'acquisition est effectuée sur cette distribution, elle décrit le potentiel d'amélioration. À un point donné, une incertitude de performance peut donc être adressée. La précision de l'approche dépend essentiellement du nombre d'observations historique, de la régression, mais également des paramétrages gaussiens. Pour une approche adaptative, l'historique des observables devrait suivre un fenêtrage donné afin d'éliminer ou écraser les valeurs ne reflétant plus la dynamique du système.

### Méthode hyperbande

La méthode hyperbande est une variante de la recherche aléatoire qui se focalise sur la vitesse d'exécution. Une étude récente (Li et al., 2016) affirme une rapidité d'exécution de 5 à 30 fois plus rapide qu'une optimisation bayésienne. Pour obtenir de tels résultats, elle se base sur le principe d'encadrement convergent de l'espace des possibles. Deux entrées sont nécessaires pour définir l'algorithme,  $R$  le nombre d'itérations au cours d'une manche et  $\eta$  la proportion d'encadrement. Une configuration de paramètres est évaluée durant  $R$  nombres d'itérations. À la fin de la manche, suivant les résultats obtenus, le domaine de la distribution se retrouve borné suivant la proportion définie  $\eta$ . Le processus est répété jusqu'à l'obtention d'un espace insécable résultant d'une optimisation effective.

### Arbre de décision par la fenêtre de Parzen

L'arbre de décision par la fenêtre de Parzen (« Tree-structured Parzen Estimators » ou TPE) est une méthode se rapprochant de la méthode bayésienne. Alors que l'optimisation bayésienne s'intéresse à l'estimation de la probabilité d'une combinaison non observée  $p(x)$ , l'optimisation TPE s'intéresse, quant à elle, à l'estimation d'appartenance d'une combinaison. Autrement dit, l'approche ne s'intéresse pas à l'estimation directe d'un meilleur candidat et de sa grandeur, mais, en sachant une appartenance initiale, l'approche vise à orienter le modèle vers une position appartenant à une classe estimée meilleure. Sur un ensemble d'échantillons uniformément répartis, deux classes d'appartenance sont établies suivant un rapport défini de 20 % de candidats acceptables  $L \in \mathbb{R}$ , et 80 % autres  $G \in \mathbb{R}$ . Un nombre commun de candidats sont échantillonnés sur ces deux classes. En utilisant une estimation de densité par la fenêtre de Parzen, des gaussiennes sont construites sur les candidats échantillonnés  $l(x)$  et  $g(x)$ . Les meilleurs candidats sont ainsi positionnés sur la zone haute de la gaussienne  $l(x)$  et les mauvais candidats sur la zone basse de  $g(x)$ . Une fonction décrivant le potentiel d'amélioration  $EI(x) = \frac{l(x)}{g(x)}$  est ainsi calculée et sa valeur maximale est utilisée comme meilleur candidat probable. Le processus est ensuite répété jusqu'à la satisfaction d'un critère.

# Annexe B La sélection de la structure de contrôle

La justification des notations effectuées pour la sélection de la structure de contrôle est établie dans cette annexe. Dans un souci de lisibilité, un rappel des critères de sélection est donné ci-dessous :

## Critères objectifs :

- C1 : L'originalité scientifique, le potentiel innovateur sous le nombre de publications.
- C2 : L'absence de modèle de connaissance, de modèle physique.
- C3 : La place du réseau de neurones, le nombre mis en place.
- C4 : L'anticipation du contrôleur, l'intégration de données futures.
- C5 : L'absence de préapprentissage.

## Critères subjectifs :

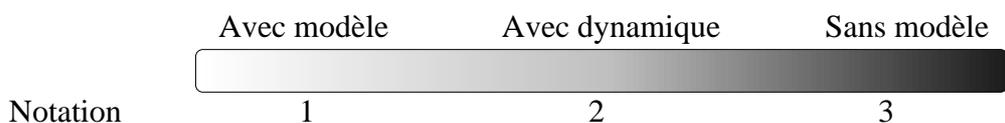
- C6 : Les performances immédiates.
- C7 : Les performances de contrôle.
- C8 : Le minimum d'effort de calcul.
- C9 : La simplicité d'intervention, de mise à jour par l'utilisateur.

La méthode d'obtention des notations est détaillée ci-dessous :

Le critère objectif C1, l'originalité scientifique, est obtenu suivant le nombre de publications présent dans l'état de l'art, pages 35 à 53.



Le critère objectif C2, l'absence de modèle, est obtenu suivant la nécessité de connaître un modèle physique ou non. De même pour la connaissance des dynamiques du système pour l'optimisation des paramètres.



Le critère objectif C3, la place du réseau de neurones, est obtenu suivant la visualisation des structures de contrôles pour l'identification et le décompte des réseaux de neurones. Une note est apportée suivant le rôle de ces derniers, 3 s'ils délivrent un signal de commande, 2 s'ils délivrent une partie du signal de commande et 1 s'ils servent d'observateur. Une appréciation (+1) est apportée suivant le nombre de modèles mis en place.

	Observateur	Commande partielle	Commande complète
Notation	1	2	3

Le critère objectif C4, l'anticipation, est obtenu suivant la présence ou non d'estimations futures dans le processus de correction. Une appréciation (+1) est apportée suivant l'horizon de prévision.

	t	t+1	t+1 avec adaptation
Notation	1	2	3

Le critère objectif C5, l'absence de préapprentissage hors ligne, est obtenu suivant la nécessité d'effectuer ou non un préapprentissage des réseaux de neurones.

	Obligatoire	Recommandé	Pas nécessaire
Notation	1	2	3

Le critère subjectif C6, les performances immédiates, est obtenu suivant la capacité du contrôleur fonctionnel à fournir au démarrage une convergence effective, sans oscillations et dépassements.

	Incapable	Lent	Rapide	Immédiat
Notation	1	2	3	4

Le critère subjectif C7, les performances de contrôle, est obtenu suivant l'appréciation des performances du contrôleur au regard des besoins de la pile PEMFC en termes de précision, temps de réponse, stabilité et rejet de perturbations.

	1	2	3	4 besoins
Notation	1	2	3	4

Le critère subjectif C8, le minimum d'effort de calcul, est obtenu suivant la présence ou non de calculs complexes.

	Complexe	Difficile	Modéré	Simple
Notation	1	2	3	4

Le critère subjectif C9, la simplicité d'intervention, est obtenu selon la simplicité de redéfinition du contrôleur. Le barème de notation est le même que le critère C8.

La notation des solutions est la suivante :

– **Le contrôleur inverse :**

- **C1** : Deux études utilisent cette méthode dans la littérature, dont un est soumis à des perturbations en bruit blanc  $\Rightarrow 2$  (3-1)
- **C2** : Aucune connaissance théorique n'est requise  $\Rightarrow 3$
- **C3** : La place du réseau de neurones est centrale et il délivre directement le signal de commande  $\Rightarrow 3$
- **C4** : La commande est de nature anticipatrice si la consigne future est connue  $\Rightarrow 1$
- **C5** : Un apprentissage préalable est obligatoire pour la phase d'initialisation  $\Rightarrow 1$
- **C6** : L'approche inverse nécessite du temps pour obtenir un contrôle immédiat, même sur un modèle ayant reçu un préapprentissage  $\Rightarrow 1$
- **C7** : Pas de présence d'oscillations ni d'oscillations sur le contrôle de stœchiométrie, stabilité également éprouvée  $\Rightarrow 3$
- **C8** : Un seul modèle RN est soumis à un apprentissage  $\Rightarrow 4$
- **C9** : Un accès aux paramètres du modèle est envisageable et leurs modifications restent aisées  $\Rightarrow 3$

– **Le contrôleur par rétroaction :**

- **C1** : Trois études utilisent cette méthode dans la littérature  $\Rightarrow 3$
- **C2** : Aucune connaissance théorique n'est requise  $\Rightarrow 3$
- **C3** : La place du réseau de neurones est centrale et il délivre directement le signal de commande  $\Rightarrow 3$
- **C4** : Aucune information de l'état futur, mais l'information ne peut être connue si un estimateur est mis en place  $\Rightarrow 1$
- **C5** : Un apprentissage préalable est obligatoire pour la phase d'initialisation  $\Rightarrow 1$
- **C6** : Un contrôleur ayant reçu un préapprentissage devrait être capable d'obtenir de bonnes performances initiales  $\Rightarrow 2$
- **C7** : Pas de présence d'oscillations ni d'oscillations sur le contrôle de stœchiométrie, stabilité également éprouvée  $\Rightarrow 3$
- **C8** : Un seul modèle RN est soumis à un apprentissage  $\Rightarrow 4$
- **C9** : Un accès aux paramètres du modèle est envisageable et leurs modifications restent aisées  $\Rightarrow 3$

– **Le contrôleur hybride :**

- **C1** : Trois études utilisent cette méthode dans la littérature, dont un est testé sous défaillance du compresseur  $\Rightarrow 2$  (3-1)
- **C2** : Le contrôleur traditionnel doit être optimisé  $\Rightarrow 2$
- **C3** : Le réseau de neurones est épaulé par un contrôleur traditionnel  $\Rightarrow 2$
- **C4** : Aucune information de l'état futur à l'heure actuelle  $\Rightarrow 1$

- **C5** : Le contrôleur traditionnel permet de ne pas avoir de préapprentissage sur le réseau de neurones ⇒ 2
- **C6** : Le contrôleur traditionnel permet d'obtenir rapidement une commande valable ⇒ 3
- **C7** : Bonne robustesse sur le contrôle de tension, commande fluide et temps de réponse rapide ⇒ 3
- **C8** : L'effort de calcul correspond à l'exécution du contrôleur traditionnel et à l'adaptation du réseau de neurones ⇒ 3
- **C9** : L'accès aux paramètres des deux contrôleurs est possible, dépendamment de leurs natures. La redéfinition des deux contrôleurs est plus fastidieuse que les contrôleurs précédents ⇒ 2

– **Le contrôleur par programmation dynamique :**

- **C1** : Une étude développe une approche semblable dans la littérature, mais la méthode en tant que telle appliquée à la pile PEMFC n'est pas publiée ⇒ 4
- **C2** : Aucune connaissance théorique n'est requise ⇒ 3
- **C3** : Trois réseaux de neurones sont implémentés en ayant chacun des rôles spécifiques ⇒ 4 (3+1)
- **C4** : Un modèle d'estimation future est implémenté dans le processus de contrôle et sa sortie sert à l'adaptation du modèle contrôleur ⇒ 3
- **C5** : Un préapprentissage hors ligne n'est pas obligatoire, mais le système doit être stable pour l'initialisation des paramètres ⇒ 1
- **C6** : La détermination de la commande optimale est itérative ⇒ 1
- **C7** : Réduction d'erreur de position sur le contrôle de tension ⇒ 1
- **C8** : L'effort de calcul est important ⇒ 1
- **C9** : Les trois réseaux de neurones restent accessibles, la redéfinition du contrôleur est aisée ⇒ 3

– **Le contrôleur proportionnel intégral dérivé :**

- **C1** : Sept études utilisent cette méthode, dont certains réalisés sous des conditions de défauts ⇒ 1
- **C2** : Des connaissances sont requises pour l'estimation initiale des paramètres du contrôleur PID ⇒ 2
- **C3** : Le réseau de neurones sert d'estimateur pour les paramètres PID, voire de contrôleur direct ⇒ 2
- **C4** : Des modèles servent d'estimateurs futurs du système et une étude utilise notamment cette fonctionnalité pour l'adaptation anticipée du contrôleur ⇒ 2
- **C5** : Le contrôleur traditionnel permet de ne pas avoir de préapprentissage sur le réseau de neurones ⇒ 3
- **C6** : Les performances doivent être immédiates par l'intermédiaire de la loi de commande traditionnelle, des oscillations peuvent être présentes avant l'ajustement du réseau de neurones ⇒ 3

- **C7** : Réduction des dépassements et oscillations sur le contrôle de température, temps de réponse rapide sur le contrôle de tension, réduction de l'erreur de position sur le contrôle stœchiométrique et robuste aux perturbations ⇒ 4
- **C8** : L'effort de calcul correspond au réseau de neurones, à son adaptation et à la loi de commande PID ⇒ 3
- **C9** : L'accès aux paramètres du contrôleur et du réseau de neurones est aisé, deux optimisations doivent avoir lieu ⇒ 2

– **Le contrôleur par retour d'état :**

- **C1** : Trois études utilisent cette méthode dans la littérature, dont certains sont soumis à des incertitudes paramétriques ou à des défauts auxiliaires ⇒ 2 (3-1)
- **C2** : Le contrôleur se construit à partir d'un modèle de connaissance, un modèle physique ⇒ 1
- **C3** : Le réseau de neurones peut servir de compensateur en agissant sur la consigne ⇒ 1
- **C4** : Un modèle d'estimation futur sert au calcul de la correction ⇒ 2
- **C5** : Le contrôleur traditionnel permet de ne pas avoir de préapprentissage sur le réseau de neurones ⇒ 2
- **C6** : Les performances doivent être immédiates par l'intermédiaire de la loi de commande traditionnelle ⇒ 4
- **C7** : Temps de réponse rapide, bonne précision et faibles dépassements sur le contrôle stœchiométrique ⇒ 3
- **C8** : L'effort de calcul correspond au réseau de neurones, à son adaptation et à la loi de commande par retour d'état ⇒ 3
- **C9** : Une intervention sur ce contrôleur est complexe, car nécessite une totale redéfinition ⇒ 1

– **Le contrôleur par rétrogradation :**

- **C1** : Une étude utilise cette méthode dans la littérature ⇒ 4
- **C2** : Le contrôleur se construit à partir d'un modèle de connaissance, un modèle physique ⇒ 1
- **C3** : Le réseau de neurones sert d'estimateur de variables non mesurables ou inconnues ⇒ 1
- **C4** : Aucun modèle d'estimation futur ⇒ 1
- **C5** : Le contrôleur traditionnel permet de ne pas avoir de préapprentissage sur le réseau de neurones ⇒ 2
- **C6** : Les performances doivent être immédiates par l'intermédiaire de la loi de commande traditionnelle ⇒ 4
- **C7** : Temps de réponse rapide, bonne précision, faibles dépassements et stabilité garantie sur le contrôle stœchiométrique ⇒ 4
- **C8** : L'effort de calcul correspond au réseau de neurones, à son adaptation et à la loi de commande par rétrogradation ⇒ 3

- **C9** : Une intervention sur ce contrôleur est complexe, car nécessite une totale redéfinition ⇒ 1
  
- **Le contrôleur par mode glissant :**
  - **C1** : Aucune étude n'utilise cette méthode dans l'état actuel de la littérature sur le contrôle adaptatif neuronal du cœur des piles PEMFC ⇒ 4
  - **C2** : Le contrôleur se construit à partir d'un modèle de connaissance, un modèle physique ⇒ 1
  - **C3** : Le réseau de neurones sert d'estimateur de variables non mesurables ou inconnues ⇒ 1
  - **C4** : Aucun modèle d'estimation futur ⇒ 1
  - **C5** : Le contrôleur traditionnel permet de ne pas avoir de préapprentissage sur le réseau de neurones ⇒ 2
  - **C6** : La convergence et la stabilisation sur la surface de glissement sont itératives ⇒ 2
  - **C7** : Pas de résultat sur le contrôle neuronal adaptatif PEMFC ⇒ 1
  - **C8** : L'effort de calcul correspond au réseau de neurones, à son adaptation et à la loi de commande ⇒ 3
  - **C9** : Une intervention sur ce contrôleur est complexe, car nécessite une totale redéfinition ⇒ 1
  
- **Le contrôleur par commande prédictive :**
  - **C1** : Une seule étude utilise le contrôleur MPC neuronale adaptatif sur la PEMFC ⇒ 4
  - **C2** : Nécessite d'un modèle physique ⇒ 1
  - **C3** : Le réseau de neurones sert d'observateur sur toute une plage future d'états ⇒ 2
  - **C4** : L'estimation de la commande considère les états futurs sur une fenêtre donnée ⇒ 4
  - **C5** : Le contrôleur traditionnel permet de ne pas avoir de préapprentissage sur le réseau de neurones, mais il doit être effectué en ligne ⇒ 2
  - **C6** : La convergence et la stabilisation sur la consigne vont dépendre de la contrainte des signaux de commandes ⇒ 3
  - **C7** : Pas de résultat sur le contrôle neuronal adaptatif PEMFC ⇒ 1
  - **C8** : L'effort de calcul correspond au réseau de neurones, à son adaptation, à la loi de commande et au processus d'optimisation ⇒ 2
  - **C9** : Une intervention sur ce contrôleur est complexe, car nécessite une totale redéfinition ⇒ 1

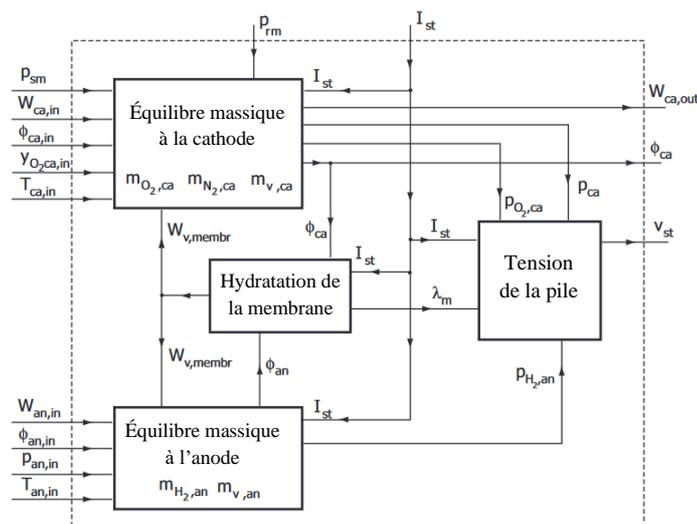
# Annexe C Le modèle physique PEMFC

Le modèle présenté ici sert aux tests du contrôleur ADP durant la phase de simulation.

## Les équations dynamiques

Le fonctionnement du cœur de la pile est représenté par une modélisation paramétrique sous forme de blocs, visible à la [Figure 90](#). Elle est obtenue par le développement de réactions physiques composées des parties fluidiques, électrique, et thermique. Les sous-systèmes, tels que l'humidificateur, le refroidissement, le compresseur, les collecteurs d'alimentations ou de sorties ne sont pas inclus. Une liste des paramètres utilisés dans la conception du modèle PEMFC est fournie au [Tableau 36](#). L'ensemble des équations provient des travaux de [Wu & Zhou \(2016\)](#), [Jay Tawee Pukrushpan \(2003\)](#), [Matraji et al. \(2012\)](#), [Liso et al. \(2014\)](#) et [Vasu & Tangirala \(2008\)](#). Des hypothèses sont considérées comme suit :

- Les volumes des multiples des chambres anodiques et cathodiques sont regroupés en un seul volume anodique et volume cathodique.
- Les composants de la pile sont supposés isothermes, à l'instant  $t$  la température est uniforme.
- L'eau peut être présente sous forme de vapeur et de liquide dans la pile.
- La distribution en tension est uniforme dans la pile, chaque cellule délivre la même tension.



**Figure 90** Schéma bloc de la pile (Pukrushpan, 2003)

**Tableau 36** Liste des paramètres utilisés pour le modèle (Wu and Zhou, 2016)

Symbole	Désignation	Valeur	Unité
$N_{cell}$	Nombres de cellules dans l'empilement	381	
$R$	Constante universelle des gaz parfaits	8.314 462	J mol <sup>-1</sup> K <sup>-1</sup>
$F$	Constante de Faraday	96 485.332 9	C mol <sup>-1</sup>
$p_{atm}$	Pression atmosphérique	101 325	Pa
$T_{atm}$	Température atmosphérique	25+273.15	K
$\phi_{atm}$	Humidité relative atmosphérique	0.5	
$\phi_{an,in}$	Humidité relative à l'anode	1.0	
$k_{ca,in}$	Constante de l'orifice d'entrée cathodique	0.3629e <sup>-5</sup>	kg Pa <sup>-1</sup> s <sup>-1</sup>
$k_{an,in}$	Constante de l'orifice d'entrée anodique	0.21e <sup>-5</sup>	kg Pa <sup>-1</sup> s <sup>-1</sup>
$k_{ca,out}$	Constante de l'orifice de sortie cathodique	2.1e <sup>-4</sup>	kg Pa <sup>-1</sup> s <sup>-1</sup>
$k_{an,out}$	Constante de l'orifice de sortie anodique	4.5e <sup>-4</sup>	kg Pa <sup>-1</sup> s <sup>-1</sup>
$M_{H_2}$	Masse molaire de l'hydrogène	0.002 015 88	kg mol <sup>-1</sup>
$M_{O_2}$	Masse molaire de l'oxygène	0.032	kg mol <sup>-1</sup>
$M_{N_2}$	Masse molaire de l'azote	0.028 013 4	kg mol <sup>-1</sup>
$M_v$	Masse molaire de la vapeur d'eau	0.018 014 88	kg mol <sup>-1</sup>
$R_{H_2}$	Constante individuelle de l'hydrogène	4 124.3	J kg <sup>-1</sup> K <sup>-1</sup>
$R_{O_2}$	Constante individuelle de l'oxygène	259.8	J kg <sup>-1</sup> K <sup>-1</sup>
$R_{N_2}$	Constante individuelle de l'azote	296.8	J kg <sup>-1</sup> K <sup>-1</sup>
$R_v$	Constante individuelle de la vapeur d'eau	461.5	J kg <sup>-1</sup> K <sup>-1</sup>
$V_{ca}$	Volume de la cathode	0.01	m <sup>3</sup>
$V_{an}$	Volume de l'anode	0.005	m <sup>3</sup>
$\rho_{m,dry}$	Densité massique de la membrane à sec	0.002	kg cm <sup>-3</sup>
$M_{m,dry}$	Poids équivalent à sec de la membrane	1.1	kg mol <sup>-1</sup>
$A$	Surface active de la membrane	280	cm <sup>2</sup>
$t_m$	Épaisseur de la membrane	0.01275	cm
$J_{max}$	Densité de courant limite	2.2	À cm <sup>-2</sup>
$C_{p,H_2}$	Capacité thermique de l'hydrogène	14 410	J K <sup>-1</sup> kg <sup>-1</sup>
$C_{p,O_2}$	Capacité thermique de l'oxygène	918.13	J K <sup>-1</sup> kg <sup>-1</sup>
$C_{p,N_2}$	Capacité thermique de l'azote	1 040	J K <sup>-1</sup> kg <sup>-1</sup>
$C_{p,l}$	Capacité thermique de l'eau liquide	4 184	J K <sup>-1</sup> kg <sup>-1</sup>
$C_{p,v}$	Capacité thermique de la vapeur d'eau	2 013.3	J K <sup>-1</sup> kg <sup>-1</sup>
$T_{an,in}$	Température en entrée anodique	60+273.15	K
$T_{ca,in}$	Température en entrée cathodique	60+273.15	K
$T_0$	Température à la pression standard	47+273.15	K
$\Delta H$	Enthalpie de combustion de l'hydrogène	2.855e <sup>5</sup>	J mol <sup>-1</sup>
$M_s$	Masse de l'empilement de cellule	17.5	kg
$C_s$	Capacité thermique de l'empilement	4 000	J K <sup>-1</sup> kg <sup>-1</sup>
$K$	Coefficient de transfert thermique de l'empilement	5	W m <sup>-2</sup> K <sup>-1</sup>

### L'équilibre massique à la cathode

Les pressions partielles dynamiques de l'oxygène, de l'azote et de l'eau cathodique sont déduites des bilans massiques suivants :

$$\frac{dp_{O_2}}{dt} = \frac{R_{O_2} T_{st}}{V_{ca}} (W_{O_2,in} - W_{O_2,rea} - W_{O_2,out}) \quad (62)$$

$$\frac{dp_{N_2}}{dt} = \frac{R_{N_2} T_{st}}{V_{ca}} (W_{N_2,in} - W_{N_2,out}) \quad (63)$$

$$\frac{dp_{w,ca}}{dt} = \frac{R_v T_{st}}{V_{ca}} (W_{v,ca,in} - W_{v,ca,out} + W_{v,mbr} + W_{v,gen}) \quad (64)$$

La pression à la sortie de la cathode est définie comme suit  $p_{ca} = p_{O_2} + p_{N_2} + p_{w,ca}$ . Les débits massiques d'entrée en oxygène, azote et eau sont donnés par les fractions massiques suivantes :

$$W_{O_2,in} = \frac{x_{O_2} M_{O_2} k_{ca,in} (p_{ca,in} - p_{ca})}{(x_{O_2} M_{O_2} + x_{N_2} M_{N_2}) (1 + \Omega_{atm})} \quad (65)$$

$$W_{N_2,in} = \frac{x_{N_2} M_{N_2} k_{ca,in} (p_{ca,in} - p_{ca})}{(x_{O_2} M_{O_2} + x_{N_2} M_{N_2}) (1 + \Omega_{atm})} \quad (66)$$

$$W_{v,ca,in} = \frac{\Omega_{atm} k_{ca,in} (p_{ca,in} - p_{ca})}{1 + \Omega_{atm}} + W_{v,inj} \quad (67)$$

où  $W_{v,inj}$  est le débit massique d'eau injecté par l'humidificateur. L'humidité relative de l'air ambiant est donnée comme suit :

$$\Omega_{atm} = \frac{M_v}{x_{O_2} M_{O_2} + x_{N_2} M_{N_2}} \frac{\phi_{atm} p_{sat}(T_{atm})}{p_{atm} - \phi_{atm} p_{sat}(T_{atm})} \quad (68)$$

Les débits massiques de sortie en oxygène, azote et eau sont donnés par les fractions massiques suivantes :

$$W_{ca,out} = v_{ca,open} \frac{k_{ca,out} \sqrt{p_{ca} - p_{atm}}}{p_{O_2} M_{O_2} + p_{N_2} M_{N_2} + p_{w,ca} M_v} \quad (69)$$

$$W_{O_2,out} = p_{O_2} M_{O_2} W_{ca,out} \quad (70)$$

$$W_{N_2,out} = p_{N_2} M_{N_2} W_{ca,out} \quad (71)$$

$$W_{v,ca,out} = p_{w,ca} M_v W_{ca,out} \quad (72)$$

où  $0 \leq v_{ca,open} \leq 1$  représente l'ouverture de la valve de sortie cathodique. Le débit massique d'oxygène consommé, réagit est donné par :

$$W_{O_2,rea} = M_{O_2} \frac{N_{cell} I_{st}}{4F} \quad (73)$$

Le débit massique d'eau générée à la cathode est donné par :

$$W_{v,gen} = M_v \frac{N_{cell} I_{st}}{2F} \quad (74)$$

Lorsque l'humidité relative du gaz dépasse la limite de condensation, la vapeur se condense sous forme liquide. La pression de vapeur à la cathode s'écrit comme suit :

$$P_{v,ca} = \begin{cases} P_{sat}(T_{ca}) & (P_{w,ca} \geq P_{sat}(T_{ca})) \\ P_{w,ca} & (P_{w,ca} < P_{sat}(T_{ca})) \end{cases} \quad (75)$$

### Le modèle d'hydratation de la membrane

Le débit massique d'eau au travers de la membrane est donné par :

$$W_{v,mbr} = M_v A_{fc} N_{cell} \left( n_d \frac{i_{fc}}{F} - D_w \frac{c_{v,ca} - c_{v,an}}{t_m} \right) \quad (76)$$

où  $n_d$  est le coefficient de résistance électro-osmotique,  $D_w$  est le coefficient de diffusion d'eau dans la membrane,  $c_{v,ca}$  et  $c_{v,an}$  sont les concentrations d'eau à la surface cathodique et anodique. Le coefficient de résistance électro-osmotique est calculé comme suit :

$$n_d = 0.0029\lambda_m^2 + 0.05\lambda_m - 3.4 \times 10^{-19} \quad (77)$$

Le coefficient de diffusion d'eau dans la membrane est obtenu par :

$$D_w = \begin{cases} 10^{-6} & \lambda_m < 2 \\ 10^{-6}(1 + 2(\lambda_m - 2)) & 2 \leq \lambda_m \leq 3 \\ 10^{-6}(3 - 1.67(\lambda_m - 3)) & 3 < \lambda_m < 4.5 \\ 1.25 \times 10^{-6} & \lambda_m \geq 4.5 \end{cases} \quad (78)$$

$$D_w = D_\lambda \exp\left(2416 \left(\frac{1}{303} - \frac{1}{T_{fc}}\right)\right)$$

Le contenu en eau de la membrane est défini comme suit :

$$\lambda_i = \begin{cases} 0.043 + 17.81a_i - 39.85a_i^2 + 36a_i^3 & 0 \leq a_i \leq 1 \\ 14 + 1.4(a_i - 1) & 1 < a_i \end{cases} \quad (79)$$

où l'indice  $i$  est soit la cathode  $\lambda_{ca}$  ou l'anode  $\lambda_{an}$ . Le contenu moyen en eau de la membrane  $\lambda_m$  est déduit à partir des activités moyennes d'eau entre la cathode et l'anode, ce qui est exprimé par :

$$a_m = \frac{a_{ca} + a_{an}}{2} \quad (80)$$

L'activité de la vapeur d'eau à la surface de la membrane à la cathode et à l'anode est donnée par :

$$a_i = \frac{p_{v,i}}{p_{sat}(T_i)} \quad (81)$$

La concentration en eau à la surface de la membrane à la cathode et à l'anode est donnée par :

$$c_{v,i} = \frac{\rho_{m,dry}}{M_{m,dry}} \lambda_i \quad (82)$$

### L'équilibre massique à l'anode

Les pressions partielles dynamiques d'hydrogène et de l'eau anodique sont déduites des bilans massiques suivants :

$$\frac{dH_2}{dt} = \frac{R_{H_2} T_{st}}{V_{an}} (W_{H_2,in} - W_{H_2,rea} - W_{H_2,out}) \quad (83)$$

$$\frac{dP_{v,an}}{dt} = \frac{R_v T_{st}}{V_{an}} (W_{v,an,in} - W_{v,an,out} - W_{v,mbr}) \quad (84)$$

La pression à la sortie de l'anode est définie comme suit  $p_{an} = p_{H_2} + p_{v,an}$ . Les débits massiques d'entrée en hydrogène et eau sont donnés par les fractions massiques suivantes :

$$W_{H_2,in} = \frac{k_{an,in}(p_{an,in} - p_{an})}{1 + \Omega_{an,in}} \quad (85)$$

$$W_{v,an,in} = \frac{\Omega_{an,in} k_{an,in}(p_{an,in} - p_{an})}{1 + \Omega_{an,in}} \quad (86)$$

L'humidité relative de l'hydrogène est donnée comme suit :

$$\Omega_{an,in} = \frac{M_v}{M_{H_2}} \frac{\phi_{atm} p_{sat}(T_{atm})}{p_{atm} - \phi_{atm} p_{sat}(T_{atm})} \quad (87)$$

Les débits massiques de sortie en hydrogène et eau sont donnés par les fractions massiques suivantes :

$$W_{an,out} = v_{an,open} \frac{k_{an,out} \sqrt{p_{an} - p_{atm}}}{p_{H_2} M_{H_2} + p_{v,an} M_v} \quad (88)$$

$$W_{H_2,out} = p_{H_2} M_{H_2} W_{an,out} \quad (89)$$

$$W_{v,an,out} = p_{v,an} M_v W_{an,out} \quad (90)$$

où  $0 \leq v_{an,open} \leq 1$  représente l'ouverture de la valve de sortie anodique. Le débit massique d'hydrogène consommé, réagit est donné par :

$$W_{H_2,rea} = M_{H_2} \frac{N_{cell} I_{st}}{2F} \quad (91)$$

### Le modèle électrique de la pile

La tension de sortie de la pile est donnée comme suit :

$$v_{cell} = E_{nerst} - v_{act} - v_{ohm} - v_{conc} \quad (92)$$

où  $E_{nerst}$  est la tension de circuit ouvert,  $v_{act}$ ,  $v_{ohm}$  and  $v_{conc}$  sont respectivement les surtensions d'activation, ohmique et de diffusion. La tension de pile  $v_{st}$  est obtenue par le raccordement en série de multiples  $n_{st}$  nombre de cellules. La tension en circuit ouvert est

calculée à partir du bilan énergétique entre les réactifs et les gaz produits, et la constante de Faraday, comme suit :

$$E_{nerst} = 1.229 - 8.5 \times 10^{-4}(T_{st} - 298.15) + 4.308 \times 10^{-5}T_{st}(\ln(p_{H_2}) + 0.5 \ln(p_{O_2})) \quad (93)$$

où les pressions partielles sont exprimées en atm. La surtension d'activation est décrite par l'équation de Tafel, et est calculée comme suit :

$$v_{act} = v_0 + v_a(1 - e^{-10J}) \quad (94)$$

$$v_0 = 0.279 - 8.5 \times 10^{-4}(T_{st} - 298.15) + 4.308 \times 10^{-5}T_{st} \left[ \ln\left(\frac{p_{ca} - p_{sat}(T_{st})}{1.01325}\right) + \frac{1}{2} \ln\left(\frac{0.1173(p_{ca} - p_{sat}(T_{st}))}{1.01325}\right) \right] \quad (95)$$

$$v_a = (-1.618e^{-5}T_{st} + 1.618e^{-2}) \left( \frac{p_{O_2}}{0.1173} + p_{sat}(T_{st}) \right)^2 + \left( 1.8e^{-4}T_{st} - 0.166 \left( \frac{p_{O_2}}{0.1173} + p_{sat}(T_{st}) \right) \right) + (-5.8e^{-4}T_{st} + 0.5736) \quad (96)$$

La surtension ohmique est donnée comme suit :

$$v_{ohm} = \frac{t_m J}{(0.005139\lambda_m - 0.00326) \exp\left(350\left(\frac{1}{303} - \frac{1}{T_{st}}\right)\right)} \quad (97)$$

La surtension de concentration est donnée comme suit :

$$v_{conc} = J \left( a \frac{J}{J_{max}} \right)^2 \quad (98)$$

$$a = \begin{cases} (7.16 \times 10^{-4}T_{st} - 0.622) \left( \frac{p_{O_2}}{0.1173} + p_{sat}(T_{st}) \right) + (-1.45 \times 10^{-3}T_{st} + 1.68) \\ \quad \text{si } \frac{p_{O_2}}{0.1173} + p_{sat}(T_{st}) < 2 \\ (8.66 \times 10^{-5}T_{st} - 0.068) \left( \frac{p_{O_2}}{0.1173} + p_{sat}(T_{st}) \right) + (-1.6 \times 10^{-4}T_{st} + 0.54) \end{cases} \quad (99)$$

### Le modèle thermique de la pile

Le système thermique de la pile PEMFC est basé sur une solution de refroidissement liquide avec une combinaison d'échangeur thermique et de ventilation forcée. Quelques hypothèses sont faites pour simplifier sa représentation :

- La température du liquide de refroidissement  $T_{cool}$  est supposé égale à la température ambiante.

- La température des gaz de sortie est supposée égale à la température de la pile.
- La température des gaz d'entrée est parfaitement contrôlée par un système de chauffe des conduites et est supposée égale à la température de la pile pour éviter la formation de condensation dans les conduites.

La température dynamique de la pile peut être obtenue par l'équilibre énergétique, qui est exprimé sous la forme suivante :

$$M_{st}C_{st} \frac{dT_{st}}{dt} = \dot{Q}_{theo} - (\dot{Q}_{elec} + \dot{Q}_{sens} + \dot{Q}_{latent} + \dot{Q}_{loss}) \quad (100)$$

L'énergie théorique de la réaction électrochimique est composée de la chaleur dégagée par la réaction elle-même et de la quantité d'hydrogène consommé, elle est définie par cette relation :

$$\dot{Q}_{theo} = \frac{NI_{st}}{2F} \Delta H \quad (101)$$

L'énergie électrique produite est calculée sous la forme :

$$\dot{Q}_{elec} = N_{cell}v_{cell}I_{st} \quad (102)$$

Le total de chaleur sensible est composé de trois éléments, la chaleur sensible provenant de la vapeur d'eau, la chaleur sensible provenant de la cathode, et la chaleur sensible provenant de l'anode. Ces éléments sont respectivement formulés par :

$$\dot{Q}_{sens} = \dot{Q}_{sens,W} + \dot{Q}_{sens,ca} + \dot{Q}_{sens,an} \quad (103)$$

$$\dot{Q}_{sens,W} = W_{cool}C_{p,l}(T_{cool,out} - T_{cool,in}) \quad (104)$$

Le phénomène de condensation à la cathode induit la présence d'eau liquide à sa sortie.

$$\begin{aligned} \dot{Q}_{sens,ca} = & W_{O_2,out}C_{p,O_2}(T_{ca,out} - T_0) + W_{N_2,out}C_{p,N_2}(T_{ca,out} - T_0) \\ & + W_{g,ca,out}C_{p,v}(T_{ca,out} - T_0) + W_{l,ca,out}C_{p,l}(T_{ca,out} - T_0) \\ & - W_{O_2,in}C_{p,O_2}(T_{ca,in} - T_0) - W_{N_2,in}C_{p,N_2}(T_{ca,in} - T_0) \\ & - W_{v,ca,in}C_{p,v}(T_{ca,in} - T_0) \end{aligned} \quad (105)$$

$$\begin{aligned} \dot{Q}_{sens,an} = & W_{H_2,out}C_{p,H_2}(T_{an,out} - T_0) + W_{v,an,out}C_{p,v}(T_{an,out} - T_0) \\ & - W_{H_2,in}C_{p,H_2}(T_{an,in} - T_0) - W_{v,an,in}C_{p,v}(T_{an,in} - T_0) \end{aligned} \quad (106)$$

Le débit massique d'eau liquide en sortie de cathode  $W_{l,ca,out}$  est définie par :

$$W_{l,ca,out} = W_{v,ca,in} + \frac{NI_{st}M_v}{2F} + W_{v,mbr} - W_{v,ca,out,max} \quad (107)$$

Le débit massique maximum de vapeur d'eau est donné par :

$$W_{v,ca,out,max} = \frac{M_v p_{sat}(T_{fc})}{p_{ca} - p_{sat}(T_{fc})} \left( \frac{W_{O_2,out}}{M_{O_2}} + \frac{W_{N_2,out}}{M_{N_2}} \right) \quad (108)$$

La chaleur latente de vapeur d'eau est obtenue par :

$$\dot{Q}_{latent} = \begin{cases} 0 & W_{v,ca,out} \leq W_{v,ca,out,max} \\ (W_{v,ca,out} - W_{v,ca,out,max}) \frac{H_{vapo}}{M_v} & W_{v,ca,out} > W_{v,ca,out,max} \end{cases} \quad (109)$$

La vaporisation latente de l'eau  $H_{vapo}$  est donnée par :

$$H_{vapo} = 45070 - 41.9T_{st} + 3.44 \times 10^{-3}T_{st}^2 + 2.54 \times 10^{-6}T_{st}^3 - 8.98 \times 10^{-10}T_{st}^4 \quad (110)$$

L'énergie perdue du au phénomène de convection est donné par :

$$\dot{Q}_{loss} = KA(T_{st} - T_{atm}) \quad (111)$$

### L'intégration du défaut de noyage, la sous-alimentation en oxygène

La visualisation du défaut de noyage est réalisée par un excès d'eau injecté  $W_{v,inj}$  à la cathode qui sature la pression saturante en eau à la cathode. L'humidité relative atmosphérique à l'entrée de la cathode devient alors la suivante :

$$\begin{aligned} \phi_{ca,in} = & \frac{M_a}{M_v} \times \\ & \frac{p_{ca,in}(p_{atm} - \phi_{atm}p_{sat}(T_{atm}))}{p_{atm}p_{sat}(T_{ca,in})(W_{O_2,in} + W_{N_2,in})(1 + \Omega_{atm})} \times \\ & \left( \frac{\Omega_{atm}k_{ca,in}(p_{ca,in} - p_{O_2} - p_{N_2} - p_{v,ca}) + ((1 + \Omega_{atm})W_{v,inj})}{p_{atm}p_{sat}(T_{ca,in})(W_{O_2,in} + W_{N_2,in})(1 + \Omega_{atm})} \right) \end{aligned} \quad (112)$$

L'augmentation du contenu en eau de la membrane entraine une augmentation de la chute de pression cathodique. La stœchiométrie en oxygène diminue en faveur de la proportion d'eau grandissante, par conséquent la tension de la pile diminue.

### L'intégration du défaut d'assèchement, la perte en eau de la membrane

La visualisation du défaut d'assèchement est réalisée par une diminution du débit de refroidissement, ce qui entraine une augmentation de la température et une diminution du contenu en eau de la pile. La diminution en eau augmente la résistivité protonique de la membrane ce qui a pour conséquence une chute de tension.

# Références

- Abbaspour, A., Khalilnejad, A., Chen, Z., 2016. Robust adaptive neural network control for PEM fuel cell. *Int. J. Hydrog. Energy* 41, 20385–20395. <https://doi.org/10.1016/j.ijhydene.2016.09.075>
- Abbaspour, A., Yen, K.K., Forouzannezhad, P., Sargolzaei, A., 2019. An Adaptive Resilient Control Approach for Pressure Control in Proton Exchange Membrane Fuel Cells. *IEEE Trans. Ind. Appl.* 55, 6344–6354. <https://doi.org/10.1109/TIA.2019.2929256>
- Abdollahzadeh, M., Ribeirinha, P., Boaventura, M., Mendes, A., 2018. Three-dimensional modeling of PEMFC with contaminated anode fuel. *Energy* 152, 939–959. <https://doi.org/10.1016/j.energy.2018.03.162>
- Almeida, P.E.M., Simoes, M.G., 2005. Neural Optimal Control of PEM Fuel Cells With Parametric CMAC Networks. *IEEE Trans. Ind. Appl.* 41, 237–245. <https://doi.org/10.1109/TIA.2004.836135>
- Andújar, J.M., Segura, F., 2009. Fuel cells: History and updating. A walk along two centuries. *Renew. Sustain. Energy Rev.* 13, 2309–2322. <https://doi.org/10.1016/j.rser.2009.03.015>
- Arif, R., Chu, H., Ryu, Y., Filios, A., Tawfik, H., Shahrabi, K., 2008. An Optimized Humidity And Temperature Control System For Fuel Cells 10.
- Bakhtiar, A., Kim, Y.-B., You, J.-K., Yoon, J.-I., Choi, K.-H., 2012. A model and simulation of cathode flooding and drying on unsteady proton exchange membrane fuel cell. *J. Cent. South Univ.* 19, 2572–2577. <https://doi.org/10.1007/s11771-012-1312-y>
- Balakrishnan, M., Eifert, L., Zeis, R., Hatton, B.D., Bazylak, A., 2019. Electrospun nano-fibrous gas diffusion layers with graded pore-sizes for polymer electrolyte membrane fuel cells. 8th Int. Conf. Fundam. Dev. Fuel Cells FDFC2019.
- Bao, C., Ouyang, M., Yi, B., 2006. Modeling and control of air stream and hydrogen flow with recirculation in a PEM fuel cell system—II. Linear and adaptive nonlinear control. *Int. J. Hydrog. Energy* 31, 1897–1913. <https://doi.org/10.1016/j.ijhydene.2006.02.030>
- Barbir, F., 2005. *PEM Fuel Cells Theory and Practice*.
- Bellman, R., 1954. The theory of dynamic programming. *Bull. Am. Math. Soc.* 60, 503–516. <https://doi.org/10.1090/S0002-9904-1954-09848-8>
- Bethapudi, V.S., Maier, M., Hinds, G., Shearing, P.R., Brett, D.J.L., Coppens, M.-O., 2019. Acoustic emission as a function of polarisation: Diagnosis of polymer electrolyte fuel cell hydration state. *Electrochem. Commun.* 109, 106582. <https://doi.org/10.1016/j.elecom.2019.106582>
- Bo, Y.-C., Zhang, X., 2018. Online adaptive dynamic programming based on echo state networks for dissolved oxygen control. *Appl. Soft Comput.* 62, 830–839. <https://doi.org/10.1016/j.asoc.2017.09.015>
- Boulon, L., Hissel, D., Bouscayrol, A., Pera, M.-C., 2010. From Modeling to Control of a PEM Fuel Cell Using Energetic Macroscopic Representation. *IEEE Trans. Ind. Electron.* 57, 1882–1891. <https://doi.org/10.1109/TIE.2009.2026760>
- Burke, K., 2003. Fuel Cells for Space Science Applications, in: 1st International Energy Conversion Engineering Conference (IECEC). Presented at the 1st International Energy Conversion Engineering Conference (IECEC), American Institute of Aeronautics and Astronautics, Portsmouth, Virginia. <https://doi.org/10.2514/6.2003-5938>
- Cerina, L., Franco, G., Santambrogio, M.D., 2019. Lightweight autonomous bayesian optimization of Echo-State Networks. *Comput. Intell.* 6.
- Chandran, P., Ghosh, A., Ramaprabhu, S., 2018. High-performance Platinum-free oxygen reduction reaction and hydrogen oxidation reaction catalyst in polymer electrolyte membrane fuel cell. *Sci. Rep.* 8, 3591. <https://doi.org/10.1038/s41598-018-22001-9>

- Charradi, K., Ahmed, Z., Cid, R.E., Aranda, P., Ruiz-Hitzky, E., Ocon, P., Chtourou, R., 2019. Amelioration of PEMFC performance at high temperature by incorporation of nanofiller (sepiolite/layered double hydroxide) in Nafion membrane. *Int. J. Hydrog. Energy* 44, 10666–10676. <https://doi.org/10.1016/j.ijhydene.2019.02.183>
- Chevrie, F., Guély, F., 1998. Cahier technique n° 191, La logique floue.
- Cho, S., Chow, T.W.S., 1999. Training multilayer neural networks using fast global learning algorithm - least-squares and penalized optimization methods. *Neurocomputing* 25, 115–131. [https://doi.org/10.1016/S0925-2312\(99\)00055-7](https://doi.org/10.1016/S0925-2312(99)00055-7)
- CONOFLOW, 2004. Conoflow electro-pneumatic transducers.
- Dai, J., Liu, C., Sun, J., 2019. Adaptive optimal fault-tolerant control scheme for a class of strict-feedback nonlinear systems. *Trans. Inst. Meas. Control* 41, 1079–1087. <https://doi.org/10.1177/0142331218786529>
- Damour, C., Benne, M., Grondin-Perez, B., Chabriat, J.-P., Pollet, B.G., 2015. A novel non-linear model-based control strategy to improve PEMFC water management – The flatness-based approach. *Int. J. Hydrog. Energy* 40, 2371–2376. <https://doi.org/10.1016/j.ijhydene.2014.12.052>
- Damour, C., Benne, M., Lebreton, C., Deseure, J., Grondin-Perez, B., 2014. Real-time implementation of a neural model-based self-tuning PID strategy for oxygen stoichiometry control in PEM fuel cell. *Int. J. Hydrog. Energy* 39, 12819–12825. <https://doi.org/10.1016/j.ijhydene.2014.06.039>
- Danzer, M.A., Wittmann, S.J., Hofer, E.P., 2009. Prevention of fuel cell starvation by model predictive control of pressure, excess ratio, and current. *J. Power Sources* 190, 86–91. <https://doi.org/10.1016/j.jpowsour.2008.12.089>
- Daud, W.R.W., Rosli, R.E., Majlan, E.H., Hamid, S.A.A., Mohamed, R., Husaini, T., 2017. PEM fuel cell system control: A review. *Renew. Energy* 113, 620–638. <https://doi.org/10.1016/j.renene.2017.06.027>
- de Man, P., Preumont, A., 1996. Hybrid feedback-feedforward control for vibration suppression. *J. Struct. Control* 3, 33–44. <https://doi.org/10.1002/stc.4300030104>
- Depature, C., Lhomme, W., Sicard, P., Bouscayrol, A., Boulon, L., 2017. Real-time Backstepping control for fuel cell vehicle using supercapacitors. *IEEE Trans. Veh. Technol.* 1–1. <https://doi.org/10.1109/TVT.2017.2728823>
- Devlin, P., Moreland, G., Gangi, J., Josek, F., Satyapal, S., 2018. Industry Deployed Fuel Cell Powered Lift Trucks, DOE Hydrogen and Fuel Cells Program Record. Department Of Energy United States of America.
- Dey, T., Deshpande, J., Singdeo, D., Ghosh, P.C., 2019. Study of PEM Fuel Cell End Plate Design by Structural Analysis Based on Contact Pressure. *J. Energy* 2019, 1–11. <https://doi.org/10.1155/2019/3821082>
- Dijoux, E., 2019. Contrôle tolérant aux défauts appliqué aux systèmes pile à combustible à membrane échangeuse de protons (pemfc).
- Dijoux, E., Steiner, N.Y., Benne, M., Péra, M.-C., Pérez, B.G., 2017. A review of fault tolerant control strategies applied to proton exchange membrane fuel cell systems. *J. Power Sources* 359, 119–133. <https://doi.org/10.1016/j.jpowsour.2017.05.058>
- Dong, W., Cao, G.-Y., Zhu, X.-J., 2003. Nonlinear modelling and adaptive fuzzy control of PEMFC 9.
- dos Santos, C.H.F., Cardozo, D.I.K., Reginatto, R., De Pieri, E.R., 2016. Bank of controllers and virtual thrusters for fault-tolerant control of autonomous underwater vehicles. *Ocean Eng.* 121, 210–223. <https://doi.org/10.1016/j.oceaneng.2016.05.029>
- dos Santos Coelho, L., Pessôa, M.W., 2009. Nonlinear identification using a B-spline neural network and chaotic immune approaches. *Mech. Syst. Signal Process.* 23, 2418–2434. <https://doi.org/10.1016/j.ymsp.2009.01.013>
- Edwards, C., Lombaerts, T., Smaili, H. (Eds.), 2010. Fault tolerant flight control: a benchmark challenge, Lecture notes in control and information sciences. Springer, Berlin.
- EERE:U.S., 2016. Highlights from U.S. Department of Energy's Fuel Cell Recovery Act Projects, Energy Efficiency and Renewable Energy. U.S. Department of Energy.
- Elba, L., Eren, H., 2016. Chapter 20 - Process Control, in: Mineral Processing Design and Operations (Second Edition). pp. 763–816.

- Evans, J.P., 2003. Experimental Evaluation of the Effect of Inlet Gas Humidification on Fuel Cell Performance 110.
- Fan, D.D., Theodorou, E.A., 2016. Differential Dynamic Programming for time-delayed systems. 2016 IEEE 55th Conf. Decis. Control CDC 573–579. <https://doi.org/10.1109/CDC.2016.7798330>
- Fang, C., Xu, L., Cheng, S., Li, J., Jiang, H., Ouyang, M., 2017. Sliding-mode-based temperature regulation of a proton exchange membrane fuel cell test bench. *Int. J. Hydrog. Energy* 42, 11745–11757. <https://doi.org/10.1016/j.ijhydene.2017.03.070>
- Frèlon, A., Audichon, T., Baranton, S., Bigarré, J., Coutanceau, C., Buvat, P., 2019. Nafion-free hybrid membrane electrode assembly for PEMFC application.
- Fukushima, K., 1979. Neural network model for a mechanism of pattern recognition unaffected by shift in position. *Neocognitron* 658–665.
- Gallicchio, C., Micheli, A., Pedrelli, L., 2018a. Design of deep echo state networks. *Neural Netw.* 108, 33–47. <https://doi.org/10.1016/j.neunet.2018.08.002>
- Gallicchio, C., Micheli, A., Silvestri, L., 2018b. Local Lyapunov exponents of deep echo state networks. *Neurocomputing* 298, 34–45. <https://doi.org/10.1016/j.neucom.2017.11.073>
- Gebregergis, A., Pillay, P., Rengaswamy, R., 2008. PEMFC fault diagnosis, modeling, and mitigation, in: *Industry Applications Society Annual Meeting, 2008. IAS'08. IEEE. IEEE*, pp. 1–8.
- Giner-Sanz, J.J., Ortega, E.M., Pérez-Herranz, V., 2014. Hydrogen crossover and internal short-circuit currents experimental characterization and modelling in a proton exchange membrane fuel cell. *Int. J. Hydrog. Energy* 39, 13206–13216. <https://doi.org/10.1016/j.ijhydene.2014.06.157>
- Guoai W., Shuhai Q., Qihong C., Liyan Z., Lin S., 2010. Neural-PID Control of Air Pressure in Fuel Cells. *IEEE*, pp. 5353–5356. <https://doi.org/10.1109/iCECE.2010.1299>
- Haghighat Ghahfarokhi, H., Saatchi, A., Monirvaghefi, S.M., 2016. Corrosion Investigation of Chromium Nitride and Chromium Carbide Coatings for PEM Fuel Cell Bipolar Plates in Simulated Cathode Condition. *Fuel Cells* 16, 356–364. <https://doi.org/10.1002/fuce.201600005>
- Han, J., Yu, S., Yi, S., 2019. Oxygen excess ratio control for proton exchange membrane fuel cell using model reference adaptive control. *Int. J. Hydrog. Energy* 44, 18425–18437. <https://doi.org/10.1016/j.ijhydene.2019.05.041>
- Henson, M.A., Seborg, D.E., 1996. Feedback Linearizing Control, in: *Nonlinear Process Control*.
- Herbert Jaeger, 2000. Adaptive Nonlinear System Identification with Echo State Network.
- Hernandez, A., Hissel, D., Outbib, R., 2010. Modeling and fault diagnosis of a Polymer Electrolyte Fuel Cell using electrical equivalent analysis. *IEEE Trans. Energy Convers.*
- Hissel, D., Pera, M.C., 2016. Diagnostic & health management of fuel cell systems: Issues and solutions. *Annu. Rev. Control* 42, 201–211. <https://doi.org/10.1016/j.arcontrol.2016.09.005>
- Huang, Y., Li, S., Sun, J., 2018. Mars entry fault-tolerant control via neural network and structure adaptive model inversion. *Adv. Space Res.* <https://doi.org/10.1016/j.asr.2018.09.016>
- Huang, Z., Xiong, X., Chen, W., Zhang, Q., Liu, Y., Chen, Y., 2018. Three bounded proofs for nonlinear multi-input multi-output approximate dynamic programming based on the Lyapunov stability theory. *Optim. Control Appl. Methods* 39, 35–50. <https://doi.org/10.1002/oca.2332>
- Ifrek, L., Rosini, S., Cauffet, G., Chadebec, O., Rouveyre, L., Bultel, Y., 2019. Fault detection for polymer electrolyte membrane fuel cell stack by external magnetic field. *Electrochimica Acta* 313, 141–150. <https://doi.org/10.1016/j.electacta.2019.04.193>
- Jaeger, H., 2000. Adaptive Nonlinear System Identification with Echo State Networks 8.
- Ji, N., Xu, D., Liu, F., 2016. A novel adaptive neural network constrained control for solid oxide fuel cells via dynamic anti-windup. *Neurocomputing* 214, 134–142. <https://doi.org/10.1016/j.neucom.2016.05.076>
- Jia, C., Li, X., Wang, K., Ding, D., 2016. Adaptive control of nonlinear system using online error minimum neural networks. *ISA Trans.* 65, 125–132. <https://doi.org/10.1016/j.isatra.2016.07.012>
- Jia, W., Zhao, D., Ding, L., 2016. An optimized RBF neural network algorithm based on partial least squares and genetic algorithm for classification of small sample. *Appl. Soft Comput.* 48, 373–384. <https://doi.org/10.1016/j.asoc.2016.07.037>
- Jing, Y.-H., Yang, G.-H., 2018. Neural-network-based adaptive fault-tolerant tracking control of uncertain nonlinear time-delay systems under output constraints and infinite number of actuator faults. *Neurocomputing* 272, 343–355. <https://doi.org/10.1016/j.neucom.2017.07.009>

- Jon, R., Wang, Z., Luo, C., Jong, M., 2017. Adaptive robust speed control based on recurrent elman neural network for sensorless PMSM servo drives. *Neurocomputing* 227, 131–141. <https://doi.org/10.1016/j.neucom.2016.09.095>
- Jordanou, J.P., Antonelo, E.A., Camponogara, E., Aguiar, M.A.S. de, 2017. Recurrent Neural Network Based Control Of An Oil Well.
- Jullian, G., 2019. Diagnostic robuste de pile à combustible PEM par modélisation physique et mesures d'impédance: prise en compte de conditions dynamiques et du vieillissement.
- Kakati, B.K., Kucernak, A.R.J., Fahy, K.F., 2016. Using corrosion-like processes to remove poisons from electrocatalysts: a viable strategy to chemically regenerate irreversibly poisoned polymer electrolyte fuel cells. *Electrochimica Acta* 222, 888–897. <https://doi.org/10.1016/j.electacta.2016.11.054>
- Kalman, R.E., Bertram, J.E., 1960. Control System Analysis and Design Via the “Second Method” of Lyapunov: II—Discrete-Time Systems. *J. Basic Eng.* 82, 394–400. <https://doi.org/10.1115/1.3662605>
- Karimi, M., 2012. Voltage Control of PEMFC Using A New Controller Based on Reinforcement Learning. *Int. J. Inf. Electron. Eng.* <https://doi.org/10.7763/IJIEE.2012.V2.200>
- K/Bidi, F., 2019. Developpements et tests de strategies de gestion de l'énergie a l'échelle de micro reseaux avec stockage et production d'hydrogene.
- Keller, R., Ding, S.X., Müller, M., Stolten, D., 2017. Fault-tolerant model predictive control of a direct methanol-fuel cell system with actuator faults. *Control Eng. Pract.* 66, 99–115. <https://doi.org/10.1016/j.conengprac.2017.06.008>
- Khalid, R., Javaid, N., 2020. A survey on hyperparameters optimization algorithms of forecasting models in smart grid. *Sustain. Cities Soc.* 61, 102275. <https://doi.org/10.1016/j.scs.2020.102275>
- Kim, S., Hong, I., 2008. Effects of humidity and temperature on a proton exchange membrane fuel cell (PEMFC) stack. *J. Ind. Eng. Chem.* 14, 357–364. <https://doi.org/10.1016/j.jiec.2008.01.007>
- Kishnani, M., Pareek, S., Gupta, D.R., 2014. Optimal Tuning of PID Controller Using Meta Heuristic Approach 6.
- Kongkanand, A., Subramanian, N.P., Yu, Y., Liu, Z., Igarashi, H., Muller, D.A., 2016. Achieving High-Power PEM Fuel Cell Performance with an Ultralow-Pt-Content Core–Shell Catalyst. *ACS Catal.* 6, 1578–1583. <https://doi.org/10.1021/acscatal.5b02819>
- Kumar, R., Srivastava, S., Gupta, J.R.P., 2017. Lyapunov stability-based control and identification of nonlinear dynamical systems using adaptive dynamic programming. *Soft Comput.* 21, 4465–4480. <https://doi.org/10.1007/s00500-017-2500-3>
- Kunde, C., Hanke-Rauschenbach, R., Mangold, M., Kienle, A., Sundmacher, K., Wagner, S., Hahn, R., 2010. Temperature and Humidity Control of a Micro PEM Fuel Cell Stack. *Fuel Cells* 10, 949–959. <https://doi.org/10.1002/fuce.201000022>
- Kundu, P.P., Dutta, K., 2016. Hydrogen fuel cells for portable applications, in: *Compendium of Hydrogen Energy*. Elsevier, pp. 111–131. <https://doi.org/10.1016/B978-1-78242-364-5.00006-3>
- Kunusch, C., Puleston, P., Mayosky, M., 2012. Sliding-Mode Control of PEM Fuel Cells, *Advances in Industrial Control*. Springer London, London. <https://doi.org/10.1007/978-1-4471-2431-3>
- Kurtz, J.M., Sprik, S., Saur, G., Onorato, S., 2019. Fuel Cell Electric Vehicle Durability and Fuel Cell Performance (No. NREL/TP-5400-73011, 1501675). <https://doi.org/10.2172/1501675>
- Laghrouche, S., Harmouche, M., Ahmed, F.S., Chitour, Y., 2014. Control of PEMFC Air-Feed System Using Lyapunov-Based Robust and Adaptive Higher Order Sliding Mode Control.
- Lebreton, C., 2015. Contrôle tolérant aux fautes en ligne d'une pile à combustible de type PEM. Contribution à la gestion de l'eau. Université de la Réunion.
- Lebreton, C., Benne, M., Damour, C., Yousfi-Steiner, N., Grondin-Perez, B., Hissel, D., Chabriat, J.-P., 2015. Fault Tolerant Control Strategy applied to PEMFC water management. *Int. J. Hydrog. Energy* 40, 10636–10646. <https://doi.org/10.1016/j.ijhydene.2015.06.115>
- Lebreton, C., Damour, C., Benne, M., Grondin-Perez, B., Chabriat, J.-P., 2016. Passive Fault Tolerant Control of PEMFC air feeding system. *Int. J. Hydrog. Energy* 41, 15615–15621. <https://doi.org/10.1016/j.ijhydene.2016.06.210>

- Lee, H., Nam, D., Park, C.H., 2004. A Sliding Mode Controller Using Neural Networks for Robot Manipulator 6.
- Lee, H., Utkin, V.I., 2007. Chattering suppression methods in sliding mode control systems. *Annu. Rev. Control* 31, 179–188. <https://doi.org/10.1016/j.arcontrol.2007.08.001>
- Li, C., Zhu, X., Sui, S., Hu, W., Hu, M., 2009. Adaptive inverse control of air supply flow for proton exchange membrane fuel cell systems. *J. Shanghai Univ. Engl. Ed.* 13, 474–480. <https://doi.org/10.1007/s11741-009-0610-3>
- Li, L., Jamieson, K., DeSalvo, G., Rostamizadeh, A., Talwalkar, A., 2016. Hyperband: A Novel Bandit-Based Approach to Hyperparameter Optimization. *ArXiv160306560 Cs Stat.*
- Li, P., Chen, J., Cai, T., Zhang, B., 2011. Adaptive control of air delivery system for PEM fuel cell using backstepping, in: *Control Conference (ASCC), 2011 8th Asian. IEEE*, pp. 1282–1287.
- Li, Y., Wang, H., Dai, Z., 2006. Using artificial neural network to control the temperature of fuel cell, in: *Communications, Circuits and Systems Proceedings, 2006 International Conference On. IEEE*, pp. 2159–2162.
- Li, Y., Zhao, X., Tao, S., Li, Q., Chen, W., 2015. Experimental Study on Anode and Cathode Pressure Difference Control and Effects in a Proton Exchange Membrane Fuel Cell System. *Energy Technol.* 3, 946–954. <https://doi.org/10.1002/ente.201500077>
- Lin, J.-S., Hwang, C., 1996. Optimal Control of Time-Delay Systems by Forward Iterative Dynamic Programming 6.
- Lin, T., Horne, B.G., Tiño, P., Giles, C.L., 1996. Learning Long-Term Dependencies in NARX Recurrent Neural Networks 10.
- Lin-Kwong-Chon, C., Grondin-Pérez, B., Kadjo, J.-J.A., Damour, C., Benne, M., 2019. A review of adaptive neural control applied to proton exchange membrane fuel cell systems. *Annu. Rev. Control* 47, 133–154. <https://doi.org/10.1016/j.arcontrol.2019.03.009>
- Liso, V., Nielsen, M.P., Kær, S.K., Mortensen, H.H., 2014. Thermal modeling and temperature control of a PEM fuel cell system for forklift applications. *Int. J. Hydrog. Energy* 39, 8410–8420. <https://doi.org/10.1016/j.ijhydene.2014.03.175>
- Liu, Z., Mao, Z., Wang, C., 2006. A two dimensional partial flooding model for PEMFC. *J. Power Sources* 158, 1229–1239. <https://doi.org/10.1016/j.jpowsour.2005.10.060>
- Lu, H., Chen, J., Yan, C., Liu, H., 2019. On-line fault diagnosis for proton exchange membrane fuel cells based on a fast electrochemical impedance spectroscopy measurement. *J. Power Sources* 430, 233–243. <https://doi.org/10.1016/j.jpowsour.2019.05.028>
- Lukoševičius, M., 2012. A practical guide to applying echo state networks, in: *Neural Networks: Tricks of the Trade. Springer*, pp. 659–686.
- Lunze, J., Richter, J.H., 2008. Reconfigurable Fault-tolerant Control: A Tutorial Introduction. *Eur. J. Control* 14, 359–386. <https://doi.org/10.3166/ejc.14.359-386>
- Lyons, K.S., Teliska, M., Baker, W., Pietron, J., 2005. Low-Platinum Catalysts for Oxygen Reduction at PEMFC Cathodes 5.
- Magoulas, G.D., Plagianakos, V.P., Vrahatis, M.N., 2002. Globally convergent algorithms with local learning rates. *IEEE Trans. Neural Netw.* 13, 774–779. <https://doi.org/10.1109/TNN.2002.1000148>
- Matraji, I., Ahmed, F.S., Laghrouche, S., Wack, M., 2015. Comparison of robust and adaptive second order sliding mode control in PEMFC air-feed systems. *Int. J. Hydrog. Energy* 40, 9491–9504. <https://doi.org/10.1016/j.ijhydene.2015.05.090>
- Matraji, I., Laghrouche, S., Wack, M., 2012. Pressure control in a PEM fuel cell via second order sliding mode. *Int. J. Hydrog. Energy* 37, 16104–16116. <https://doi.org/10.1016/j.ijhydene.2012.08.007>
- MKS, 2018a. 1179C Mass Flow Controller.
- MKS, 2018b. 640B-641B Electronic pressure controller.
- Mohamed, I.S., Rovetta, S., Do, T.D., Dragicevic, T., Diab, A.A.Z., 2019. A Neural-Network-Based Model Predictive Control of Three-Phase Inverter With an Output LC Filter. *ArXiv190209964 Cs Stat.*
- Mortazavi, M., Tajiri, K., 2014. Effect of the PTFE content in the gas diffusion layer on water transport in polymer electrolyte fuel cells (PEFCs). *J. Power Sources* 245, 236–244. <https://doi.org/10.1016/j.jpowsour.2013.06.138>

- Mumtaz, S., Ahmad, S., Khan, L., Ali, S., Kamal, T., Hassan, S., 2018. Adaptive Feedback Linearization Based NeuroFuzzy Maximum Power Point Tracking for a Photovoltaic System. *Energies* 11, 606. <https://doi.org/10.3390/en11030606>
- Nagarale, R., Chile, R.H., Patre, B.M., Kulkarni, P.A., 2007. Comparative study of SMC and SMFLC robustness Property, in: *Mechatronics and Automation, 2007. ICMA 2007. International Conference On. IEEE*, pp. 1135–1140.
- Nakama, T., 2009. Theoretical analysis of batch and on-line training for gradient descent learning in neural networks. *Neurocomputing* 73, 151–159. <https://doi.org/10.1016/j.neucom.2009.05.017>
- Narvekar, S.V., Upadhye, V.K., 2016. Review of PI and PID Controllers. *Int. J. Recent Trends Eng. Res.* 2.
- Nehrir, M.H., Wang, C., 2009. Modeling and control of fuel cells: distributed generation applications, IEEE Press series on power engineering. IEEE Press [u.a.], Piscataway, NJ.
- Nguyen, T., Nguyentien, K., Do, T., Pham, T., 2018. Neural Network-based Adaptive Sliding Mode Control Method for Tracking of a Nonholonomic Wheeled Mobile Robot with Unknown Wheel Slips, Model Uncertainties, and Unknown Bounded External Disturbances. *Acta Polytech. Hung.* 15. <https://doi.org/10.12700/APH.15.1.2018.2.6>
- Niane, M., 2018. Contribution au diagnostic et à la commande de la pile à combustible de type PEM.
- Noorkami, M., Robinson, J.B., Meyer, Q., Obeisun, O.A., Fraga, E.S., Reisch, T., Shearing, P.R., Brett, D.J.L., 2014. Effect of temperature uncertainty on polymer electrolyte fuel cell performance. *Int. J. Hydrog. Energy* 39, 1439–1448. <https://doi.org/10.1016/j.ijhydene.2013.10.156>
- OER, 2019. Bilan énergétique de La Réunion 2018, édition 2019.
- Pasaogullari, U., Wang, C.Y., 2004. Liquid Water Transport in Gas Diffusion Layer of Polymer Electrolyte Fuel Cells. *J. Electrochem. Soc.* 151, A399. <https://doi.org/10.1149/1.1646148>
- Pham, H., 2007. Equation d'Hamilton-Jacobi-Bellman 7.
- Prado, F., Minutolo, M.C., Kristjanpoller, W., 2020. Forecasting based on an ensemble Autoregressive Moving Average - Adaptive neuro - Fuzzy inference system – Neural network - Genetic Algorithm Framework. *Energy* 197, 117159. <https://doi.org/10.1016/j.energy.2020.117159>
- Pukrushpan, J.T., 2003. Modelling and control of Fuel Cell systems and fuel processors.
- Pukrushpan, J.T., Stefanopoulou, A.G., Peng, H., 2004. Control of Fuel Cell Power Systems, *Advances in Industrial Control*. Springer London, London. <https://doi.org/10.1007/978-1-4471-3792-4>
- Ragb, O., Jones, K., Yu, D., Barry Gomm, J., 2011. Adaptive Feed-forward and Feedback control using neural networks for oxygen ratio in Fuel cell stacks.
- Rakhtala, S.M., Ghaderi, R., Ranjbar Noei, A., 2011. Proton exchange membrane fuel cell voltage-tracking using artificial neural networks. *J. Zhejiang Univ. Sci. C* 12, 338–344. <https://doi.org/10.1631/jzus.C0910683>
- Rezazadeh, A., Askarzadeh, A., Sedighzadeh, M., 2011. Adaptive Inverse Control of Proton Exchange Membrane Fuel Cell Using RBF Neural Network.
- Richards, S.M., Berkenkamp, F., Krause, A., 2018. The Lyapunov Neural Network: Adaptive Stability Certification for Safe Learning of Dynamical Systems. *ArXiv180800924 Cs*.
- Roland, P., 2011. Gestion de projet par l'approche de l'analyse de la valeur.
- Rotondo, D., Nejjari, F., Puig, V., 2016. Fault tolerant control of a proton exchange membrane fuel cell using Takagi–Sugeno virtual actuators. *J. Process Control* 45, 12–29. <https://doi.org/10.1016/j.jprocont.2016.06.001>
- Sadeghassadi, M., Macnab, C.J.B., Gopaluni, B., Westwick, D., 2018. Application of neural networks for optimal-setpoint design and MPC control in biological wastewater treatment. *Comput. Chem. Eng.* 115, 150–160. <https://doi.org/10.1016/j.compchemeng.2018.04.007>
- Sanchez, V., Ramírez, J.M., Arriaga, G., 2010. On-line air supply control of PEM fuel cell by an adaptive neural network, in: *North American Power Symposium (NAPS), 2010. IEEE*, pp. 1–6.
- Sanchez, V.M., Barbosa, R., Arriaga, L.G., Ramirez, J.M., 2014. Real time control of air feed system in a PEM fuel cell by means of an adaptive neural-network. *Int. J. Hydrog. Energy* 39, 16750–16762. <https://doi.org/10.1016/j.ijhydene.2014.05.153>
- Satterfield, M.B., 2007. Mechanical and water sorption properties of Nafion and Composite Nafion/Titanium dioxide membranes for polymer electrolyte membrane fuel cells.

- Savidan, L., Schaffar, A., Dimou, M., Garde, F., 2008. La Consommation énergétique des ménages à La Réunion : vers un retour à l'autonomie par le biais des énergies renouvelables. *Études Caribéennes*. <https://doi.org/10.4000/etudescaribeennes.3519>
- Sedighizadeh, M., Rezazadeh, A., 2010. Adaptive Self-Tuning Wavelet Neural Network Controller for a Proton Exchange Membrane Fuel Cell, in: Schumann, J., Liu, Y. (Eds.), *Applications of Neural Networks in High Assurance Systems*. Springer Berlin Heidelberg, Berlin, Heidelberg, pp. 221–245. [https://doi.org/10.1007/978-3-642-10690-3\\_11](https://doi.org/10.1007/978-3-642-10690-3_11)
- Sedighizadeh, M., Rezazadeh, A., 2007. A Neuro Adaptive Control Strategy for Movable Power Source of Proton Exchange Membrane Fuel Cell Using Wavelets. *Int. J. Energy Power Eng.* 1, 5.
- Sethuraman, V.A., Weidner, J.W., Haug, A.T., Motupally, S., Protsailo, L.V., 2008. Hydrogen Peroxide Formation Rates in a PEMFC Anode and Cathode. *J. Electrochem. Soc.* 155, B50. <https://doi.org/10.1149/1.2801980>
- Shafiq, M., Shafiq, M.A., Yousef, H.A., 2017. Stability and Convergence Analysis of Direct Adaptive Inverse Control. *Complexity* 2017, 1–12. <https://doi.org/10.1155/2017/7834358>
- Shafiq, M.A., 2016. Direct adaptive inverse control of nonlinear plants using neural networks, in: *Future Technologies Conference (FTC)*. IEEE, pp. 827–830.
- Sheng, W., Gasteiger, H.A., Shao-Horn, Y., 2010. Hydrogen Oxidation and Evolution Reaction Kinetics on Platinum: Acid vs Alkaline Electrolytes. *J. Electrochem. Soc.* 157, B1529. <https://doi.org/10.1149/1.3483106>
- Shirzadeh, M., Amirkhani, A., Jalali, A., Mosavi, M.R., 2015. An indirect adaptive neural control of a visual-based quadrotor robot for pursuing a moving target. *ISA Trans.* 59, 290–302. <https://doi.org/10.1016/j.isatra.2015.10.011>
- Silva, R.E., Harel, F., Jemei, S., Gouriveau, R., Hissel, D., Boulon, L., Agbossou, K., 2014. Proton Exchange Membrane Fuel Cell Operation and Degradation in Short-Circuit. *Fuel Cells* 14, 894–905. <https://doi.org/10.1002/fuce.201300216>
- Son, N.N., Kien, C.V., Anh, H.P.H., 2017. A novel adaptive feed-forward-PID controller of a SCARA parallel robot using pneumatic artificial muscle actuator based on neural network and modified differential evolution algorithm. *Robot. Auton. Syst.* 96, 65–80. <https://doi.org/10.1016/j.robot.2017.06.012>
- Steiner, N.Y., Candusso, D., Hissel, D., Moçoteguy, P., 2010. Model-based diagnosis for proton exchange membrane fuel cells. *Math. Comput. Simul.* 81, 158–170. <https://doi.org/10.1016/j.matcom.2010.02.006>
- Su, H., Sita, C., Pasupathi, S., 2016. The Effect of Gas Diffusion Layer PTFE Content on The Performance of High Temperature Proton Exchange Membrane Fuel Cell. *Int. J. Electrochem. Sci.* 2919–2926. <https://doi.org/10.20964/110402919>
- Sun, T., Yan, S., Cao, G., Zhu, X., 2005. Modelling and control PEMFC using fuzzy neural networks. *J. Zhejiang Univ.-Sci. A* 6, 1084–1089. <https://doi.org/10.1631/jzus.2005.A1084>
- Sussillo, D., Corrado, G.S., 2017. Resizing neural networks.
- Tapachès, E., 2020. *Projet PEPS Production Électrique Photovoltaïque et Stockage à La Réunion*. Laboratoire PIMENT, Université de La Réunion.
- UQM, 2018. R340 and R410 Fuel Cell Compressor Motor and Controller Assembly.
- Vasu, G., Tangirala, A.K., 2008. Control-orientated thermal model for proton-exchange membrane fuel cell systems. *J. Power Sources* 183, 98–108. <https://doi.org/10.1016/j.jpowsour.2008.03.087>
- Veen, F. van, 2017. A mostly complete chart of Neural Networks. Asimov institute.
- Visioli, A., 2012. Research trends for PID controllers. *Acta Polytech.* 52.
- Wang, C., Zhao, W., Luan, Z., Gao, Q., Deng, K., 2018. Decoupling control of vehicle chassis system based on neural network inverse system. *Mech. Syst. Signal Process.* 106, 176–197. <https://doi.org/10.1016/j.ymsp.2017.12.032>
- Wang, L., Yang, Y., Min, R., Chakradhar, S., 2017. Accelerating deep neural network training with inconsistent stochastic gradient descent. *Neural Netw.* 93, 219–229. <https://doi.org/10.1016/j.neunet.2017.06.003>
- Werbos, P., 1977. *Advanced Forecasting Methods for Global Crisis Warning and Models of Intelligence*. Gen. Syst. XXII.

- Wong, W., Chee, E., Li, J., Wang, X., 2018. Recurrent Neural Network-Based Model Predictive Control for Continuous Pharmaceutical Manufacturing. *Mathematics* 6, 242. <https://doi.org/10.3390/math6110242>
- Wu, N., Wang, H., 2018. Deep learning adaptive dynamic programming for real time energy management and control strategy of micro-grid. *J. Clean. Prod.* 204, 1169–1177. <https://doi.org/10.1016/j.jclepro.2018.09.052>
- Wu, X., Zhou, B., 2016. Fault tolerance control for proton exchange membrane fuel cell systems. *J. Power Sources* 324, 804–829. <https://doi.org/10.1016/j.jpowsour.2016.05.066>
- Xu, D., Yan, W., Ji, N., 2016. RBF neural network based adaptive constrained PID control of a solid oxide fuel cell, in: *Control and Decision Conference (CCDC), 2016 Chinese*. IEEE, pp. 3986–3991.
- Yan, C., Li, M., Liu, W., Qi, M., 2020. Improved adaptive genetic algorithm for the vehicle Insurance Fraud Identification Model based on a BP Neural Network. *Theor. Comput. Sci.* 817, 12–23. <https://doi.org/10.1016/j.tcs.2019.06.025>
- Yildiz, I.B., Jaeger, H., Kiebel, S.J., 2012. Re-visiting the echo state property. *Neural Netw.* 35, 1–9. <https://doi.org/10.1016/j.neunet.2012.07.005>
- Yin, Y., Niu, H., Liu, X., 2017. Adaptive Neural Network Sliding Mode Control for Quad Tilt Rotor Aircraft. *Complexity* 2017, 1–13. <https://doi.org/10.1155/2017/7104708>
- Yousfi Steiner, N., Hissel, D., Moçotéguy, P., Candusso, D., Marra, D., Pianese, C., Sorrentino, M., 2012. Application of Fault Tree Analysis to Fuel Cell diagnosis. *Fuel Cells* 12, 302–309. <https://doi.org/10.1002/fuce.201100072>
- Yousfi-Steiner, N., Moçotéguy, Ph., Candusso, D., Hissel, D., 2009. A review on polymer electrolyte membrane fuel cell catalyst degradation and starvation issues: Causes, consequences and diagnostic for mitigation. *J. Power Sources* 194, 130–145. <https://doi.org/10.1016/j.jpowsour.2009.03.060>
- Zhai, S., Zhou, S., Sun, P., Chen, F., Niu, J., 2012. Modeling Study of Anode Water Flooding and Gas Purge for PEMFCs. *J. Fuel Cell Sci. Technol.* 9, 031007. <https://doi.org/10.1115/1.4006053>
- Zhang, J., Liu, G., Yu, W., Ouyang, M., 2008. Adaptive control of the airflow of a PEM fuel cell system. *J. Power Sources* 179, 649–659. <https://doi.org/10.1016/j.jpowsour.2008.01.015>
- Zhang, Jianlu, Li, H., Zhang, Jiujun, 2009. Effect of Operating Backpressure on PEM Fuel Cell Performance. pp. 65–76. <https://doi.org/10.1149/1.3271363>
- Zhang, Jianlu, Zhang, H., Wu, J., Zhang, Jiujun, 2013. Pressure Effects on PEM Fuel Cell Performance, in: *Pem Fuel Cell Testing and Diagnosis*. Elsevier, pp. 225–241. <https://doi.org/10.1016/B978-0-444-53688-4.00009-7>
- Zhang, L., Pan, M., Quan, S., 2008. Model predictive control of water management in PEMFC. *J. Power Sources* 180, 322–329. <https://doi.org/10.1016/j.jpowsour.2008.01.088>
- Zhang, L., Pan, M., Quan, S., Chen, Q., Shi, Y., 2006. Adaptive neural control based on pemfc hybrid modeling, in: *Intelligent Control and Automation, 2006. WCICA 2006. The Sixth World Congress On*. IEEE, pp. 8319–8323.
- Zhang, P., 2010. CHAPTER 2 - Industrial control engineering, in: *Advances Industrial Control Technology*. pp. 41–70.
- Zribi, A., Chtourou, M., Djemel, M., 2015. A New PID Neural Network Controller Design for Nonlinear Processes.

### **LETTRE D'ENGAGEMENT DE NON-PLAGIAT**

Je, soussigné LIN-KWONG-CHON Christophe, en ma qualité de doctorant de l'Université de La Réunion, déclare être conscient que le plagiat est un acte délictueux passible de sanctions disciplinaires. Aussi, dans le respect de la propriété intellectuelle et du droit d'auteur, je m'engage à systématiquement citer mes sources, quelle qu'en soit la forme (textes, images, audiovisuel, internet), dans le cadre de la rédaction de ma thèse et de toute autre production scientifique, sachant que l'établissement est susceptible de soumettre le texte de ma thèse à un logiciel anti-plagiat.

Fait à SAINT-DENIS, le 10/06/2020.

Signature :



**Extrait du Règlement intérieur de l'Université de La Réunion**  
(validé par le Conseil d'Administration en date du 11 décembre 2014)

**Article 9. Protection de la propriété intellectuelle – Faux et usage de faux, contrefaçon, plagiat**

L'utilisation des ressources informatiques de l'Université implique le respect de ses droits de propriété intellectuelle ainsi que ceux de ses partenaires et plus généralement, de tous tiers titulaires de tels droits.

En conséquence, chaque utilisateur doit :

- utiliser les logiciels dans les conditions de licences souscrites ;
- ne pas reproduire, copier, diffuser, modifier ou utiliser des logiciels, bases de données, pages Web, textes, images, photographies ou autres créations protégées par le droit d'auteur ou un droit privatif, sans avoir obtenu préalablement l'autorisation des titulaires de ces droits.

**La contrefaçon et le faux**

Conformément aux dispositions du code de la propriété intellectuelle, toute représentation ou reproduction intégrale ou partielle d'une œuvre de l'esprit faite sans le consentement de son auteur est illicite et constitue un délit pénal.

L'article 444-1 du code pénal dispose : « Constitue un faux toute altération frauduleuse de la vérité, de nature à causer un préjudice et accomplie par quelque moyen que ce soit, dans un écrit ou tout autre support d'expression de la pensée qui a pour objet ou qui peut avoir pour effet d'établir la preuve d'un droit ou d'un fait ayant des conséquences juridiques ».

L'article L335\_3 du code de la propriété intellectuelle précise que : « Est également un délit de contrefaçon toute reproduction, représentation ou diffusion, par quelque moyen que ce soit, d'une œuvre de l'esprit en violation des droits de l'auteur, tels qu'ils sont définis et réglementés par la loi. Est également un délit de contrefaçon la violation de l'un des droits de l'auteur d'un logiciel (...) ».

**Le plagiat** est constitué par la copie, totale ou partielle d'un travail réalisé par autrui, lorsque la source empruntée n'est pas citée, quel que soit le moyen utilisé. Le plagiat constitue une violation du droit d'auteur (au sens des articles L 335-2 et L 335-3 du code de la propriété intellectuelle). Il peut être assimilé à un délit de contrefaçon. C'est aussi une faute disciplinaire, susceptible d'entraîner une sanction.

Les sources et les références utilisées dans le cadre des travaux (préparations, devoirs, mémoires, thèses, rapports de stage...) doivent être clairement citées. Des citations intégrales peuvent figurer dans les documents rendus, si elles sont assorties de leur référence (nom d'auteur, publication, date, éditeur...) et identifiées comme telles par des guillemets ou des italiques.

Les délits de contrefaçon, de plagiat et d'usage de faux peuvent donner lieu à une sanction disciplinaire indépendante de la mise en œuvre de poursuites pénales.