



Modélisation d'une Pile à Combustible de type PEM par Réseaux de Neurones

Samir Jemeï

► To cite this version:

Samir Jemeï. Modélisation d'une Pile à Combustible de type PEM par Réseaux de Neurones. Energie électrique. Université de Franche-Comté; Université de Technologie de Belfort-Montbéliard, 2004. Français. <NNT: >. <tel-00777611>

HAL Id: tel-00777611

<https://theses.hal.science/tel-00777611v1>

Submitted on 21 Jan 2013

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.



HAL Authorization

THESE

présentée
pour obtenir le grade de

DOCTEUR DE L'UNIVERSITE DE TECHNOLOGIE DE
BELFORT MONTBELIARD ET DE L'UNIVERSITE DE
FRANCHE COMTE

Spécialité : Sciences Pour l'Ingénieur et Microtechniques

par

Samir JEMEI

D.E.A Procédés et Traitement de l'Energie Electrique

Modélisation d'une pile à combustible de type PEM par réseaux de neurones

soutenue le 14 octobre 2004 devant le jury composé de :

Mme	B. SEMAIL	Président
MM.	M. FADEL L. FOULLOY	Rapporteur Rapporteur
Mme MM.	M. CLOAREC J.M. KAUFFMANN D. HISSEL J.P LISSE S. MILLEMANN	Directeur de thèse Co-directeur de thèse

RESUME

Modélisation d'une Pile à Combustible de type PEM par Réseaux de Neurones

Mots clés

-
- | | |
|----------------------------------|-------------------------------------|
| • Pile à Combustible et systèmes | • Validation expérimentale |
| • Réseaux de Neurones | • Etude de sensibilité paramétrique |
| • Modélisation non linéaire | |
-

Résumé

Ce travail apporte une contribution à la modélisation des piles à combustible de type PEM. La modélisation fait ici appel aux réseaux artificiels de neurones et est appliquée à deux piles à combustible de puissances différentes.

La première partie de ce mémoire rappelle les verrous technologiques liés à l'intégration des piles à combustibles dans un véhicule. Puis l'auteur s'interroge sur la nécessité de modéliser une pile à combustible avant de se pencher sur les différentes méthodes de modélisation existante.

La réalisation d'un modèle neuronal décrivant le comportement statique d'une pile à combustible de type PEM est la première étape de cette étude. La deuxième partie décrit la démarche qui a permis de réaliser ce modèle. Elle se décompose en trois points essentiels : 1) choix d'une topologie adaptée, 2) choix d'essais expérimentaux pour établir une séquence d'apprentissage représentative du système et choix des entrées/sorties du modèle, 3) étude de différentes techniques d'apprentissage menant à une modélisation satisfaisante.

Afin d'obtenir un modèle complet, le comportement dynamique de la pile doit être décrit. L'élaboration du modèle dynamique à l'aide de réseaux de neurones bouclés est exposée dans la troisième partie.

Pour conclure ce mémoire, une méthode originale basée sur l'analyse de Fourier permet d'obtenir une boîte noire multi-modèle permettant de coupler les modèles dynamiques et statiques pour prédire l'évolution temporelle de la tension de la pile à combustible selon des sollicitations de courant à fréquence variable. Enfin, une étude de sensibilité paramétrique est réalisée.

ABSTRACT

Neural Network Model of a PEM Fuel Cell Power Generator

Keywords

-
- | | |
|------------------------------------|---------------------------------|
| • Fuel Cell generators and systems | • Experimental validation |
| • Artificial Neural Network | • Sensitive parametric analysis |
| • Non linear modelling | |
-

Abstract

This work deals with the modeling of a PEM fuel cell generator. This item will be seen here under the angle of Artificial Neural Network and applied to two different PEM fuel cells. By training, Artificial Neural Networks enable to carry out models which adapt to experimental behaviours observed.

The first part talks about the technological problems bonded to the fuel cell integration in a vehicle. Then, the author points out the necessity of modelling a fuel cell generator before listing the different way of modelling.

The first step of this study is dedicated to the possibility to realize a Neural Network model able to evaluate the static mode of a PEM fuel cell. The second part describes the approach which allows carrying out this first model. This part is divided in three essential points; choice of a network structure, choice of experimental tests to establish a representative training sequence of the system and choice of inputs/outputs of the model, study of different training methods carrying out to a good modeling. The conclusion of this part emphasizes the extrapolation ability of this model to more powerful fuel cell.

To have a complete model, dynamic behaviour of the fuel cell must be studied. The development of the dynamic model using recurrent neural network is presented in a third part.

In order to conclude this work, an original method based on Fourier analysis is proposed. By this way, in order to predict the voltage response of the fuel cell under dynamic current solicitations, a multi model black box, which couples dynamic and static models, has been developed. Finally, a sensitive parametric analysis is done.

Avant Propos

Les travaux de recherche présentés dans ce mémoire ont été réalisés au sein du laboratoire de recherche en Electronique, Electrotechnique et Systèmes (L2ES) que dirige Monsieur Jean-Marie Kauffmann, professeur à l'Université de Franche Comté. Cette thèse a été financée par le constructeur automobile PSA Peugeot Citroën.

Au terme de ces trois années de recherche, je souhaiterais remercier ici tous ceux qui ont contribué à l'aboutissement de ce travail, en me soutenant tant d'un point professionnel que personnel. Ainsi, je souhaiterais remercier :

- *Madame B. SEMAIL, Professeur à l'école polytechnique de Lille (POLYTECH'LILLE) pour m'avoir fait l'honneur d'accepter la présidence de mon jury de thèse,*
- *Monsieur M. FADEL, Professeur à l'Institut National Polytechnique de Toulouse, pour l'intérêt qu'il a manifesté à l'égard de ce travail en acceptant d'en être rapporteur,*
- *Monsieur L. FOULLOY, Professeur à l'Université de Savoie et Directeur de l'Ecole Supérieure d'Ingénieurs d'Annecy, pour s'être chargé de la tâche de rapporteur de ce travail,*
- *Monsieur J.P LISSE, chef de groupe Sciences pour l'Automobile et Recherche Avancée Electromécanique, Electrochimie, Electronique et Systèmes de la société PSA Peugeot Citroën, pour sa participation à ce jury de thèse et pour le regard industriel qu'il a porté à ce travail,*
- *Madame M. CLOAREC, ingénieur PSA Peugeot Citroën, pour avoir participé à ce jury de thèse et pour ses remarques pertinentes et constructives durant ces trois dernières années.*
- *Monsieur S. MILLEMANN, ingénieur PSA Peugeot Citroën, pour l'attention portée à ce travail en acceptant de participer à ce jury,*
- *Monsieur J.M. KAUFFMANN, Professeur à l'Université de Franche Comté et Directeur du laboratoire de recherche en Electronique, Electrotechnique et Systèmes (L2ES), pour m'avoir accueilli au sein de son laboratoire et pour avoir accepté d'être Directeur de cette thèse. Je le remercie pour les moyens qu'il a mis à ma disposition, permettant ainsi l'avancée de mes travaux dans le meilleur environnement qui soit. Ses conseils avisés et sa clairvoyance m'ont permis de conduire cette thèse à bon port,*
- *Monsieur D. HISSEL, Maître de Conférences à l'Université de Technologie de Belfort Montbéliard, pour avoir accepté de co-diriger cette thèse et pour l'encadrement scientifique dans le domaine des piles à combustible et de la modélisation de processus. Ses compétences, sa rigueur, sa disponibilité, son engagement, sa patience ainsi que sa gentillesse à mon égard ont été un apport indispensable pour l'orientation et l'aboutissement de ces travaux. Je suis honoré d'avoir eu l'opportunité de travailler avec Monsieur HISSEL. Enfin, je tiens à le*

remercier pour sa franchise et ses nombreux conseils qui me seront fort utiles quelles que soient mes futurs orientations professionnelles.

Je remercie également :

- *Madame M.C. PERA, Maître de Conférences à l'Université de Franche Comté, pour avoir guidé mes premiers pas dans le domaine des piles à combustibles et pour avoir encadré mon DEA,*
- *Monsieur X. FRANCOIS, Ingénieur de Recherche au Laboratoire de recherche en Electronique, Electrotechnique et Systèmes, pour sa gentillesse et sa grande disponibilité pour la mise en place du premier banc d'essais pile à combustible,*
- *Monsieur F. HAREL, Ingénieur d'étude INRETS, pour son implication dans le développement d'un banc d'essais performant sans quoi, mes travaux n'auraient pu être effectués dans de bonnes conditions.*

Je tiens également à remercier tout le personnel du LEES et plus particulièrement Messieurs GUSTIN et BOUQUAIN pour leur disponibilité et leur aide précieuse dans les domaines informatiques et électroniques. Sans oublier Denis CANDUSSO qui a su m'accorder le temps nécessaire pour me former sur le banc d'essais Hélion.

J'adresse également une pensée amicale à tous mes amis thésards ou docteurs et les maîtres de conférences du L2ES que j'ai eu l'occasion de cotoyer ces dernières années. Je pense notamment :

- *aux inconditionnels du café du commerce, El Hadj M. (je te remercie particulièrement pour m'avoir ouvert les yeux sur la condition de la femme dans le monde), Laurent D. (notre chasseur de grenouille national qui se voit de temps à autre politicien d'une planète bien étrange...), Didier Z. (notre alsacien belfortain sans qui je n'aurai jamais pu organiser mon pot de thèse dans de bonnes conditions et qui a su me coacher pour l'exercice final) et tous ceux qui ont participé, ne serait ce qu'une fois à ce rendez-vous quotidien. Merci pour ces moments de détente indispensables...*
- *aux faux footballeurs, Daniel H. (supporteur inconditionnel du FC Metz), Christophe E. (allez Sochaux !), Raynal G. (LE strasbourgeois) et enfin Didier C. (la gloire stéphanoise). Je vous remercie pour le temps passé à pronostiquer les résultats et les compétences des différentes équipes du championnat de France. Allez l'OM...*

Je tiens à remercier aussi tous mes amis qui m'ont soutenu au cours des périodes difficiles encourues ces dernières années. Je pense plus particulièrement :

- *aux anciens, la famille Gobetti (pour tous ce qu'elle a pu m'apporter), Cyril N. (qui était présent le jour du déclin et qui est toujours présent), Ludovic G. (mon petit papy), Céline S. (ma mère poule préférée), Cécile G. (ma petite sœur de cœur) et enfin Elise à qui je dois beaucoup...*

- *aux petits nouveaux, Nicolas M. (mon mentor...), Frédéric J. (smile-man), la bande du FC Bourogne et enfin ma chère et tendre Carole.*

Que ce mémoire vienne récompenser mes sœurs Amèle et Anissa ainsi que mes parents pour leur amour, leur soutien et leur compréhension.

Ma dernière pensée revient à mon oncle Nabil et mon grand-père Mustapha, qui auraient été certainement très fiers de me voir atteindre mon objectif.

TABLE DES MATIERES

TABLE DES MATIERES	1
TABLE DES FIGURES.....	7
LISTE DES TABLEAUX.....	13
NOMENCLATURE	17
GLOSSAIRE.....	19
INTRODUCTION GENERALE.....	21
- CHAPITRE 1 - INTRODUCTION SUR LES PILES A COMBUSTIBLE	27
1.1. Introduction	28
1.2. Description d'une pile à combustible	29
1.2.1. Composition d'une pile à combustible.....	29
1.2.2. Les différents types de pile à combustible.....	29
1.2.3. Principe de fonctionnement d'une pile à combustible	30
1.3. Problématiques des piles à combustibles dans les véhicules.....	32
1.3.1. Intégration et coût.....	32
1.3.1.1. Intégration	32
1.3.1.2. Coût.....	35
1.3.2. Optimisation énergétique du système.....	38
1.3.3. Stockage de l'hydrogène.....	39
1.3.3.1. Stockage de l'hydrogène sous forme comprimée.....	39
1.3.3.2. Stockage de l'hydrogène sous forme liquide	40
1.3.3.3. Stockage de l'hydrogène dans les hydrures.....	40
1.3.3.4. Autres formes de stockage.....	41
1.3.4. Le reformage	41
1.3.5. Risques liés à l'hydrogène.....	41
1.4. Introduction à la modélisation.....	43
1.4.1. Types de modélisation	43
1.4.1.1. Les modèles de connaissance.....	43
1.4.1.2. Les modèles de représentation ou comportementaux.....	44
1.4.1.2.1. Les modèles boîte noire	44
1.4.1.2.2. Les modèles boîte grise.....	44
1.4.2. Quel modèle pour le système pile à combustible ?	45
1.5. Conclusion	46

Table des matières

- CHAPITRE 2 - LES RESEAUX DE NEURONES POUR LA MODELISATION STATIQUE D'UNE PILE DE TYPE PEM	49
2.1. Introduction sur les réseaux de neurones (RN)	50
2.2. Le neurone formel	51
2.2.1. Les réseaux de neurones monocouche non bouclés	52
2.2.2. Les réseaux de neurones multicouches non bouclés	52
2.3. Les méthodologies d'apprentissage	54
2.3.1. La fonction coût	54
2.3.2. La méthode du gradient	55
2.3.3. La méthode de Newton	57
2.3.4. La méthode de quasi-Newton	58
2.3.5. Pas de descente variable	58
2.3.6. Apprentissage et estimation de la performance	59
2.3.6.1. La validation croisée	59
2.3.6.2. La modération des poids	60
2.3.7. Le « bootstrap »	61
2.3.7.1. L'erreur de généralisation estimée par le « bootstrap »	62
2.3.7.2. Statistique de l'erreur de généralisation	63
2.3.7.3. Mise en œuvre de l'apprentissage par la méthode du « bootstrap »	63
2.3.7.4. Intérêt de cette méthodologie	64
2.4. Modélisation statique d'une pile à combustible de type PEM 500W	66
2.4.1. Présentation du banc d'essai	66
2.4.2. Essais expérimentaux	68
2.4.2.1. Courbes de polarisation à stœchiométrie constante ($FSA = 2$, $FSC = 5$) pour différentes températures de fonctionnement	68
2.4.2.2. Courbes de polarisation à température ($T=50^{\circ}C$) et stœchiométries constantes ($FSA = 2$, $FSC = 5$) pour différentes hygrométries relatives	69
2.4.2.3. Courbes de polarisation à température ($T = 50^{\circ}C$) et hygrométrie relative constantes ($H = 100\%$) pour différentes valeurs de stœchiométries	70
2.4.2.4. Conclusions sur les essais expérimentaux	70
2.4.3. Architecture	71
2.4.3.1. Entrées/sorties du modèle	71
2.4.3.2. Choix du nombre de couches cachées	71
2.4.3.3. Choix du nombre de neurones et leur fonction d'activation	72
2.4.4. Apprentissage	73
2.4.4.1. Normalisation des données	73
2.4.4.2. Choix des bases de données	73
2.4.5. Résultats de simulation	74
2.4.6. Ajout de bruit dans la base d'apprentissage	77
2.4.7. Neural Network Toolbox (NNToolbox)	78
2.4.8. Résultats obtenus avec le Bootstrap	79
2.5. Modélisation statique d'une pile de type PEM 5 kW	80
2.5.1. Présentation du banc d'essai	80
2.5.2. Essais expérimentaux	81
2.5.3. Architecture et méthodes d'apprentissage	82
2.5.4. Résultats de simulation	82
2.6. Conclusion	85
 - CHAPITRE 3 - LES RESEAUX DE NEURONES POUR LA MODELISATION DYNAMIQUE D'UNE PILE DE TYPE PEM	 87
3.1. Introduction	88
3.2. Méthodologies pour la modélisation dynamique	89
3.2.1. Les réseaux de neurones bouclés	89
3.2.1.1. Les réseaux bouclés localement	89

Table des matières

3.2.1.2. Les réseaux bouclés globalement	89
3.2.2. Les modèles d'Elman et de Jordan.....	90
3.2.2.1. Le réseau de Jordan	90
3.2.2.2. Le réseau d'Elman.....	91
3.2.2.3. Les tours de Jordan et d'Elman.....	91
3.2.3. Méthode d'apprentissage	92
3.2.3.1. Création du vecteur d'états.....	93
3.2.3.2. Différences entre le bouclage artificiel et réel.....	94
3.3. Modélisation dynamique d'une pile à combustible de 500W	96
3.3.1. Résultats expérimentaux.....	96
3.3.1.1. Créneaux de courant	97
3.3.1.2. Sinusoïdes de courant.....	98
3.3.1.3. Sollicitation triangulaire.....	99
3.3.2. Post-traitement des données expérimentales	99
3.3.3. Architecture multi-modèle	101
3.3.3.1. Résultats issus d'un apprentissage « créneaux ».....	102
3.3.3.2. Comparaison entre un apprentissage artificiel et réel.....	106
3.3.3.3. Importance du choix des séquences d'apprentissage et de validation.....	107
3.4. Modélisation dynamique d'une pile à combustible de 5 kW	109
3.4.1. Résultats expérimentaux.....	109
3.4.1.1. Créneaux de courant	110
3.4.1.2. Sinusoïdes de courant.....	111
3.4.1.3. Sollicitation triangulaire.....	111
3.4.2. Utilisation du modèle.....	112
3.4.3. Résultats de simulations	112
3.4.3.1. Tests sur des formes créneaux à basse fréquence.....	112
3.4.3.2. Test sur des formes créneaux à moyenne fréquence.....	113
3.4.3.3. Tests sur des formes créneaux à haute fréquence.....	113
3.4.4. Comparaison entre un apprentissage artificiel et réel.....	115
3.5. Connexions des sous réseaux.....	116
3.5.1. Méthodologie.....	116
3.5.2. Etude d'une sollicitation créneau à fréquence fixe.....	118
3.6. Conclusion	121
- CHAPITRE 4 - APPLICATION DU MODELE AU TRANSPORT	123
4.1. Introduction	124
4.2. Adaptation du modèle dynamiques aux contraintes transport.....	125
4.2.1. Rappel.....	125
4.2.2. Principe.....	125
4.2.3. Les fenêtres de pondération.....	126
4.2.4. Application et perfectionnement de la méthodologie de fenêtrage sur le modèle de pile 500W	129
4.2.4.1. Essais expérimentaux	129
4.2.4.2. Résultats de simulations obtenus à l'aide du modèle 500W	130
4.3. Portage de la méthodologie sur le modèle 5kW	135
4.3.1. Essais expérimentaux.....	135
4.3.2. Simulations à l'aide du modèle 5kW	136
4.4. Etude de sensibilité paramétrique.....	139
4.4.1. Etude du modèle statique.....	139
4.4.1.1. Modèle 500W.....	139
4.4.1.2. Modèle statique 5kW	141
4.4.2. Etude du modèle dynamique.....	143
4.4.2.1. Modèle 500W.....	143
4.4.2.2. Modèle 5 kW	144
4.5. Conclusion	145

CONCLUSION GENERALE	149
ANNEXE A : PRESENTATION DU BANC D’ESSAIS PILE A COMBUSTIBLE DE 500W	155
OBJECTIFS DU BANC D’ESSAIS.....	156
DESCRIPTION DU BANC D’ESSAI	157
Caractéristiques de la pile à combustible PEM de 500W testée.....	157
Le système de gestion du banc	158
Synoptique détaillé du banc d’essais.....	158
Nature des mesures et commandes sur le banc d’essai.....	159
Circuits d’air et d’hydrogène.....	160
Système de régulation de température d’eau de la pile	163
ANNEXE B : PRESENTATION DU BANC D’ESSAI HELION 5 KW	165
DESCRIPTION DU BANC D’ESSAI	166
Domaine de fonctionnement du stack Héliion 5 kW.....	166
Le système de contrôle commande	168
Auxiliaires et circuits annexes	168
Système de régulation de température.....	168
Circuits d’air et d’hydrogène.....	169
ANNEXE C : METHODES DU GRADIENT ET DE QUASI NEWTON.....	171
CALCUL DU GRADIENT DE LA FONCTION COUT DANS UN RESEAU MULTICOUCHE	172
Calcul du gradient de la fonction coût aux points $w_{uq,2}$	173
Calcul du gradient de la fonction coût aux points $w_{pu,1}$	174
Calcul du gradient de la fonction coût aux points $w_{hp,0}$	175
BIBLIOGRAPHIE	177

TABLE DES FIGURES

- Chapitre 1 -

Figure 1.1: Composition d'une cellule élémentaire d'une pile à combustible de type PEM	29
Figure 1.2: Schéma de principe d'un assemblage de cellules élémentaires Cathode/Electrolyte/Anode et plaques bipolaires d'une pile PEMFC.....	30
Figure 1.3: Illustration des interconnexions entre le cœur de pile et ses auxiliaires	33
Figure 1.4: Intégration du système pile à combustible.	34
Figure 1.5: Evolution de la masse spécifique d'un système pile à combustible au cours des dix dernières années.	35
Figure 1.6: Répartition des coûts des composants d'un cœur de pile.....	37
Figure 1.7: Répartition des puissances consommées par les périphériques dans un système pile à combustible.	38

- Chapitre 2 -

Figure 2.1: Représentation d'un neurone.....	51
Figure 2.2: Exemples de fonctions d'activation a) signe, b) identité, c) linéaire saturée, d) sigmoïde, e) tangente hyperbolique.....	51
Figure 2.3: Représentation d'une couche de neurones.	52
Figure 2.4: Représentation d'un réseau de neurones multicouches ou feedforward.	53
Figure 2.5: Connexions partielles a) et totales b).....	53
Figure 2.6: Architecture d'un réseau de neurones à 2 couches cachées	56
Figure 2.7: Evolution de l'erreur quadratique sur les séquences d'apprentissage et de test.	60
Figure 2.8: le « bootstrap »	62
Figure 2.9: Algorithme du « bootstrap »	64
Figure 2.10: répartition des données.	64
Figure 2.11: Banc de test pour une pile à combustible de type PEM basse puissance version 2.	67
Figure 2.12: Courbes de polarisations à différentes températures, air sec.....	68
Figure 2.13: Courbes de polarisations à différentes températures, air humidifié.....	69
Figure 2.14: Courbes de polarisations à différentes hygrométries de l'air, température de fonctionnement et facteurs stoechiométriques constants (FSA=2, FSC=5).....	69

Table des figures

Figure 2.15: Courbes de polarisations à différentes valeurs de stœchiométries, température de fonctionnement et hygrométrie relative constantes.	70
Figure 2.16: Paramètres du réseau	72
Figure 2.17: Erreur Quadratique Moyenne sur la séquence d'Apprentissage (EQMA).....	75
Figure 2.18: Erreur Quadratique Moyenne sur la séquence de Validation (EQMV)	75
Figure 2.19: Courbes de polarisation mesurées et calculées (FSA=2, FSC=6, T°=25°C, H=100%)....	76
Figure 2.20: Courbes de polarisation mesurées et calculées (FSA=2, FSC=6, T°=25°C, H=100%)....	76
Figure 2.21: hystérésis U (I).	77
Figure 2.22: Corrélation entre l'erreur quadratique et le bruit.	78
Figure 2.23: Banc de test pour une pile à combustible de type PEM 5kW.....	80
Figure 2.24: courbes de polarisation pour différents facteurs de stœchiométrie à T = 30°C.....	81
Figure 2.25: courbes de polarisation pour différents facteurs de stœchiométrie à T = 40°C.....	81
Figure 2.26: courbes de polarisation pour différents facteurs de stœchiométrie à T = 50°C.....	82
Figure 2.27: paramètres du réseau.....	82
Figure 2.28: Courbes polarisation mesurée et calculée (FSA=1.1 FSC=2.4, T°=40°C, H=100%).....	83
Figure 2.29: Courbes polarisation mesurée et calculée (FSA=1.1, FSC=2, T°=50°C, H=100%).....	83
Figure 2.30: Courbes polarisation mesurée et calculée (FS=1 et 2.2, T°=60°C, H=100%).....	83
Figure 2.31: Comparaison des courbes statiques U(I) de pile de type PEM de différentes puissances.	84

- Chapitre 3 -

Figure 3.1: Exemple d'architecture de réseau comportant une boucle locale sur les neurones.	89
Figure 3.2: Exemple d'architecture de réseau comportant une boucle globale sur le réseau.....	90
Figure 3.3: Exemple d'architecture d'un réseau de Jordan.....	90
Figure 3.4: Exemple d'architecture d'un réseau d'Elman.	91
Figure 3.5: Tour de Jordan a) et tour d'Elman b).....	92
Figure 3.6: Composition du vecteur d'état.	93
Figure 3.7: Algorithmes d'apprentissage.....	95
Figure 3.8: Réponses en tension d'une sollicitation courant sinusoïdale pour différentes fréquences élevées.....	96
Figure 3.9: Réponses en tension d'une sollicitation courant créneau pour différentes fréquences.	97
Figure 3.10: Réponses en tension d'une sollicitation courant sinusoïdale pour différentes fréquences.	98
Figure 3.11: Réponses en tension d'une sollicitation courant triangulaire pour différentes fréquences.	99
Figure 3.12: Echantillonnage de la tension mesurée.	100
Figure 3.13: Architecture (entrées sortie) d'un sous réseau.....	101
Figure 3.14: Modèle global composé de trois sous réseaux.....	101
Figure 3.15: U(t) mesurée et calculée par le réseau RNA1 et I(t) « rectangulaire ».	103
Figure 3.16: U(t) mesurée et calculée par le réseau RNA2 et I(t) « rectangulaire ».	103
Figure 3.17: U(t) mesurée et calculée par le réseau RNA3 et I(t) « rectangulaire ».	104
Figure 3.18: U(t) mesurée et calculée par le réseau RNA1 et I(t) « sinusoïdal ».	104
Figure 3.19: U(t) mesurée et calculée par les réseaux RNA2, RNA3 et I(t) « sinusoïdal ».	105
Figure 3.20: U(t) mesurée et calculée par les réseaux RNA2, RNA3 et I(t) « triangulaire ».	105

Table des figures

Figure 3.21: a) $U(t)$ calculée par le réseau RNA1 avec un bouclage artificiel, b) $U(t)$ calculée par le réseau RNA1 avec un bouclage réel.	107
Figure 3.22: Réponses en tension d'une sollicitation en courant de la pile 5kW pour différentes fréquences élevées (FSA=1.2, FSC=2.3, T=60°C et H=100%).	109
Figure 3.23: Réponses en tension d'une sollicitation courant créneau pour différentes fréquences ...	110
Figure 3.24: Réponses en tension d'une sollicitation courant sinusoïdale pour différentes fréquences	111
Figure 3.25: Réponses en tension d'une sollicitation courant triangulaire pour différentes fréquences	111
Figure 3.26: $U(t)$ mesurée et calculée par le réseau RNA1 et $I(t)$ « rectangulaire »	113
Figure 3.27: $U(t)$ mesurée et calculée par le réseau RNA2 et $I(t)$ « rectangulaire »	113
Figure 3.28: $U(t)$ mesurée et calculée par le réseau RNA3 et $I(t)$ « rectangulaire »	114
Figure 3.29: $U(t)$ mesurée et calculée par les réseaux RNA1, RNA2 et RNA3 et $I(t)$ « sinusoïdal ».	114
Figure 3.30: Algorithme de la méthodologie adoptée.	117
Figure 3.31: Créneau de courant	118
Figure 3.32: Analyse spectrale.....	118
Figure 3.33: Représentation de la phase en fonction de la fréquence.....	119
Figure 3.34: Tensions prédites par le modèle, extrapolation a) et émulation b).	120

- Chapitre 4 -

Figure 4.1: a) Signal sinusoïdal de fréquence $f = 10$ Hz, b) représentation fréquentielle du sinus	125
Figure 4.2: a) Signal sinusoïdal de fréquence $f = 15$ Hz, b) représentation fréquentielle du sinus	126
Figure 4.3: Les fonctions fenêtre dans leur aspect temporel.....	127
Figure 4.4: Signal sinusoïdal de 15 Hz fenêtré.	128
Figure 4.5: Spectre du signal fenêtré.....	128
Figure 4.6: Gabarit de Hamming utilisé pour notre étude	129
Figure 4.7: Signaux trapézoïdaux à fréquence variable.....	130
Figure 4.8: a) Réponses expérimentale et numérique en tension d'une sollicitation courant trapézoïdale à fréquence variable (fenêtrage de Hamming), b) zoom.	131
Figure 4.9: Comparaison de l'évolution temporelle de la tension pour deux amplitudes différentes a) $> 1A$ et b) $> 0.2A$	132
Figure 4.10: Réponses expérimentale et numérique en tension d'une sollicitation courant trapézoïdale à fréquence variable (fenêtrage de Hamming), prédiction à $t+1$	133
Figure 4.11: Evolution temporelle de la tension avec initialisation du fenêtrage	133
Figure 4.12: Evolution temporelle de la tension calculée par le modèle à l'aide d'un fenêtrage a) rectangulaire, b) de Bartlett et c) de Hanning.....	134
Figure 4.13: Réponses en tension d'une sollicitation de forme trapézoïdale à fréquence variable.....	136
Figure 4.14: Réponses en tension d'une sollicitation de forme trapézoïdale pour des moyennes fréquences	136
Figure 4.15: Résultats obtenus pour une amplitude supérieure à 7 A	137
Figure 4.16: Evolution temporelle de la tension calculée par le modèle	138
Figure 4.17: Evolution temporelle de la tension calculée par le modèle pour des moyennes fréquences	138
Figure 4.18: Evolution temporelle de la tension calculée par le modèle, prédiction à $t+1$	138

Table des figures

Figure 4.19: Variation de la tension en fonction de la variation des paramètres d'entrée du modèle 500W pour I=10A.....	140
Figure 4.20: Variation de la tension en fonction de la variation des paramètres d'entrée du modèle 500W pour I=25A et I=30A.	141
Figure 4.21: Variation de la sortie en fonction de la variation des paramètres d'entrée du modèle 5 kW pour I=50A.	142
Figure 4.22: Variation de la sortie en fonction de la variation des paramètres d'entrée du modèle 5 kW pour I=100A et I=150A.	142
Figure 4.23: Variations de l'énergie fournie par la pile au bout d'une seconde en fonction de la fréquence de la sollicitation en courant et des différents paramètres d'entrée (modèle 500W). .	144
Figure 4.24: Variations de l'énergie fournie par la pile au bout d'une seconde en fonction de la fréquence de la sollicitation en courant et des différents paramètres d'entrée (modèle 5 kW)...	145

- Annexe A -

Figure A 1: Banc d'essai 500W.	156
Figure A 2 : Interface graphique du système de gestion.....	158
Figure A 3: Synoptique détaillé de l'architecture du banc de test.....	159
Figure A 4 : Schéma de principe du circuit d'humidification d'air.....	162
Figure A 5 : Evolution des températures d'entrée air et de rosée en fonction des consignes	163
Figure A 6 : Régulation de la température et de l'hygrométrie de l'air.....	164

- Annexe B -

Figure B 1 : Banc d'essai Héliion 5 kW.	166
Figure B 2 :: Cœur de pile Héliion 5 kW.....	167
Figure B 3 : Circuits annexes de fluides.....	168
Figure B 4 : Régulation de la température de pile.....	169
Figure B 5 : Compresseur de recirculation	169

- Annexe C -

Figure C 1 : Architecture du réseau.....	172
--	-----

LISTE DES TABLEAUX

- Chapitre 1 -

Tableau 1.1: Les différents types de pile à combustible.....	30
--	----

- Chapitre 2 -

Tableau 2.1 : Notations.....	55
Tableau 2.2: Liste des paramètres contrôlables et mesurés.	67
Tableau 2.3 : Liste des paramètres normalisés.....	73
Tableau 2.4: Répartition des différentes bases de données.....	74
Tableau 2.5: Erreurs relevées sur modèle 500W.....	77
Tableau 2.6: Erreur minimale relevée avec la NNToolbox et temps de calcul.....	79
Tableau 2.7 : Erreurs relevées avec la méthode du Bootstrap	79
Tableau 2.8: Erreurs relevées sur le modèle 5kW.....	84

- Chapitre 3 -

Tableau 3.1 : Echantillonnage des différentes données expérimentales.....	100
Tableau 3.2 : Moyenne des erreurs de test en fonction du type d'apprentissage.	106
Tableau 3.3 : Liste des paramètres normalisés pour le modèle 5kW.	112
Tableau 3.4 : Moyenne des erreurs de test en fonction du type d'apprentissage	115

- Chapitre 4 -

Tableau 4.1 : Caractéristiques et utilisation des fenêtres de pondération	127
Tableau 4.2 : Erreurs et temps de calcul relevés en fonction de l'amplitude des harmoniques prise en compte (PAC 500W)	131
Tableau 4.3 : Erreurs et temps de calcul relevés en fonction de l'amplitude des harmoniques pris en compte (5kW).....	137
Tableau 4.4 : Variations des entrées du modèle 500W	139
Tableau 4.5: Variations des entrées du modèle 5kW	141

- Annexe A -

Tableau A 1 : Caractéristiques de la pile à combustible ZSW 500W.....	157
Tableau A 2 : Paramètres contrôlables	159
Tableau A 3 : Paramètres mesurés	160

- Annexe B -

Tableau B 1 : Point de fonctionnement nominal.....	167
Tableau B 2 : Limites de fonctionnement.....	167

NOMENCLATURE¹

Lettres latines

B_p	nombre d'itérations de l'algorithme du gradient	—
B_{pm}	nombre d'itération maximale de l'algorithme du gradient	—
b	biais	—
d	direction de descente du gradient	—
F	constante de Faraday (= 96485)	C mol ⁻¹
f	fréquence	Hz
H	hygrométrie relative de l'air entrant	%
H	enthalpie de réaction	KJ mol ⁻¹
I	activation du neurone	—
I	courant	A
J	fonction coût	—
M_n	amplitude de l'harmonique n	A
N_h	nombre de neurones cachés	—
P	pression	bar
Q_n	nombre d'itérations de l'algorithme de quasi Newton	—
Q_{nm}	nombre d'itération maximale de l'algorithme de quasi Newton	—
qH_2	débit massique d'hydrogène	Nl/min
qO_2	débit massique d'oxygène	Nl/min
T	température de fonctionnement de pile	°C
T	vecteur de sortie désiré	—
t_{ech}	instant d'échantillonnage	—
W	poids synaptiques	—
X	vecteur d'entrée du réseau de neurones	—
Y	vecteur de sortie du réseau de neurones	—

¹ Différentes grandeurs ont parfois une même notation utilisée de façon classique. Ces notations sont utilisées dans des contextes différents et ne prêtent pas à confusion.

Lettres grecques

α	pas de descente du gradient	—
δ	espérance du biais	—
ΔqH_2	variation du débit d'hydrogène de $\pm 50\%$ autour de la valeur nominale	%
ΔqO_2	variation du débit d'air de $\pm 50\%$ autour de la valeur nominale	%
ΔT	variation de la température de $\pm 50\%$ autour de la valeur nominale	%
ΔH	variation de l'hygrométrie de $\pm 50\%$ autour de la valeur nominale	%
Δw	gradient	—
ε	erreur relative entre les points calculés et les points mesurés	%
η_{pile}	rendement du générateur	%
η_E	rendement en potentiel	%
η_F	rendement faradique	%
η_s	rendement tenant compte des périphériques du générateur	%
Φ	vecteur de sortie d'une couche de neurones	—
ϕ_n	phase de l'harmonique n	rad
μ	hyperparamètre pour la modération des poids	—
σ	variance du biais	—
ω	pulsation	rad/s

GLOSSAIRE

Acronymes

AFC :	Alkaline Fuel Cell
APU :	Auxiliary Power Unit
DMFC :	Direct Methanol Fuel Cell
EME :	Electrode Membrane Electrode
EQMA :	Erreur Quadratique Moyenne sur la séquence d'Apprentissage
EQMV :	Erreur Quadratique Moyenne sur la séquence de Validation
EQMT :	Erreur Quadratique Moyenne sur la séquence de Test
FSA :	Facteur Stœchiométrie Anode
FSC :	Facteur Stœchiométrie Cathode
MCFC :	Molten Carbonate Fuel Cell
PAC :	Pile A Combustible
PAFC :	Phosphoric Acid Fuel Cell
PEMFC :	Proton Exchange Membrane Fuel Cell
RN :	Réseau de Neurones
SOFC :	Solid Oxid Fuel Cell
TTW :	Tank To Wheel
WTT :	Well To Tank
ZEV:	Zero Emission Vehicle

INTRODUCTION GENERALE

Introduction générale

La mondialisation caractérise une nouvelle donne économique dans laquelle l'industrialisation a pris une ampleur considérable. Ce développement économique a eu pour conséquences la création d'une société peu intéressée par son environnement et il a fallu attendre le début des années 1970 pour que les écologistes prennent conscience que cette croissance avait un impact négatif sur l'environnement. La protection de l'atmosphère constitue depuis une question essentielle qui touche à des politiques aussi diverses que les transports ou l'énergie. Le respect des engagements de Kyoto [UNF01] sur la réduction des émissions de gaz à effet de serre impose des mesures drastiques en faveur des économies d'énergie et le développement des énergies renouvelables. En effet, compte tenu de la poussée démographique mondiale, une attention croissante est accordée au fait que les réserves d'énergie sont nécessairement limitées et que le risque de se retrouver un jour devant une pénurie d'énergie est inévitable. Le domaine des transports est aujourd'hui sérieusement menacé car il est d'une part, extrêmement dépendant du pétrole et d'autre part il est en parti responsable des émissions de gaz à effet de serre. Il semble donc plus que nécessaire de commencer à réfléchir à ce qui pourrait remplacer les hydrocarbures et de proposer de nouvelles technologies de véhicules les plus propres possibles et cherchant à réduire autant que faire se peut les émissions polluantes.

Dans cette perspective, l'utilisation de la pile à combustible (PAC) dans une chaîne de traction d'un véhicule électrique est une solution porteuse d'espoir car elle promet à terme une pollution in situ proche de zéro. De plus, la filière hydrogène présente l'avantage de pouvoir réduire sur le long terme, la dépendance du secteur des transports vis-à-vis des énergies fossiles. Cependant, cette affirmation doit être tempérée. Si effectivement la pollution est quasi nulle pour un véhicule alimenté en hydrogène, il n'en est pas de même pour ceux générant de l'hydrogène directement de l'essence, du gazole voire du méthanol au moyen d'un reformeur. La seule comparaison valable doit être faite du « puits à la roue ». Les résultats sont alors moins probants. Il est vrai qu'il s'agit d'une technique non mature tant pour les piles à combustible que pour les reformeurs. De nombreux progrès sont à faire tant au niveau de la génération d'hydrogène qui rappelons le n'existe pas à l'état naturel et on parle plus du vecteur hydrogène, que du générateur pile à combustible.

Cette indépendance vis-à-vis des énergies fossiles suppose en fait que l'on dispose d'autres sources d'énergies comme l'énergie électrique pour produire l'hydrogène soit par électrolyse, qui est très gourmande en énergie soit par des techniques plus sophistiquées par procédés plasma [LUT03]. La pile à combustible présente en effet de nombreux avantages environnementaux. En plus de contribuer à la réduction de l'effet de serre, les véhicules propulsés à l'aide d'une pile à combustible, appelés plus communément véhicule zero émission (ZEV), permettent l'amélioration de la qualité de vie urbaine grâce à leur faible nuisance sonore. Cependant, de nombreux verrous technologiques et économiques doivent encore être relevés avant que les véhicules pile à combustible soient commercialisés. Néanmoins, les perspectives d'un développement commercial n'ont jamais été aussi bonnes par suite des efforts combinés de divers instituts de recherche au niveau mondial, de plusieurs grands groupes industriels et de constructeurs automobiles. De fait, l'apparition de cette nouvelle technologie dans l'automobile de masse va sans nul doute se réaliser progressivement.

Un système pile à combustible est un dispositif complexe où de nombreux phénomènes de nature différente interagissent entre eux. Aujourd'hui, les objectifs des différents constructeurs automobiles sont d'étudier les différents composants du système, de les modéliser et de les interconnecter au mieux en vue d'une optimisation globale du système. Le générateur PAC produit de l'énergie électrique et le véhicule est typiquement un véhicule hybride série. La génération par

Introduction générale

l'association moteur thermique et génératrice est remplacée par le générateur PAC. Nous ne reviendrons pas ici sur l'architecture de ces véhicules ni même sur l'intérêt d'un stockage tampon.

Parmi les différentes piles existantes, les piles à combustibles à membranes échangeuses de protons (PEM) semblent aujourd'hui les mieux adaptées pour servir de base à la motorisation des véhicules électriques. Ceci s'explique notamment par leur basse température de fonctionnement (environ 70°C) et la nature solide de l'électrolyte mise en jeu. Le but de ce mémoire est de proposer une modélisation statique et dynamique d'une telle pile à combustible de type PEM.

Devant la nature explicitement non linéaire du système à modéliser, le choix d'un outil de modélisation de processus non linéaires s'impose. Il existe de nombreuses méthodes capables de les traiter mais beaucoup souffrent de ne pas apporter de solutions universelles. Les modèles de connaissance apportent souvent une modélisation complète et fine mais ils nécessitent des connaissances approfondies du système étudié. A ce jour, les modèles de pile à combustible existant reposent souvent sur des modèles complexes basés sur une connaissance approfondie des phénomènes physico chimiques mis en jeu [NGU93], [BER91], [FRI03]. Or la connaissance des paramètres de ces modèles est souvent, pour une pile à combustible du commerce, difficile à appréhender. En effet, ces paramètres relèvent du « savoir faire » personnel du constructeur de pile à combustible ; celui-ci est dès lors souvent légitimement, peu enclin à les fournir. C'est pourquoi, nous nous sommes intéressés aux réseaux artificiels de neurones qui permettent une modélisation comportementale de type boîte noire.

La principale qualité des réseaux de neurones réside en effet dans leur aptitude à la modélisation des caractéristiques linéaires, non linéaires ou discontinues, à partir d'échantillons, en utilisant des méthodes d'optimisation non linéaires telles que la rétropropagation du gradient, les algorithmes génétiques, ... Ce mémoire présente ainsi une stratégie de modélisation d'une pile à combustible de type PEM par réseaux de neurones ; il se décompose en quatre chapitres.

Le premier chapitre consiste en une introduction sur les piles à combustible et sur la modélisation de processus. Dans une première partie, le principe d'une pile à combustible de type PEM et les problématiques liées à l'intégration dans un véhicule sont décrits. De nombreux points durs rendent encore aujourd'hui une application industrielle difficilement envisageable avant une dizaine d'années : coût du cœur de pile et des périphériques, problèmes d'intégration, de poids ou encore de performances atteintes par le système. A ces dilemmes s'ajoute celui, essentiel, du transport et du stockage d'hydrogène. Dans une seconde partie, une justification du choix des méthodes neuronales est fournie en s'appuyant sur une comparaison des différentes méthodes de modélisation existantes.

Les réseaux de neurones non bouclés sont présentés dans le deuxième chapitre. Ce chapitre a pour but d'introduire le vocabulaire et les méthodes utilisées pour l'élaboration d'un modèle statique d'une pile à combustible de type PEM. Les différentes architectures de réseaux de neurones susceptibles d'être adoptées pour notre étude sont rapidement présentées puis les différentes méthodologies d'apprentissage sont détaillées. Pour illustrer ces notions, nous décrirons la réalisation du modèle neuronal statique appliqué à une pile à combustible de type PEM d'une puissance de 500W. Cette première étude permettra de mettre en œuvre les notions de séquences d'apprentissage, de choix de topologie de réseaux de neurones, d'algorithme d'apprentissage ainsi que les différentes techniques susceptibles d'améliorer les résultats obtenus. Une autre méthode, appelée Bootstrap, permettant l'apprentissage de modèles par réseaux de neurones est également présentée. Un point clé de notre étude consiste dans un deuxième temps, à montrer la portabilité du modèle neuronal

développé sur d'autres piles à combustible. Ce chapitre s'achèvera ainsi par la présentation de l'adaptation du modèle neuronal statique proposé à une pile à combustible de type PEM de puissance dix fois supérieure (5kW).

La modélisation de la pile à combustible doit non seulement tenir compte du comportement en mode statique mais également décrire le comportement dynamique. Comme nous avons mis en œuvre les réseaux de neurones non bouclés pour la modélisation statique de la pile à combustible, il est intéressant de mettre en œuvre, de façon similaire, des réseaux de neurones bouclés pour modéliser de manière dynamique cette même pile. Le troisième chapitre est donc consacré à l'étude du modèle dynamique. Dans un premier temps, nous décrirons les architectures et méthodes d'apprentissage retenues puis nous présenterons les résultats obtenus à l'aide du modèle dynamique caractérisant la pile à combustible de 500W mais également celle de 5kW. Enfin, ce chapitre se terminera par l'introduction d'une méthodologie basée sur l'analyse de Fourier, permettant de fusionner les modèles statiques et dynamiques obtenus pour un signal périodique.

Un dernier chapitre est enfin consacré à l'étude du modèle établi pour des conditions transports. Pour cela, il est tout d'abord nécessaire d'étudier la réponse du générateur pile à combustible pour des sollicitations de courant à fréquences variables. Dans une première partie, nous décrirons donc les modifications apportées à la méthodologie basée sur l'analyse de Fourier pour permettre une telle approche. Ainsi, notre modèle sera capable de prédire l'évolution temporelle de la tension face à des sollicitations de courant à fréquences variables et ce, pour différentes valeurs des paramètres les plus influents sur le comportement de la pile à combustible. De plus, nous verrons que l'utilisation des modèles en tant que prédicteur à court terme se révèle efficace, ce qui laisse supposer que le modèle ainsi établi pourrait être envisagé pour la réalisation du contrôle commande du système pile à combustible. Dans une seconde partie, une étude de sensibilité paramétrique des modèles 500W et 5kW est présentée. Cette étude nous permettra d'appréhender les relations de causalité mises en jeu dans le modèle mais aussi permettre de définir les paramètres les plus influents sur le fonctionnement de la pile à combustible, et donc les plus pertinents à contrôler, en vue de son implantation dans un véhicule.

**- CHAPITRE 1 -INTRODUCTION SUR
LES PILES A COMBUSTIBLE**

1.1. Introduction

Le principe de la pile à combustible a été décrit dès 1839 par le savant anglais Sir William Grove. Depuis cette époque, l'intérêt pour cette technologie a subi de nombreux aléas. Cependant, nous sommes incontestablement depuis une trentaine d'années dans une période de redécouverte de cette technologie. Cette période a commencé au début des années 60 grâce aux programmes piles à combustible, financées par la NASA qui ont permis la mise en place de tels générateurs dans les applications spatiales (Gemini, Apollo).

Depuis le début des années 90, les piles à combustible suscitent un nouvel intérêt qui semble s'être encore accru durant les cinq dernières années.

Ce nouvel intérêt s'est notamment manifesté dans les applications terrestres du fait, entre autres, d'une réelle volonté de protection de l'environnement. En effet, l'évolution de l'atmosphère est devenue un problème majeur dû à la constante augmentation des concentrations d'émissions polluantes telles que l'oxyde de carbone (CO), le dioxyde de carbone (CO₂), le dioxyde de soufre (SO₂) ou encore les oxydes d'azote (NO_x) [PER03], [PUL02]. C'est pourquoi, depuis quelques années, des actions de recherche concertées, associant des constructeurs de matériel de transport, des fabricants de piles, des ensembliers ainsi que des laboratoires de recherche sont menées. Dans la plupart de ces programmes, ce sont des piles à combustible à membranes échangeuses de protons (PEM : **P**roton **E**xchange **M**embrane) qui sont à la base du système car elles seules répondent aux critères de dynamique requise, de température et de densités de puissance massique et volumique.

On distingue deux applications des piles dans le domaine de l'automobile : la propulsion du véhicule et l'alimentation en électricité des seuls appareils de bord (climatisation, lève vitres électriques, appareils électroniques) par le biais d'une APU (**A**uxiliary **P**ower **U**nit).

Les véhicules électriques alimentés par une pile à combustible de type PEM sont classés dans la catégorie des véhicules « Zero Emission » (ZEV : **Z**ero **E**mission **V**ehicle) car ils ont la particularité de ne rejeter que de l'eau si on considère un stockage direct de l'hydrogène à bord du véhicule. Néanmoins, on ne peut considérer la voiture seule, il faut aussi se soucier de la fabrication du carburant (l'hydrogène pour les PEM). On distingue ainsi les émissions (CO, CO₂, SO₂, NO_x, CH₄,) du puit au réservoir (WTT : **W**ell **T**o **T**ank) et celles du réservoir à la roue (TTW : **T**ank **T**o **W**heel). Pour un véhicule qui utilise un stockage d'hydrogène à bord, le bilan d'émissions TTW est quasiment nul. En revanche, si le carburant est fabriqué à partir d'un reformeur embarqué, il subsistera des émissions de CO, de particules, de NO_x inférieures à celle des véhicules traditionnels, mais non nulles.

Malgré les importants travaux réalisés sur les véhicules pile à combustible, de nombreux progrès restent à faire. Indépendamment des problèmes de production, de transport et de stockage d'hydrogène, il est nécessaire d'ajouter les problèmes liés aux coûts, à l'intégration, au poids et aux performances atteintes par le système. En plus de ces facteurs, l'utilisation d'un système pile à combustible à bord d'un véhicule nécessite de bien maîtriser son fonctionnement et donc de savoir modéliser son comportement global.

Nous présentons dans ce chapitre succinctement les piles à combustible et leur fonctionnement puis la problématique de l'utilisation des piles à combustible dans les applications transports. Nous nous interrogerons ensuite sur la nécessité de modéliser un système pile à combustible avant de se pencher sur les différentes méthodes de modélisation existantes.

1.2. Description d'une pile à combustible

1.2.1. Composition d'une pile à combustible

Une pile à combustible fonctionne sur le principe inverse de l'électrolyse de l'eau. Des réactifs chimiques permettent la production d'énergie électrique. Un cœur de pile est constitué d'une électrode négative (anode) où a lieu la réaction d'oxydation du carburant (hydrogène) et une électrode positive (cathode) où est réduit le comburant (oxygène de l'air) (Figure 1.1). Ces fluides doivent être fournis à la pile en respectant certaines conditions de pression, température, hygrométrie. De la même façon, la pile elle-même nécessite une régulation de température pour garantir des performances optimales.




Figure 1.1: Composition d'une cellule élémentaire d'une pile à combustible de type PEM

Une pile à combustible est constituée d'un empilement d'éléments anode/électrolyte/cathode reliés par l'intermédiaire de plaques bipolaires formant ainsi un « stack ». Elles sont placées en série électriquement et leur alimentation en gaz se fait en parallèle comme illustré à la figure 1.2 [KIN01].

1.2.2. Les différents types de pile à combustible

L'électrolyte doit être un isolant électronique et un conducteur ionique. Il peut être soit liquide, soit solide. Les plaques bipolaires permettent l'accès des gaz par la présence de canaux, jusqu'aux sites réactionnels. Il existe six types de piles à combustible qui, suivant l'électrolyte, fonctionnent à différentes températures. Leurs caractéristiques sont données dans le Tableau 1.1.

- Pile alcaline (Alkaline Fuel Cell)
- Pile à membrane échangeuse de protons (Proton Exchange Membrane Fuel Cell)
- Pile à membrane fonctionnant au méthanol (Direct Methanol Fuel Cell)
- Pile à acide phosphorique (Phosphoric Acid Fuel Cell)
- Pile à carbonate fondu (Molten Carbonate Fuel Cell)
- Pile à oxyde solide (Solid Oxid Fuel Cell)

<i>PàC</i>	<i>Electrolyte</i>	<i>T° fonctionnement</i>	<i>Combustible</i>	<i>Comburant</i>
AFC	Solution KOH	<100°C	H ₂ pur	Air ou O ₂ pur
PEMFC	Membrane à échange de protons (à base de fluor)	50-85°C	H ₂ pur	Air ou O ₂ pur
DMFC	Membrane à échange de protons	60-120°C	CH ₃ OH	Air ou O ₂ pur
PAFC	Acide phosphorique	160-220°C	H ₂ , CH ₄ , CH ₃ OH	Air
MCFC	Mélange de Li ₂ CO ₃ et de KCO ₃	600-800°C	H ₂ , CH ₄	Air
SOFC	Oxyde de zirconium stabilisé ZrO ₂ et yttrium Y ₂ O ₃	600-1000°C	H ₂ , CH ₄ , CH ₃ OH, CO	Air

Tableau 1.1: Les différents types de pile à combustible




Figure 1.2: Schéma de principe d'un assemblage de cellules élémentaires Cathode/Electrolyte/Anode et plaques bipolaires d'une pile PEMFC.


1.2.3. Principe de fonctionnement d'une pile à combustible

Une pile à combustible est un générateur d'électricité transformant de l'énergie chimique d'un gaz ou liquide combustible en énergie électrique. De manière générale, le combustible est de l'hydrogène et il se combine avec de l'oxygène pour former de l'eau selon la réaction chimique (équation 1.1). Cette relation correspond à celle de la combustion de l'hydrogène. L'énergie de cette réaction est libérée sous forme de chaleur et sous forme d'électricité. La combustion se produit à l'aide d'un catalyseur à base de platine (Pt).




Pour quantifier l'énergie fournie lors de la réaction, le repère généralement utilisé est l'énergie libérée lors de la combustion des réactants. Cette énergie est appelée enthalpie ΔH , elle dépend de l'état des réactants avant et après la réaction. L'enthalpie de réaction est définie par $\Delta H_R = \Delta H_{produits} - \Delta H_{réactifs}$. Pour la combustion de l'hydrogène créant de l'eau, on considère deux possibilités [FRI03].

La première est la création d'eau sous forme vapeur (équation 1.2) :





Si l'eau est condensée après la combustion, la valeur de l'enthalpie change (équation 1.3) :



La différence entre les deux valeurs correspond à l'enthalpie d'évaporation de l'eau, ou chaleur latente. La valeur négative de ΔH explique la création de chaleur ($\Delta H < 0$) lors de la réaction.

Dans le cas particulier de la pile à combustible à membrane échangeuse de protons (PEMFC), les deux demi réactions s'écrivent :



Le transport des protons à travers l'électrolyte est assuré par les molécules d'eau qu'il contient. Ainsi, la PEMFC fonctionne à une température d'environ 80°C, de façon à maintenir l'eau contenue dans la membrane sous forme liquide. Un assèchement de la membrane induit une augmentation de la résistance protonique et ainsi à une diminution des performances électrique de la pile. La gestion de l'eau doit donc être particulièrement soignée. Le transport de l'eau dans la membrane supposée dense est la résultante de deux phénomènes opposés. Du fait d'une différence d'activité de part et d'autre de la membrane, il existe un flux diffusif d'eau qui aurait tendance à s'établir de la cathode vers l'anode puisque l'eau est produite à la cathode (équation 1.5). D'autre part, la migration des cations de l'anode vers la cathode sous l'effet du champ électrique, engendre un flux d'eau de même sens dû à l'électro-osmose (drainage de molécules d'eau dans le sillage des porteurs de charge) [GER96]. En ce sens, les degrés d'humidification des gaz se révèlent importants.

Après avoir expliqué le principe de fonctionnement d'une pile à combustible de type PEMFC, nous allons nous intéresser aux problématiques des piles à combustible dans les applications transport.

1.3. Problématiques des piles à combustibles dans les véhicules

La propulsion des véhicules par un système pile à combustible semble être une alternative séduisante et prometteuse car elle permettrait de s'affranchir de la dépendance énergétique aux réserves pétrolières tout en proposant des véhicules pas ou peu polluants. Il est cependant important de souligner les progrès réalisés sur les moteurs à combustion interne en terme d'émissions polluantes, néanmoins, celles-ci restent toujours présentes, même en faible quantité.

Certains constructeurs automobiles ont annoncé un lancement des véhicules à pile à combustible dès 2008.. Il est aujourd'hui évident que les premiers véhicules qui seront proposés sur le marché seront des flottes captives plutôt destinées aux entreprises et services publics. Pour atteindre cet objectif, il sera nécessaire de pallier les problèmes liés à l'intégration, aux coûts, à l'optimisation énergétique du système et également au stockage d'hydrogène.

1.3.1. Intégration et coût

Dans la chaîne de traction du véhicule, la pile à combustible se situe dans la partie appelée « source d'énergie électrique » ou « groupe électrogène », elle en est l'élément central. Ce groupe se situe entre le réservoir de combustible et la partie motorisation de la chaîne de traction, composée du groupe motopropulseur et de la transmission.

Il convient de souligner qu'un module de pile à combustible doit, pour fonctionner, être associé à des équipements auxiliaires. Ceux-ci assurent l'approvisionnement en réactifs (hydrogène et air) de la pile, leur conditionnement (pression, débit) et la gestion des produits de la réaction (eau, chaleur, électricité).

Ces auxiliaires peuvent représenter jusqu'à 60% en masse et en volume du système et une dépense énergétique de l'ordre de 30% [DEC01]. Par ailleurs, l'organe de stockage du combustible constitue un challenge technologique majeur car il conditionne notamment l'autonomie du véhicule.

1.3.1.1. Intégration

Comme pour un moteur thermique, divers périphériques sont donc nécessaires à la mise en œuvre d'un générateur d'énergie à pile à combustible de type PEM. Pour fonctionner, ce convertisseur doit au minimum être connecté à cinq composantes : une source d'hydrogène, une source d'oxygène (air ambiant), des évacuations des résidus ou des produits de la réaction, un système de gestion thermique qui assure le maintien en température du « convertisseur » et de ses constituants (refroidissement/chauffage), et enfin une charge électrique. Pour les PEMFC, il est également souvent nécessaire d'avoir une source d'eau pour maintenir un bon état d'hydratation des membranes (nota : de nombreux systèmes sur véhicule cherchent à être autosuffisants en eau de façon à s'affranchir de cette source, c'est à dire que l'eau produite par la réaction électrochimique est utilisée pour couvrir les besoins d'eau du système, l'hydratation des réactifs notamment). Toutes ces connexions se font par l'intermédiaire de circuits spécifiques soit, au minimum, quatre circuits de fluides et un circuit électrique.

La complexité des circuits est liée à la qualité des sources de combustible et de comburant ainsi qu'à l'autonomie recherchée. Si le combustible embarqué est un hydrocarbure, un reformeur est alors nécessaire. Si l'oxygène est prélevé dans l'atmosphère, il devra être dépoussiéré, exempt d'huile et comprimé à une pression compatible d'une part avec l'obtention d'une tension de pile suffisante,

d'autre part avec la perte de charge hydraulique des circuits et du réacteur. La recherche d'un rendement énergétique global satisfaisant nécessite la récupération de toutes les formes d'énergie sortant du réacteur, y compris l'énergie disponible dans les effluents gazeux. [SCH00]

Le schéma de la figure 1.3 présente l'ensemble du dispositif avec ses composants et ses différents circuits.




Figure 1.3: Illustration des interconnexions entre le cœur de pile et ses auxiliaires

A la cathode, la pile est alimentée en oxygène de l'air sous une pression qui varie, selon les constructeurs, de quelques centaines de millibars à 1,5 bars voire 2,5 bars (pressions relatives). Dans le cas des piles fonctionnant à pression atmosphérique, seul un circuit de circulation d'air suffit. Cependant ce type de pile implique un contrôle plus délicat de l'humidité dans la pile. Le débit d'air dans le compartiment cathodique varie de 1,5 à 3 fois le débit minimal nécessaire (débit stœchiométrique) pour une meilleure répartition de la concentration en oxygène et pour le drainage de l'eau produite. Cet air doit être humidifié pour assurer une conduction protonique correcte de la membrane. Ce procédé est généralement effectué à l'aide d'un humidificateur.

Dans le cas d'une pile haute pression, un compresseur est nécessaire. Pour les applications transports, il est impératif d'utiliser des compresseurs d'air compacts et légers fournissant de l'air exempt d'huile. Cependant, ceux-ci restent onéreux, bruyants et encombrants car en plus de la tête de compression, il faut intégrer le moteur, la commande et le système de refroidissement. Il existe plusieurs technologies pour les piles de type PEM, le turbocompresseur de Honeywell pèse environ 4 kg et occupe un volume de 6 l et peut alimenter une pile PEM de 50 kW. Le compresseur à spirale de Arthur D. Little,

également testé avec une pile de 50 kW pèse environ 36 kg pour un volume de 27 l. Les compagnies Meruit Inc. (compresseurs à paliers à gaz) et Vairex Corp. (compresseurs à piston ou à double vis) proposent aussi des solutions pour l'alimentation des piles PEM [CHA98], [CHA99], [CHA00]. Le problème majeur est qu'il est très difficile d'obtenir des compresseurs dédiés, ces derniers n'étant pas encore de réels produits commerciaux. De nombreuses recherches sont effectuées dans ce domaine pour fournir un groupe motocompresseur compact, léger, peu bruyant et moins onéreux [TEK03].

Le compartiment anodique est alimenté en hydrogène à partir d'un système de régulation qui impose le débit souhaité sous une pression sensiblement égale à la pression cathodique pour limiter les efforts mécaniques transverses sur la membrane électrolyte et par conséquent éviter le déchirement de la membrane. Son encombrement varie en fonction du stockage d'hydrogène choisi (pressurisé ou reformatage).

Le circuit d'air est donc le plus encombrant dans le cas où un compresseur est utilisé. Cependant, il faut ajouter à ces deux circuits des équipements nécessaires au bon fonctionnement du système notamment des capteurs de débits, pressions et températures.

Un autre circuit important est celui nécessaire à **l'extraction de l'énergie thermique** produite dans les cellules lors de la réaction. Il est généralement composé d'échangeurs et de radiateurs.

L'utilisation des piles à combustible pour la propulsion demande d'intégrer non seulement la pile mais aussi tous ces circuits annexes dans un véhicule (Figure 1.4). C'est donc toute la conception du véhicule qui va se trouver bouleversée. La structure traditionnelle de l'automobile n'a plus lieu d'être avec un véhicule dont les éléments mécaniques et électriques n'ont plus rien en commun avec ceux d'un véhicule conventionnel. La figure 1.4 montre une intégration possible sur deux prototypes de PSA (HYDRO-GEN et TAXIPAC) dont la masse et le volume du système complet est plus massif et volumineux que ceux d'une chaîne de traction à moteur à combustion interne. Il est donc nécessaire de trouver d'autres espaces disponibles pour l'intégration sur ce type de véhicule.




Figure 1.4: Intégration du système pile à combustible.

Certaines contraintes sont à prendre en compte pour l'intégration des systèmes. Notamment, il existe des zones de choc où certains éléments (réservoir, cœur de pile) ne peuvent pas être intégrés. Par ailleurs, l'autonomie du véhicule est conditionnée par la place disponible pour l'intégration du réservoir. Un autre problème important concerne le positionnement du (ou des) moteur(s) électrique(s) qui imposera le positionnement précis des autres éléments (compresseur, systèmes d'humidification et

de récupération d'eau, échangeurs et radiateurs). La majorité des constructeurs utilisent la partie se situant sous l'habitacle pour intégrer ces éléments.

Les constructeurs automobiles ont effectué de nombreux progrès pour l'intégration des système piles à combustible dans leurs véhicules. On voit sur la figure 1.5 que la masse d'un système pile à combustible est environ douze fois moins importante qu'il y a une dizaine d'années (cette masse ne comprend pas le stockage d'hydrogène) [WEI03].




Figure 1.5: Evolution de la masse spécifique d'un système pile à combustible au cours des dix dernières années.

Les efforts conjugués des industriels, des constructeurs automobiles et des équipementiers sur l'intégration des systèmes pile à combustible dans les véhicules ont aujourd'hui permis d'améliorer sensiblement la situation difficile de 1994. Ces efforts doivent néanmoins encore être poursuivis.

1.3.1.2. Coût

Dans un système pile à combustible, le coût du cœur de pile représente environ un tiers du coût total [DEC01]. Le cœur de pile présente à ce jour un prix très élevé (de 3000 à 10000 €/kWe) dû à une production en faible quantité. Les spécialistes affirment que le niveau actuel de développement technologique permettrait d'atteindre en grande série un coût de 500 €/kWe pour le cœur de pile seul. Cette valeur permettrait d'atteindre un coût de l'ordre de 1500 €/kWe pour un système complet, seuil haut pour les applications stationnaires et les bus. On pourrait donc entrevoir un début d'industrialisation autour de 2005-2007.

Néanmoins, ce coût est encore dix fois trop élevé pour les applications automobiles pour lesquelles il faudra atteindre 50 €/kWe (et une durée de vie de 4000 heures) pour rivaliser avec le moteur thermique.

Afin de diminuer le prix de revient d'un cœur de pile, il est nécessaire de lever une série de verrous technologiques [PAC00] :

- Les électrodes et EME (assemblage Electrode/Membrane/Electrode)
 - Les électrodes : leur coût tient pour partie à la quantité de platine nécessaire à la mise en œuvre encore largement artisanale. La mise au point d'un catalyseur moins sensible au CO issu du reformage est également souhaitable.
 - Les membranes : le matériau de référence reste le Nafion, quasi monopole de Dupont de Nemours qui en fixe le prix, trop élevé (300 à 500 €/m²). Par ailleurs, on sait que la gestion hydraulique et thermique de la pile serait grandement facilitée si la membrane pouvait fonctionner au delà de 100°C ; cela permettrait également d'accroître le rendement.
- Les plaques bipolaires : Elles ont pour fonction la collecte du courant, la distribution et la séparation des gaz à l'anode et à la cathode. Les matériaux de plaques bipolaires doivent donc posséder un niveau de conductivité électrique suffisant (supérieur à 10 siemens/cm), une imperméabilité au gaz supérieure à celle de la membrane échangeuse de protons et une bonne inertie chimique vis-à-vis des fluides présents dans le cœur de pile (eau, acide, oxygène...). Les plaques les plus courantes sont réalisées en graphite et les canaux de distribution des gaz sont obtenus par usinage. Ces plaques, disponibles commercialement mais à des prix très élevés, essentiellement dus à la phase d'usinage, ne permettent pas d'envisager une utilisation industrielle. Des matériaux organiques et des matériaux métalliques pourraient être utilisés pour développer un nouveau concept de plaques bipolaires, ce qui permettrait de voir leur coût à la baisse.
- L'assemblage : le bon fonctionnement des empilements d'EME et plaques bipolaires nécessite une excellente tenue mécanique ; actuellement des plaques en inox épaisses sont utilisées en bout d'empilement, qui sont coûteuses et lourdes. La puissance massique de l'empilement est très dépendante de cet assemblage et pourrait être considérablement améliorée.
- Système : dans le prix du système intervient celui des auxiliaires, dont le bon dimensionnement doit permettre une optimisation du rendement global et une réduction du coût du système ; enfin le rapport coût/performance du stack est fonction de son architecture et donc sujet également à innovation. Parmi les points durs liés au fonctionnement du système, on peut souligner la gestion d'eau (humidification, condensation), la gestion des calories et le démarrage de la pile à basse température.

Pour diminuer les coûts de production des systèmes pile à combustible, des progrès significatifs doivent être réalisés avec les objectifs suivants [ALL03] :

- Diminuer le coût de la membrane à 15 €/m². Fonctionnement à 120°C minimum afin de réduire la taille des échangeurs et radiateurs.
- Les plaques bipolaires devront atteindre une fourchette de prix comprise entre 1 à 2 € pièce.
- Fabriquer en série des EME à faible taux de platine (0,1 mg/cm²).
- Supprimer l'humidificateur pour l'intégrer au cœur de pile
- Contrôler le fonctionnement de la pile à basse pression pour supprimer le compresseur d'air et le remplacer par un simple circulateur.

La figure 1.6 illustre la répartition des coûts des composants d'un cœur de pile à combustible type PEM [DEC01].




Figure 1.6: Répartition des coûts des composants d'un cœur de pile

Tous les constructeurs automobiles sont sur les rangs. La société Ballard, le spécialiste canadien de la pile à combustible, s'est alliée avec DaimlerChrysler et Ford. Renault Nissan a investi 700 millions de dollars sur cinq ans. Le groupe PSA a présenté plusieurs prototypes (HYDRO-GEN, TaxiPaC, H₂O) intéressants. General Motors, les japonais Toyota, Honda et Mazda relèvent aussi le défi. Mais, selon Thierry Alleau, président de l'Association Française de l'Hydrogène (AFH₂), il faudra patienter une ou deux décennies « pour parvenir à des solutions industrielles viables et rentables, et cela en toute sécurité ». La production industrielle de camions et de deux roues équipés en pile à combustible pourrait démarrer en 2005. Le constructeur italien Aprilia propose déjà un vélomoteur à pile à combustible de 600 We, garantissant 75 Km d'autonomie. Mais en raison des difficultés techniques à surmonter, il faudra vraisemblablement attendre 2020 pour l'équipement en série des voitures individuelles, même si, peut être un peu prématurément, Toyota et Honda annonçaient encore récemment, des petites séries courant 2004 et Renault Nissan vers 2005 ou 2006 [FAR02].

En marge du coût et de l'intégration des systèmes piles à combustible, un autre verrou s'oppose à la commercialisation des véhicules piles à combustible ; le stockage de l'hydrogène, sa production et la maîtrise des risques liés à l'utilisation de ce gaz.

1.3.2. Optimisation énergétique du système

L'avantage essentiel d'une pile à combustible pour la production d'énergie électrique, par rapport à un moteur thermique, réside dans le fait que le rendement de conversion est très élevé. En effet, le rendement d'un moteur à combustion est limité par le cycle de Carnot et est souvent inférieur à 30%. Au contraire, le rendement théorique d'une pile η_{pile} fonctionnant aux conditions nominales est en général très élevé (de l'ordre de 80%). Ces 2 rendements ne sont pas comparés au même point de charge.

Cependant, le rendement pratique d'une pile, qui débite sur une charge extérieure est inférieur à ce rendement théorique, par suite de l'existence de surtensions (particulièrement à la cathode) et des pertes ohmiques dues à la résistance de l'électrolyte entre les deux électrodes et aux résistances de contacts. Ce rendement est appelé rendement en potentiel η_E . Il dépend de la densité de courant qui traverse la pile.

De plus, en considérant l'énergie et la puissance de la pile, il faut introduire le rendement faradique η_F , défini comme étant le rapport entre le courant débité et le courant maximal correspondant à la réaction globale de la pile.

Enfin, il faut introduire un dernier rendement η_s qui tient compte des périphériques et de leur fonctionnement qui utilisent l'énergie délivrée par la pile. La figure 1.7 représente la consommation de puissance des différents auxiliaires [DEC01] :




Figure 1.7: Répartition des puissances consommées par les périphériques dans un système pile à combustible.

Au total, le rendement global η_{total} de la pile est le produit des rendements précédents qui se situe autour de 35% pour une PEMFC. Si en plus nous considérons l'extraction du pétrole et le moteur électrique dans ce rendement, le rendement du « puit à la roue » sera à peine de 20%.

$$\eta_{pile} = \frac{We}{-\Delta H} \quad \text{avec } We : \text{travail électrique fourni et } \Delta H : \text{enthalpie de réaction}$$

$$\eta_E = \frac{E(j)}{E_{eq}} \quad \text{avec } E(j) : \text{f.é.m de la pile en fonction de la densité de courant}$$

$E_{eq} : \text{f.é.m équivalente}$

$$\eta_F = \frac{I}{I_m} \quad \eta_s \approx 75\% \Rightarrow \eta_{total} = \eta_{pile} * \eta_E * \eta_F * \eta_s$$

Pour augmenter le rendement global d'un système pile à combustible, il est nécessaire de réduire les consommations des différents auxiliaires. Les améliorations les plus significatives pour contribuer à la diminution de cette consommation peuvent essentiellement être faites sur le circuit d'air [BOE02], [JOH01], [TEK01].

Une autre solution qui peut prétendre à l'amélioration du rendement global est l'hybridation. Ces hybridations concernent généralement des systèmes piles à combustible associés à des supercondensateurs [ROD00] ou à des batteries [FRI99].

1.3.3. Stockage de l'hydrogène

En matière de stockage, la faible masse volumique de l'hydrogène entraîne des densités massiques, c'est-à-dire un rapport masse d'hydrogène/masse du contenant de l'ordre de quelques pour cent, ce qui est un facteur très pénalisant.

Parallèlement, dans la perspective du développement des véhicules pile à combustible, il est nécessaire de mettre au point un système de stockage de l'hydrogène sûr et performant, dans le but de pallier les problèmes inhérents du reformage.

Pour fixer les idées, pour obtenir une autonomie d'environ 500 kilomètres pour un véhicule, la masse d'hydrogène à stocker est de l'ordre de 5 kg. L'hydrogène doit donc être stocké avec des contraintes sévères de volume et de masse pour rester compatible avec les dimensions des véhicules. Ce stockage peut se faire sous forme comprimée, liquide, dans des microbilles, par absorption dans un hydrure, enfin par adsorption dans du charbon actif ou dans des nanotubes de carbones [GAL01]. Une autre voie de recherche consiste en une production d'hydrogène à bord du véhicule grâce à un reformeur.

1.3.3.1. Stockage de l'hydrogène sous forme comprimée

Le stockage sous pression constitue une solution très simple, peu coûteuse en énergie et capable de délivrer le gaz stocké avec une dynamique largement supérieure aux besoins. Ce stockage met en oeuvre les mêmes techniques que celles utilisées pour le gaz naturel.

Les réservoirs sont techniquement au point. Ils sont constitués d'une vessie servant de barrière à l'hydrogène. Celle-ci est généralement en alliage d'aluminium renforcé par de la fibre de verre ou de carbone imprégnée de résine époxy.

Dans le cadre du programme européen « HYDRO GEN », coordonné par PSA Peugeot Citroën dont les partenaires sont le C.E.A. (Commissariat de l'Energie Atomique), Renault et Air Liquide, a été mis au point un réservoir pour le stockage à haute pression, à une pression de 700 bars. La capacité massique de stockage obtenue est de l'ordre de 5,7%, c'est-à-dire, 5,7 kg d'hydrogène gazeux stocké pour 100 kg de structure [ALL03.2].

1.3.3.2. Stockage de l'hydrogène sous forme liquide

Du fait de la faible densité de ce composé sous sa forme liquide, $70,8 \text{ kg/m}^3$, le volume correspondant à 5 kg d'hydrogène est d'environ 70 litres. Ce mode de stockage peut donc paraître séduisant d'autant plus que l'hydrogène liquide est aisément disponible dans les pays développés. Néanmoins, plusieurs inconvénients existent [PES98], [GAL01] :

- Il est nécessaire de maintenir l'hydrogène à une température de -253°C . Il faut donc une isolation thermique extrêmement soignée et donc encombrante. Cela n'empêche pas une évaporation parasite mais qui reste cependant contrôlable à un niveau admissible de l'ordre de 3% par jour. Cette évaporation peut ne pas être permanente en réalisant une enceinte pressurisée dotée d'une vanne de décharge : c'est la solution qui a été retenue dans le cadre du projet européen « FEVER ».
- L'énergie nécessaire à la liquéfaction de l'hydrogène représente environ 40% de l'énergie contenue dans le gaz.
- La manipulation de l'hydrogène liquide exige des stations de remplissage automatique complexes mais cependant tout à fait techniquement réalisables.

Néanmoins les problèmes posés par le stockage liquide de l'hydrogène sont aujourd'hui maîtrisés, notamment grâce au développement des activités spatiales. Mais il faut reconnaître que les coûts et les contraintes de cette voie sont très difficilement applicables à l'automobile.

1.3.3.3. Stockage de l'hydrogène dans les hydrures

Ce type de stockage très prometteur est fondé sur la propriété de certains solides d'adsorber des quantités importantes d'hydrogène et de le restituer par dépression ou légère élévation de température. Les recherches sont orientées vers les terres rares, le lanthane notamment, le nickel et le magnésium. La proportion d'hydrogène adsorbée est de l'ordre d'un atome de gaz pour un atome de métal. C'est une réaction réversible exothermique à l'adsorption et endothermique à la libération de l'hydrogène. Un grand intérêt de cette technique est que la pression de libération de l'hydrogène peut être calibrée en fonction de l'application. Malheureusement les alliages capables d'adsorber le plus d'hydrogène par unité de poids sont aussi ceux qui demandent des températures très élevées. Il en est ainsi par exemple pour tous les composés à base de magnésium. Le magnésium est très intéressant car il a une capacité d'adsorption massique de 7%, ce qui est un avantage considérable pour les applications mobiles. Mais il pose un problème de réversibilité car il est alors nécessaire de chauffer à 500 ou 600°C . Un gain important en température peut être fait en alliant le magnésium au nickel mais de la capacité massique est alors perdue. D'autres alliages font l'objet de recherches comme ceux à base de zirconium manganèse chrome. Une autre difficulté est qu'il faut stocker de l'hydrogène très pur car les hydrures ne supportent pas le monoxyde de carbone.

Des hydrures chimiques sont également développés. Il existe par exemple le borohydrure de sodium, technologie adoptée par PSA pour le prototype H2O. Les densités théoriques peuvent atteindre 10% en incluant l'eau. Toutefois ces hydrures seraient assez instables. De plus certains de ces hydrures chimiques sont corrosifs ce qui entraîne des difficultés de manipulation. Enfin le contrôle de la réaction pour obtenir l'hydrogène est délicat.

1.3.3.4. Autres formes de stockage

Le stockage de l'hydrogène dans les nanotubes de carbone est actuellement au centre de beaucoup de publications et aussi de controverses [HAI03], [MAS03], [ZID03]. Il faut toutefois considérer avec une grande prudence ces nanotubes compte tenu de la méconnaissance de la plupart des mécanismes mis en jeu lors de l'adsorption de l'hydrogène. L'activité de recherche est en pleine effervescence sur ce thème. Un certain nombre de domaines sont encore entachés de grandes incertitudes. Les questions portent aussi sur la faisabilité à terme d'une production en masse de ces matériaux qui est aujourd'hui limitée à quelques grammes obtenus en laboratoire.

D'autre part, le stockage de l'hydrogène dans les microbilles peut être une voie intéressante. Ce type de stockage repose sur la double propriété de certains verres d'être étanches à l'hydrogène à froid et poreux à chaud. Cependant la mise en œuvre de cette technologie se révèle délicate [HER03a].

1.3.4. Le reformage

L'unité de reformage a pour fonction de contourner un des obstacles à la commercialisation des véhicules piles à combustibles, en l'occurrence le stockage de l'hydrogène dans une automobile. En effet le reformage permet de produire de l'hydrogène à partir d'un composé hydrocarboné (méthanol, éthanol, méthane, essence...).

Le vaporeformage est souvent utilisé pour extraire l'hydrogène des hydrocarbures ou des alcools. Le composé contenant de l'hydrogène réagit avec la vapeur d'eau pour produire un mélange d'hydrogène, de monoxyde de carbone (CO) et de dioxyde de carbone (CO₂). Cette réaction est endothermique, elle nécessite donc des températures très élevées (environ 600°C). Un système de reformage est relativement lourd à intégrer dans un véhicule car il est composé du reformeur (réacteur principal), d'un système de purification des gaz (diminue la teneur en CO), d'un système de désulfuration (pour le gaz naturel), d'un brûleur et des échangeurs de chaleur.

Il existe d'autres techniques de reformage (oxydation partielle, reformage autotherme, reformage adiabatique, ...).

A l'heure actuelle le système de reformage doit encore faire des progrès en termes de coût, de rendement, de réactivité et en particulier en termes de volume et de poids.

1.3.5. Risques liés à l'hydrogène

Suite à la rapide revue des modes de stockage de l'hydrogène existant, il est nécessaire d'évoquer les problèmes de sécurité posés par l'utilisation de ce gaz. En effet, l'hydrogène semble être aux yeux du grand public un produit ayant une mauvaise réputation. Ces appréhensions sont certainement dues à la catastrophe du dirigeable « Hindenburg » survenue le 6 mai 1937 aux Etats-Unis. Cependant, contrairement aux idées reçues, cet accident n'était pas dû à l'hydrogène mais à la nature extrêmement inflammable de la peinture de son enveloppe.

Quelques caractéristiques de l'hydrogène peuvent tout de même susciter l'inquiétude. En effet, si sa température d'inflammation est dix fois inférieure à celle des hydrocarbures, sa température d'auto-inflammation est plus élevée. Sa vitesse de combustion est grande, ce qui lui confère une aptitude élevée à transiter de la déflagration à la détonation.

Les risques liés à l'hydrogène peuvent intervenir à plusieurs niveaux ; au niveau du cœur de pile et au niveau des installations de stockage.

Chapitre I : Introduction sur les piles à combustible

En ce qui concerne les risques liés au cœur de pile, ils sont a priori très faibles car l'hydrogène et l'air n'entrent jamais en contact. Cependant il faut prendre en considération l'éventualité d'une rupture de l'étanchéité entre les deux compartiments, par dégradation de la membrane (pour une pile de type PEM). Ce genre d'incident peut conduire à la constitution d'un mélange explosif au sein d'une cellule voire dans l'ensemble du cœur de pile. Il faut tout de même noter que les quantités d'hydrogène contenues dans le cœur de pile sont relativement faibles et constituent un potentiel de danger limité.

Cependant, l'utilisation de l'hydrogène dans les applications transports nécessitera une procédure d'homologation avant toute fabrication industrielle de manière similaire aux travaux ayant précédés la mise sur le marché des véhicules fonctionnant au G.P.L.

Au cours de différents projets, des essais ont été réalisés sur différents prototypes utilisant un stockage d'hydrogène. C'est ainsi que B.M.W. a pratiqué sur ses véhicules à moteur à combustion interne à hydrogène une série d'essais de collisions conformes aux spécifications américaines (chocs frontaux et au niveau de l'alimentation du réservoir à hydrogène) très concluante en terme de résultats.

Le C.E.A. a également soumis un réservoir d'hydrogène comprimé à 700 bars à des tirs d'armes automatiques sans provoquer d'explosion. Concernant les autres formes de stockage (hydrures, adsorption sur des surfaces poreuses...) le retour d'expérience est moindre compte tenu de leur caractère encore très largement expérimental.

Le dernier point à étudier est la sécurité des infrastructures de remplissage. En effet, en cas de développement de la filière, des études de sécurité mais également la formation des futurs utilisateurs sera nécessaire.

1.4. Introduction à la modélisation

Comme il a déjà été évoqué, le système pile à combustible est constitué d'un cœur de pile interconnecté à de nombreux périphériques permettant son bon fonctionnement. Dans la chaîne de traction d'un véhicule électrique, le système pile à combustible constitue l'élément central. Compte tenu des interactions fortes entre chacun des sous systèmes en termes de réponse énergétique, encombrement, poids et coûts, la recherche de la chaîne de traction idéale ne peut être obtenue par la simple juxtaposition de composants optimaux et relève d'un nécessaire compromis difficilement atteignable par l'unique prototypage.

La modélisation dynamique des systèmes permet de répondre à cette problématique. Les enjeux en sont multiples : le modèle développé doit permettre à la fois d'apporter une compréhension des phénomènes physiques en cause, d'évaluer la réponse dynamique du système à des fins de calculs de rendement et contribuer à la définition d'une architecture de système et d'une stratégie de régulation optimales [SCH00].

1.4.1. Types de modélisation

Le but de toute modélisation de processus est de construire un modèle, c'est-à-dire une représentation mathématique ou comportementale de son fonctionnement. L'objectif poursuivi est la compréhension des phénomènes physiques mis en jeu, ou la conception d'un système automatique pour leur commande. Il existe différentes classifications de modèles en fonction de leur mode de conception ou de leur mode d'utilisation.

1.4.1.1. Les modèles de connaissance

Les modèles de connaissance découlent d'une analyse physique des phénomènes mis en jeu dans le processus. Ces modèles sont élaborés soit à partir de lois générales, fondées sur des principes (lois de la mécanique, de l'électromagnétisme, de la thermodynamique, de la physique quantique...), soit à partir de lois empiriques (finance, économie), qui régissent les phénomènes intervenant au sein de processus étudiés.

Ces modèles représentent ainsi les relations entre les entrées et les sorties du processus par des équations. Le modèle est dit statique si les équations régissant le fonctionnement du processus sont de types algébriques, ou dynamique si les équations sont différentielles.

Les modèles de connaissance sont souvent utilisés pour la modélisation de processus car ils permettent une utilisation sur des plages relativement larges et sont souvent utilisés pour l'extrapolation du comportement du processus. De plus, ils ne nécessitent que très peu d'essais expérimentaux pour déterminer les paramètres du modèle et valider le comportement ainsi obtenu. Néanmoins, les processus à modéliser peuvent être d'une grande complexité dans le cas où de nombreux phénomènes sont à prendre en compte. Il devient dès lors délicat de réaliser un modèle de connaissance si ces phénomènes sont mal connus. Dans ce cas, il est nécessaire de concevoir des modèles purement empiriques, fondés exclusivement sur des résultats expérimentaux.

1.4.1.2. Les modèles de représentation ou comportementaux

Selon la théorie des systèmes, un système ou processus est une collection d'éléments qui sont en interaction et dont l'ensemble produit un traitement. En général, un système est défini comme recevant un signal d'entrée et générant un signal en sortie. La relation entre l'entrée et la sortie d'un système représente une transformation du signal et caractérise la fonction du système. Ainsi la théorie des systèmes produit un cadre d'étude possible pour l'identification fonctionnelle d'un système physique à travers l'examen de la relation entrée-sortie, cette démarche étant classiquement appelée l'approche boîte noire.

1.4.1.2.1. Les modèles boîte noire

La modélisation utilisant les modèles « boîte noire » permet grâce à des équations paramétrées (algébriques, différentielles ou récurrentes) de représenter les relations entre les entrées-sorties du système. L'estimation numérique de ces paramètres repose essentiellement sur un ensemble d'observations expérimentales disponible sur le processus ; dans le domaine des réseaux de neurones, cet ensemble d'observations est appelé « apprentissage ». Il est important de noter que les paramètres n'ont ici aucune signification physique contrairement aux paramètres des modèles de connaissance.

L'avantage principal des modèles « boîte noire » est qu'ils ne nécessitent pas une connaissance approfondie du processus. De plus, ils sont bien souvent moins onéreux en temps de calcul que les modèles de connaissance. Cependant la validité des modèles « boîte noire » est limitée à un domaine de fonctionnement déterminé par l'ensemble d'apprentissage. De ce fait, ces modèles se trouvent pénalisés par rapport aux modèles de connaissances car ils ne peuvent pas prendre en compte les phénomènes exceptionnels pouvant intervenir au sein du processus et ils sont souvent limités à l'interpolation de résultats.

Les modèles boîte noire sont d'excellents candidats pour la modélisation de processus non linéaires car ils peuvent être aisément transposés d'un système à un autre (en restant dans le même domaine technologique). Pour cela, il sera nécessaire d'ajouter de nouveaux paramètres issus de nouvelles données expérimentales. Ce point est un avantage par rapport aux modèles de connaissance car leur conception est fortement liée au processus particulier que l'on cherche à modéliser, et aux connaissances disponibles sur la physique de celui-ci.

Pour élaborer des modèles « boîte noire » de processus non linéaires, plusieurs méthodologies (éléments finis, méthodes statistiques, réseaux de neurones...) sont utilisables. Dans cette étude, nous nous focalisons sur les modèles neuronaux qui permettent généralement d'approcher le comportement statique et dynamique du processus de façon satisfaisante : en effet, les réseaux de neurones sont des approximateurs universels de fonctions non linéaires qui peuvent être employés aussi bien dans un cadre déterministe que dans un cadre probabiliste.

1.4.1.2.2. Les modèles boîte grise

Une autre approche comportementale est possible pour la modélisation des processus non linéaires avec les modèles de type « boîte grise ». Ces modèles sont utilisés lorsque des connaissances mathématiques sont disponibles mais insuffisantes pour concevoir des modèles de connaissance satisfaisants. Les modèles de type « boîte grise » (ou modèles semi physique) prennent en considération à la fois les connaissances et les comportements expérimentaux.

Une telle démarche peut concilier les avantages de l'intelligibilité d'un modèle de connaissance avec la souplesse d'un modèle comportant des paramètres ajustables.

Enfin, il convient de préciser que les modèles mathématiques ou comportementaux sont caractérisés par leur domaine de validité. La validité des modèles de connaissance est déterminée par l'exactitude des hypothèses et la pertinence des approximations faites lors de l'analyse physique des phénomènes et de leur mise en équation [OUS98], [URB95].

Après cette revue rapide des différentes méthodes de modélisation, la méthode semblant être la mieux adaptée à notre étude sera présentée.

1.4.2. Quel modèle pour le système pile à combustible ?

A ce jour, les modèles de générateur pile à combustible proposés font souvent appel à des modèles complexes [NGU93], [BER91] basés sur la connaissance des phénomènes physico-chimiques. Ces modèles nécessitent une bonne connaissance des paramètres mis en jeu et ils sont, pour une pile à combustible, difficiles à déterminer [FRI03].

Certains paramètres physico-chimiques, internes au cœur de pile, sont déterminants pour évaluer les performances du système mais ne sont pas mesurables. Par exemple, la puissance électrique délivrable par la pile dépend fortement de la forme et de la taille des canaux de distribution des gaz. Dans la même optique, le niveau d'hydratation des membranes joue un rôle prépondérant sur la puissance délivrée ; si la membrane se trouve asséchée ou a contrario noyée, la puissance fournie par le système chutera rapidement. Tous ces paramètres doivent être pris en compte dans le cas d'une modélisation par modèles de connaissance. Cependant malgré l'importance de ces paramètres sur le comportement du système, les constructeurs de pile à combustible ne fournissent pas nécessairement les paramètres technologiques nécessaires à la réalisation de tels modèles de connaissance.

Il existe malgré tout un certain nombre de modèles de connaissance traduisant le comportement d'une pile à combustible. Ces derniers sont généralement des modèles électrochimiques très complexes prenant en compte la distribution des gaz (pression, débit et température), les différents coefficients de transferts de chaleur ou encore la répartition des réactifs sur les sites catalytiques. C'est le cas pour le modèle électrochimique d'Amphlett [AMP96] qui permet de prédire la réponse en tension d'une pile à combustible de type PEM. Cependant de tels modèles traduisent nécessairement le fonctionnement d'une pile à combustible particulière. Si une autre pile, toujours de type PEM, doit être modélisée, il sera nécessaire de recalculer ou de réidentifier tous les paramètres de ce modèle.

D'autres modèles de connaissance ont été établis mais ces derniers sont généralement des modélisations de parties ou de régions du cœur de pile. Il convient de citer Nguyen [NGU93] ou Picot [PIC98] qui ont modélisé les canaux de distribution de gaz ou Bernardi et Verbrugge [BER92] qui ont quant à eux modélisé les sites catalytiques. La modélisation par modèles de connaissance du système pile à combustible complet se trouve moins répandue. Boettner [BOE01] a étudié le système complet mais en régime statique.

A l'opposé de ces modèles, il est possible d'utiliser des modèles de type « boîte noire » qui permettent une modélisation comportementale sans avoir nécessairement recours à la connaissance de ces paramètres. De plus, ce type de modèle pourra être aisément transposable sur un autre système.

Le but de ce travail consistera donc à établir des modèles de type « boîte noire », exploitables et évolutifs d'un système pile à combustible basé sur la technologie Proton Exchange Membrane. Cette

méthode permet par apprentissage de réaliser des modèles qui s'adaptent aux comportements expérimentaux observés.

Dans un premier temps, l'objectif est d'établir un « modèle comportemental minimal » d'une pile, capable de calculer les grandeurs de sortie et leurs variations. Ces grandeurs électriques sont dépendantes de la puissance de la pile et de la charge connectée, mais aussi de la nature des auxiliaires utilisés et des gaz utilisés. Il sera nécessaire d'identifier le nombre et la nature des paramètres d'entrée et de sortie ainsi que les relations entre sorties et entrées. Ce modèle est développé dans l'environnement Matlab/Simulink afin d'être intégré dans une chaîne de traction complète d'un véhicule. Ce modèle pourra ensuite être utilisé pour procéder à l'élaboration et à la simulation des lois de commande destinées à gérer les transferts énergétiques à bord d'un véhicule à pile à combustible.

1.5. Conclusion

La technologie de pile à combustible la plus compatible aujourd'hui avec les exigences automobiles est la PEM (et dans une moindre mesure la SOFC). Les piles alcalines resteront quant à elles employées dans un domaine restreint (spatial ou sous-marin) car leur mise en œuvre paraît difficile pour les véhicules. Pour les applications transports, les PEM bénéficient d'un retour d'expérience certain au travers du grand nombre de prototypes déjà réalisés à ce jour. De plus, leur fonctionnement à basse température garantit une mise en fonctionnement rapide et réduit les contraintes cycliques thermiques appliquées aux matériaux.

Cependant, il a été montré au cours de ce premier chapitre qu'il reste différents verrous à lever pour permettre l'utilisation des piles à combustible dans les applications transports. Ceux-ci se situent aussi bien au niveau du cœur de pile que des auxiliaires. L'intégration du système semble aujourd'hui quasi résolue, par contre, le choix d'installer un reformeur ou d'alimenter directement la pile en hydrogène pose encore un certain nombre de difficultés. Le coût du système complet est un autre handicap fondamental.

Dans ce chapitre, les principes envisageables pour la modélisation du générateur pile à combustible ont été présentés en balayant les différentes méthodologies existantes. Compte tenu de la difficulté de réalisation d'un modèle analytique, notre choix s'est axé vers une modélisation de type « boîte noire » par réseaux de neurones. Ceci semble être une alternative intéressante et prometteuse aux méthodes analytiques, plus conventionnellement employées pour la modélisation de tels systèmes. Les prochains chapitres seront consacrés à la présentation et à la mise en œuvre de cette démarche de modélisation appliquée au générateur pile à combustible.

**- CHAPITRE 2 -LES RESEAUX DE
NEURONES POUR LA MODELISATION
STATIQUE D'UNE PILE DE TYPE PEM**

2.1. Introduction sur les réseaux de neurones (RN)

C'est au début des années 1940 que les premiers modèles de neurones artificiels ont été conçus. C'est plus précisément en 1943 que deux biophysiciens de l'université de Chicago Mc Culloch et Pitts conçoivent le premier modèle de neurone biologique en s'inspirant des récentes découvertes en neurobiologie. Ce modèle est appelé neurone formel. Très vite, ces deux pionniers découvrent que des associations de tels neurones artificiels sont capables de produire des fonctionnements intéressants : le concept des réseaux de neurones artificiels est né.

Cependant, il faut attendre le début des années 1980 pour voir un regain d'intérêt pour les réseaux de neurones artificiels dans le domaine du traitement de l'information et ceci grâce à l'écriture d'un algorithme d'apprentissage purement mathématique pour des réseaux comportant plusieurs couches de neurones (la rétropropagation du gradient, en 1985).

Les réseaux de neurones artificiels sont des modèles inspirés de la biologie du cerveau humain. Nous sommes actuellement bien loin du souci premier de modélisation du cerveau humain. Aujourd'hui, les réseaux de neurones apparaissent comme des outils pratiques de traitement de l'information plutôt que des modèles biologiques.

Dans cette mesure, les techniques neuronales s'opposent, ou plutôt sont complémentaires, à l'intelligence artificielle (IA). Cette dernière repose sur des systèmes de règles (systèmes experts) alors que les méthodes neuronales s'appuient sur une acquisition implicite de connaissances par apprentissage à partir d'exemples. Ainsi les réseaux de neurones sont susceptibles d'apporter des solutions efficaces et élégantes dans divers domaines : reconnaissance de formes, modélisation de procédés industriels, modélisation statique ou dynamique de processus non linéaires, contrôle de l'environnement, robotique, bio ingénierie, précision de séries temporelles, commande de processus, etc.

Pour notre étude, les réseaux de neurones pour modéliser un système non linéaire, en l'occurrence un système pile à combustible, ont été utilisés.

Dans un premier temps, la définition d'un réseau de neurones sera établie. Nous poursuivrons par les différentes méthodologies adoptées pour l'apprentissage des réseaux de neurones. Puis, le modèle statique d'une pile à combustible de 500W établi grâce aux techniques des réseaux neuromimétiques sera présenté. Enfin, ce chapitre sera conclu par un modèle statique d'une pile à combustible de plus forte puissance (5kW).

2.2. Le neurone formel

Un neurone est une fonction algébrique non linéaire, paramétrée, à valeurs bornées. Il est commode de représenter graphiquement un neurone comme indiqué sur la figure 2.1. Les variables sur lesquelles opère le neurone sont habituellement désignées sous le terme d'entrées du neurone, et la valeur de la fonction sous celui de sortie [DRE02].




Figure 2.1: Représentation d'un neurone.

Le neurone reçoit une combinaison d'entrées (variables x_i) et les pondère grâce à des valeurs réelles appelées coefficients synaptiques ou poids synaptiques (paramètres w_i). Ces coefficients peuvent être positifs, et l'on parle alors de synapses excitatrices, ou négatifs pour des synapses inhibitrices. Le neurone calcule ainsi une somme (appelée potentiel v) de ses entrées pondérées par les poids (équation 2.1). Ce potentiel v auquel est ajouté un terme constant ou « biais », noté ici « b », devient l'argument d'une fonction d'activation f qui calcule la sortie y (équation 2.2).

$$v = w_0.b + \sum_{i=1}^S w_i x_i \quad (2.1)$$

$$y = f(v) \quad (2.2)$$

La fonction f peut être paramétrée de différentes manières, selon l'utilisation du neurone et selon la nature continue ou discrète, voire binaire de l'état y du neurone. Les fonctions décrites sur la figure 2.2 sont fréquemment utilisées en guise de fonctions d'activation.




Figure 2.2: Exemples de fonctions d'activation a) signe, b) identité, c) linéaire saturée, d) sigmoïde, e) tangente hyperbolique.

Un neurone réalise donc simplement une fonction linéaire ou non linéaire, paramétrée, de ses variables d'entrée. L'intérêt des neurones réside dans les propriétés qui résultent de leur association en réseaux. Il existe deux types de réseaux de neurones : les réseaux non bouclés et les réseaux bouclés. Les réseaux bouclés seront décrits dans le troisième chapitre.

2.2.1. Les réseaux de neurones monocouche non bouclés

Sur le plan architectural, un réseau de neurones peut être vu comme un ensemble d'unités élémentaires (les neurones) interconnectées de manière à former un système avec une ou plusieurs entrées et une ou plusieurs sorties. Il est possible de rassembler plusieurs neurones dans une même structure et former ainsi une couche de neurones (figure 2.3). Dans une couche, les neurones agissent indépendamment et ne reçoivent aucune connexion des autres neurones. Ce type de modèle permet de traiter des problèmes pour lesquels la sortie attendue n'est pas une seule valeur mais un vecteur de m valeurs [REU95].




Figure 2.3: Représentation d'une couche de neurones.

La capacité de traitement présentée par une couche de neurones ne diffère pas de celle d'un neurone. Cette structure ne permet de traiter que des problèmes relativement simples (présentant une faible non linéarité).

2.2.2. Les réseaux de neurones multicouches non bouclés

Pour des applications non linéaires, il faut enrichir la structure du réseau et en particulier superposer des couches. La plupart des réseaux de neurones ont une topologie définie sous forme de couches. L'architecture du réseau peut alors être décrite par le nombre de couches et le nombre de neurones dans chaque couche.

Dans un réseau de neurones, deux types de neurones sont à différencier :

- Les neurones cachés qui sont présents sur la couche se situant entre les entrées du réseau et la couche de sortie.
- Les neurones de sortie présents sur la dernière couche qui définissent la sortie du réseau.

Il est important de noter qu'il n'existe pas de neurones d'entrée ou de couche d'entrée. Les entrées ne font que transmettre les valeurs des variables aux différentes couches du réseau de neurones, elles ne réalisent aucun traitement de l'information.

D'autre part, dans un réseau multicouche, les différentes couches sont généralement ordonnées et indexées dans le sens croissant de la première couche cachée vers la couche de sortie (figure 2.3 et figure 2.4).




Figure 2.4: Représentation d'un réseau de neurones multicouches ou feedforward.

La topologie (ou architecture) d'un réseau de neurones est définie par son nombre de couches, son nombre de neurones par couche mais également par son modèle de connexion.

Le modèle de connexion définit la manière dont sont interconnectés les neurones d'un réseau. En se basant sur la structure à couches d'un réseau non bouclé, il est nécessaire de différencier les types de connexions : les connexions intercouches (interconnexion entre les neurones de couches voisines), les connexions supracouches (lorsque les couches ne sont pas adjacentes) et les connexions intracouches (connexions entre neurones d'une même couche).

De manière générale, le sens de transfert de l'information dans un réseau non bouclé est défini par la nature des connexions directes (figure 2.4). Elles sont dirigées d'une couche d'indice inférieur vers une couche d'indice supérieur. Par ailleurs, entre deux couches, les connexions peuvent être partielles ou totales (figure 2.5). L'utilisation de connexions partielles permet de regrouper certaines zones du réseau pour effectuer une fonction spécifique.

Dans le cadre de notre étude, nous nous sommes limités à un modèle de connexion direct total pour le développement du modèle statique.




Figure 2.5: Connexions partielles a) et totales b).

Les réseaux de neurones sont utilisés pour réaliser des fonctions particulières, dans notre cas, il s'agit d'une modélisation. Ils peuvent également être utilisés pour de la classification, de la prédiction ou encore du contrôle commande.

Le résultat de cette fonction est obtenu lors d'une phase d'utilisation (ou propagation) du réseau. La propagation à travers le réseau s'effectue par modification de l'état des neurones, de la première couche jusqu'à la sortie du réseau.

Le paragraphe suivant est consacré aux méthodes d'apprentissages utilisées pour estimer les différents paramètres du réseau, afin que celui-ci remplisse au mieux la tâche qui lui est affectée.

2.3. Les méthodologies d'apprentissage

Dans un réseau de neurones, l'information est codée par les poids liés aux connexions. L'apprentissage est réalisé par des algorithmes de calcul dont le but est d'adapter ces poids en fonction des stimuli présentés à l'entrée du réseau. Une fois l'apprentissage réalisé, les poids ne sont plus modifiés.

Les procédures d'apprentissages peuvent être classées en deux catégories : l'apprentissage supervisé et l'apprentissage non supervisé. Dans le cadre d'une modélisation, les valeurs que doit avoir la sortie du réseau en fonction des entrées correspondantes sont connues en tous points ou seulement en certains points, ce qui permet de fournir au réseau des exemples de la fonction qu'il doit réaliser. L'apprentissage est alors qualifié de supervisé.

L'apprentissage non supervisé est plutôt adapté à des réseaux généralement appelés « auto organisateurs » ou à apprentissage compétitif. L'apprentissage s'effectue alors par présentation, à un réseau autonome, de données possédant une certaine redondance. L'objectif du réseau est alors de dégager des régularités [ELI97]. L'objectif de notre étude étant d'effectuer une modélisation, il n'y aura que l'apprentissage de type supervisé qui sera utilisé.

Tout le problème de l'apprentissage de type supervisé sur une structure à couches vient du fait que la sortie que l'on souhaite associer à une entrée n'est disponible que pour les unités (neurones) de sortie. Les unités internes, celles qui sont placées entre les entrées et la couche de sortie, n'ont aucune information sur le but à atteindre. Or, c'est essentiellement grâce à l'écart entre la sortie calculée et celle désirée qu'est estimée la correction à appliquer pour s'approcher de l'erreur minimale. Une méthode a été proposée par P. Werbos puis par D. Rumelhart et Le Cun, qui consiste à fixer un but aux couches cachées à partir de l'erreur mesurée en sortie du réseau, et véhiculée par les poids qui relient les couches entre elles [RUM86]. Cette méthode appelée algorithme de rétropropagation, permet l'évaluation du gradient de la fonction coût.

2.3.1. La fonction coût

L'apprentissage des réseaux à couches est réalisé à l'aide d'algorithmes fondés sur le calcul du gradient de la fonction coût. L'équation (2.3) exprime cette fonction de coût à partir de l'erreur quadratique, pour un couple entrée-sortie, avec T_N la sortie désirée pour l'exemple N et Y_N la sortie obtenue par le réseau (M étant le nombre total d'exemples). L'algorithme de rétropropagation calcule le gradient de la fonction coût par rapport aux paramètres synaptiques (poids) dans un réseau multicouche. Pour minimiser cette erreur, il est nécessaire d'avoir recours à des méthodes itératives, qui modifient les paramètres du réseau en fonction du gradient de la fonction coût.

$$J(W) = \frac{1}{2} \sum_{N=1}^M (T_N - Y_N(W))^2 \quad (2.3)$$

2.3.2. La méthode du gradient

Le but de l'apprentissage par la méthode du gradient est donc de déterminer la valeur des poids synaptiques (W) minimisant l'erreur (calculée grâce à l'équation (2.3)) après avoir évalué le gradient grâce à l'algorithme de rétropropagation.

La méthode du gradient consiste à descendre sur la surface d'erreur, pas à pas, dans le sens opposé à celui du gradient, par modifications des paramètres synaptiques. Après avoir initialisé les paramètres du réseau, les modifications conduisent à faire converger l'erreur quadratique $J(W)$ (équation 2.3) vers une valeur faible. Le choix du pas de descente n'est pas critique pour la convergence, mais il ne doit être ni trop petit (pour la rapidité de la descente), ni trop grand (pour assurer la descente). De ce fait, la méthode est efficace loin d'un minimum mais la vitesse de convergence diminue lorsque l'on s'approche du minimum (la modification des poids est proportionnelle au gradient de J , qui tend vers 0).

Les exemples de la base d'apprentissage sont présentés successivement au réseau, les gradients accumulés au fur et à mesure et la modification des poids n'intervient qu'après présentation de tous les exemples (par opposition au gradient stochastique où la modification des poids est effectuée pour chaque exemple présenté) [ELI97].

Les poids doivent être modifiés proportionnellement au gradient, dans la direction opposée. Cette modification est obtenue suivant l'équation (2.4) :

$$W_{N+1} = W_N - \alpha \frac{\partial J}{\partial W_N} \quad (2.4)$$

avec $\frac{\partial J}{\partial W_N}$: gradient de la fonction coût (direction de descente).

N : numéro d'ordre de l'itération d'apprentissage

α : pas de descente du gradient

W : poids synaptiques.

La modification des poids des couches cachées s'effectue de la couche de sortie vers la couche d'entrée ; d'où le terme rétropropagation.

Pour faciliter la compréhension des calculs du gradient de la fonction coût dans un réseau multicouches, un réseau à i entrées avec deux couches cachées comportant respectivement j et l neurones d'activation et k neurones de sortie (Figure 2.6) sera considéré. Soit les notations du tableau 2.1 relatives à la figure 2.6 :

<i>Notations</i>	<i>Significations</i>
i	entrées, index h
j	nombre de neurones sur la 1 ^{ère} couche cachée (index p)
l	nombre de neurones sur la 2 ^{ème} couche cachée (index u)
k	nombre de neurones sur la couche de sortie (index q)
b_μ	biais sur la couche μ
x	vecteur d'entrée
T	vecteur de sorties désirés pour le réseau
I	activation du neurone (somme)
Φ	vecteur des sorties de la couche μ

Tableau 2.1: Notations




Figure 2.6: Architecture d'un réseau de neurones à 2 couches cachées

Les fonctions d'activations pour les neurones sont ici des sigmoïdes. Cette fonction et sa dérivée sont déterminées par les équations (2.5) et (2.6):

$$\Phi(x) = \frac{2}{1 + e^{-x}} - 1 \quad (2.5)$$

$$\Phi'(x) = 2 \cdot \Phi(x)(1 - \Phi(x)) \quad (2.6)$$

Pour le calcul de la mise à jour des poids synaptiques, il est nécessaire de rétro-propager le gradient en partant de la couche cachée pour aller vers l'entrée. La première étape consiste donc à calculer le gradient entre la couche de sortie et la deuxième couche cachée (équation (2.7)) :

$$\Delta w_{uq,2} = \alpha_{u,q} \frac{\partial J}{\partial w_{uq,2}} \quad (2.7)$$

avec $J = \frac{1}{2} \|T - \Phi\|^2$ où $\|T - \Phi\|^2$ désigne la norme euclidienne. En remplaçant l'expression de J dans l'équation (2.7) et après développement [Annexe 3], il vient l'équation (2.8) pour la valeur du gradient et la mise à jour de ces poids se fera suivant la relation (2.9):

$$\Delta w_{uq,2} = -\alpha_{u,q} \times (T_q - \Phi_{q,2}) \times \Phi_{u,1} \quad (2.8)$$

$$w_{uq,2}(n+1) = w_{uq,2}(n) - \alpha_{u,q} \times (T_q - \Phi_{q,2}) \times \Phi_{u,1} \quad (2.9)$$

Il faut maintenant calculer le gradient entre la deuxième couche cachée et la première couche cachée (équation 2.10) :

$$\Delta w_{pu,1} = \alpha_{pu} \sum_{u=1}^l \frac{\partial J}{\partial w_{pu,1}} \quad (2.10)$$

La valeur du gradient est fournie par l'équation (2.11) et la mise à jour de ces poids est donnée par l'équation (2.12) :

$$\Delta w_{pu,l} = -(T_q - \Phi_{q,2}) \times w_{uq,2} \times 2 \cdot \Phi_{u,l} (1 - \Phi_{u,l}) \times \Phi_{p,0} \quad (2.11)$$

$$w_{pu,l}(n+1) = w_{pu,l}(n) - \alpha_{p,u} \sum_{u=1}^l ((T_q - \Phi_{q,2}) \times w_{uq,2} \times 2 \cdot \Phi_{u,l} (1 - \Phi_{u,l}) \times \Phi_{p,0}) \quad (2.12)$$

Enfin la dernière étape consiste à calculer le gradient entre la première couche cachée et les entrées (équation (2.13)) :

$$\Delta w_{hp,0} = \alpha_{hp} \sum_{p=1}^j \frac{\partial J}{\partial w_{hp,0}} \quad (2.13)$$

Il vient alors l'équation (2.14) pour la valeur du gradient et la mise à jour de ces poids se fera suivant la relation (2.15):

$$\Delta w_{hp,0} = -\alpha_{hp} \sum_{p=1}^j 4(T_q - \Phi_{q,2}) \times w_{uq,2} \times \Phi_{u,l} (1 - \Phi_{u,l}) \times w_{pu,l} \times \Phi_{p,0} (1 - \Phi_{p,0}) \times x_h \quad (2.14)$$

$$w_{hp,0}(n+1) = w_{hp,0}(n) + \Delta w_{hp,0} \quad (2.15)$$

Il est important de noter que pour pouvoir débiter les algorithmes utilisant la méthode du gradient, il est nécessaire d'initialiser les paramètres du réseau à des valeurs aléatoires. Il faut éviter que ces valeurs soient trop élevées car il serait possible de saturer la sortie du neurone et de bloquer l'apprentissage. Si le neurone est saturé en tout point, ses dérivées sont nulles ou quasiment nulles et les paramètres ne sont que très peu modifiés.

La méthode du gradient simple est un algorithme efficace loin d'un minimum. Cependant, il devient très lent à l'approche d'un minimum. Pour accélérer la convergence, les méthodes « newtoniennes » sont utilisées.

2.3.3. La méthode de Newton

La méthode de Newton utilise la dérivée seconde de la fonction de coût pour atteindre plus rapidement le minimum de la surface d'erreur. La modification des paramètres est donnée par l'équation (2.16) :

$$W_{N+1} = W_N - \alpha [H_{W_N}]^{-1} \frac{\partial J}{\partial W_N} \quad (2.16)$$

où H_{W_N} désigne le Hessien

Le sens de la direction de descente est fonction du Hessien et du gradient (équation 2.17) :

$$d_{N+1} = -[H_{W_N}]^{-1} \frac{\partial J}{\partial W_N} \quad (2.17)$$

Dans cette méthode de Newton, la partie la plus coûteuse en temps de calcul est la gestion de la matrice hessienne. En effet, pour que la méthode converge vers le minimum, la matrice H_w doit être définie positive. De plus cette méthode nécessite le calcul et l'inversion du Hessien à chaque itération,

et la condition de positivité du Hessien doit être satisfaite à chaque itération. Ces calculs sont longs et difficiles à mettre en oeuvre, des méthodes plus économiques en temps de calcul dites de “quasi-Newton” seront donc utilisées.

2.3.4. La méthode de quasi-Newton

Les méthodes de quasi-Newton reprennent la méthode de Newton tout en lui apportant une modification concernant la matrice hessienne. Cette amélioration consiste à ne plus calculer la matrice hessienne à chaque itération, mais à approcher directement son inverse. Pour cela, il est nécessaire d'approximer l'inverse du Hessien par une matrice n'utilisant que la diagonale du Hessien soit :

$$\frac{\partial^2 J}{\partial W_N^2}$$

La modification des paramètres à chaque itération est alors donnée par l'équation (2.18):

$$W_{N+1} = W_N - \alpha \frac{\partial J}{\partial W_N} \left/ \frac{\partial^2 J}{\partial W_N^2} \right. \quad (2.18)$$

Pour les équations de mises à jour relatives à l'algorithme de quasi Newton, il est nécessaire de

calculer les relations suivantes : $\frac{\partial^2 J}{\partial w_{hp,0}^2}, \frac{\partial^2 J}{\partial w_{pu,1}^2}, \frac{\partial^2 J}{\partial w_{uq,2}^2}$.

Les méthodes de quasi-Newton permettent d'obtenir une vitesse de convergence beaucoup plus grande que la méthode du gradient. Il faut noter que la méthode de quasi-Newton est directement issue de la méthode BFGS, développée indépendamment par Broyden [BRO70], Fletcher [FLE70], Goldfarb [GOL70] et Shanno [SHA70].

Néanmoins, il est encore possible d'accélérer la convergence en utilisant un pas de descente variable.

2.3.5. Pas de descente variable

La vitesse de convergence des méthodes présentées peut être améliorée en asservissant le pas de descente noté α . Les méthodes les plus efficaces sont les méthodes de dichotomie (la méthode de Fibonacci, par exemple), mais elles nécessitent généralement beaucoup de calculs. Des méthodes plus économiques ont été proposées, en particulier la méthode de Nash [NAS90] et la méthode de Wolfe et Powell [WOL69], [POW76]. Ces méthodes unidimensionnelles permettent d'obtenir un pas convenable avec un nombre limité d'évaluations de la fonction de coût et du gradient de la fonction coût [URB95].

Notons W_i les coefficients synaptiques, D_i la direction de descente sur la surface d'erreur et α_i le pas de descente à l'itération i . La fonction g dont on cherche le minimum en fonction du pas est définie par $g(\alpha_i) = J(C_i + \alpha_i D_i)$ et sa dérivée par $g'(\alpha_i) = D_i^T \nabla J(C_i + \alpha_i D_i)$. Pour les deux règles (Nash et Wolfe Powell), le pas de descente ne doit pas être choisi trop grand pour que l'algorithme n'ait pas un comportement oscillatoire et il ne doit pas être trop petit pour permettre une convergence rapide de l'algorithme. Le pas de descente doit être choisi de façon telle que $g(\alpha_i) \leq g(0) + m_1 \alpha_i g'(0)$ [RIV95].

2.3.6. Apprentissage et estimation de la performance

L'apprentissage est le processus le plus important lors d'une modélisation par réseaux de neurones. Jusqu'à présent l'apprentissage était basé sur la fonction coût. Cependant la valeur de la fonction coût d'un réseau sur un ensemble d'apprentissage n'est pas suffisante pour estimer la qualité de prédiction d'un modèle neuronal. C'est pourquoi, il est nécessaire d'avoir une base de données relativement conséquente pour pouvoir la séparer en deux sous ensembles :

- Un ensemble d'apprentissage proprement dit avec lequel les paramètres du réseau sont estimés.
- Un ensemble de test sur lequel la performance du réseau est estimée.

Ces deux ensembles doivent explorer le même domaine de fonctionnement du réseau (espace des entrées et des sorties). Cependant l'ensemble de test est constitué de données différentes de celles de l'ensemble d'apprentissage. Alors que l'erreur quadratique sur l'ensemble d'apprentissage (EQMA, définie par l'équation (2.19)) peut décroître jusqu'à s'annuler (surajustement) lorsque le réseau est trop complexe, l'erreur quadratique moyenne sur la séquence de test (EQMT, équation (2.19)) diminue, passe par un minimum puis augmente. L'équation (2.19) est utilisée pour calculer les EQMA et EQMT.

$$EQM = \frac{1}{2} \sum_{n=1}^m (T_n - y_n)^2 \quad (2.19)$$

avec : T : valeur désirée, y : valeur réelle et n : indice du vecteur

Afin d'éviter ce phénomène de surajustement (ou overfitting en anglais), nous allons introduire la méthode de la validation croisée.

2.3.6.1. La validation croisée

L'objectif recherché dans la modélisation « boîte noire » par réseaux de neurones est l'obtention d'un modèle qui soit suffisamment complexe pour apprendre les données mais qui ne soit pas pénalisé par le problème de surajustement [DRE02]. Le surajustement est provoqué par la capacité d'un réseau de neurones, possédant un nombre d'unités de mémorisation (neurones) plus élevé que nécessaire (« sur-paramétrisation »), à apprendre parfaitement les exemples de la séquence d'apprentissage. De ce fait, le réseau n'a plus aucune capacité de généralisation.

Typiquement, l'évolution de l'erreur quadratique sur la base d'apprentissage en fonction du nombre de cycles d'apprentissage, se comporte comme la courbe A de la figure 2.7. Sur cette même figure est également représentée l'évolution de l'erreur quadratique sur la séquence de test calculée à partir d'une base de données différente de la base d'apprentissage. Cette dernière passe par un minimum, puis recommence à croître. L'idée directrice est bien entendu, d'arrêter l'apprentissage lorsque l'EQMT passe par son minimum.

Afin d'éviter ce phénomène de surajustement, plusieurs méthodes ont été proposées.

La plus simple consiste à disposer de trois bases de données distinctes : une base d'apprentissage, une base de test et une base dite de « validation croisée ». Cette dernière base est utilisée pendant l'apprentissage afin d'examiner le comportement du réseau pour des données qui lui sont inconnues.

Tous les paramètres du réseau sont mémorisés à chaque itération de l'apprentissage. Les paramètres retenus seront ceux obtenus lorsque l'erreur sur la courbe B (base de validation croisée) atteint un minimum. Notons que cette technique nécessite d'avoir suffisamment de données pour constituer trois bases à la fois représentatives et distinctes.




Figure 2.7: Evolution de l'erreur quadratique sur les séquences d'apprentissage et de test.

Dans le cas où le nombre de données n'est pas suffisant, une technique a été développée pour n'utiliser que la base d'apprentissage ; elle consiste à effectuer deux apprentissages successifs. Pour le premier apprentissage, la base d'apprentissage est divisée en deux de manière à constituer une plus petite base d'apprentissage et une base de validation croisée. Le nombre de cycles d'apprentissage nécessaire pour parvenir à la zone d'apprentissage optimale est conservé. Ce nombre est ensuite utilisé pour stopper l'apprentissage avec la base d'apprentissage globale [LAN90]. Cette méthode est plus communément appelée « early stopping ».

Dans le cadre de notre étude, la première technique a été retenue. Une autre méthode qui aurait pu être utilisée consiste à limiter la valeur numérique des poids du réseau. Cette technique est appelée méthode de « modération des poids » ou « weight decay ».

2.3.6.2. La modération des poids

La méthode de modération des poids permet d'éviter le surajustement même en ayant un nombre de paramètres importants. Le but de cette méthode est d'empêcher les poids de prendre des valeurs trop importantes. En effet Bartlett [BAR97] a montré pour un réseau complexe que si l'erreur quadratique obtenue est faible avec des poids de valeurs absolues faibles, alors les performances en généralisation dépendent de la norme des poids plutôt que de leur nombre.

Pour mettre en œuvre cette méthode, il faut minimiser, pendant l'apprentissage, une fonction de coût J' qui est la somme de la fonction coût J et d'un terme de régularisation proportionnel à la somme des carrés des paramètres (équation 2.20) :

$$J' = J + \frac{\mu}{2} \sum_{i=1}^q W_i^2 \quad (2.20)$$

où q est le nombre de paramètres du réseau et μ est un hyperparamètre dont la valeur doit être déterminée par un compromis. Si μ est trop grand, la minimisation tend à faire diminuer la valeur des paramètres sans se préoccuper de l'EQMA; à l'inverse, si μ est trop petit, le terme de régularisation a très peu d'effet sur l'apprentissage, donc le surajustement risque d'apparaître.

Le principe de la méthode est relativement simple : le gradient de la fonction de coût J est calculé par rétropropagation, puis la contribution du terme de régularisation lui est ajoutée (équation 2.21) :

$$\frac{\partial J'}{\partial W} = \frac{\partial J}{\partial W} + \mu W \quad (2.21)$$

Il faut noter néanmoins que tous les paramètres du réseau n'ont pas le même effet [DRE02] :

- Les poids correspondant aux connexions entre les variables du modèle et les entrées des neurones cachés déterminent la vitesse de variation des sigmoïdes des neurones cachés.
- Les poids correspondant aux connexions entre l'entrée constante (biais) et les entrées des neurones cachés déterminent une translation horizontale des sigmoïdes des neurones cachés.
- Les poids correspondant aux connexions entre les sorties des neurones cachés et les entrées des neurones cachés déterminent l'influence de chaque neurone sur la sortie.
- Les poids correspondant aux connexions entre le biais et le neurone de sortie déterminent une translation verticale de la sortie du réseau.

Il est donc justifié d'introduire différents hyperparamètres pour ces différents types de paramètres [MAC92]. La fonction coût devient alors (équation 2.22) :

$$J' = J + \frac{\mu_0}{2} \sum_{w_0} W_i^2 + \frac{\mu_1}{2} \sum_{w_1} W_i^2 + \frac{\mu_2}{2} \sum_{w_2} W_i^2 \quad (2.22)$$


où W_0 représente l'ensemble des paramètres reliant les biais aux neurones cachés, W_1 l'ensemble des poids reliant les paramètres aux neurones cachés, et W_2 l'ensemble des paramètres reliés au neurone de sortie. Il est donc nécessaire d'évaluer les trois hyperparamètres μ_0 , μ_1 , μ_2 . En pratique, il apparaît que les valeurs de ces hyperparamètres ne sont pas critiques ; une démarche heuristique, qui consiste à effectuer plusieurs apprentissages avec des valeurs différentes des paramètres, à tester les modèles obtenus sur un ensemble de données de validation et à choisir le meilleur est généralement suffisante [STR00].

Avant de passer à la modélisation statique proprement dite, nous allons présenter dans les paragraphes suivants une méthodologie permettant d'automatiser la construction et l'apprentissage des réseaux de neurones.

2.3.7. Le « bootstrap »

Cette méthode permet d'automatiser la construction et l'apprentissage des réseaux de neurones. Elle s'articule autour de la méthode statistique du « bootstrap » et de la technique de l'arrêt prématuré ou « early stopping ». L'orientation prise est donc celle qui consiste à utiliser des réseaux suffisamment complexes, puis à les régulariser par arrêt de l'apprentissage. Avec le « bootstrap », il est possible d'évaluer avec efficacité la variabilité du réseau, et de son erreur par rapport aux données

(Figure 2.8). Associé à l'arrêt prématuré, il permet le contrôle de l'apprentissage en optimisant automatiquement le nombre de cycles nécessaire, tout en fournissant les caractéristiques statistiques de l'erreur de généralisation [DREY02].



$e1$: erreur d'approximation, $e2$: erreur d'estimation, $e3$: erreur de généralisation

H : Hyperspace des fonctions d'approximation envisageables compte tenu de la structure du RN choisie (2 couches, $N1$ et $N2$ neurones sur les couches cachées et fonctions d'activations)

Figure 2.8: le « bootstrap »

Le « bootstrap », proposé par EFRON [EFR93], est une technique aujourd'hui très étudiée, notamment pour les tests d'hypothèses et l'estimation des intervalles de confiance. Appliqué à la régression, le « bootstrap » permet d'estimer les caractéristiques statiques de l'écart entre l'erreur d'apprentissage et celle de généralisation. L'approche est particulièrement adaptée aux problèmes pour lesquels les échantillons d'exemples sont de petite taille. C'est le cas notamment du calcul scientifique et de la simulation de systèmes complexes. A partir d'une base de calculs, des fonctions analytiques sont construites par régression ou interpolation, afin d'être utilisées en lieu et place de modules de calculs plus coûteux en temps de calcul.

Le principe général de la méthode est de rééchantillonner un grand nombre de fois l'échantillon initial qui a été réellement prélevé dans la population.

2.3.7.1. L'erreur de généralisation estimée par le « bootstrap »

La capacité de généralisation d'un réseau de neurones est souvent déterminée à l'aide de l'erreur quadratique sur la séquence de test (également appelée erreur de généralisation). La technique du « bootstrap » permet d'estimer cette erreur. Le principe est de partir d'une base d'échantillons initiale, on simule de nouveaux échantillons, appelés « répliques », de taille n , par tirage aléatoires avec remise [DREY02]. Par tirages aléatoires avec remise, on obtient ainsi plusieurs répliques dans lesquelles certaines valeurs de l'échantillon initial ne figurent pas, et où d'autres apparaissent plusieurs fois. Plusieurs échantillons sont ainsi simulés et on obtient alors B bases « bootstrapées ».

Loi binomiale des bases bootstrapées [SAP90]

A chaque tirage, tous les exemples ont la même probabilité $p = 1/n$, en notant n le nombre d'exemples. Le nombre d'apparitions d'un exemple dans une base bootstrapée suit donc une loi binomiale $B(n, p = 1/n)$. La probabilité qu'un exemple apparaisse k fois est donnée par $P(k) = C_n^k p^k (1-p)^{n-k}$.

La probabilité qu'un élément n'apparaisse pas dans la base « bootstrapée » est donc $P(0) = (1 - 1/n)^n$. Pour n suffisamment grand $P(0)_{n \rightarrow \infty} = e^{-1} \approx 0.368$. En moyenne, 37% des exemples ne seront pas utilisés en apprentissage.

2.3.7.2. Statistique de l'erreur de généralisation

L'écart entre l'erreur d'apprentissage (EQMA) calculée sur la base « bootstrapée » et l'erreur de validation (EQMV) évaluée sur la base initiale est considérée comme une variable aléatoire représentative de l'écart entre l'erreur d'apprentissage et l'erreur de généralisation.

Une statistique est faite sur l'ensemble de ces écarts (un par base « bootstrapée ») afin d'estimer la loi de distribution de l'écart entre l'apprentissage et l'erreur de test (EQMT).

Soient B la base initiale des exemples et B^*_b , $b = 1, \dots, N$ l'ensemble des répliques. Désignons par ε_b^* l'erreur d'apprentissage du réseau entraîné sur la réplique k , et par ε_b l'erreur du même réseau calculée sur la base initiale B . L'écart $\delta_b = \varepsilon_b - \varepsilon_b^*$ entre les deux erreurs peut alors être considéré comme une variable aléatoire représentative du phénomène du sur-apprentissage. Cet écart peut être considéré comme le biais qui apparaît sur l'estimation de l'erreur de généralisation par l'erreur d'apprentissage. L'espérance $\bar{\delta}$ et la variance σ_δ du biais peuvent alors être estimées sur l'ensemble des valeurs δ_b .

$$\delta_b = \varepsilon_b - \varepsilon_b^* \quad \bar{\delta} = \frac{1}{B} \sum_{b=1}^B \delta_b \quad \sigma_s^2 = \frac{1}{B-1} \sum_{b=1}^B (\delta_b - \bar{\delta})^2$$

2.3.7.3. Mise en œuvre de l'apprentissage par la méthode du « bootstrap »

Pour réaliser l'apprentissage, il est nécessaire de déterminer une base d'apprentissage initiale. De cette base, on crée différentes bases par un tirage aléatoire avec remise (Figure 2.9). Ces dernières vont être utilisées pour réaliser des apprentissages sur un réseau identique ou seul le nombre d'itérations de l'algorithme d'optimisation varie. Pour chaque modèle, on évalue la différence entre l'erreur d'apprentissage (à partir des bases « bootstrapées ») et l'erreur de validation (à partir de la base initiale). Le nombre d'itérations optimal ($N_C^{optimal}$) sera celui obtenu avec le modèle présentant la différence d'erreurs minimale (méthode de l'arrêt prématuré ou « early Stopping »).

Après avoir déterminé le nombre d'itérations optimal, on lance un nouvel apprentissage fondé sur la totalité des exemples (base initiale), avec, pour nombre de cycles, le nombre de cycles optimisé $N_C^{optimal}$ défini à l'étape précédente. Pour ce dernier apprentissage, les valeurs des poids initiaux du réseau obtenu précédemment sont utilisés et l'architecture du réseau reste la même.

Il suffit enfin de lancer une séquence de test pour déterminer la capacité de généralisation du réseau.




Figure 2.9: Algorithme du « bootstrap »

2.3.7.4. Intérêt de cette méthodologie

Le schéma représenté sur la figure 2.10 montre la répartition des données pour établir les différentes bases nécessaires à la réalisation d'un modèle pour la méthode de la validation croisée et la méthode du « bootstrap ».




Figure 2.10: répartition des données.

Chapitre II : Les réseaux de neurones pour la modélisation statique d'une pile de type PEM

Avec la méthode de validation croisée, l'apprentissage du réseau ne se fait réellement que sur environ 60 % des exemples issus des essais expérimentaux ; 25 % des points sont utilisés pour la validation et 15 % pour le test, alors que la méthode du « bootstrap » permet de réaliser un apprentissage sur environ 85 % des données disponibles.

Cette dernière méthode est d'autant plus avantageuse qu'elle nécessite soit moins d'exemples expérimentaux pour parvenir à la même qualité d'apprentissage soit en utilisant le même nombre d'exemples expérimentaux, conduit à un meilleur apprentissage. Quelques résultats obtenus à l'aide de cette méthode seront présentés dans les paragraphes suivants.

A présent, les méthodologies présentées dans les paragraphes précédents vont être mises en oeuvre pour développer un modèle statique de pile à combustible de type PEM.

2.4. Modélisation statique d'une pile à combustible de type PEM 500W

Un modèle de type boîte noire est uniquement établi à partir de données expérimentales ou d'observations. Pour établir le modèle de la pile à combustible, il est nécessaire d'avoir un certain nombre de connaissances sur le processus. Dans le cadre de notre étude, un banc d'essai d'une pile à combustible de type PEM de 500 W a été utilisé. Ce banc d'essai a permis d'obtenir de nombreuses connaissances sur le fonctionnement des piles à combustible de manière générale, notamment sur l'influence respective des différentes variables de contrôle sur le fonctionnement de la pile. Cela est important en vue de l'élaboration du modèle et du choix des entrées sorties.

De plus, grâce à ce banc d'essais un grand nombre d'essais ont pu être réalisés afin de recueillir un maximum de données expérimentales permettant l'apprentissage des réseaux de neurones.

Pour réaliser l'approximation de la fonction de régression recherchée, à partir d'exemples, à l'aide d'un réseau de neurones, plusieurs étapes successives sont nécessaires :

- Choix de l'architecture du réseau de neurones
- Détermination des paramètres du réseau grâce à l'apprentissage
- Estimer la qualité du réseau obtenu

Ces différentes étapes vont être décrites dans les paragraphes suivants. Cependant, dans un premier temps, le banc d'essais sur lequel la plus grande partie de nos travaux a été réalisée va être brièvement décrit.

2.4.1. Présentation du banc d'essai

Le banc de test pour pile à combustible de type PEM jusqu'à 1 kW (figure 2.11) a été entièrement conçu et réalisé [HAR03], [JEM01], [MOR01] au sein du Laboratoire de recherche en Electronique Electrotechnique et Systèmes (L2ES), laboratoire Université de Franche Comté (UFC), Université de Technologie de Belfort Montbéliard (UTBM) et Institut National de Recherche sur les Transports et leur Sécurité (INRETS). Ce premier banc d'essais fonctionnait en boucle ouverte et il ne comportait aucun système de régulation. Sur le banc en version définitive, les éléments de base sont les suivants :

- le générateur (PAC),
- le système d'acquisition qui assure le contrôle commande du système pile à combustible,
- la charge active qui permet de faire débiter du courant à la pile,
- les condensateurs qui assèchent les gaz en sortie de pile afin de récupérer une partie de l'eau produite pendant la réaction,
- le bouilleur qui est à la base du circuit d'humidification d'air.

Ce banc de test a été conçu de manière à mener une caractérisation complète d'une pile à combustible de type PEM, sous des sollicitations statiques et dynamiques. Pour étudier les performances du système et valider des modèles de simulations, un grand nombre d'essais a été réalisé. Ce banc est instrumenté de manière à acquérir le plus grand nombre de paramètres significatifs caractérisant le système. Le contrôle de certains paramètres, tels que la température de la boucle de refroidissement,

les débits et pressions de gaz ou le courant, est assuré afin d'obtenir un point de fonctionnement spécifique. Les paramètres mesurés et contrôlables du système sont regroupés dans le tableau 2.2.




Figure 2.11: Banc de test pour une pile à combustible de type PEM basse puissance version 2.

<i>Paramètres mesurés</i>	<i>Paramètres contrôlés</i>
Tensions unitaires de cellules	Courant de pile
Courant de pile	Débit air amont
Débits air amont/aval	Débit H ₂ amont
Débits H ₂ amont/aval	Débit eau
Débit eau de refroidissement	Pressions H ₂ et air aval
Pressions air amont/aval	Températures air et H ₂ amont
Pressions H ₂ amont/aval	Hygrométrie air
Hygrométrie air amont/aval	Température bouilleur
Températures H ₂ amont/aval	Température réchauffeur air
Températures air amont/aval	Température H ₂
Températures eau amont/aval	Température eau
Température surface pile	Mode de fonctionnement H ₂ (ouvert ou fermé)
Température bouilleur	
Température réchauffeur air	

Tableau 2.2: Liste des paramètres contrôlables et mesurés.

Le système de pilotage du banc est réalisé avec le logiciel Labview. Il permet l'acquisition des différentes grandeurs mesurées, le contrôle des sécurités, la gestion des automatismes et le pilotage des actionneurs à partir des consignes de l'utilisateur ou de grandeurs de commande lues dans un fichier (suivi de cycle).

2.4.2. Essais expérimentaux

Les expérimentations présentées dans cette partie permettent d'une part, d'illustrer le type d'essais qu'il est possible de mener avec le banc de tests et d'autre part de caractériser la pile à combustible ZSW de 500W présentée en [Annexe 1]. La courbe de polarisation de la pile à combustible est la caractéristique tension en fonction du courant. Elle est mesurée de manière statique, en positionnant le point de courant et en laissant la tension se stabiliser avant de noter les valeurs.

2.4.2.1. Courbes de polarisation à stœchiométrie constante ($FSA = 2$, $FSC = 5$) pour différentes températures de fonctionnement

Cette première série de courbes de polarisation a été relevée pour des températures de fonctionnement variant de 22°C à 50°C. Les facteurs de stœchiométrie anodique et cathodique, notés respectivement FSA et FSC sont fixés. Ces facteurs sont directement liés aux débits d'hydrogène et d'air. Les débits sont définis à partir des équations (2.23 et 2.24); ils varient en fonction du facteur de stœchiométrie, du nombre de cellules et du débit d'électrons exprimé par le rapport entre le courant et la charge d'une mole d'électron (constante de Faraday) :

$$q_{H_2} [mol/s] = FSA \times \frac{I}{2F} \times N \quad (2.23)$$

$$q_{O_2} [mol/s] = FSC \times \frac{I}{4F} \times N \times \frac{1}{0.21} \quad (2.24)$$

avec $F = 96485 \text{ C.mol}^{-1}$ (constante de Faraday), N = nombre de cellules et I = courant de pile (A). Pour ces expérimentations, nous avons travaillé en air sec. Au vu des courbes de polarisation obtenues (figure 2.12), nous constatons globalement que les performances sont améliorées avec une augmentation de la température de refroidissement mesurée comme étant la température de sortie du circuit de refroidissement à partir d'environ cinq ampères. Il faut également remarquer que les courants maxima obtenus sont relativement faibles (environ 10 ampères). Au delà de dix ampères, il apparaît de fortes chutes de tensions de cellules pouvant entraîner des dégâts irréremédiables sur les membranes. Ces chutes de tensions sont dues à un assèchement des membranes.




Figure 2.12: Courbes de polarisations à différentes températures, air sec

Pour pallier ce problème, il est nécessaire d'humidifier les gaz. Dans notre cas, seul le côté cathode est humidifié. La figure 2.13 illustre un essai où l'hygrométrie de l'air entrant est contrôlée.




Figure 2.13: Courbes de polarisations à différentes températures, air humidifié.

Les caractéristiques statiques obtenues à présent atteignent des courants de trente ampères, ce qui n'était possible que sur des transitoires en gaz sec. Pour bien identifier l'influence de l'humidification, ces essais ont été renouvelés à une température de fonctionnement constante et des valeurs d'humidification relative de l'air variant de 50 à 100% (Figure 2.14):

2.4.2.2. Courbes de polarisation à température ($T=50^{\circ}\text{C}$) et stœchiométries constantes ($FSA = 2$, $FSC = 5$) pour différentes hygrométries relatives




Figure 2.14: Courbes de polarisations à différentes hygrométries de l'air, température de fonctionnement et facteurs stoechiométriques constants ($FSA=2$, $FSC=5$)

La figure 2.14 illustre parfaitement la nécessité d'humidifier le côté cathodique de la pile. Au-delà de 50% d'hygrométrie relative de l'air entrant dans la pile, les performances sont nettement améliorées.

2.4.2.3. Courbes de polarisation à température ($T = 50^{\circ}\text{C}$) et hygrométrie relative constantes ($H = 100\%$) pour différentes valeurs de stœchiométries.

Ces essais sont destinés à mettre en évidence l'effet du sur-débit de gaz sur les performances de la pile (figure 2.15). Pour cette gamme de courant, l'augmentation de la stœchiométrie côté air est bénéfique. D'autres essais ont permis de conclure que le sur débit de gaz côté anodique n'améliorait en rien les performances.




Figure 2.15: Courbes de polarisations à différentes valeurs de stœchiométries, température de fonctionnement et hygrométrie relative constantes.

2.4.2.4. Conclusions sur les essais expérimentaux

Les essais de mesure sur les courbes de polarisation ont permis de connaître le comportement de la pile sous plusieurs contraintes et de dégager les paramètres les plus influents sur les performances du générateur pile à combustible.

Ainsi, nous pouvons conclure que :

- la température de fonctionnement,
- l'hygrométrie de l'air entrant
- les facteurs de stœchiométries

sont les paramètres les plus importants dans le cadre d'une optimisation énergétique du fonctionnement de la pile à combustible. La pression des gaz est un paramètre qui n'a pas été exploré en raison de sa très faible influence sur les performances de la pile. En effet, la pile étudiée est une pile qui fonctionne à pression atmosphérique et de ce fait, la variation de pression (relative) est de l'ordre de quelques millibar.

Grâce à ces essais, il est dès lors aisé de déterminer les paramètres d'entrée sortie du modèle boîte noire basé sur les réseaux de neurones.

2.4.3. Architecture

La première étape nécessaire à l'élaboration d'un modèle utilisant les réseaux de neurones consiste à choisir l'architecture du réseau, c'est-à-dire les entrées sorties. L'architecture d'un réseau de neurones comprend aussi le choix du nombre de neurones cachés ainsi que le nombre de couches cachées. Les fonctions d'activations pour les neurones de chaque couche doivent être correctement choisies afin que cet ensemble soit en mesure de reproduire ce qui est déterministe dans les données.

2.4.3.1. Entrées/sorties du modèle

La définition des entrées sorties d'un modèle neuronal nécessite un minimum de connaissances sur le processus à modéliser. La détermination des paramètres les plus pertinents est nécessaire. La détermination du nombre de ces paramètres a des conséquences à la fois sur la taille du réseau mais aussi sur ses performances. Dans le premier cas, si le réseau est surdimensionné, les temps d'apprentissages seront excessifs. A l'inverse, si le réseau est sous-dimensionné, les qualités de prédiction ne seront pas satisfaisantes.

Grâce à l'étude expérimentale précédente, un ensemble d'entrées qui regroupe les paramètres les plus influents sur les performances du processus a été déterminé. La sortie considérée pour le modèle est la tension de pile [JEM02], [JEM03a].

Les entrées retenues pour le développement du modèle sont les suivantes (figure 2.16):

- Courant de pile
- Température de fonctionnement
- Hygrométrie relative de l'air
- Débit massique d'entrée H₂
- Débit massique air

Il est nécessaire de préciser que les entrées « débits » sont directement liées aux facteurs de stœchiométries des gaz et donc à la demande en courant. Les relations permettant de déterminer les débits massiques sont présentés en [Annexe 1].

2.4.3.2. Choix du nombre de couches cachées

De nombreux problèmes pratiques et théoriques se posent dès lors qu'on s'interroge sur la capacité des réseaux à couches. Combien de couches sont nécessaires à la résolution de tel ou tel problème ? Combien de neurones par couches ? Quelle sera la vitesse de convergence ?... Ces questions font toujours l'objet de recherches intenses mais aujourd'hui aucune théorie ne permet de déterminer le nombre optimal de neurones et de couches cachées à utiliser pour obtenir une modélisation correcte d'un processus.

De nombreux résultats indiquent que les réseaux « surdimensionnés » permettent de réaliser un apprentissage de meilleure qualité. Une explication simple à cette conclusion est que l'importance du nombre de paramètres aide à la convergence de l'algorithme d'apprentissage car le risque de « tomber » dans un minimum local ou sur un plateau de la surface d'erreur est fortement diminué. Il reste pourtant souhaitable de trouver des solutions avec le plus petit nombre de paramètres, c'est-à-dire

une topologie de réseau de neurones comprenant un minimum de neurones sur la ou les couches cachées. De plus, un réseau « surdimensionné » amène bien souvent à une mauvaise prédiction due à un surajustement.

2.4.3.3. Choix du nombre de neurones et leur fonction d'activation

La propriété d'approximation universelle des réseaux de neurones a été démontrée par Cybenko [CYB89] et Funahashi [FUN89]. Pour s'assurer de la plus grande précision d'une approximation d'une fonction, il suffirait de choisir le nombre de neurones cachés le plus grand possible. Cependant nous sommes confrontés avec les réseaux de neurones à un problème d'ajustement d'une fonction à un nombre fini de points. Cela signifie qu'à l'issue de l'apprentissage, la fonction réalisée par le modèle doit se rapprocher le plus possible des points de la base d'apprentissage mais doit être également capable de généraliser de manière satisfaisante.

Les problèmes de surdimensionnement et de sous dimensionnement d'un réseau de neurones ont été évoqués précédemment. Le dilemme entre le choix du nombre de neurones cachés et la précision obtenue sur la généralisation est appelée « dilemme biais variance » [DRE02].

La figure 2.16 schématise le réseau obtenu pour la modélisation statique de la pile 500W.




Figure 2.16: Paramètres du réseau

2.4.4. Apprentissage

Nous avons introduit dans les paragraphes précédents les types d'apprentissages adaptés aux réseaux de neurones. Les critères de choix sont généralement la rapidité de convergence et les performances de généralisation. Néanmoins avant d'appliquer ces méthodologies sur les bases d'apprentissages, plusieurs procédures doivent être effectuées [JEM03b].

2.4.4.1. Normalisation des données

De manière générale, les bases de données doivent subir un prétraitement afin d'être adaptées aux entrées et sortie du réseau de neurones. Un prétraitement courant consiste à effectuer une normalisation appropriée, qui tient compte de l'amplitude des valeurs acceptées par le réseau, ou plutôt par les fonctions d'activation.

De plus, dans un système donné, toutes les valeurs ne varient pas sur la même échelle. Il est donc préférable de normaliser (entre -1 et +1 ou 0 et 1) les entrées présentées au réseau afin de faciliter l'apprentissage, d'obtenir une meilleure homogénéité des valeurs finales des paramètres et de ne pas négliger des valeurs qui peuvent être déterminantes.

Pour notre étude, toutes les entrées ont été normalisées entre 0 et 1 (tableau 2.3) car des fonctions d'activation de types tangentes hyperboliques sont utilisées.

<i>Paramètres</i>	<i>Plage de variation</i>	<i>Plage normalisée</i>
Courant I en A.	[0 – 50]	[0 – 1]
Tension U en V	[0 – 19.6]	[0 – 1]
Débit H ₂ en NI/min	[0 – 20.9]	[0 – 1]
Débit O ₂ en NI/min	[0 – 99]	[0 – 1]
Température de fonctionnement en °C	[0 – 58]	[0 – 1]
Hygrométrie de l'air en %	[0 – 100]	[0 – 1]

Tableau 2.3: Liste des paramètres normalisés

2.4.4.2. Choix des bases de données

Comme défini précédemment l'apprentissage nécessite d'avoir deux bases de données distinctes : une base pour l'apprentissage et une base dite de « validation croisée » qui permet de contrôler la phase d'apprentissage. Enfin, une dernière base de données est nécessaire pour le test du réseau.

Il n'y a pas de règles pour déterminer ce partage de manière quantitatif. Il résulte souvent d'un compromis tenant compte du nombre de données disponible et du temps de calcul pour l'apprentissage. Il est tout de même conseillé de choisir la base d'apprentissage sur le domaine complet d'étude du processus. Par ailleurs, les bases de validation et de test doivent être nécessairement englobées dans le domaine d'ensemble représenté par la base d'apprentissage pour espérer obtenir une bonne représentation de la fonction à approximer.

La collecte de données effectuée sur le banc de test pile à combustible représente environ 2500 échantillons regroupés suivant différents points de fonctionnement. Les différents points de fonctionnement utilisés pour les différentes bases de données sont représentés dans le tableau 2.4.

Base d'apprentissage	Base de validation croisée	Base de test
U(I), FSA=2, FSC=4, T=25°C, H=100%	FSA=2, FSC=5, T=25°C, H=100%	FSA=2, FSC=6, T=25°C, H=100%
U(I), FSA=2, FSC=4, T=35°C, H=100%	FSA=2, FSC=5, T=35°C, H=100%	FSA=2, FSC=4, T=50°C, H=50%
U(I), FSA=2, FSC=6, T=35°C, H=100%	FSA=2, FSC=6, T=50°C, H=50%	FSA=2, FSC=5, T=50°C, H=75%
U(I), FSA=2, FSC=5, T=50°C, H=50%		FSA=2, FSC=5, T=50°C, H=100%
U(I), FSA=2, FSC=4, T=50°C, H=75%		
U(I), FSA=2, FSC=6, T=50°C, H=100%		

Tableau 2.4: Répartition des différentes bases de données.

2.4.5. Résultats de simulation

Pour nos travaux, l'apprentissage débute avec la méthode de rétropropagation du gradient. Lorsque l'on s'approche d'un minimum, ce gradient prend des valeurs de plus en plus faibles et la convergence vers ce minimum est fortement ralentie. La méthode de quasi-Newton est alors utilisée pour accélérer la convergence. Le problème est de choisir le nombre d'itérations pour la méthode du gradient. En règle général, une centaine d'itérations sont nécessaires pour se rapprocher d'un minimum. Après avoir basculé sur la méthode de quasi-Newton, le nombre d'itérations choisi dépend du concepteur. Il n'y a pas ici de critères d'arrêt particulier car la méthode de la validation croisée est utilisée. Dans le cadre de notre étude, le nombre d'itération maximale a été limité à 50000 pour des problèmes de temps de calculs. Il aurait été possible de stopper l'apprentissage plus tôt mais le problème de ces algorithmes est qu'ils ne garantissent pas d'obtenir le minimum global de la surface d'erreur. En prenant un nombre conséquent d'itérations, les chances de tomber dans des minima locaux sont limitées.

La technique adoptée est donc la suivante : Le nombre d'itérations pour l'apprentissage est fixé et l'Erreur Quadratique Moyenne sur la séquence d'Apprentissage (EQMA) et l'Erreur Quadratique Moyenne sur la séquence de Validation (EQMV, équation (2.19)) sont calculées à chaque itération. L'apprentissage pourrait être stoppé dès qu'un minimum de l'EQMV est atteint mais rien n'assure d'avoir le minimum global de l'erreur de validation. C'est pourquoi l'apprentissage est mené jusqu'à ce que le nombre d'itérations fixé soit atteint. Généralement l'EQMV obtenue à la fin de l'apprentissage est médiocre car le phénomène de surajustement intervient (figure 2.17).

La stratégie adoptée consiste à mémoriser les paramètres du réseau lorsqu'un minimum de l'EQMV est atteint. Les paramètres utilisés pour calculer la sortie du réseau sont ceux obtenus avec le minimum global de l'EQMV.




Figure 2.17: Erreur Quadratique Moyenne sur la séquence d'Apprentissage (EQMA)




Figure 2.18: Erreur Quadratique Moyenne sur la séquence de Validation (EQMV)

L'efficacité de la méthode de quasi-Newton à proximité d'un minimum est vérifiée sur les figures 2.17 et 2.18. Les premières itérations ne réduisent que faiblement le coût et dès qu'une direction de descente efficace est trouvée, l'apprentissage s'accélère (diminution de 33% pour l'EQMA et 15% pour l'EQMV):

à la 15 ^{ème} itération de quasi-Newton	EQMA = $4 \cdot 10^{-3} \text{ V}^2$	EQMV = $2.75 \cdot 10^{-3} \text{ V}^2$
à la 250 ^{ème} itération de quasi-Newton	EQMA = $3 \cdot 10^{-4} \text{ V}^2$	EQMV = $2.55 \cdot 10^{-4} \text{ V}^2$

Pour la méthode du gradient, au bout de 1000 itérations, l'EQMA a été réduite de 10,3%. En ce qui concerne l'EQMV, la diminution est de 6,4%.

Par ailleurs, nous remarquons que la valeur minimale de l'EQMV est atteinte au bout de 7700 itérations. Les paramètres retenus pour la prédiction sont donc calculés à cette itération. D'autre part, le temps de calcul pour cet apprentissage s'élève à 42 minutes sur un PC Pentium 4 cadencé à 2 GHz.

Suite à cet apprentissage que nous pouvons qualifier de satisfaisant dans un premier temps au vu des erreurs relevées sur les séquences d'apprentissage et de validation, il est nécessaire de tester le réseau de neurones avec les points de la séquence de test. Nous rappelons qu'aucun des points de la séquence de test n'a été appris par le réseau durant l'apprentissage.

Les erreurs obtenues sur cette séquence de test pourront permettre de conclure sur les qualités d'apprentissage et de prédictions du modèle. Une partie des résultats calculés par le réseau de neurones sont représentés sur les figures 2.19 et 2.20.




Figure 2.19: Courbes de polarisation mesurées et calculées ($FSA=2$, $FSC=6$, $T=25^{\circ}C$, $H=100\%$)




Figure 2.20: Courbes de polarisation mesurées et calculées ($FSA=2$, $FSC=6$, $T=25^{\circ}C$, $H=100\%$)

En considérant l'allure des points calculés par le réseau, les résultats peuvent être considérés satisfaisants. Néanmoins, une évaluation des erreurs quadratiques et des erreurs maximales entre les points calculés et les points mesurés ($\epsilon_{\max}$) est nécessaire (tableau 2.5).

	FS=2, 6 T°=25°C H=100%	FS=2, 4 T°=50°C H=50%	FS=2, 5 T°=50°C H=75%	FS=2, 5 T°=50°C H=100%
<i>EQMT</i>	0.29 V ²	0.20 V ²	0.19 V ²	0.88 V ²
<i>$\epsilon_{\max}$</i>	1.67%	1.28%	1.35%	2.1%

Tableau 2.5: Erreurs relevées sur modèle 500W.

Grâce à la quantification des différentes erreurs sur les courbes de test obtenues avec le modèle statique, nous pouvons conclure que le réseau de neurones remplit bien son rôle d'approximation.

2.4.6. Ajout de bruit dans la base d'apprentissage

Les bases d'apprentissage qui ont été utilisées pour notre modèle sont issues d'essais réalisés sur le banc de test pile à combustible 500 W disponible au L2ES. Malgré les précautions prises pour le câblage de tous les appareils de mesure, il est possible que certaines mesures soient quelque peu erronées. Ces erreurs peuvent avoir plusieurs provenances : mauvais étalonnage de l'appareil, connectiques défectueuses ou encore présence de bruits de mesure. Nous avons donc décidé de bruite les points d'apprentissage pour, d'une part, se rapprocher le plus possible du système réel et d'autre part, permettre une meilleure généralisation [STR00], [LAW96].

Pour se rapprocher le plus possible du système réel, la valeur de ce bruit a été quantifiée en réalisant des essais par hystérésis sur une courbe de polarisation. La figure 2.21 donne l'essai qui présente l'écart le plus important entre les valeurs prises à la « montée » et celles prises à la « descente ».




Figure 2.21: hystérésis $U(I)$.

La valeur maximale du bruit obtenue est la moyenne de la différence entre les points de la courbe de polarisation relevée à la descente et à la montée :

$$\langle \text{bruit} \rangle = 680 \text{ mV}$$

Afin de quantifier l'impact du bruit sur la qualité de prédiction du réseau, nous avons tracé sur la figure 2.22 la moyenne des erreurs quadratiques obtenues sur les points de test en fonction de la valeur du bruit.




Figure 2.22: Corrélation entre l'erreur quadratique et le bruit.

Ces résultats semblent montrer que l'ajout de bruit dans la base d'apprentissage n'améliore ici que très peu la qualité de prédiction du modèle. En revanche, ceci permet également de conclure que la méthode d'apprentissage proposée semble relativement robuste face aux problèmes de bruit sur la tension mesurée.

2.4.7. Neural Network Toolbox (NNToolbox)

La Neural Network Toolbox étend l'environnement de calcul Matlab® afin d'offrir des outils pour la conception, la mise en oeuvre, la visualisation et la simulation de réseaux de neurones. Cet outil offre une prise en charge complète de nombreuses structures réseau éprouvées, ainsi qu'une interface utilisateur graphique permettant de concevoir et de gérer les réseaux. La conception modulaire, ouverte et extensible de cette boîte à outils simplifie la création de fonctions et de réseaux personnalisés.

La Neural Network Toolbox a été étudiée afin de comparer les résultats obtenus avec cet outil et ceux obtenus avec notre modèle. Il est nécessaire de préciser que le modèle utilisé dans tous ces travaux a été entièrement programmé par nos soins à partir d'un algorithme du gradient proposé par [IM01]. L'utilisation de la NNToolbox n'a pas été retenue pour deux raisons. D'une part, il est impossible de réaliser des modifications sur les algorithmes proposés ou d'accéder à certains paramètres nécessaires à l'optimisation des apprentissages (modération des poids par exemple) et d'autre part, l'utilisation de cet outil pour la modélisation dynamique est limitée. Il n'est par exemple pas possible d'inclure plus d'un retard dans un réseau de neurones récurrent.

Cependant, les résultats obtenus pour la modélisation statique fournissent des erreurs équivalentes à celles obtenues avec notre modèle et les temps de calcul sont bien inférieurs (tableau 2.6). Mais il est souvent nécessaire de réaliser plusieurs apprentissages avant d'obtenir des résultats cohérents.

Temps de calcul pour l'apprentissage	Nombre d'itérations	EQMT	ϵ_{max}
12 minutes	1243	0.309 V ²	1.87%

Tableau 2.6: Erreur minimale relevée avec la NNToolbox et temps de calcul

2.4.8. Résultats obtenus avec le Bootstrap

La méthode du Bootstrap a été programmée afin de comparer les résultats obtenus (tableau 2.7) avec ceux issus de la validation croisée.

Nombre d'exemples dans la base Bootstrapée	EQMT	ϵ_{max}
50 exemples	0.8 V ²	2.86%
100 exemples	0.25 V ²	1.89%
150 exemples	0.3 V ²	1.96%

Tableau 2.7: Erreurs relevées avec la méthode du Bootstrap

Elle a permis de faire apparaître plusieurs propriétés essentielles. L'erreur de test est relativement faible même dans les cas où le nombre d'exemples est petit. De plus, le « bootstrap » permet d'obtenir de bons résultats de prédiction par contrôle de l'arrêt de l'apprentissage (« early stopping »). Cependant les résultats n'ont été améliorés que « localement » mais les erreurs restent inférieures à 3%. Enfin, elle permet de proposer en quelque sorte un formalisme unifié pour la procédure de modélisation ; procédure certes longue mais systématiquement couronnée de succès. Néanmoins, le fait d'avoir des bases « bootstrapées » conséquentes augmente le temps d'apprentissage. Cette méthode n'a pas été retenue pour la suite de nos travaux en raison de sa mise en œuvre trop coûteuse en temps.

2.5. Modélisation statique d'une pile de type PEM 5 kW

Notre choix de méthode de modélisation s'est porté sur les méthodes neuronales du fait de leurs capacités d'adaptation à différents types de processus. Un point clé de notre étude consiste donc à montrer la portabilité du modèle neuronal développé sur d'autres piles à combustible. Pour cela, il est nécessaire de réaliser des essais expérimentaux sur une autre pile à combustible puis de réaliser un apprentissage du même modèle que précédemment sur ces nouveaux essais.

L'objectif recherché est double :

- d'une part le modèle développé à partir de la pile 500 W est utilisable sur n'importe quel autre pile à combustible, présentant les mêmes paramètres contrôlables et mesurables,
- d'autre part montrer qu'un facteur d'échelle sur la puissance de la pile à combustible n'altère pas la qualité de la méthode.

L'idée est donc de reprendre le modèle 500 W et de changer les bases d'apprentissage, de validation et de test. L'architecture du réseau et les techniques d'optimisation restent bien entendu identiques.

2.5.1. Présentation du banc d'essai

Le banc de test pile à combustible 5 kW (figure 2.23) est instrumenté de manière analogue au banc de test 500W. Néanmoins certains paramètres (débits de gaz) ne peuvent pas être maintenus fixes pour de faibles courants et le contrôle de l'hygrométrie ne peut pas être validé du fait de l'absence d'un hygromètre à miroir sur le circuit d'air. Une présentation est fournie en [Annexe 2].




Figure 2.23: Banc de test pour une pile à combustible de type PEM 5kW

2.5.2. Essais expérimentaux

De la même manière que pour le modèle présenté dans le paragraphe 2.4, une collecte de données permettant de « caler » ce réseau de neurones est nécessaire. Quelques courbes de polarisation relevées à différents points de fonctionnement sont ici présentées (figure 2.24, figure 2.25 et figure 2.26). Le seul paramètre qui n'est pas ici variable est l'hygrométrie, du fait de l'absence d'un hygromètre à miroir sur le circuit d'air. Les facteurs stoechiométriques sont ici plus bas que ceux utilisés sur la pile 500 W. Les plages de variations sont les suivantes :

- De 1 à 1,2 pour le facteur de stœchiométrie anodique
- De 1,2 à 2,5 pour le facteur de stœchiométrie cathodique
- De 30°C à 60°C pour la température de fonctionnement

Les courbes de polarisations relevées montrent l'influence des facteurs stoechiométriques sur les performances de la pile. Il en est de même pour la température de fonctionnement.

Par ailleurs, nous remarquons que le comportement de la pile 5 kW est similaire à celui de la 500 W de part l'influence similaire de leurs paramètres respectifs.




Figure 2.24: courbes de polarisation pour différents facteurs de stœchiométrie à $T = 30^{\circ}\text{C}$.




Figure 2.25: courbes de polarisation pour différents facteurs de stœchiométrie à $T = 40^{\circ}\text{C}$.




Figure 2.26: courbes de polarisation pour différents facteurs de stœchiométrie à $T = 50^{\circ}\text{C}$.

2.5.3. Architecture et méthodes d'apprentissage

L'architecture du modèle neuronal reste identique au modèle 500 W. Pour mémoire, la figure 2.27 rappelle la topologie retenue pour le réseau de neurones.




Figure 2.27: paramètres du réseau

La méthode d'apprentissage reste également inchangée. Nous utilisons les méthodes de descente du gradient avec celle de quasi-Newton, couplées avec la validation croisée pour éviter les phénomènes de sur-apprentissage.

2.5.4. Résultats de simulation

Les résultats de simulation obtenus avec le modèle décrit dans les paragraphes précédents sont présentés sur les figures 2.28 à 2.30.




Figure 2.28: Courbes polarisation mesurée et calculée ($FSA=1.1$, $FSC=2.4$, $T=40^{\circ}C$, $H=100\%$).




Figure 2.29: Courbes polarisation mesurée et calculée ($FSA=1.1$, $FSC=2$, $T=50^{\circ}C$, $H=100\%$).




Figure 2.30: Courbes polarisation mesurée et calculée ($FS=1$ et 2.2 , $T=60^{\circ}C$, $H=100\%$).

Les performances du modèle statique de la pile 5 kW sont établies en fonction des erreurs relevées (tableau 2.8) sur les différentes courbes calculées. Nous pouvons également comparer ces erreurs par rapport à celles du modèle statique 500 W. En reprenant la moyenne des erreurs du modèle 5 kW, l'erreur maximale entre les points relevés et calculés est de 1.25% (0.3 V² pour l'EQMT) et de 1.41% pour le modèle 500W (0.25 V² pour l'EQMT). Cependant, il était prévisible d'obtenir des erreurs de la même grandeur que celles relevées sur le modèle statique 500 W car les courbes statiques des deux piles sont très semblables (figure 2.31).




Figure 2.31: Comparaison des courbes statiques $U(I)$ de pile de type PEM de différentes puissances

Les résultats et erreurs obtenues permettent de conclure sur l'efficacité du modèle établi.

	FSA=1,1 FSC= 2,4 $T^{\circ}=40^{\circ}\text{C}$ H=100%	FSA=1,1 FSC= 2 $T^{\circ}=50^{\circ}\text{C}$ H=100%	FSA=1 FSC= 2,2 $T^{\circ}=60^{\circ}\text{C}$ H=100%
EQMT	0,16 V ²	0,4 V ²	0,36 V ²
ϵ_{max}	0,71%	1,58%	1,45%

Tableau 2.8: Erreurs relevées sur le modèle 5kW.

2.6. Conclusion

Au cours de ce chapitre, les différentes méthodologies nécessaires à la mise en œuvre d'un modèle « boîte noire » grâce aux réseaux de neurones ont été introduites. Elles ont alors servi pour le développement d'un modèle neuronal de la pile à combustible en mode statique. De plus, un certain nombre de points relatifs à l'utilisation des réseaux de neurones ont pu être mis en évidence.

Cette première partie a donc permis d'acquérir les techniques fondamentales pour la modélisation de processus par réseaux de neurones. Si ces méthodes semblent ici très performantes, il est généralement nécessaire d'effectuer plusieurs tests pour obtenir un modèle neuronal performant. En cas de difficulté, il faut être capable d'analyser les causes des problèmes rencontrés au cours de ces essais.

- Mauvais choix d'architecture, mauvais choix des entrées, mauvais choix du nombre de neurones cachés, initialisation des paramètres à des valeurs trop importantes.
- Séquences d'apprentissage de tailles trop petites ou mal réparties.
- Mauvais choix de la méthodologie d'apprentissage.

C'est l'expérience et la maîtrise du concepteur qui permet d'identifier la ou les raisons de l'échec d'un apprentissage. Il est donc nécessaire d'acquérir une vision aussi globale que possible des types de problèmes pouvant subvenir et des solutions à mettre en œuvre. Quand on utilise les réseaux de neurones pour la première fois, une mauvaise compréhension de leur fonctionnement peut laisser imaginer qu'ils peuvent « tout » apprendre pour peu qu'il y ait assez de neurones [CON00]. Une démarche rigoureuse et progressive est donc la meilleure solution pour arriver à utiliser au mieux les techniques neuronales.

D'autre part, l'étude de portabilité du modèle est un point important dans notre étude. En effet, l'objectif de ce mémoire ne se limite pas à la modélisation d'une pile à combustible particulière mais doit permettre de contribuer à la modélisation de la pile à combustible de type PEM. D'après les résultats obtenus pour la modélisation statique de la pile à combustible 5kW, nous pouvons conclure que le modèle « boîte noire » proposé devrait, a priori, pouvoir être utilisé pour d'autres piles de puissances différentes mais présentant les mêmes entrées/sorties.

Nous avons, donc à ce stade, obtenu un modèle neuronal statique performant pour une pile à combustible de type PEM. Néanmoins, pour modéliser au mieux la pile à combustible dans tous ses modes de fonctionnement, il est nécessaire d'étudier son comportement en dynamique et de le modéliser. Ce point fait l'objet du chapitre suivant.

**- CHAPITRE 3 -LES RESEAUX DE
NEURONES POUR LA MODELISATION
DYNAMIQUE D'UNE PILE DE TYPE
PEM**

3.1. Introduction

L'approche par modélisation et simulation de la chaîne de traction s'avère extrêmement efficace lors du développement des véhicules électriques. Elle permet en effet de tester différentes architectures de la chaîne et de tenir compte aisément des conditions d'utilisation du véhicule. L'objectif de notre étude doit permettre, à terme, l'intégration du modèle pile à combustible dans une modélisation d'une chaîne de traction complète d'un véhicule. Dans cette optique, il est évident que le comportement en régime statique mais aussi en régime dynamique doit être simulé.

D'autres motivations nous ont également poussé à concevoir un modèle dynamique :

- La possibilité d'utiliser ce modèle comme prédicteur à court terme (une période d'échantillonnage) afin de l'intégrer dans un système de contrôle commande.
- L'utilisation du modèle comme simulateur en vue de l'émulation en temps réel. Généralement les modèles de connaissance conduisent à des équations différentielles, ou aux dérivées partielles, dont la résolution numérique est lourde et ne peuvent répondre à des contraintes de fonctionnement en temps réel.
- Possibilité d'utiliser ce modèle dans le cadre de la détection de défauts [HIS02].

Par ailleurs, il est important de noter qu'il existe très peu de modèles de connaissance décrivant le régime dynamique d'une pile à combustible. Cette étude à partir des réseaux de neurones offre donc une alternative intéressante.

Les propriétés des réseaux de neurones bouclés à apprentissage supervisé sont directement liées à celles des réseaux non bouclés. Comme nous avons mis en œuvre les réseaux de neurones non bouclés pour modéliser, de manière statique, la pile à combustible (système non linéaire), il est intéressant de mettre en œuvre, de façon similaire, des réseaux de neurones bouclés pour modéliser, de manière dynamique cette même pile à combustible.

La modélisation dynamique présente, par rapport à la modélisation statique, des particularités importantes. La première d'entre elles réside dans le fait qu'il existe plusieurs représentations possibles pour un modèle dynamique d'un même processus. Nous verrons, dans une première partie, les solutions qui pourraient être le mieux adaptées à notre travail. Dans une deuxième partie, nous exposerons les méthodes d'apprentissages retenues et les résultats de simulations obtenus avec un modèle dynamique développé pour la pile à combustible 500W. La troisième partie sera consacrée aux résultats issus du même modèle dynamique mais utilisé sur la pile à combustible 5kW. Finalement dans une dernière partie, nous introduirons une méthodologie basée sur l'analyse de Fourier, permettant de fusionner les modèles statiques et dynamiques obtenus pour un signal périodique.

3.2. Méthodologies pour la modélisation dynamique

3.2.1. Les réseaux de neurones bouclés

Contrairement aux réseaux de neurones non bouclés, les réseaux bouclés peuvent avoir une topologie de connexions quelconque, comprenant notamment des boucles qui ramènent aux entrées la valeur d'une ou plusieurs sorties. Ces boucles peuvent être présentes soit au niveau des neurones soit entre les différentes couches. Elles permettent de prendre en compte les aspects temporels et de mémoire. Quelques architectures permettant de mettre en œuvre une modélisation dynamique par réseaux de neurones sont ici présentées.

3.2.1.1. Les réseaux bouclés localement

Dans l'approche utilisant une boucle locale sur les neurones (figure 3.1), la prise en compte de l'aspect temporel est réalisée au niveau local, sur chaque neurone. La sortie de chaque neurone est calculée à partir de son entrée présente et de son état passé [SCH88]. En théorie, l'aspect temporel est pris en compte sur une profondeur infinie. En pratique, l'influence du neurone s'atténue rapidement dans le temps car les informations mémorisées sur chaque neurone restent minimales. De ce fait, le réseau de neurones détecte difficilement les corrélations entre les entrées sorties dans le temps. La longueur des séquences pouvant être traitées par ce moyen reste donc faible [SCH88].




Figure 3.1: Exemple d'architecture de réseau comportant une boucle locale sur les neurones.

3.2.1.2. Les réseaux bouclés globalement

Dans l'approche utilisant une boucle globale sur les neurones (figure 3.2), la prise en compte de l'aspect temporel est réalisée au niveau du réseau. Une boucle globale lie un certain nombre de neurones du réseau à un sous-ensemble de la couche d'entrées. Ces cellules d'entrée rendent compte en fait l'état du réseau. Selon Sarzeaud [SAR95], la notion explicite d'état permet cette fois une prise en compte de l'aspect temporel sur une durée plus importante.




Figure 3.2: Exemple d'architecture de réseau comportant une boucle globale sur le réseau.

3.2.2. Les modèles d'Elman et de Jordan

Une attention particulière a été apportée aux réseaux dédiés aux traitements des séquences temporelles : il en résulte ce qui est appelé les réseaux temporels récurrents. Les signaux récurrents sont retardés et permettent ainsi la mémorisation et le rappel de l'état précédent. Ils peuvent détecter et stocker des corrélations entre des entrées successives dans le temps. Une attention particulière est allouée sur des réseaux qui portent le nom de Time Delay Recurrent Network (TDRN) du fait de leurs connexions retardées. Les deux types de réseaux les plus connus sont les réseaux de Jordan et les réseaux de Elman.

3.2.2.1. Le réseau de Jordan

C'est une classe simple de réseaux récurrents qui utilise un vecteur d'état qui contient les copies des activations de la couche de sortie du réseau à l'instant précédent (figure 3.3).




Figure 3.3: Exemple d'architecture d'un réseau de Jordan.

Cette architecture peut être comparée à un réseau de type feedforward dans lequel les sorties du réseau sont ramenées avec un retard afin de générer une séquence temporelle. Il s'agit donc d'une classe réduite de réseaux récurrents. Le principal désavantage de ce type de réseau réside dans le fait que l'état qui doit être retenu par le réseau doit se manifester dans le calcul des sorties du réseau. En d'autres termes, le vecteur d'état ramené à l'entrée est composé d'une ou plusieurs sorties du réseau. Il faut également savoir que l'apprentissage de ce type de réseau est assuré par un apprentissage supervisé.

3.2.2.2. Le réseau d'Elman

Ce type de réseau est basé sur la même architecture que le réseau de Jordan (figure 3.4) mais le modèle d'Elman utilise les copies des activations de la couche cachée à l'instant précédent pour le vecteur d'état.




Figure 3.4: Exemple d'architecture d'un réseau d'Elman.

Dans ces deux types de réseaux, le vecteur d'état permet au réseau de stocker des informations sur les entrées précédentes. C'est pourquoi, ils sont utilisés dans la prédiction de séries temporelles [MOR98]. Comparés au réseau de type feedforward qui travaille avec des fenêtres temporelles, ils ont l'avantage de tenir compte implicitement du contexte temporel. Pour l'apprentissage de son réseau, Elman a développé une version de la rétropropagation dans le temps en ne conservant que une ou deux copies d'échantillonnage. Grâce à ce moyen, il est possible de réaliser un apprentissage utilisant les algorithmes du gradient comme pour un réseau de type feedforward.

3.2.2.3. Les tours de Jordan et d'Elman

Par la suite, afin d'augmenter les performances de leurs réseaux, Elman et Jordan ont décidé d'intégrer plusieurs vecteurs d'états à l'intérieur de leurs réseaux : on parle alors de tour de Jordan et de tour d'Elman (figure 3.5)

L'idée est, en multipliant les vecteurs d'état, de stocker un maximum d'informations sur les états précédents. En effet, il s'avère qu'avec le même nombre de poids mais avec un nombre de vecteurs d'états plus grand, le réseau apprend plus vite [MOR98].




Figure 3.5: Tour de Jordan a) et tour d'Elman b).

Les réseaux de Jordan et Elman ont une récurrence restreinte (soit de la sortie de la couche cachée vers l'entrée, soit de la couche de sortie vers l'entrée) totalement déterminée par la structure. Le problème majeur de cette structure est qu'elle ne peut tenir compte des structures temporelles évolutives. En effet, les retards sont fixés dans l'architecture du réseau et la part des données réutilisées en entrée est fixée par le concepteur. Ceci peut être tout à fait convenable si il y a une connaissance a priori du problème à résoudre.

Les réseaux de Jordan utilisent un apprentissage supervisé et en considérant sa structure, les récurrences apparaissent sur la couche de sortie. Si ces sorties sont supervisées, la récurrence est orientée et nous obtenons en fait un réseau feedforward avec une entrée en plus qui est la sortie du réseau retardée. Ce réseau est classé dans les TDNN (Time Delay Neural Network). C'est ce type de réseau qui a été mis en œuvre pour le développement du modèle dynamique.

3.2.3. Méthode d'apprentissage

La principale difficulté de l'apprentissage des réseaux neuronaux récurrents par une méthode du gradient, du premier ou second ordre, provient de ce que l'influence de la valeur d'un poids sur la sortie du réseau, donc sur la fonction coût à minimiser durant l'apprentissage, n'est pas limitée à une étape de temps : elle se répercute sur toute une période. En toute rigueur, pour effectuer le calcul du gradient de la fonction coût, il faudrait, pour chaque instance de la base d'exemples et pour chaque étape d'apprentissage, effectuer le calcul sur tout l'horizon de prédiction, calculer la correction du réseau et recommencer. L'apprentissage des réseaux bouclés sans modification par rapport aux réseaux classiques serait donc une procédure très lourde, très gourmande en temps de calcul et en espace mémoire.

Dans notre cas où l'état du système à identifier est complètement connu par mesure à chaque instant, il n'y a pas en réalité de difficulté particulière : un algorithme dirigé peut être mis en œuvre. Lorsqu'un

apprentissage dirigé pour les réseaux extérieurement bouclés est utilisé, toutes les entrées du réseau sont connues pendant l'apprentissage, puisque ce sont les quantités qui sont mesurées sur le processus. Le modèle est alors calé à chaque instant sur les données expérimentales. L'apprentissage du réseau se résume donc à une régression non linéaire de la sortie du réseau sur son entrée.

Pour l'apprentissage, une trajectoire dans l'espace des états (ensemble de N couples entrée-état) est utilisée. Les états intermédiaires (temps t) sont utilisés à la fois comme sortie pour évaluer les performances du réseau calculant l'évolution du temps t-1 au temps t, et comme entrée pour calculer l'évolution du temps t au temps t+1. La pratique de cette méthode simple exige que l'entrée du réseau à chaque étape de temps soit connue.

3.2.3.1. Création du vecteur d'états

L'utilisation d'un réseau de Jordan nécessite la création d'un ou plusieurs vecteurs d'états pour prendre en compte l'aspect temporel du système. Pour cela, il est nécessaire de mémoriser les états antérieurs du réseau mais il est seulement possible de capturer des informations durant un temps limité. Il est possible de retenir plus d'états mais des problèmes de temps de calculs rendraient impossible la mise en œuvre.

L'alternative proposée pour réduire ces temps de calcul, tout en conservant un nombre d'états antérieurs suffisants, est de créer un réseau artificiellement bouclé. Cela permet de simuler un réseau feedforward durant l'apprentissage et, de plus, il sera possible d'utiliser la méthode traditionnelle de rétropropagation du gradient.

En résumé, la principale modification à apporter par rapport au modèle statique est la présentation des entrées au réseau. En effet, un vecteur d'entrée séparé en deux parties est utilisé. Une partie supérieure contenant les entrées externes et une partie inférieure contenant les données rebouclées.

Ces données rebouclées sont les sorties retardées. Le nombre de retard dépend de la précision souhaitée mais également du temps de calcul. Plus le nombre de retard sera grand, plus le temps de calcul augmentera. Il est possible de représenter le vecteur d'entrée suivant le schéma proposé par la figure 3.6.




Figure 3.6: Composition du vecteur d'état.

Ce rebouclage contient donc les sorties désirées retardées du réseau et la matrice d'entrée est établie comme suit :

$$\begin{pmatrix} X_1(0) & X_1(1) & X_1(2) & \cdots & \cdots & \cdots & X_1(t_{ech}-3) & X_1(t_{ech}-2) & X_1(t_{ech}-1) & X_1(t_{ech}) \\ X_2(0) & X_2(1) & X_2(2) & \cdots & \cdots & \cdots & X_2(t_{ech}-3) & X_2(t_{ech}-2) & X_2(t_{ech}-1) & X_2(t_{ech}) \\ X_3(0) & X_3(1) & X_3(2) & \cdots & \cdots & \cdots & X_3(t_{ech}-3) & X_3(t_{ech}-2) & X_3(t_{ech}-1) & X_3(t_{ech}) \\ X_4(0) & X_4(1) & X_4(2) & \cdots & \cdots & \cdots & X_4(t_{ech}-3) & X_4(t_{ech}-2) & X_4(t_{ech}-1) & X_4(t_{ech}) \\ X_5(0) & X_5(1) & X_5(2) & \cdots & \cdots & \cdots & X_5(t_{ech}-3) & X_5(t_{ech}-2) & X_5(t_{ech}-1) & X_5(t_{ech}) \\ 0 & Y_1(0) & Y_1(1) & Y_1(2) & \cdots & \cdots & \cdots & Y_1(t_{ech}-3) & Y_1(t_{ech}-2) & Y_1(t_{ech}-1) \\ 0 & 0 & Y_1(0) & Y_1(1) & Y_1(2) & \cdots & \cdots & \cdots & Y_1(t_{ech}-3) & Y_1(t_{ech}-2) \\ 0 & 0 & 0 & Y_1(0) & Y_1(1) & Y_1(2) & \cdots & \cdots & \cdots & Y_1(t_{ech}-3) \end{pmatrix}$$

X représentent les entrées du réseau, Y sont les sorties artificiellement rebouclées et t_{ech} représente les instants séparés d'un intervalle Δt .

Après avoir établi cette matrice d'entrée, il est alors possible de lancer l'apprentissage. Afin de mener à bien cette opération, il faut conserver en mémoire toutes les activations des neurones de sortie au cours du temps dans la phase de propagation avant, afin de pouvoir utiliser l'algorithme de rétro propagation du gradient dans la phase propagation arrière. Dans cette approche simple, nous opérons un dépliage temporel du réseau continu en un réseau échantillonné avec une valeur d'échantillonnage Δt fixe et la rétropropagation usuelle sur ce réseau discrétisé est appliquée. Cette procédure va permettre de tenir compte implicitement de l'espace temporel entre chaque point de mesures et de pouvoir utiliser la rétro propagation comme dans un réseau non bouclé.

Cependant cette mise en œuvre peut s'avérer compliquée dans le cas où le nombre d'échantillons présent en entrée du réseau est trop élevé.

3.2.3.2. Différences entre le bouclage artificiel et réel

Deux types de bouclages sont possibles pour l'apprentissage d'un réseau de Jordan. Le premier fait état d'un rebouclage des sorties désirées retardées (appelé ici bouclage artificiel). Le second reboucle les sorties réelles calculées par le réseau (bouclage réel).

Dans le cas d'un bouclage réel, plusieurs problèmes peuvent se poser lors des premières itérations de l'apprentissage. En effet, les sorties calculées par le réseau peuvent être très loin des valeurs désirées du fait de l'initialisation aléatoire des poids synaptiques. Comme ces sorties sont rebouclées en entrée pour créer le vecteur d'état, l'erreur de rétropropagation risque d'être trop importante entraînant ainsi une possible instabilité du réseau. De plus, si on retrouve dans le vecteur d'état des valeurs trop grandes (ou trop petites), il y a de fortes chances pour que l'apprentissage ne converge pas du fait de la saturation des neurones.

L'utilisation d'un bouclage artificiel simplifie en outre l'apprentissage car la mise à jour des paramètres du réseau se réalise en une étape grâce à l'utilisation du vecteur d'état qui comporte déjà les sorties retardées. Pour un bouclage réel, la mise à jour des paramètres se fait en effet après avoir calculé la sortie et réalimenté le vecteur d'état. En utilisant un bouclage artificiel, les temps de calculs sont considérablement réduits.

Par ailleurs, un apprentissage utilisant un bouclage artificiel permet également d'obtenir une approximation de la solution plus rapidement. Les sorties retardées utilisées pour alimenter le vecteur d'état étant connues à chaque pas de calcul, la sortie calculée se rapproche rapidement de la sortie

désirée. De ce fait, les problèmes cités précédemment sont atténués. Néanmoins, les capacités de généralisation à l'aide d'un tel apprentissage sont limitées car le réseau ne compense pas les erreurs de dérives. Pour faire face à ce problème, il est nécessaire de mettre en œuvre un apprentissage utilisant un bouclage réel.

Pour notre étude, nous avons décidé de réaliser l'apprentissage en deux étapes. La première étape consiste à réaliser un « apprentissage artificiel » qui va permettre au réseau de s'approcher rapidement de la solution recherchée.

Pour la deuxième étape, nous réalisons un apprentissage réel pour pallier les problèmes de dérives mais aussi pour rendre le réseau plus robuste face aux bruits de mesure [HER03b]. Cependant, pour limiter les temps de calcul, nous initialisons les paramètres du réseau aux valeurs calculées issues du premier apprentissage (artificiel).

La figure 3.7 représente les deux algorithmes mis en œuvre pour l'apprentissage.




Figure 3.7: Algorithmes d'apprentissage.

3.3. Modélisation dynamique d'une pile à combustible de 500W

La recherche d'un modèle dynamique de la pile à combustible de 500W à base de réseau de neurones nécessite tout d'abord la réalisation d'un certain nombre d'essais expérimentaux permettant de caractériser le fonctionnement de la pile en mode transitoire. Pour ce faire, plusieurs sollicitations en courant de la pile pour différents points de fonctionnement ont été réalisées. Les sollicitations sont de types sinusoïdales, créneaux et triangulaires.

Pour réaliser ces essais dynamiques, il a été nécessaire de coupler un Générateur Basse Fréquence sur la charge active. Il était alors possible de fixer le profil souhaité de la sollicitation en courant pour les différentes fréquences requises. De plus, les acquisitions du courant et de la tension de pile ont été réalisées à l'aide d'un oscilloscope numérique.

3.3.1. Résultats expérimentaux

Les essais expérimentaux en mode dynamique ont été réalisés sur une gamme de fréquence variable. Les essais ont été menés jusqu'à 1 kHz car au-delà de cette valeur, la réponse en tension de la pile à combustible reste quasi continue. La variation de tension en sortie de pile ne dépasse en effet pas 300 mV, ce qui est négligeable par rapport à la tension totale (moins de 2%) (figure 3.8)




Figure 3.8: Réponses en tension d'une sollicitation courant sinusoïdale pour différentes fréquences élevées.

Il est important de noter que pour tous les essais expérimentaux (figure 3.9 à figure 3.11) présentés dans ce paragraphe, les débits de gaz ont été fixés, moyennant les facteurs de stœchiométrie donnés, pour un courant égal à sa valeur moyenne (soit environ 10 A). De ce fait, la pile fonctionne soit en sur-stœchiométrie lorsque la sollicitation en courant est inférieure à 10 A, soit en sous-stœchiométrie lorsque la sollicitation est supérieure à cette valeur. Nous vérifions ce phénomène sur la figure 3.9

Chapitre III : Les réseaux de neurones pour la modélisation dynamique d'une pile de type PEM

pour une sollicitation en courant à basse fréquence ($f=1$ Hz). Lorsque le courant est inférieur à 10 A, la réponse en tension évolue de façon exponentielle jusqu'à atteindre une valeur proche de la tension à vide (environ 19V). Dans le cas contraire, pour un courant supérieur à 10 A, la réponse en tension chute rapidement, due au manque de gaz dans la pile.

Les essais présentés dans ce paragraphe permettent d'établir les différentes bases de données pour l'apprentissage, la validation et le test du modèle neuronal en mode dynamique. Elles ont été établies, comme pour le modèle statique, à différents points de fonctionnement.

Ainsi la température varie de 25°C à 50°C, l'hygrométrie de 50% à 100%, et les débits sont calculés avec des facteurs de stœchiométrie égaux à 2 côté anode et variant de 4 à 6 côté cathode.

3.3.1.1. Créneaux de courant

Les sollicitations de la pile à combustible par des créneaux de courant sont les plus simples à mettre en œuvre. En effet, il sera seulement nécessaire de disposer d'un interrupteur commandé pour réaliser les créneaux. La figure 3.9 représente les résultats obtenus pour différentes fréquences.




Figure 3.9: Réponses en tension d'une sollicitation courant créneau pour différentes fréquences.

Nous observons une variation de tension importante à basse fréquence ($\Delta V=5.4V$ à $f=1$ Hz) alors que pour des fréquences plus élevées, cette variation de tension s'atténue, le ΔV s'élève à $1.6V$ pour une fréquence de 50 Hz et seulement $1V$ pour une fréquence de $1kHz$.

Les essais en créneaux sont ceux qui peuvent engendrer la plus forte variation instantanée de courant. De ce fait, certains n'ont pas pu être réalisés. Les sollicitations en basse fréquence pour des températures faibles et des facteurs de stœchiométrie bas n'ont ainsi pas pu être menées à bien à cause des sécurités logicielles programmées sur le banc d'essai ; elles agissent pour toute chute de tension en deçà de 380 mV. En effet, à basse fréquence, certaines tensions de cellules de la pile, chutaient en dessous de la tension critique ($\approx 380mV$, voir [Annexe 1]) entraînant la coupure automatique de la sollicitation de courant et de la distribution des gaz.

3.3.1.2. Sinusoïdes de courant

Les mêmes essais ont été réalisés pour des sollicitations de courant sinusoïdales (Figure 3.10). Nous observons une réponse en tension de la pile particulière du fait qu'elle est aussi sinusoïdale. Les pentes de la sollicitation sont ici moins importantes, c'est pourquoi la chute de tension est plus faible lorsque la pile se trouve en sous-stœchiométrie. La variation de tension se trouve donc réduite par rapport aux sollicitations en courant de formes créneaux: $\Delta V=3.4V$ pour $f=1Hz$, $\Delta V=1.2V$ pour $f=100Hz$ et $\Delta V=0.8V$ pour $f=500Hz$.




Figure 3.10: Réponses en tension d'une sollicitation courant sinusoïdale pour différentes fréquences.

3.3.1.3. Sollicitation triangulaire

Les dernières sollicitations en courant réalisées, sont de forme triangulaire (figure 3.11). Les réponses en tension sont très semblables à celles obtenues pour une sollicitation sinusoïdale mais les variations de tension se trouvent encore diminuées ($\Delta V=1V$ pour $f=100Hz$ et $\Delta V=0.8V$ pour $f=1kHz$).




Figure 3.11: Réponses en tension d'une sollicitation courant triangulaire pour différentes fréquences.

3.3.2. Post-traitement des données expérimentales

Dans le précédent paragraphe, les différents types d'essais expérimentaux réalisés sur le banc d'essai 500 W nécessaires à l'établissement du modèle dynamique ont été décrits. Ils ont été réalisés pour différents modes de fonctionnement (températures, stoechiométries, hygrométries et fréquences variables) et les points de mesures ont été relevés à l'aide d'un oscilloscope numérique. Par ailleurs, il a été précisé dans le paragraphe 3.2.3.1 que pour établir un modèle dynamique et prendre en compte implicitement le temps, il est nécessaire d'avoir une période d'échantillonnage Δt identique pour chaque essai des bases d'apprentissage, de validation et de test.

Pour cela, il a donc été nécessaire de retraiter les données expérimentales en fixant le pas d'échantillonnage Δt à l'aide d'une méthode d'interpolation disponible sous le logiciel Matlab permettant de fixer le pas d'échantillonnage entre chaque point de mesure. Cette méthode permet de réaliser une interpolation non linéaire (cubique) en reliant les points expérimentaux par une courbe sous forme de portions de courbes polynomiales.

Cependant, il est malheureusement impossible de conserver cette même valeur d'échantillonnage pour tous les essais expérimentaux car les fréquences des signaux de courant varient de 0,1 Hz à 1 kHz. A titre d'illustration, pour un essai réalisé à une fréquence de 1 kHz, si nous prenons un échantillonnage égal à 25 μs sur une période, 41 points de mesures seront obtenus (figure 3.12). Pour cette même valeur d'échantillonnage à une fréquence de 0.2 Hz, obtenons 200 000 points sont obtenus, ... Il est évident qu'en conservant une même valeur d'échantillonnage pour toutes les fréquences, l'apprentissage du réseau serait délicat du fait d'une part du nombre trop important d'échantillons qui rendrait la convergence des algorithmes d'optimisation beaucoup trop longue et d'autre part, son corollaire, de la « dilution » des points expérimentaux significatifs à fréquence élevée.

Chapitre III : Les réseaux de neurones pour la modélisation dynamique d'une pile de type PEM

Pour remédier à ce problème, il est donc nécessaire d'avoir différentes valeurs de pas d'échantillonnages pour les différents essais réalisés. Ils ont été définis comme indiqués dans le tableau 3.1:




Figure 3.12: Echantillonnage de la tension mesurée.

Gammes de fréquence	Fréquence du signal	Période	Echantillonnage Δt	Nombre de points
Basses Fréquences 0 Hz < f ≤ 1.5 Hz	f = 0.2 Hz	T = 5 s	100 ms	51
	f = 1 Hz	T = 1 s	100 ms	11
Moyennes Fréquences 1.5 Hz < f ≤ 150 Hz	f = 10 Hz	T = 0.1 s	1 ms	101
	f = 100 Hz	T = 10 ms	1 ms	11
Hautes Fréquences 150 Hz < f	f = 500 Hz	T = 2 ms	25 μs	81
	f = 1 kHz	T = 1 ms	25 μs	41

Tableau 3.1: Echantillonnage des différentes données expérimentales.

Les gammes de fréquences ont été définies de manière à respecter le théorème de Shannon et de façon à avoir un nombre de points suffisants lors de la reconstitution du signal d'après le développement en séries de Fourier. De plus, les fréquences des signaux utilisés pour les différents apprentissages se trouvent pour chaque gamme de fréquences idéalement placées.

Nous pouvons également remarquer que pour certaines fréquences, le nombre d'échantillons à disposition pour l'apprentissage est relativement faible. Cette valeur résulte aussi d'un compromis entre le nombre de points nécessaires pour réaliser un apprentissage correct et la recherche d'un nombre de valeurs échantillonnées limité.

Le temps d'échantillonnage n'est donc pas la même pour chaque fréquence ; il est alors nécessaire d'établir trois gammes d'échantillonnage correspondant aux signaux basses fréquences, moyennes fréquences et hautes fréquences. Compte tenu de ces trois valeurs d'échantillonnage différentes et de la topologie retenue pour le réseau de neurones dynamique, il sera donc nécessaire d'avoir recours à

trois apprentissages distincts (un par valeur de pas d'échantillonnage et donc un par gamme de fréquences). Il en résultera donc trois apprentissages distincts pour le réseau de neurones dynamique auquel il faut bien entendu ajouter l'apprentissage réalisé par le réseau de neurones statique.

3.3.3. Architecture multi-modèle

La solution proposée consiste donc à établir un modèle comportant trois sous-réseaux artificiellement bouclés (figure 3.14). L'architecture utilisée pour chaque sous-réseau (figure 3.13) est identique, tout comme le nombre de couches cachées, le nombre de neurones sur chaque couche, les fonctions d'activations mais également les entrées, la sortie et le nombre de rebouclages présents.




Figure 3.13: Architecture (entrées sortie) d'un sous réseau.

Chaque sous-réseau possède une valeur fixe d'échantillonnage. De ce fait, les apprentissages pour les différentes fréquences peuvent se faire indépendamment via le sous-réseau adapté à la fréquence utilisée.




Figure 3.14: Modèle global composé de trois sous réseaux.

Chapitre III : Les réseaux de neurones pour la modélisation dynamique d'une pile de type PEM

Différentes études ont permis de constater que le rebouclage répété de la sortie tension du réseau vers l'entrée donnait une meilleure qualité de prédiction. Plusieurs retards ont ainsi été inclus dans le modèle afin d'améliorer sa qualité de prédiction.

L'apprentissage et la validation se font donc indépendamment alors que la séquence de test devra être réalisée sur le réseau global car l'information sur la fréquence du signal à prédire ne sera, a priori, pas connue. Une méthode de couplage des sous-réseaux pour la séquence de test sera présentée dans le paragraphe 3.3.4. Dans un premier temps, les résultats issus des différents apprentissages mis en œuvre sur les trois sous-réseaux sont exposés.

3.3.3.1. Résultats issus d'un apprentissage « créneaux »

Tous les essais utilisés pour ce premier apprentissage ont été faits pour une sollicitation de courant de forme créneaux avec des variations des facteurs de stœchiométrie (débits), de la température de fonctionnement et de l'hygrométrie de l'air.

La technique d'apprentissage est identique à celle mise en œuvre pour le modèle statique, à savoir la méthode du gradient et de quasi Newton avec un pas d'apprentissage variable couplée avec la méthode de validation croisée.

Les réponses en tension numériques obtenues pour une sollicitation créneau en basse fréquence sont satisfaisantes. Cependant, nous remarquons sur la figure 3.15 que la réponse calculée par le réseau de neurones est moins bonne à une température de fonctionnement de 35°C. En effet, le « niveau bas » de la tension n'est pas totalement atteint car la base de donnée utilisée pour l'apprentissage comporte peu d'exemples de sollicitation de courant de formes créneaux à basse température et à faible fréquence. Les raisons pour lesquelles ces essais étaient difficilement réalisables ont été données dans le paragraphe 3.3.1.1.




Figure 3.15: $U(t)$ mesurée et calculée par le réseau RNA1 et $I(t)$ « rectangulaire ».

Pour les fréquences plus élevées, les niveaux de tensions sont ici correctement respectés. Cependant, un certain nombre d'essai à une fréquence de 10Hz n'a pas pu être réalisé à basse température pour les raisons évoquées ci-dessus. C'est pourquoi, l'allure générale de la tension calculée par le réseau de neurones ne correspond pas parfaitement à la réponse mesurée sur le système. A 50Hz, ces problèmes ne se posent plus et l'erreur entre les points mesurés et calculés devient minime.




Figure 3.16: $U(t)$ mesurée et calculée par le réseau RNA2 et $I(t)$ « rectangulaire ».

La particularité des essais à haute fréquence est que la variation de tension est très faible ($\Delta V \leq 0.8V$). Le modèle dynamique correspondant aux hautes fréquences s'apparente à un modèle quasi statique. Les réponses calculées sont, de ce fait, de très bonnes qualités.




Figure 3.17: $U(t)$ mesurée et calculée par le réseau RNA3 et $I(t)$ « rectangulaire ».

Les sollicitations sinusoïdales présentent une variation de tension moins importante que les sollicitations de formes rectangulaires. En effet, pour une sollicitation rectangulaire, le niveau bas de la tension mesurée se trouvait à une valeur de 13,1V alors que la tension calculée était de 13,8V. Pour les mêmes conditions de fonctionnement (FSA=2, FSC=5, $T=35^{\circ}\text{C}$, $H=100\%$ et $f=1\text{Hz}$) mais avec une sollicitation sinusoïdale, le niveau bas de tension mesurée est de 13,8V. Nous retrouvons donc sur la figure 3.18, des réponses en tension calculées respectant l'allure générale mais aussi les niveaux de tension.




Figure 3.18: $U(t)$ mesurée et calculée par le réseau RNA1 et $I(t)$ « sinusoïdal ».




Figure 3.19: $U(t)$ mesurée et calculée par les réseaux RNA2, RNA3 et $I(t)$ « sinusoïdal ».

Les réponses en tension calculées par le réseau pour des sollicitations triangulaires (figure 3.20) sont d'aussi bonnes qualités que les réponses calculées pour des sollicitations sinusoïdales du fait de la similitude des essais expérimentaux.




Figure 3.20: $U(t)$ mesurée et calculée par les réseaux RNA2, RNA3 et $I(t)$ « triangulaire ».

Des apprentissages à partir de sollicitations sinusoïdales et triangulaires ont également été menées. Ces résultats ne sont pas ici présentés, mais le tableau 3.2 regroupe les erreurs de test obtenues sur les signaux en tension issus des différents apprentissages.

Chapitre III : Les réseaux de neurones pour la modélisation dynamique d'une pile de type PEM

	<i>Moyenne des erreurs maximum entre les points calculés et mesurés sur la séquence de test pour une sollicitation triangulaire</i>	<i>Moyenne des erreurs maximum entre les points calculés et mesurés sur la séquence de test pour une sollicitation sinusoïdale</i>	<i>Moyenne des erreurs maximum entre les points calculés et mesurés sur la séquence de test pour une sollicitation rectangulaire</i>
Apprentissage crêteaux en BF RNA1	3.41 %	2.28 %	3.11 %
Apprentissage crêteaux en MF RNA2	2.94 %	2.8 %	2.39 %
Apprentissage crêteaux en HF RNA3	2.09 %	1.63 %	1.6 %
Apprentissage sinusoïdal en BF RNA1	2.06 %	1.79 %	4.44 %
Apprentissage sinusoïdal en MF RNA2	1.65 %	2.44 %	2.79 %
Apprentissage sinusoïdal en HF RNA3	3.5 %	2.46 %	3.58 %
Apprentissage triangulaire en BF RNA1	2.17 %	4.15 %	4.8 %
Apprentissage triangulaire en MF RNA2	1.91 %	2.4 %	2.82 %
Apprentissage triangulaire en HF RNA3	1.82 %	2.06 %	4.8 %

Tableau 3.2: Moyenne des erreurs de test en fonction du type d'apprentissage.

Les différents apprentissages réalisés à partir de sollicitations de formes rectangulaires, sinusoïdales et triangulaires permettent de déterminer quelle sollicitation de courant est la mieux adaptée pour notre modèle. D'après le tableau 3.2, on remarque que les apprentissages issus de sollicitations rectangulaires fournissent les meilleurs prédictions sur les séquences de test ayant des formes de courant sinusoïdales, triangulaires et rectangulaires.

D'après les erreurs regroupées dans le tableau 3.2, il est donc possible de conclure sur la qualité de prédictions issues des différents apprentissages réalisés. Il est nécessaire de préciser que les apprentissages effectués dans cette partie sont des apprentissages artificiels, c'est-à-dire que le rebouclage de la sortie vers l'entrée est effectué artificiellement (voir paragraphe 3.2.3.2).

3.3.3.2. Comparaison entre un apprentissage artificiel et réel

Comme il a été précisé dans le paragraphe 3.2.3.2, il est nécessaire, pour les réseaux de neurones bouclés, d'effectuer deux apprentissages successifs. Le premier apprentissage, réalisé avec les sorties désirées rebouclées en entrée permet au réseau d'avoir une faculté de généralisation alors que le second permet au réseau d'être plus robuste face aux bruits de mesure.

Deux types d'apprentissages ont été effectués dans le cadre de cette étude. La figure 3.21a représente la prédiction obtenue sur une séquence de test avec un apprentissage artificiel alors que la figure 3.21b fournie la prédiction pour un apprentissage réel. Les figures 3.21a et b sont très similaires. La différence entre les deux erreurs reste minime puisque une différence maximale entre les points calculés et les points mesurés sur le premier relevé de 2.3 % est obtenue et pour le deuxième relevé, une erreur maximale de 1.9 % soit une différence de 0.4%. Nous pouvons donc conclure qu'il n'existe ici quasiment pas de différence entre les deux apprentissages, ce qui est en contradiction avec la théorie [HAY99]. Cependant, il n'est pas surprenant d'obtenir des résultats similaires du fait que nos

signaux mesurés sont très peu bruités. Or, l'apprentissage avec un rebouclage réel s'avère particulièrement efficace lorsque les signaux sont bruités. Il a donc été impossible de vérifier les avantages d'un apprentissage artificiel du fait que les mesures sont faiblement bruitées.




Figure 3.21: a) $U(t)$ calculée par le réseau RNA1 avec un bouclage artificiel, b) $U(t)$ calculée par le réseau RNA1 avec un bouclage réel.

Pour réaliser un apprentissage avec un bouclage artificiel, le temps de calcul nécessaire est de 3 heures sur un PC équipé d'un processeur AMD Athlon 1900. En considérant les mêmes bases d'apprentissage et de validation pour un apprentissage avec un bouclage réel, 78 heures de calculs sont nécessaires. La faible amélioration apportée par un apprentissage avec un rebouclage réel sur la qualité de prédiction nous amène à opter préférentiellement pour un apprentissage avec un rebouclage artificiel. De plus, un tel apprentissage nécessite alors 26 fois moins de temps de calcul.

3.3.3.3. Importance du choix des séquences d'apprentissage et de validation

Suite aux nombreux apprentissages réalisés pour caler ces différents modèles, quelques remarques sont à faire. Elles sont surtout valables pour la séquence de validation. Comme le précise Kalogirou dans [KAL01] nous avons aussi remarqué que le choix de la séquence de validation a une influence prépondérante sur la qualité de prédiction du réseau neuronal. La séquence de validation est utilisée durant l'apprentissage pour estimer la qualité de prédiction du réseau et elle permet également d'éviter le phénomène du sur apprentissage.

- Si cette séquence ne comprend pas assez d'exemples ou s'ils ne sont pas correctement distribués, l'erreur de validation va converger rapidement vers un minimum et le réseau utilisera les paramètres obtenus pour réaliser la prédiction. Il va de soi que la capacité de prédiction ne sera dès lors pas de bonne qualité.
- La séquence d'apprentissage comprend généralement les exemples extrêmes car les réseaux de neurones se comportent mieux pour l'interpolation. Pour avoir une séquence de validation efficace, il est donc nécessaire de choisir les exemples qui sont compris entre ces « extrêmes » de la séquence d'apprentissage sans que ceux-ci soient trop proches des exemples

Chapitre III : Les réseaux de neurones pour la modélisation dynamique d'une pile de type PEM

d'apprentissage. En effet, si les exemples « extrêmes » se trouvent dans un espace réduit, le domaine de validité du modèle se trouvera également réduit. D'autre part, il est bien nécessaire d'avoir les exemples de la séquence de validation « éloignés » de ceux de la séquence d'apprentissage pour ne pas tester le réseau sur des exemples qu'il a partiellement appris.

3.4. Modélisation dynamique d'une pile à combustible de 5 kW

Pour terminer l'étude sur la portabilité du modèle neuronal développé, il est nécessaire d'étudier dans un premier temps le comportement de la pile 5kW en mode dynamique. A partir de l'étude expérimentale terminée, il faudra réaliser de nouveaux apprentissages afin de tester le modèle neuronal. De la même manière que pour la pile 500W, plusieurs sollicitations en courant de la pile pour différents points de fonctionnement ont été effectuées.

3.4.1. Résultats expérimentaux

L'amplitude des sollicitations en courant de la pile 5kW est ici plus importante que celle demandée sur la pile 500W. Tous les essais utilisés pour caractériser le fonctionnement en mode dynamique de la pile 5kW ont été réalisés pour une sollicitation de courant d'une amplitude crête d'environ 100A. La gamme de fréquence utilisée reste identique à celle utilisée sur la pile 500W car les essais à plus hautes fréquences (figure 3.22) montrent une variation de tension maximale d'environ 2V (soit moins de 5% de la tension totale).




Figure 3.22: Réponses en tension d'une sollicitation en courant de la pile 5kW pour différentes fréquences élevées ($FSA=1.2$, $FSC=2.3$, $T=60^{\circ}C$ et $H=100\%$).

Pour cette caractérisation dynamique de la pile 5kW, la pile a été sollicitée suivant différents points de fonctionnement. Les variations concernent notamment la température de fonctionnement (de $30^{\circ}C$ à $60^{\circ}C$), les débits de gaz en entrée de pile (calculés avec des facteurs de stœchiométrie égaux à 1.2 côté

anode et variant de 2.1 à 2.5 côté cathode). L'hygrométrie relative de l'air est fixé à 100% et n'est pas variable car il est impossible de contrôler ce paramètre sur le banc d'essai (absence d'un hygromètre à miroir).

3.4.1.1. Créneaux de courant

Les valeurs crêtes des différentes sollicitations en courant sont, pour tous les essais menés sur la pile 5kW, environ égaux à 100 A. Les débits de gaz ont été fixés, moyennant les facteurs de stœchiométries donnés, pour un courant égal à 90 A. Contrairement aux essais menés sur la pile 500W, les gaz n'ont pas été fixés pour la valeur moyenne de la sollicitation et cela par commodités. La procédure de mise en route du banc d'essais 5kW est relativement longue. En fixant les gaz pour un courant de 90 A, nous évitons le déclenchement des sécurités sur les tensions de cellules (surtout pour les basses fréquences). De ce fait, la pile fonctionne en très légère sous stœchiométrie lorsque la sollicitation en courant est supérieure à 90 A.

Nous remarquons à basse fréquence (figure 3.23) que la réponse en tension est quasi rectangulaire. Ce phénomène est lié au fait que la puissance demandée (lorsqu'on passe de 0 à 100A) est directement disponible car les gaz sont fixés pour une sollicitation de courant égale à 90A. En moyenne et haute fréquences, les réponses s'apparentent à des formes exponentielles : dans ce cas, c'est la dynamique de la pile qui impose ses temps de réponses.




Figure 3.23: Réponses en tension d'une sollicitation courant créneau pour différentes fréquences

3.4.1.2. Sinusoïdes de courant

Les sollicitations en courant de forme sinusoïdale (figure 3.24) fournissent des réponses en tension avec des niveaux de tension quasi-identiques aux sollicitations de forme créneau mais l'allure des tensions est ici sinusoïdale. Les variations de tensions en basse fréquence sont de l'ordre de 12V ($f=0.5\text{Hz}$ et $f=1\text{Hz}$) et d'environ 4V pour les hautes fréquences ($f=200, 500$ et 1000Hz).




Figure 3.24: Réponses en tension d'une sollicitation courant sinusoïdale pour différentes fréquences

3.4.1.3. Sollicitation triangulaire

A nouveau, les réponses obtenues avec les sollicitations triangulaires sont très semblables à celles obtenues en sinusoïdale. Les valeurs des pentes des sollicitations triangulaires et sinusoïdales sont très proches ce qui explique l'obtention de réponses en tension similaires. Les variations de tension aux différentes fréquences étudiées sont également du même ordre de grandeur.




Figure 3.25: Réponses en tension d'une sollicitation courant triangulaire pour différentes fréquences

3.4.2. Utilisation du modèle

Suite aux différents essais expérimentaux réalisés sur le banc 5kW, il est à présent possible d'utiliser les trois sous réseaux dynamiques pour estimer leurs performances sur une autre pile. Pour cela, il est évidemment nécessaire d'effectuer de nouveaux apprentissages.

Les architectures ainsi que les méthodes d'apprentissages restent identiques à celles utilisées pour le modèle de la pile 500W. Le post-traitement des données expérimentales reste également inchangé. Seules les bases de données et la normalisation des valeurs des essais expérimentaux vont se différencier du modèle 500W (tableau 3.3).

<i>Paramètres</i>	<i>Plage de variation</i>	<i>Plage normalisée</i>
Courant I en A	[0 – 100]	[0 – 1]
Tension U en V	[0 – 42]	[0 – 1]
Débit H ₂ en NI/min	[0 – 45]	[0 – 1]
Débit O ₂ en NI/min	[0 – 200]	[0 – 1]
Température de fonctionnement en °C	[0 – 60]	[0 – 1]
Hygrométrie de l'air en %	[0 – 100]	[0 – 1]

Tableau 3.3: Liste des paramètres normalisés pour le modèle 5kW.

3.4.3. Résultats de simulations

Afin d'utiliser le modèle global pour la prédiction temporelle de signaux à fréquence variable, il est nécessaire d'effectuer dans un premier temps l'apprentissage de chaque sous réseau puis de les tester. Nous rappelons que les séquences d'apprentissage et de test de chaque sous réseaux se font indépendamment. Deux séquences d'apprentissage ont été réalisées : la première utilise les essais relevés pour une sollicitation de courant de forme créneaux et la seconde reprend les essais issus d'une sollicitation sinusoïdale. Les apprentissages issus de formes triangulaires n'ont pas été menés vu les résultats obtenus avec le modèle 500W. Cependant, chaque sous réseau est testé à l'aide des trois formes d'ondes. Les résultats présentés dans ce paragraphe permettent d'apprécier les paramètres obtenus à partir d'un apprentissage réalisé sur des sollicitations de courant de formes créneaux.

3.4.3.1. Tests sur des formes créneaux à basse fréquence

Les résultats obtenus sur des sollicitations de courant de forme créneaux en basse fréquence (figure 3.26) sont ici de meilleures qualités que ceux obtenus avec le modèle 500W. En effet, nous disposons dans la base d'apprentissage de la pile 5kW de nombreux essais relevés à basse fréquence mais également à faible température de fonctionnement alors que ce n'était pas le cas pour la pile de 500W. Nous rappelons que les essais expérimentaux relevés sur la pile 5kW ont été réalisés en fixant des débits de gaz pour une valeur du courant égale à 90A. Cependant, nous apercevons un léger décalage entre les points calculés par le réseau et les points mesurés lors du passage de 0 à 100A ou inversement ; les séquences d'apprentissage et de test sont réalisées sur des données qui ont été rééchantillonnées et interpolées (post-traitement des données expérimentales). Or les résultats numériques proposés (issus des données traitées) sont superposés aux résultats expérimentaux directement relevés sur le banc d'essai, ce qui explique ce décalage.




Figure 3.26: $U(t)$ mesurée et calculée par le réseau RNA1 et $I(t)$ « rectangulaire »

3.4.3.2. Test sur des formes créneaux à moyenne fréquence

Pour les fréquences moyennes, l'allure des réponses numériques correspond parfaitement aux tensions mesurées et les niveaux de tensions sont correctement respectés (figure 3.27).




Figure 3.27: $U(t)$ mesurée et calculée par le réseau RNA2 et $I(t)$ « rectangulaire »

3.4.3.3. Tests sur des formes créneaux à haute fréquence

A haute fréquence, les variations de tensions sont diminuées. Contrairement aux réponses obtenues avec la pile 500W, les réponses de la pile 5kW ne peuvent pas être considérées comme étant quasi-statiques. En effet, les variations relevées sur la pile 500W à haute fréquence restaient inférieures à 4% de la tension à vide alors que pour la pile de 5kW, les variations atteignent 12% de la tension à vide (pour $f=200\text{Hz}$).

Cependant, les résultats obtenus (figure 3.28) avec le sous réseau haute fréquence sont d'aussi bonnes qualités que ceux obtenus avec le modèle 500W. Pour ces gammes de fréquences, les allures et les niveaux de tensions sont également respectés.




Figure 3.28: $U(t)$ mesurée et calculée par le réseau RNA3 et $I(t)$ « rectangulaire »

La figure 3.29 illustre deux résultats issus de test sur une sollicitation de courant de forme sinusoïdale. Les paramètres utilisés sont toujours issus d'un apprentissage « créneaux ». Nous remarquons que les réponses numériques correspondent aux valeurs mesurées.




Figure 3.29: $U(t)$ mesurée et calculée par les réseaux RNA1, RNA2 et RNA3 et $I(t)$ « sinusoïdal »

Chapitre III : Les réseaux de neurones pour la modélisation dynamique d'une pile de type PEM

Le tableau 3.4 regroupe toutes les erreurs de test obtenues sur les signaux en tension issus des deux apprentissages réalisés.

	<i>Moyenne des erreurs maximum entre les points calculés et mesurés sur la séquence de test pour une sollicitation rectangulaire</i>	<i>Moyenne des erreurs maximum entre les points calculés et mesurés sur la séquence de test pour une sollicitation sinusoïdale</i>	<i>Moyenne des erreurs maximum entre les points calculés et mesurés sur la séquence de test pour une sollicitation triangulaire</i>
Apprentissage créneaux en BF RNA1	2.7 %	3.1 %	3.3 %
Apprentissage créneaux en MF RNA2	2.1 %	2.6 %	1.96 %
Apprentissage créneaux en HF RNA3	3.2 %	2.1 %	1.6 %
Apprentissage sinusoïdal en BF RNA1	3.1 %	1.8 %	2.4 %
Apprentissage sinusoïdal en MF RNA2	4 %	2.6 %	1 %
Apprentissage sinusoïdal en HF RNA3	2.9 %	3.2 %	2.7 %

Tableau 3.4: Moyenne des erreurs de test en fonction du type d'apprentissage

Les erreurs obtenues restent toutes inférieures à 4%, ce qui permet de conclure sur la qualité de prédiction de chaque sous réseau. De plus, les apprentissages issus d'essais obtenus à partir de sollicitations de courant de forme créneaux sont légèrement meilleurs que ceux obtenus avec des sollicitations sinusoïdales. Les paramètres issus de ces apprentissages seront donc utilisés pour le modèle global.

De la même manière que pour les apprentissages réalisés sur le modèle 500W, les résultats présentés dans ce paragraphe sont issus d'apprentissage à rebouclage artificiel. Le paragraphe suivant compare les résultats obtenus entre un apprentissage artificiel et un apprentissage réel.

3.4.4. Comparaison entre un apprentissage artificiel et réel

Pour le modèle 500W, nous n'avions pas retenu l'apprentissage réel du fait de ses temps de calcul conséquents mais également du faible apport de précision par rapport aux apprentissages artificiels. Cette étude a été de nouveau menée pour le modèle de la pile 5kW.

Les conclusions restent identiques à celles émises pour le modèle 500W. L'apprentissage artificiel fournit une prédiction conduisant à une erreur de 2.1% alors que l'apprentissage réel donne une erreur de 2% soit une différence de seulement 0.1%. Les ordres de grandeurs des temps de calcul sont quasi identiques à ceux du modèle 500W, soit environ 3 heures pour un apprentissage artificiel et 70 heures pour un apprentissage réel. La méthode d'apprentissage à rebouclage artificiel a donc été préférée à celle à rebouclage réel pour son gain en temps calcul.

3.5. Connexions des sous réseaux

Ce paragraphe est dédié à la finalisation du modèle neuronal dynamique. Le but final est de définir une unique boîte noire multi modèles. En effet, dans le paragraphe 3.3.3, trois sous réseaux permettant de traiter les signaux établis à différentes fréquences ont été développés. Il est donc nécessaire de connaître la fréquence de la sollicitation en courant. L'ajout d'un paramètre « fréquence » en entrée du réseau global est ici à exclure, car il y aurait alors nécessité d'une connaissance a priori de la sollicitation en courant appliquée au système. De plus, dans le cadre d'une application transport, la sollicitation en courant de la pile dépendra de la sollicitation du conducteur qui est totalement inconnue. Notons qu'il est nécessaire d'ajouter également un réseau correspondant au modèle statique à l'architecture du modèle multi réseaux (figure 3.14).

La méthodologie proposée pour résoudre ce problème repose sur l'analyse spectrale de la sollicitation en courant [JEM04]. Cette méthode va permettre de coupler relativement facilement et rapidement les trois sous-modèles dynamiques ainsi que le modèle statique. Notons que cette première étude est réalisée sur le modèle établi à partir de la pile 500W.

3.5.1. Méthodologie

Pour notre étude, nous utilisons la transformée de Fourier sur des signaux discrets dans la mesure où lors de l'acquisition sur le banc d'essai, les données que l'on enregistre sont des ensembles de valeurs à des instants périodiques dans le temps. Ce sont des valeurs représentant des signaux échantillonnés. Cette étude va permettre d'obtenir les informations nécessaires sur le domaine fréquentiel de la sollicitation en courant. En utilisant la transformée de Fourier, il sera donc possible de faire abstraction d'une entrée fréquence sur le modèle global proposé.

Si un signal $i(t)$ est considéré, le développement en série de Fourier est l'approximation de cette fonction par une somme de fonctions sinusoïdales (équation 3.1).

En appliquant le développement en série de Fourier sur $iT(t)$, il vient :

$$i(t) = \sum_{n=1}^{i_0+\infty} M_n \sin(n\omega t + \phi_n) \quad (3.1)$$
$$i(t) \approx i_0 + i_1(t) + i_2(t) + i_3(t) + \dots + i_n(t)$$

avec i_0 composante continue qui représente la moyenne de $iT(t)$ sur la fenêtre temporelle considérée, i_1 fondamentale, i_2 harmonique 2, ..., i_n harmonique n.

La méthode proposée pour réaliser le modèle global sans adjonction d'une entrée fréquence repose sur un prétraitement de la sollicitation en courant. Elle consiste dans un premier temps à faire une décomposition du signal d'entrée en série de Fourier afin d'obtenir les informations fréquentielles nécessaires. Grâce au spectre obtenu, on reconstitue les différentes sinusoïdes et il suffit ensuite d'orienter, en fonction de la fréquence, les échantillons vers les sous réseaux adaptés. Il est évidemment nécessaire de compléter ces échantillons avec les autres entrées du modèle (débits, températures et hygrométrie). Dès que toutes les entrées sont présentées au modèle global, il suffit de

Chapitre III : Les réseaux de neurones pour la modélisation dynamique d'une pile de type PEM

recupérer les tensions calculés par chaque sous réseaux et de les sommer de manière temporelle pour obtenir la tension totale.

L'algorithme représenté sur la figure 3.30 explicite la méthode.




Figure 3.30: Algorithme de la méthodologie adoptée.

Si cette méthodologie s'avère efficace, le modèle doit être utilisable pour n'importe quelle gamme de fréquence. Le modèle calé sur la pile à combustible de 500W pour une sollicitation en courant de type créneau à fréquence fixe est alors testé. Dans le paragraphe suivant toutes les procédures à suivre sont décrites.

3.5.2. Etude d'une sollicitation créneau à fréquence fixe

La figure 3.31 représente la forme du courant introduite comme entrée du modèle neuronal. Dans un premier temps, il est nécessaire de réaliser la décomposition de ce signal en série de Fourier (Figure 3.32). La figure 3.33 représente la phase nécessaire au développement (équation 3.1). Les harmoniques de fréquences vont du fondamental (10 Hz qui est la fréquence du signal) jusqu'à 170 Hz en supposant que les harmoniques de rang supérieur sont négligeables. Cela implique donc qu'il est nécessaire de solliciter trois des quatre sous modèles (modèles moyennes, hautes fréquences et modèle statique pour la composante moyenne).




Figure 3.31: Créneau de courant




Figure 3.32: Analyse spectrale




Figure 3.33: Représentation de la phase en fonction de la fréquence

La décomposition en série de Fourier permet de recomposer toutes les sinusoïdes correspondant à chaque harmonique de courant.

La dernière opération consiste à normaliser les sinusoïdes avant de les présenter aux différents sous réseaux. La normalisation est ici réalisée entre $[-1 ; 1]$ (référéncée sur la valeur maximale du courant) car les sinusoïdes présentent une partie négative.

Un point important est à souligner suite à cette normalisation. Physiquement, il est impossible qu'une pile à combustible génère un courant négatif et de plus, lors des apprentissages des sous réseaux neuronaux, aucun point négatif n'a été appris.

- La première solution proposée est d'émuler cette partie négative. Nous effectuons un pré traitement sur les sinusoïdes d'entrée pour obtenir un signal exclusivement positif. Il suffit pour cela d'ajouter aux parties négatives de la sinusoïde la moitié de l'amplitude crête de façon à ce que cette portion de courbe garde la même allure mais soit positive. Le réseau de neurones calcule ensuite la réponse en tension et un post traitement est nécessaire pour obtenir le résultat. Ce post traitement consiste à détecter les portions de courbes émuls et de leur soustraire la valeur ajoutée lors du pré traitement.
- La deuxième solution est basée sur l'extrapolation des réseaux de neurones. Ils sont souvent reconnus pour leur capacité d'interpolation. Néanmoins, de nombreux travaux [BRO01], [KIO03], [BOA92], [ERI02], [MOS00] montrent que les réseaux de neurones peuvent être efficaces aussi bien pour l'interpolation que pour l'extrapolation. Browne et Erickson expliquent dans leurs études qu'une base d'apprentissage comportant un nombre d'échantillons importants permet aux réseaux de neurones de déterminer des règles qui ne sont pas nécessairement définies dans la base d'apprentissage. Mostafa [MOS00], quant à lui, a défini un réseau de neurones multi-modèles capable d'extrapoler des valeurs non présentées dans les différentes bases d'apprentissages. Cependant, aucune explication mathématique n'est donnée quant aux capacités des réseaux de neurones à extrapoler.

Chapitre III : Les réseaux de neurones pour la modélisation dynamique d'une pile de type PEM

Les deux solutions ont été étudiées et les résultats sont fournis par les figures 3.34a et b. Ces résultats sont obtenus suite au post traitement des données effectuées sur les échantillons fournis par chaque sous réseaux.

- Les résultats obtenus par le biais de l'extrapolation sont fournis par la figure 3.34a. L'erreur maximale relevée entre les points mesurés sur le processus et calculés par le réseau s'élève à 2.96 %. Pour les résultats issus de l'émulation de la partie négative (Figure 3.34b), l'erreur obtenue est de 3.18%
- Les résultats obtenus par les deux méthodes sont ici très intéressants du fait que l'erreur maximale entre les points expérimentaux et calculés par le réseau reste de l'ordre de 3%. Pour conclure, les deux méthodes peuvent donc répondre à nos besoins.

Cependant, l'extrapolation est ici privilégiée car c'est la méthode qui est la plus directe et qui fournit de surcroît l'erreur la plus faible. De plus, l'utilisation de l'émulation entraîne un pré-traitement des entrées et un post-traitement des sorties calculées par le modèle supplémentaires. En revanche, une question reste ouverte quant à savoir si la capacité du réseau de neurones est due aux réseaux de neurones lui-même ou au système modélisé.




Figure 3.34: Tensions prédites par le modèle, extrapolation a) et émulation b).

3.6. Conclusion

La mise en œuvre d'un modèle boîte noire dynamique d'une pile à combustible par la méthode des réseaux de neurones a été décrite dans de ce chapitre.

Ce travail se révèle délicat dans la mesure où il existe un certain nombre d'architectures envisageable pour traiter ce genre de problème. Néanmoins, de nombreuses topologies ont été écartées dès le début de l'étude, comme les cartes auto organisatrices de Kohonen, les réseaux de Hopfield ou encore les réseaux ART (Adaptative Resonance Theorie) qui sont préférentiellement utilisés dans le domaine de la classification.

Dès lors que l'architecture du réseau de neurones a été arrêtée, il est nécessaire de déterminer les essais expérimentaux qui caractérisent, le mieux, la dynamique du processus étudié. Les essais que réalisés sur les deux bancs de test pile à combustible ont été faits de manière à se rapprocher des demandes en courant d'une chaîne de traction (profils de type triangulaires pour les montées progressives en puissance, profils créneaux pour les contraintes liées à l'électronique de puissance). De plus, différentes richesses de contenus harmoniques ont également été étudiées, de la sinusoïde pure au créneau.

La nécessité de réaliser un modèle multi réseaux est directement liée aux réseaux de neurones bouclés. La plage de variation des fréquences (de 0 à 1 kHz) utilisée pour les essais expérimentaux nous a en effet amené à choisir différentes périodes d'échantillonnage et par conséquent à établir différents réseaux pour chaque gamme de fréquence.

L'apprentissage des sous réseaux est la procédure la plus longue à mettre en œuvre du fait des temps de calculs importants. Une stratégie d'apprentissage en deux temps a ici été utilisée. Tout d'abord un rebouclage artificiel des sorties est effectué de manière à accélérer la convergence de l'apprentissage. Dans un deuxième temps et à partir des poids synaptiques issus du premier apprentissage, un deuxième apprentissage est lancé (avec rebouclage réel des sorties cette fois), de manière à augmenter la robustesse de l'apprentissage.

Ainsi, quatre sous réseaux de neurones décrivant le comportement du système pour chaque gamme de fréquence ont donc été obtenus. Il reste dès lors à coupler ces sous réseaux, tout en faisant abstraction d'une entrée fréquence supplémentaire, peu réaliste du fait qu'elle implique une connaissance a priori de la sollicitation en courant. Pour cela, une méthode permettant un prétraitement des données d'entrée à partir d'une décomposition en série de Fourier a été adoptée. La première étude sur un signal créneau à fréquence fixe a fourni de bons résultats de prédiction pour la tension de sortie estimée par le réseau global.

Cependant, il est nécessaire, dans le cadre de notre étude, de pouvoir prédire la tension délivrée par la pile à combustible en fonction d'un courant d'entrée à fréquence variable. Le chapitre IV est en partie consacré à cette étude.

**- CHAPITRE 4 -APPLICATION DU
MODELE AU TRANSPORT**

4.1. Introduction

Ce chapitre est consacré à l'étude du modèle établi pour des conditions d'utilisation dans les transports. Le modèle dynamique présenté dans le chapitre précédent prend en compte différentes sollicitations en courant de la pile à combustible pour des fréquences fixes. Il est évident que pour une application au transport, l'évolution du courant demandé par la chaîne de traction impliquera une variation en fréquence.

Pour répondre à cette problématique, nous avons étudié la réponse du générateur pile à combustible pour des sollicitations de courant à fréquences variables.

La méthode de couplage du modèle multi réseaux utilisant la transformée de Fourier est bien adaptée pour des signaux à fréquences fixes. Néanmoins, des modifications doivent être apportées à cette technique pour pouvoir prédire l'évolution de la tension face à des sollicitations à fréquences variables. La première partie de ce chapitre est destinée à présenter les modifications.

Une seconde partie plus prospective est consacrée à une étude de sensibilité paramétrique. Une telle étude doit nous permettre d'appréhender les relations de causalité mises en jeu dans le modèle. Ainsi, l'objectif poursuivi est :

- de comprendre les phénomènes mis en jeu
- d'aider à des choix technologiques et énergétiques
- d'explorer de nouveaux champs d'investigation qu'une approche expérimentale rendrait trop longue et coûteuse.

Le modèle validé devient donc un outil d'investigation. L'étude de sensibilité paramétrique consiste à reprendre la question : « Que seraient les résultats si au lieu de la valeur X, j'avais Y pour tel paramètre déterministe du modèle ? ».

4.2. Adaptation du modèle dynamiques aux contraintes transport

L'étude des comportements statiques et dynamiques du système est fondamentale car il faut tenir compte des contraintes des profils de missions transports urbain constitués de cycles de l'ordre de la seconde avec de grandes variations de demande de courants selon les différents profils. Cette partie est donc consacrée à l'adaptation du modèle aux contraintes transport.

4.2.1. Rappel

Suite à la méthodologie adoptée, pour faire abstraction d'une entrée en fréquence sur notre modèle, nous utilisons la transformée de Fourier sur les signaux d'entrée pour obtenir les informations nécessaires sur les domaines fréquentiels des signaux à étudier.

La transformée de Fourier rapide (FFT : Fast Fourier Transform) nous permet de décomposer tout signal en une somme unique de sinusoides ayant chacune des fréquences, amplitudes et phases différentes. La représentation temporelle de cette transformation n'est pas forcément explicite car on obtient un certain nombre de sinusoides ayant des amplitudes très faibles. La FFT permet donc de passer du domaine temporel au domaine fréquentiel en gardant toutes les informations nécessaires. Il est évidemment possible de reconstruire le signal initial à partir de ses composantes (équation 3.1).

4.2.2. Principe

Dans ce paragraphe, les problèmes rencontrés sont listés et différentes solutions sont proposées. Afin de comprendre les phénomènes provoqués par la FFT, nous allons traiter un signal de base (figure 4.1a) pour un temps d'observation de 0.5 s. Lorsque nous réalisons la FFT de ce signal et que nous traçons son spectre (figure 4.1b), nous obtenons naturellement une raie d'amplitude maximale correspondant au fondamental (fréquence du premier harmonique, ici 10 Hz).




Figure 4.1: a) Signal sinusoïdal de fréquence $f = 10$ Hz, b) représentation fréquentielle du sinus

A présent, retraçons une sinusoïde mais à une fréquence de 15 Hz (figure 4.2a) sur le même temps d'observation, le spectre associé est représenté sur la figure 4.4. La forme du spectre est totalement différente et la fréquence de la raie principale n'est pas aussi nette. De plus, quelques sous harmoniques d'amplitudes non négligeables sont présents sur le spectre représenté sur la figure 4.2b.




Figure 4.2: a) Signal sinusoïdal de fréquence $f = 15$ Hz, b) représentation fréquentielle du sinus

L'explication de ce phénomène est relativement simple si nous prêtons attention aux deux signaux de bases. Sur le premier ($f=10$ Hz), le dernier point (à $t = 0.5$ s) est considéré comme étant le prédécesseur du premier (à $t = 0$ s). C'est-à-dire que sur le temps d'observation (temps sur lequel la FFT du signal est calculée), il n'y a pas de discontinuité. Sur la figure 4.2a, nous voyons clairement que le point à $t = 0.5$ s de droite ne se raccorde pas au point de départ, une discontinuité est donc introduite sur le temps d'observation.

On comprend clairement qu'avec un changement de fréquence sur un temps d'étude identique, on crée alors une discontinuité due au nombre non entier de périodes considéré dans le deuxième cas. En situation pratique, lorsque le spectre d'un signal dont on ne connaît pas la fréquence est étudié, il y a très peu de chance d'échantillonner sur un temps qui comprenne un nombre entier de périodes.

4.2.3. Les fenêtres de pondération

Que ce soit dans le domaine temporel ou dans le domaine fréquentiel, une fonction fenêtre est créée à chaque fois qu'il y a limitation volontaire ou non de la durée d'observation, d'enregistrement ou d'utilisation d'un signal. Cette opération s'appelle encore apodisation ou fenêtrage [FUR04]. En effet, en numérique, il n'est pas possible d'effectuer des opérations sur un nombre infini de points. Il est alors nécessaire de « tronquer » la durée du temps d'observation. Cette connaissance limitée du signal équivaut à le multiplier par une fonction fenêtre rectangulaire, ce qui en fréquence se traduit par une convolution entre le spectre du signal à analyser et celui de la fenêtre. Dans la majorité des cas, cette fenêtre rectangulaire est trop brutale et on lui préfère d'autres fenêtres plus douces, aux conséquences fréquentielles moins désastreuses.

Nous avons remarqué sur l'exemple précédent que le problème se situait aux extrémités du signal à étudier. Le rôle des fenêtres de pondération est aussi de faire tendre ces valeurs extrêmes vers une valeur fixe puis d'appliquer la FFT sur l'ensemble des données ainsi modifiées. Il existe différentes fenêtres de pondération dont les gabarits sont représentés sur la figure 4.3 :




Figure 4.3: Les fonctions fenêtre dans leur aspect temporel

Chacune de ces fenêtres présente un certain nombre de particularités, celles-ci sont regroupées dans le tableau 4.1. Notons que la fenêtre de pondération utilisée avant le calcul d'une transformée de Fourier doit répondre à deux critères opposés : elle doit suffisamment déformer le signal pour le rendre périodique, mais elle doit aussi le laisser passer intégralement pour le respecter.

Notre choix se porte sur la fenêtre de Hamming car c'est la fonction qui fournit la meilleure résolution fréquentielle tout en gardant une résolution en amplitude cohérente. Le tableau 4.1 donne la description des différentes fenêtres de pondération le plus fréquemment utilisées.

<i>Fenêtre</i>	<i>Caractéristiques</i>	<i>Utilisation</i>
Rectangulaire	Tout le signal doit entrer dans le bloc temporel. Le signal n'est pas déformé	A n'utiliser que dans le cas où le signal peut être inclus en totalité dans la mémoire de calcul, c'est-à-dire pour des signaux très courts qui partent de 0 pour se terminer à 0, comme par exemple les signaux impulsionnels.
Hanning	La plus utilisée en analyse de Fourier car elle optimise le mieux le compromis résolution fréquentielle/résolution en amplitude	A utiliser pour l'analyse des signaux pseudo-stationnaires (bruit d'une machine par exemple).
Hamming	Meilleure résolution fréquentielle que Hanning, mais moindre résolution en amplitude.	A conseiller quand on recherche la fréquence exacte.
Bartlett	Meilleure résolution en amplitude aux dépens d'une résolution fréquentielle qui est moins bonne	A conseiller pour la recherche de l'amplitude exacte.

Tableau 4.1: Caractéristiques et utilisation des fenêtres de pondération

De plus et comme il sera précisé par la suite, ce choix est parfaitement justifié au vu des résultats de simulation obtenus grâce à notre modèle. En effet, si les résultats sont relativement satisfaisants, quel que soit le fenêtrage retenu, ils s'avèrent meilleurs grâce à une fenêtre de Hamming.

Nous reprenons à présent l'exemple traité dans le paragraphe 4.2.2 pour établir une comparaison entre le fenêtrage rectangulaire et le fenêtrage de Hamming. D'après le gabarit de la fenêtre de Hamming (figure 4.3) proposé, si l'ensemble des points du signal à étudier est multiplié par cette fonction, les points se trouvant aux extrémités vont être ramenés à une valeur très faible et le phénomène de discontinuité tendra à disparaître. La multiplication du signal sinusoïdal de 15 Hz par le gabarit de la fenêtre de Hamming fournit le résultat illustré par la figure 4.4. Le spectre aura alors la forme représentée sur la figure 4.5 :




Figure 4.4: Signal sinusoïdal de 15 Hz fenêtré.




Figure 4.5: Spectre du signal fenêtré.

Le spectre obtenu à l'aide du fenêtrage de Hamming est bien moins bruité que celui obtenu avec un fenêtrage rectangulaire (figure 4.2b) et la fréquence du fondamental est ici bien distincte à 15 Hz. Pour la suite de nos travaux, ce type de fenêtrage sera utilisé.

Cependant, pour notre étude, la fenêtre de Hamming ne sera pas considérée dans son intégralité, seule une moitié du gabarit sera prise en compte (figure 4.6).




Figure 4.6: Gabarit de Hamming utilisé pour notre étude

Ce choix a pour but de donner plus d'importance aux derniers échantillons utilisés dans la fenêtre glissante et par conséquent moins d'importance aux premiers points. Comme le modèle va être utilisé en tant que prédicteur à court terme, il est préférable que les échantillons précédents la prédiction soient considérés dans leur intégralité.

4.2.4. Application et perfectionnement de la méthodologie de fenêtrage sur le modèle de pile 500W

Dans ce paragraphe, nous décrivons dans un premier temps les essais expérimentaux réalisés sur le banc d'essai 500W qui vont permettre de valider la méthodologie proposée dans le chapitre 3. Dans un second temps, les résultats obtenus à l'aide du modèle pour des sollicitations de courant de formes trapézoïdales à fréquence variable sont présentés. Les différentes étapes permettant d'obtenir des résultats satisfaisants pour notre étude dans ce dernier cas de figure sont également décrites.

4.2.4.1. Essais expérimentaux

Les essais menés sur le banc d'essai 500W ont été effectués à différents points de fonctionnement (température de fonctionnement, hygrométrie relative de l'air, stœchiométries variables et fréquence du courant variable). Les sollicitations en courant de la pile sont ici de formes trapézoïdales.

Les conditions de test sur les essais présentés sont les suivantes :

- Les débits de gaz d'hydrogène et d'air sont constants. Ils ont été établis pour une valeur de courant égale à 10 ampères sur toute la durée des essais moyennant les facteurs de stœchiométries.
- La plage de variation de fréquence s'étend de 0,1 Hz à 1 kHz.

- L'amplitude maximale des sollicitations est de 20 A.

La figure 4.7 représente quelques essais expérimentaux. Nous remarquons que les réponses en tension obtenues sont de formes sinusoïdales lorsque la fréquence du courant est environ supérieure à 5 Hz. En deçà de cette fréquence, nous relevons des formes d'ondes constituées de portions exponentielles.




Figure 4.7: Signaux trapézoïdaux à fréquence variable.

4.2.4.2. Résultats de simulations obtenus à l'aide du modèle 500W

Les résultats présentés dans ce paragraphe ont été obtenus en utilisant un fenêtrage de Hamming pour la décomposition en série de Fourier. Afin de limiter les temps de calcul, il est nécessaire de réaliser un fenêtrage évolutif qui consiste à faire glisser la fenêtre de pondération sur le signal à étudier. Néanmoins, deux contraintes sont à clarifier ; la première consiste à définir une taille de fenêtre convenable pour calculer la FFT sur au moins une période du signal ; la seconde est de définir la valeur des amplitudes à prendre en compte pour la recombinaison du signal. Un compromis suivant les temps de calcul et la précision des résultats obtenus doit être trouvé.

- **Calibration du fenêtrage de Hamming**

Pour répondre à la première contrainte, nous avons asservi la taille de la fenêtre glissante à la fréquence du fondamental calculée sur la fenêtre glissante à l'instant d'échantillonnage précédent. Néanmoins, nous ne pouvons pas obtenir un nombre entier de périodes sur toute l'évolution temporelle du signal étudié, en particulier, lorsque la valeur de la fréquence du fondamental change. Cependant, les résultats restent satisfaisants lorsque la fréquence de la sollicitation de courant ne varie pas brusquement. La figure 4.8a illustre les résultats obtenus.

Sur cette figure la réponse en tension calculée par le modèle et la réponse en tension obtenue expérimentalement sont parfaitement superposées. L'erreur maximale entre les points calculés et mesurés est ici de 2.5 %. Ce résultat a été obtenu avec une amplitude des harmoniques supérieure à 0.1A et une largeur de fenêtre de pondération comprenant 100 échantillons ($N_e = 100$) sur toute l'évolution temporelle du signal.




Figure 4.8: a) Réponses expérimentale et numérique en tension d'une sollicitation courant trapézoïdale à fréquence variable (fenêtrage de Hamming), b) zoom.

En ce qui concerne les amplitudes des harmoniques à prendre en compte pour la transformée de Fourier, une étude itérative en relevant les temps de calcul, les précisions et les Erreurs Quadratiques Moyennes sur la séquence de Test (EQMT) obtenus pour différentes amplitudes a été réalisée. Les résultats obtenus sont regroupés dans le tableau 4.2.

Amplitude des harmoniques pris en compte (A)	Erreur maximale relevée entre les points mesurés et les points calculés	EQMT (V ²)	Temps de calcul
> 1	3.9 %	5.5	12 s
> 0.9	3.6 %	5.3	13 s
> 0.8	3.6 %	5	14 s
> 0.7	3.5 %	4.6	17 s
> 0.6	3.4 %	4.4	20 s
> 0.5	3.2 %	3.9	27 s
> 0.4	3.1 %	3.4	40 s
> 0.3	3 %	2.9	51 s
> 0.2	2.5 %	2.6	1 min 47 s
> 0.1	2.5 %	2.3	4 min 32 s
> 0	2.4 %	2.2	8 min 30 s

Tableau 4.2: Erreurs et temps de calcul relevés en fonction de l'amplitude des harmoniques prise en compte (PAC 500W)

Il est évident que si tous les harmoniques (> 0 A) sont considérés pour la méthodologie, la précision du résultat obtenue sera meilleure. Dans le tableau 4.2, l'erreur maximale relevée entre les points mesurés et les points calculés par le modèle ne varie cependant que très peu pour des amplitudes inférieures à 0.2 A. De plus, les temps de calculs sont bien plus importants, ils passent ainsi de 1 min 50s pour une amplitude de 0.2 A à 8 min 30s pour une amplitude de 0 A. La précision a quant à elle

légèrement diminuée passant de 2.5 % à 2.4 %. Une erreur de 3.9 % (figure 4.9a), relevée pour une amplitude supérieure à 1 A pourrait être acceptable et serait préférable vu le temps de calcul nécessaire dans ces conditions mais notre choix privilégie ici la précision au temps de calcul. C'est pourquoi, l'étude sera poursuivie en ne prenant en compte que les harmoniques ayant une amplitude supérieure à 0.2 A (figure 4.9b).




Figure 4.9: Comparaison de l'évolution temporelle de la tension pour deux amplitudes différentes a) $> 1A$ et b) $> 0.2A$.

- **Utilisation du modèle en prédiction**

La méthode adoptée permet d'obtenir des résultats satisfaisants tant au point de vue de la précision qu'en temps de calcul. Cependant, dans l'optique de l'intégration d'une loi de commande à base de modèle, il pourrait être intéressant d'utiliser ce modèle comme prédicteur à court terme.

Nous avons donc réalisé une étude afin de voir le comportement du modèle lorsqu'il est utilisé dans cette condition. Pour cela, nous retenons la même méthodologie que celle adoptée jusqu'à présent, à la différence près que nous allons prédire la tension à l'instant $t(Ne+1)$ sans connaître a priori la valeur du courant à cet instant. Lors de la reconstitution de la sollicitation du courant à l'aide de la transformée de Fourier, on définit simplement les sinusoides jusqu'à l'instant $Ne+1$ alors que la transformée de Fourier n'utilise que les Ne échantillons précédents. L'évolution temporelle en tension résultante sera alors composée de chaque point calculé aux différents instants d'échantillonnage et pour l'instant $Ne+1$.

Les résultats obtenus sont présentés sur la figure 4.10. L'utilisation du modèle en tant que prédicteur à court terme se révèle efficace en vue de l'évolution temporelle de la tension calculée. L'erreur maximale relevée entre les points calculés et les points expérimentaux s'élève à 2.7%.




Figure 4.10: Réponses expérimentale et numérique en tension d'une sollicitation courant trapézoïdale à fréquence variable (fenêtrage de Hamming), prédiction à $t+1$.

- **Initialisation de la fenêtre temporelle**

Suite à cette étude, nous restons confrontés à un problème d'initialisation de la fenêtre temporelle glissante. En effet, pour les résultats présentés précédemment, l'évolution temporelle du courant durant les itérations précédant le premier point calculé était considérée comme étant connue. Or, pour une prédiction, cette évolution est a priori inconnue. Nous avons donc choisi de fixer les premiers points de la fenêtre temporelle glissante à la même valeur que le premier point prédit soit la valeur du courant obtenue à l'instant $t(Ne+1)$. Avec un courant ainsi initialisé, il est évident que la prédiction de la tension sera perturbée durant les premières itérations. La sollicitation présente ici une valeur continue d'environ 1.7 A, de ce fait, seul le sous réseau statique va être sollicité. Sur la figure 4.11a, l'évolution temporelle de la tension calculée et le niveau de tension calculé durant les premières itérations est bien de l'ordre de 18 V (proche de la tension à vide, $U_0 = 19.4$ V).




Figure 4.11: Evolution temporelle de la tension avec initialisation du fenêtrage

La figure 4.11b est un grossissement des premières itérations de calcul. L'évolution de la tension calculée rejoint celle de la tension mesurée au bout d'environ 45 ms. Au cours de ces 45 premières

itérations, l'erreur maximale entre les points calculés et mesurés est de 9.6%, puis on retrouve le même ordre de grandeur d'erreur que celui relevé lors de la simulation sans l'initialisation de la fenêtre soit 2.5%. En effectuant cette opération, nous répondons aux conditions réelles d'utilisation du modèle sans altérer de manière trop importante son fonctionnement.

- **Bilan**

Le modèle établi permet donc de prédire correctement l'évolution temporelle de la tension de pile en fonction d'une sollicitation de courant de forme trapézoïdale à fréquence variable. De plus, le choix d'un fenêtrage de Hamming est une solution adaptée à nos besoins. A titre d'illustration, une simulation utilisant un fenêtrage rectangulaire a été réalisé (figure 4.12a). L'évolution temporelle en tension calculée est ici très médiocre au vue de son allure générale mais également au niveau de l'erreur maximale relevée qui est de 7.2 %. L'utilisation des fenêtres de Hanning (figure 4.12b) et de Bartlett (figure 4.12c) fournit des résultats plus satisfaisants mais le fenêtrage de Hamming est celui qui donne les meilleurs résultats. En effet, l'erreur maximale relevée pour l'utilisation de la fenêtre de Hanning est de 3.3% et pour la fenêtre de Bartlett, l'erreur s'élève à 3.6% alors que pour le fenêtrage de Hamming cette même erreur est de 2.5%. Cette comparaison justifie bien le choix d'un fenêtrage de Hamming pour notre étude.




Figure 4.12: Evolution temporelle de la tension calculée par le modèle à l'aide d'un fenêtrage a) rectangulaire, b) de Bartlett et c) de Hanning.

4.3. Portage de la méthodologie sur le modèle 5kW

Cette partie va nous permettre de terminer l'étude de portabilité du modèle. Nous avons vu dans les chapitres précédents (2 et 3) que le modèle établi sur le fonctionnement de la pile 500W pouvait être adapté à une pile de puissance plus importante en recalant le modèle avec des apprentissages issus d'essais expérimentaux réalisés sur la pile en question. Les résultats obtenus à l'aide du modèle en mode statique et dynamique sur la pile 5 kW sont cohérents avec ceux obtenus pour la pile de 500W. La dernière étape de cette étude de portabilité est donc de vérifier si le modèle est capable de prédire l'évolution temporelle en tension de la pile 5 kW pour des sollicitations de courant à fréquence variable. Il est important de préciser que toute la méthodologie du modèle 500W est portée sur le modèle 5kW.

4.3.1. Essais expérimentaux

Les essais expérimentaux menés sur la pile 5 kW s'apparentent forcément à ceux réalisés sur la pile de 500W. Cependant, les sollicitations de courant ont ici des amplitudes supérieures. Compte tenu de la puissance, les sollicitations ont ici des amplitudes environ égales à 70 A. Comme pour l'étude sur la pile 500W, ces essais ont été relevés à différents points de fonctionnement (température de fonctionnement, stœchiométries variables et fréquences variables).

Les mesures courant/tension ont été relevées à l'aide d'une chaîne d'acquisition rapide Labview® sur laquelle seule les deux voies courant/tension étaient câblées.

Les conditions de test sur les essais présentés sont les suivantes :

- Les débits de gaz d'hydrogène et d'air sont constants. Ils ont été établis pour une valeur de courant égale à 60 ampères sur toute la durée des essais moyennant les facteurs de stœchiométries.
- La plage de variation de fréquence s'étend de 0,1 Hz à 1 kHz.
- L'amplitude maximale des sollicitations est de 70 A.
- L'hygrométrie relative de l'air entrant est fixée à 100%

Pour réaliser les sollicitations de forme trapézoïdale, un générateur basse fréquence (GBF) et un circuit électronique sont nécessaires. Le GBF qui délivre un signal de forme triangulaire est couplé à un circuit électronique (basé sur une fonction d'écêtage) permettant de fournir des signaux de forme trapézoïdale. Ce signal est ensuite envoyé en consigne externe sur la charge active de la pile à combustible. Cependant, la régulation de la charge fournit des bruits de mesure sur les basses fréquences. C'est pourquoi des pics de courant sont présents sur les essais expérimentaux présentés sur la figure 4.13b (zoom de la figure 4.13a).

Les figures 4.13a et 4.14 représentent deux essais expérimentaux. Les réponses en tension obtenues sont de formes sinusoïdales lorsque la fréquence du courant est environ supérieure à 100 Hz. En deçà de cette fréquence, nous relevons des formes d'ondes quasi exponentielles.




Figure 4.13: Réponses en tension d'une sollicitation de forme trapézoïdale à fréquence variable




Figure 4.14: Réponses en tension d'une sollicitation de forme trapézoïdale pour des moyennes fréquences

4.3.2. Simulations à l'aide du modèle 5kW

Les simulations réalisées à l'aide du modèle 5 kW ont été effectuées dans les mêmes conditions que celles présentées avec le modèle 500W. De la même manière, une fenêtre de pondération de type Hamming et un asservissement de la taille de cette fenêtre sur le fondamental du signal à étudier ont été nécessaires pour la prédiction de l'évolution temporelle de la tension de pile. L'utilisation du modèle pour la pile 5kW reste identique à celle présentée pour le modèle 500W. Cependant, les amplitudes de courant sont différentes entre les deux piles, une nouvelle étude a donc été menée sur la valeur des amplitudes des harmoniques à prendre en compte pour l'utilisation de la transformée de Fourier.

Le tableau 4.3 regroupe les temps de calcul, les précisions et les Erreurs Quadratiques Moyennes sur la séquence de Test obtenus pour différentes amplitudes.

Chapitre IV : Application transport du modèle

Amplitude des harmoniques pris en compte (A)	Erreur maximale relevées entre les points mesurés et les points calculés	EQMT (V²)	Temps de calcul
> 10	7 %	20	10 s
> 7	5.7 %	14	13 s
> 5	5.7 %	10.8	17 s
> 2	5.7 %	5.6	31 s
> 1	5.7 %	4	1 min 43 s
> 0.5	5 %	3.6	2 min 13 s
> 0.2	4.7 %	3.5	2 min 35 s
> 0	4.6 %	3.3	3 min 34 s

Tableau 4.3: Erreurs et temps de calcul relevés en fonction de l'amplitude des harmoniques pris en compte (5kW)

Ces résultats (tableau 4.3) montrent l'importance de quantifier l'EQMT. En effet, les erreurs maximales entre les points calculés et les points mesurés sont égales à 5.7 % pour une prise en compte des amplitudes comprises entre 1 A et 7 A. De plus, les temps de calcul dans ces conditions sont faibles (< 30s). Cependant, l'EQMT est trop importante et les évolutions obtenues pour la prédiction sont médiocres (figure 4.15) :




Figure 4.15: Résultats obtenus pour une amplitude supérieure à 7 A

Afin de garder les mêmes conditions de simulations que celles utilisées pour le modèle 500W, le choix de l'amplitude des harmoniques à prendre en compte se sont portées sur 0.2 A. Les temps de calcul sont plus importants mais les erreurs maximales entre les points relevés et les points mesurés ainsi que l'EQMT permettent de réaliser un bon compromis précision/temps de calcul (figure 4.16).

Les erreurs présentées dans le tableau 4.3 restent plus importantes que celles obtenues avec le modèle 500W. Ces erreurs ont été relevées sur des signaux à faible fréquence (trapèzes déformés). Dans ces conditions, les résultats de la figure 4.16 présentent une erreur maximale entre les points calculés et mesurés de 4.7 % alors que sur la figure 4.17, cette erreur est de 2.9 %. Elle est ici moins importante car les signaux utilisés ne présentent pas de déformations particulières.

Enfin pour terminer cette étude, la figure 4.18 représente la prédiction à court terme ($t+1$) de l'évolution temporelle de la tension. L'utilisation du modèle en tant que prédicteur à court terme reste

ici satisfaisante car l'erreur maximale obtenue entre les points mesurés et calculés par le réseau est inférieure à 4.8 %.




Figure 4.16: Evolution temporelle de la tension calculée par le modèle




Figure 4.17: Evolution temporelle de la tension calculée par le modèle pour des moyennes fréquences




Figure 4.18: Evolution temporelle de la tension calculée par le modèle, prédiction à $t+1$

4.4. Etude de sensibilité paramétrique

L'étude de sensibilité paramétrique doit fournir les informations sur les paramètres d'entrée qui ont le plus d'influence sur la sortie du modèle. Pour réaliser cette étude, plusieurs possibilités sont envisageables. Ici, deux solutions sont proposées sur les modèles statiques et dynamiques des piles 500 W et 5 kW. Dans un premier temps, l'approche statique est développée puis dans une seconde partie, les résultats de l'approche dynamique sont fournis. Les discussions quant à l'étude de sensibilité paramétrique seront établies dans la conclusion de ce chapitre.

4.4.1. Etude du modèle statique

Cette étude est réalisée autour d'un point de fonctionnement, établi en fonction des résultats expérimentaux obtenus sur les deux piles étudiées. Chaque paramètre d'entrée du modèle varie sur une plage définie autour du point de fonctionnement choisi. L'influence de la variation des différentes entrées est quantifiée en fonction de la variation de tension obtenue pour la sortie du modèle. Plusieurs points de fonctionnement ont été définis pour chaque pile en fonction du courant fourni par la pile. Cela permet de voir l'influence des paramètres pour différentes conditions de sollicitation de la pile à combustible.

4.4.1.1. Modèle 500W

Pour le modèle 500W, trois sollicitations de courant ont été retenues (10 A, 25 A et 30 A). La sollicitation maximale est ici de 30 A en raison du domaine de validité du modèle. En effet, le modèle statique a été établi pour un courant maximal de 30 A. Cependant, il est possible de voir le comportement du modèle pour des courants de plus forte valeur mais cela reste délicat dans le sens où l'extrapolation est requise. Le point de fonctionnement choisi est le suivant :

- Facteurs de stœchiométrie anodique et cathodique, FSA = 2 et FSC = 5
- Température de fonctionnement, T = 50°C
- Hygrométrie relative de l'air, H = 100%

Ce point de fonctionnement a été retenu car le fonctionnement expérimental de la pile à combustible a été jugé très satisfaisant. Chaque entrée du modèle a été étudiée séparément et leurs variations sont définies dans le tableau 4.4. Les variations des paramètres sont de $\pm 50\%$ autour de la valeur nominale.

Paramètre d'entrée	Valeur nominale	Plage de variation
q_{H_2} à I = 10 A moyennant FSA = 2	2.78 NL/min	1.4 NL/min < q_{H_2} < 4.2 NL/min
q_{H_2} à I = 25 A moyennant FSA = 2	6.95 NL/min	3.5 NL/min < q_{H_2} < 10.4 NL/min
q_{H_2} à I = 30 A moyennant FSA = 2	8.34 NL/min	4.2 NL/min < q_{H_2} < 12.5 NL/min
q_{O_2} à I = 10 A moyennant FSA = 5	16.6 NL/min	8.3 NL/min < q_{O_2} < 24.9 NL/min
q_{O_2} à I = 25 A moyennant FSA = 5	41.5 NL/min	20.7 NL/min < q_{O_2} < 62.2 NL/min
q_{O_2} à I = 30 A moyennant FSA = 5	49.8 NL/min	24.9 NL/min < q_{O_2} < 74.7 NL/min
T	50°C	25°C < T < 50°C
H	100 %	50% < H < 100 %

Tableau 4.4: Variations des entrées du modèle 500W

La figure 4.19 représente la première étude réalisée sur le modèle 500W à partir d'une sollicitation de courant de 10 A dans les conditions de fonctionnement décrites ci-dessus. Cette courbe donne la variation de la tension par rapport à celle obtenue normalement pour le point de fonctionnement considéré en fonction de la variation des différents paramètres d'entrée du modèle.




Figure 4.19: Variation de la tension en fonction de la variation des paramètres d'entrée du modèle 500W pour $I=10A$

Le paramètre le plus influent sur la pile est ici le débit d'entrée d'air. La tension de sortie est plus élevée lorsque le débit d'air est plus important et les performances de la pile sont diminuées lorsque le débit d'air est réduit. A l'inverse, un faible débit d'hydrogène permet d'obtenir une tension plus importante et son influence s'atténue lorsque le débit est plus fort. Cependant, il est évident que ces remarques concernent la pile 500W qui a été caractérisée. Un autre comportement pourrait être attendu pour une pile différente. De plus, comme nous pouvons le constater, les variations de tension obtenues sont relativement faibles (de l'ordre de $\pm 6\%$ autour point qualifié de nominal). Ces faibles variations sont du même ordre que la précision obtenue grâce à notre modèle (de l'ordre de 2% entre les points issus de la simulation et les points expérimentaux). Il est dès lors délicat de tirer des conclusions ; pour s'assurer que les variations estimées se retrouvent bien d'un point de vue expérimental, quelques points expérimentaux ont été placés (à titre de validation) sur les figures 4.19 et 4.20. Les points expérimentaux correspondent aux résultats obtenus grâce au modèle.

La figure 4.20 regroupe les études menées pour des sollicitations de courant de 25 A et 30 A. Les résultats sont très similaires. Pour des courants plus élevés, le débit d'air fournit un niveau de tension plus élevé lorsque le débit est plus important. Il faut également noter l'influence de l'hygrométrie de l'air qui ne doit pas être trop faible pour ne pas diminuer de manière trop importante la tension.




Figure 4.20: Variation de la tension en fonction de la variation des paramètres d'entrée du modèle 500W pour I=25A et I=30A.

4.4.1.2. Modèle statique 5kW

La même étude a été menée pour le modèle de 5 kW. Seuls les points de fonctionnement diffèrent de l'étude précédente. Le point de fonctionnement choisi est le suivant pour des courants de (50 A, 100 A et 150 A):

- Facteurs de stœchiométrie anodique et cathodique, FSA = 1.2 et FSC = 2
- Température de fonctionnement, T = 60°C
- Hygrométrie relative de l'air, H = 100%

Les variations de chaque entrée du modèle sont définies dans le tableau 4.5 :

Paramètre d'entrée	Valeur nominale	Plage de variation
qH ₂ à I = 50 A moyennant FSA = 1.2	17.55 NI/min	8.7 NI/min < qH ₂ < 26.2 NI/min
qH ₂ à I = 100 A moyennant FSA = 1.2	35.1 NI/min	17.5 NI/min < qH ₂ < 52.6 NI/min
qH ₂ à I = 150 A moyennant FSA = 1.2	52.65 NI/min	26.3 NI/min < qH ₂ < 78.9 NI/min
qO ₂ à I = 50 A moyennant FSA = 2	69.65 NI/min	34.8 NI/min < qO ₂ < 104.4 NI/min
qO ₂ à I = 100 A moyennant FSA = 2	139.3 NI/min	69.6 NI/min < qO ₂ < 208.9 NI/min
qO ₂ à I = 150 A moyennant FSA = 2	208.95 NI/min	104.5 NI/min < qO ₂ < 313.4 NI/min
T	60°C	30°C < T < 90°C
H	100 %	50% < H < 100 %

Tableau 4.5: Variations des entrées du modèle 5kW

La figure 4.21 montre que le comportement de la pile 5 kW n'est pas totalement identique à celui de la pile 500W. D'une part, le débit d'air est ici moins influent sur la tension de la pile. D'après la figure 4.21, la tension de pile est bien meilleure pour une variation du débit d'air inférieur à 20% mais il est important de noter qu'en deçà de 20% de variation, nous nous situons ici en extrapolation. Ce résultat est donc à interpréter avec prudence.




Figure 4.21: Variation de la sortie en fonction de la variation des paramètres d'entrée du modèle 5 kW pour $I=50A$.

D'autre part, pour le modèle 500W, le comportement de la pile était amélioré lorsque le débit d'hydrogène était diminué. Ici, le phénomène inverse peut être constaté. Il est cependant à souligner qu'une comparaison abrupte des résultats issus des deux campagnes d'expérimentation est difficile à réaliser. En effet, les deux piles proviennent de fournisseurs différents (ZSW pour la pile 500W et Héliion pour la pile 5kW) et il est donc tout à fait légitime de considérer que leurs comportements respectifs ne soient pas identiques.

Enfin, pour des sollicitations de courant plus importantes (à 100 A et 150 A, représentées sur la figure 4.22), les conclusions à apporter sont identiques à celles obtenues pour la sollicitation de 50 A. En revanche, l'influence du débit d'hydrogène est ici plus marqué pour des courants importants.

Pour chaque sollicitation, la température de fonctionnement joue un rôle prépondérant sur le fonctionnement de la pile et il est clair que ce comportement est amélioré lorsque la température augmente.




Figure 4.22: Variation de la sortie en fonction de la variation des paramètres d'entrée du modèle 5 kW pour $I=100A$ et $I=150A$.

4.4.2. Etude du modèle dynamique


L'étude de sensibilité paramétrique sur les modèles dynamiques est également basée autour d'un point de fonctionnement (identique à celui proposé, pour chacune des PAC, pour l'étude statique) des deux piles étudiées. Cependant, l'estimation du comportement de la pile à combustible est ici réalisée au moyen de la quantification de l'énergie fournie par la pile à combustible en fonction des variations des paramètres d'entrée et de la fréquence de la sollicitation en courant. Pour les deux modèles, des sollicitations de courant de forme créneau, d'une amplitude crête de 20 A (pour le modèle 500W) et de 95 A (pour le modèle 5 kW), ont été utilisées à différentes fréquences.

4.4.2.1. Modèle 500W

La figure 4.23a représente l'énergie fournie par la pile en fonction de la variation du débit d'hydrogène montre que le comportement est semblable à celui obtenu en statique. En effet, l'énergie fournie par la pile est plus importante lorsque le débit d'hydrogène est faible. De plus, ce comportement est semblable pour toutes les gammes de fréquence et la variation d'énergie est, par ailleurs, la plus conséquente. En ce qui concerne le débit d'air (figure 4.23b), l'influence est moins prononcée, tout comme les résultats obtenus pour les variations de la température de fonctionnement (figure 4.23c) et les variations de l'hygrométrie relative de l'air (figure 4.23d). Cependant, il est intéressant de noter que pour tous les paramètres d'entrées du modèle, le comportement de la pile est amélioré lorsque la fréquence des sollicitations est supérieure à 500 Hz.


Il semblerait dès lors que notre pile à combustible soit en mesure de fournir plus d'énergie lors de sollicitations très dynamiques en courant. Cette conclusion est particulièrement intéressante dans la mesure où une pile à combustible sera nécessairement couplée à un convertisseur DC/DC ou DC/AC dans le cadre de son utilisation embarquée (ou même stationnaire). Ainsi, le convertisseur de par sa fréquence de découpage, pourrait conduire à une amélioration des performances du générateur PAC.

Energie fournie au bout d'une seconde en fonction du ΔqH_2 pour différentes fréquences




a)

Energie fournie au bout d'une seconde en fonction du ΔqO_2 pour différentes fréquences




b)

Energie fournie au bout d'une seconde en fonction du ΔT pour différentes fréquences



c)

Energie fournie au bout d'une seconde en fonction du ΔH pour différentes fréquences




d)

Figure 4.23: Variations de l'énergie fournie par la pile au bout d'une seconde en fonction de la fréquence de la sollicitation en courant et des différents paramètres d'entrée (modèle 500W).

4.4.2.2. Modèle 5 kW


Les variations du débit d'hydrogène (figure 4.24a) et du débit d'air (figure 4.24b) représentent une influence non négligeable puisqu'il existe, en mode dynamique, une variation d'énergie entre les faibles fréquences (< 10 Hz) et les hautes fréquences (> 200 Hz) d'environ 300 J. La température de fonctionnement (figure 4.24c) fait apparaître, quant à elle une différence d'énergie d'environ 200 J selon la valeur de la variation de ce paramètre. Par ailleurs, ces remarques permettent de conclure que l'utilisation de la pile 5 kW pour des fréquences élevées (> 200 Hz) est aussi préférable. De la même manière que l'étude menée sur la pile de 500W, le couplage de la pile à combustible de 5kW avec un convertisseur ayant une fréquence de découpage élevée améliorera les performances du système.

Energie fournie au bout d'une seconde en fonction du ΔqH_2 pour différentes fréquences



a)

Energie fournie au bout d'une seconde en fonction du ΔqO_2 pour différentes fréquences



b)




Figure 4.24: Variations de l'énergie fournie par la pile au bout d'une seconde en fonction de la fréquence de la sollicitation en courant et des différents paramètres d'entrée (modèle 5 kW).

4.5. Conclusion

La première partie de ce chapitre a été consacrée à l'utilisation des modèles pour la prédiction de l'évolution temporelle en tension des piles étudiées. Pour réaliser cette étude, plusieurs problèmes ont dû être solutionnés. Dans un premier temps, les problèmes rencontrés avec l'utilisation de la transformée de Fourier ont été exposés et différentes études ont dû être menées pour obtenir les résultats escomptés.

D'une part, l'utilisation d'une fenêtre de pondération s'est avérée efficace en adoptant plusieurs méthodes. Le choix d'une fenêtre glissante a permis un gain en temps de calcul. Cependant, il a été nécessaire de déterminer une solution permettant à la fenêtre évolutive d'adapter sa taille (nombre d'échantillons) selon la fréquence de la sollicitation en courant. L'asservissement de la taille de la fenêtre en fonction de la fréquence du fondamental du courant est a priori une solution intéressante. Par ailleurs, l'étude itérative sur l'amplitude des harmoniques à prendre en compte pour la reconstitution du signal a permis d'obtenir un compromis temps de calcul/précision satisfaisant. Enfin, la technique adoptée pour l'initialisation de la fenêtre de pondération a montré que la qualité de prédiction était affectée seulement sur les premières itérations.

D'autre part, il était intéressant de voir le comportement des modèles en les utilisant comme prédicteurs à court terme. L'utilisation des modèles dans cette condition se révèle efficace en vue de l'évolution temporelle de la tension calculée. Les erreurs maximales relevées entre les points calculés et les points expérimentaux sur les deux modèles restent dans ce cas de figure inférieures à 5 %. L'utilisation du modèle ainsi établi pourrait donc tout à fait être envisagée pour la réalisation du contrôle commande du système pile à combustible.

La deuxième partie de ce chapitre est axée sur une étude de sensibilité paramétrique. Les études proposées en statique et dynamique permettent de fournir une première série de conclusions.

Les résultats présentés montrent que le comportement de la pile 500 W ZSW est amélioré lorsque le débit d'entrée d'hydrogène est faible et que le débit d'entrée d'air est important. Cette remarque est valable aussi bien pour un fonctionnement statique que dynamique alors que l'hygrométrie relative de l'air semble plus influente en mode statique. Par ailleurs, la température a une influence moindre sur la pile 500 W que sur la pile 5 kW.

Concernant, la pile 5 kW, les débits d'hydrogène et d'air agissent de manière aussi représentatives en mode dynamique que statique. Cependant il est préférable, en mode statique, d'avoir une sur-stœchiométrie côté anodique lorsque le courant débité par la pile est important.

Enfin, l'étude en mode dynamique a permis de constater que le fonctionnement des deux piles est préférable pour des sollicitations de courant ayant une fréquence supérieure à 200 Hz.

Il est important de souligner que ces conclusions ne sont à considérer que pour les deux piles à combustible étudiées.

CONCLUSION GENERALE

Conclusion générale

Les travaux de recherche présentés dans ce mémoire apportent une contribution à la modélisation d'une pile à combustible de type PEM. Parmi les différentes méthodes de modélisation, nous nous sommes intéressés ici plus particulièrement à la modélisation par méthode neuronale en proposant des solutions novatrices permettant de développer un modèle décrivant le comportement dynamique d'une pile à combustible. Depuis une dizaine d'années, les réseaux de neurones, qui sont catalogués dans l'intelligence artificielle, sont de plus en plus utilisés dans la communauté du Génie Electrique pour la modélisation de processus non linéaires. Cependant, à notre connaissance aucune étude sur la modélisation d'une pile à combustible de type PEM par réseaux de neurones n'a été réalisée à ce jour. Les seuls travaux présentés décrivent un comportement statique du générateur [LEE03], [SHE02]. Les réseaux de neurones sont des outils de modélisation séduisants de part leur mise en œuvre mais aussi pour leur adaptation à des systèmes de différentes natures. Notre objectif a donc été de prouver que les réseaux de neurones pouvaient être utilisés pour la modélisation d'une pile à combustible et que le modèle ainsi réalisé s'averait très facile d'utilisation et qu'il fournissait des résultats très satisfaisants.

Dans une première partie de ce travail, les différents verrous à lever pour permettre l'utilisation des piles à combustibles de type PEM dans les applications transports ont été présentés. Si les problèmes d'intégration du système semblent quasi-résolus, le choix d'installer un reformeur ou d'alimenter directement la pile en hydrogène fait l'objet de nombreuses controverses. Le coût du système est un autre handicap fondamental. Cependant la modélisation d'un générateur intégré dans une chaîne de traction peut diminuer les coûts de prototypage. Après avoir fait l'inventaire des divers principes de modélisation, nous avons montré qu'il était possible de considérer une modélisation de type « boîte noire » à l'aide des réseaux de neurones, les autres techniques nous apparaissant comme trop complexes et trop ciblées.

Les principes de base des réseaux de neurones ainsi que quelques architectures ont été exposés dans la première partie du second chapitre. Le principe de l'apprentissage qui est le fondement même des réseaux de neurones et qui permet l'approche de n'importe quelle caractéristique y a été présenté ; différentes techniques d'apprentissages ont également été évoquées. A ce stade, il était nécessaire de sélectionner les entrées/sorties du modèle. Cette étape est d'une grande importance car un mauvais choix des paramètres du modèle pourrait entraîner une mauvaise modélisation. Afin de déterminer les entrées/sorties prépondérantes du système, de nombreuses expérimentations ont été effectuées sur deux bancs d'essais pile à combustible disponibles au L2ES. Ces différentes campagnes d'essais ont permis d'une part de bien maîtriser les fonctionnements et comportements des deux systèmes pile à combustible objets de notre modélisation et d'autre part de déterminer les différentes bases d'apprentissage, de validation et de test. Dès lors, un premier modèle décrivant le comportement statique d'une pile de 500W a pu être développé. Cette étude s'est avérée très riche en enseignements car elle nous a permis d'acquérir les techniques fondamentales pour la modélisation de processus par réseaux de neurones. De plus, deux méthodes d'apprentissage ont été programmées ; la validation croisée et le Bootstrap. Les résultats fournis par ces deux méthodologies sont toutes deux couronnées de succès. Notre choix s'est cependant porté sur la méthode de validation croisée pour le reste de nos travaux car la méthode du Bootstrap nous a semblé trop coûteuse en temps, pour une amélioration du modèle somme toute minime.

L'objectif de ce mémoire ne se limite pas à la modélisation d'une pile à combustible particulière mais doit permettre de contribuer à la modélisation d'une pile à combustible de type PEM. Le choix des méthodes neuronales pour cette modélisation nous semble pertinent de par les capacités d'adaptation à

Conclusion générale

différents types de processus, caractéristiques essentielles des réseaux de neurones. Ainsi, nous avons étudié la portabilité du modèle établi de la pile 500W sur une pile de plus forte puissance (5 kW) mais de même technologie (PEM). Seules les bases d'apprentissage, de validation et de test se différencient du précédent modèle. Les résultats obtenus pour la modélisation statique de la pile à combustible de 5 kW permettent de conclure que le modèle « boîte noire » proposé devrait, a priori, pouvoir être utilisé pour d'autres piles à combustible de puissances différentes mais présentant les mêmes entrées/sorties.

Pour modéliser au mieux la pile à combustible dans tous ses modes de fonctionnement, il est également nécessaire de maîtriser son fonctionnement en dynamique et de le modéliser. A terme, notre modèle pourrait être intégré dans une modélisation d'une chaîne de traction complète d'un véhicule. Dans cette optique, il est évident que le comportement en régime statique mais aussi en régime dynamique doit être simulé. Le troisième chapitre de ce mémoire est consacré à cette étude dynamique. Pour établir une modélisation dynamique à l'aide des réseaux de neurones, il est nécessaire d'utiliser des réseaux bouclés. Ces interconnexions présentent l'intérêt de prendre en compte les aspects temporels et de mémoire. Cependant, une multitude d'architectures et de techniques d'apprentissage existent pour élaborer des modèles dynamiques. Après avoir brièvement présenté quelques architectures, notre choix s'est porté sur un réseau de Jordan, qui fait partie d'une classe simple de réseaux récurrents utilisant un vecteur d'état. Le point suivant à traiter était alors de déterminer les essais expérimentaux permettant de caractériser au mieux le fonctionnement de la pile en mode transitoire. Afin de s'approcher des conditions de profil de courant des applications transports, nous avons décidé de solliciter la pile à combustible avec des formes de courant de types sinusoïdales, créneaux et triangulaires pour différentes fréquences (de 0.1 Hz à 1 kHz). Ces différents essais ont permis d'établir les différentes bases d'apprentissage, de validation et de test. Cependant, pour établir un modèle dynamique et prendre en compte implicitement le temps, il est nécessaire d'avoir une période d'échantillonnage Δt identique pour chacun des essais expérimentaux. Si le même échantillonnage est conservé lors de l'apprentissage, le nombre d'échantillons à traiter par le réseau de neurones sera trop important et par conséquent les temps de calculs deviendront prohibitifs. De plus, la convergence des algorithmes du gradient sera nécessairement ralentie. Pour pallier ce problème, deux solutions ont été proposées et appliquées. La première consiste à scinder le réseau de neurone global en trois sous réseaux auxquels une gamme de fréquence est affectée. Nous retrouverons alors trois pas d'échantillonnage différents. Ainsi, il faudra procéder à trois apprentissages distincts et le nombre d'échantillons présentés à chaque sous réseau sera plus raisonnable entraînant des temps de calcul moins importants. Il faudra bien entendu ajouter l'apprentissage réalisé par le réseau de neurones statique. Néanmoins, l'apprentissage des réseaux bouclés devient un processus lourd à mettre en œuvre lorsque le nombre de retard rebouclé en entrée est important. Afin de diminuer les temps de calcul, nous avons créé un vecteur d'état qui comporte non pas les sorties calculées par le réseau mais les sorties désirées par le réseau. Cette technique conjuguée avec la création de trois sous réseaux nous a permis de diminuer les temps de calcul de façon drastique.

Cependant, nous nous retrouvons avec une configuration comportant quatre sous réseaux pour lesquels quatre apprentissages distincts doivent être effectués en fonction des plages fréquentielles des bases d'apprentissage. Le but final est définir une unique boîte noire multi modèles. Il aurait pu être possible d'ajouter une entrée fréquence sur les sous réseaux mais cette solution aurait impliqué de connaître, a priori, la sollicitation en courant appliquée au système. Or dans le cadre d'une application transport, la sollicitation en courant de la pile dépend notamment et principalement de la sollicitation du conducteur, laquelle est totalement inconnue. La méthodologie proposée pour résoudre ce problème

Conclusion générale

repose sur un prétraitement des données d'entrée à partir d'une décomposition en série de Fourier. Cette méthode nous permet de coupler relativement facilement et rapidement les trois sous modèles dynamiques ainsi que le modèle statique.

Nous nous sommes proposé d'étudier, dans le dernier chapitre, la capacité du modèle à prédire la tension délivrée par la pile à combustible en fonction d'un courant d'entrée à fréquence variable. La méthodologie, basée sur la décomposition en série de Fourier se voit agrémentée de quelques modifications pour répondre aux attentes escomptées. Il a notamment été nécessaire d'utiliser un fenêtrage temporel évolutif. Cependant, l'utilisation d'une fenêtre de pondération apporte quelques contraintes ; le choix d'une fenêtre temporelle évolutive a été pris pour gagner en temps de calcul. En effet, en travaillant avec un nombre d'échantillons limité, le nombre de calculs par itération est réduit. Néanmoins, le nombre d'échantillons pris en compte dans la fenêtre doit être adapté en fonction de la fréquence de la sollicitation en courant. Pour répondre à cette contrainte, nous avons asservi la taille de la fenêtre glissante à la fréquence du fondamental calculé sur la fenêtre glissante à l'instant d'échantillonnage précédent. Cette technique s'avère efficace mais il est tout de même difficile d'obtenir un nombre entier de périodes sur toute l'évolution temporelle du signal étudié, en particulier, lorsque la valeur du fondamental change. Les modifications apportées à la méthodologie ont permis d'obtenir des résultats très satisfaisants (erreur < 5%) que ce soit en utilisant le modèle en instantané ou en tant que prédicteur à court terme. De plus, ces modifications ont considérablement réduit les temps de calcul tout en gardant un compromis temps de calcul/précision adéquat.

Enfin la dernière partie de ce chapitre, plus prospective, est axée sur une étude de sensibilité paramétrique. Cette étude est réalisée sur les deux modèles établis (500W et 5kW) et doit permettre, à terme, de comprendre les phénomènes mis en jeu, d'aider à des choix technologiques et énergétiques ou encore d'explorer de nouveaux champs d'investigation qu'une approche expérimentale rendrait trop longue et coûteuse. Cette étude nous a notamment conforté dans le choix adopté des paramètres d'entrées/sorties de notre modèle. Le modèle validé devient donc ainsi un outil efficace d'investigation.

Cependant, notre modèle affiche certaines limites. Les plages de fonctionnement des deux générateurs pile à combustible restent étroites dans le cadre de notre étude. Il pourrait être intéressant d'étudier leur comportement pour des températures plus élevées (de l'ordre de 90°C) ou encore pour des sollicitations de courant plus conséquentes (80 A pour la pile 500W et 200 A pour la pile 5kW). L'étude de sensibilité paramétrique a permis de fournir quelques résultats hors des plages de fonctionnement établies pour les modèles. Cependant, ces résultats sont à considérer avec une grande prudence car ils relèvent de l'extrapolation tant pour les réseaux de neurones que pour les générateurs PAC. De la même manière, le modèle n'a pas été testé pour des gammes de fréquences plus élevées. En effet, pour cette étude, une borne maximale de 1kHz a été judicieusement choisie mais dans le cas où des piles de plus forte puissance sont à modéliser, cette borne ne sera certainement plus adaptée. Enfin, le point le plus important est que notre modèle est capable de prédire l'évolution temporelle en tension à partir d'une sollicitation de courant à fréquence variable mais présentant néanmoins une certaine périodicité. Il serait intéressant d'étudier le comportement du modèle voire de procéder à une adaptation du modèle, pour des profils de courants non périodiques.

Conclusion générale

Les perspectives de ce travail sont multiples de par l'aspect encore innovant de l'utilisation des réseaux de neurones pour une telle application. Ainsi, il conviendrait d'approfondir les problèmes intrinsèques concernant les temps de calcul pour les phases d'apprentissage. En ce sens, il serait intéressant de mettre en œuvre un apprentissage « on-line » sur le système à modéliser. Cependant, nous avons vu que les bases d'apprentissages souvent conséquentes augmentaient considérablement les temps de calcul. Tous les échantillons des bases d'apprentissages ne sont pas forcément significatifs. Le concepteur, qui a une connaissance approfondie du système étudié, se doit de trier ces échantillons mais il subsistera toujours des essais expérimentaux plus ou moins inutiles. Pour aider le concepteur à réaliser ce choix, il serait intéressant de mettre en œuvre un apprentissage à partir d'algorithmes génétiques. Une telle application pourra déterminer les échantillons les plus pertinents et de ce fait, les bases d'apprentissages seraient moins volumineuses. Les temps de calcul pourront ainsi être diminués tout en gardant une qualité de prédiction intéressante.

Une seconde perspective attirante à ce travail serait d'utiliser notre modèle pour le contrôle commande du système pile à combustible. En effet, nous avons vu dans le dernier chapitre de ce mémoire que l'utilisation du modèle en tant que prédicteur à court terme fournissait des résultats très prometteurs. Cependant, il existe de nombreuses méthodes pour réaliser la commande d'un tel système. Nous pouvons citer, entre autres, les réseaux de neurones, la logique floue ou encore un contrôleur neuroflou qui repose sur une association des réseaux de neurones et de la logique floue. Bien entendu, l'utilisation des réseaux de neurones pour réaliser la commande nécessite de déterminer, au sens des entrées/sorties, quelle doit être la caractéristique ou la stratégie de commande à apprendre en vue de son utilisation. La logique floue est de plus en plus considérée dans le domaine du Génie Électrique pour l'élaboration de stratégies de commande [TEK04]. Les algorithmes flous sont en meilleure adéquation avec le raisonnement humain de par leur côté intuitif et qualitatif. Ces contrôleurs proposent une alternative intéressante aux stratégies conventionnelles de commande [HIS98].

Enfin, il pourrait être intéressant de revoir la méthodologie de couplage des quatre sous réseaux en adoptant une modification du pas de calcul des modèles neuronaux à temps discret [CON00]...

**ANNEXE A : PRESENTATION DU BANC
D'ESSAIS PILE A COMBUSTIBLE DE
500W**

OBJECTIFS DU BANC D'ESSAIS

Le banc d'essai pile à combustible de 500W (figure A1) a été conçu de manière à mener une caractérisation complète d'une pile à combustible de type PEM, sous des sollicitations statiques et dynamiques. Pour étudier les performances du système et valider des modèles de simulations développés au L2ES, un grand nombre d'essais pratiques doivent être réalisés. Ce banc est instrumenté de manière à acquérir le plus grand nombre de paramètres significatifs caractérisant le système. Le contrôle de certains paramètres, tels que la température de la boucle de refroidissement, les débits et pressions de gaz, l'hygrométrie relative de l'air ou le courant, est assuré afin d'obtenir un point de fonctionnement spécifique.

Ce banc d'essai est dimensionné pour tester des piles à combustibles de type PEM d'une puissance maximale de 1 kW. Une première version fonctionnant en boucle ouverte avait été réalisée lors de mon DEA [JEM01]. Fabien Harel, ingénieur d'étude INRETS, a entièrement repris cette version provisoire du banc d'essai pour créer un système complet [HAR03]. Les principales modifications apportées à ce banc concernent plus particulièrement les circuits annexes de fluides. En effet, le système comporte maintenant une boucle de régulation de température d'eau séparée, une boucle de régulation de l'hygrométrie relative de l'air et de la température de l'air ainsi qu'une régulation en pression à l'anode et à la cathode. Les autres changements majeurs concernent la structure du banc (châssis en aluminium), la connectique (alimentation et conditionnement des données des capteurs et actionneurs) et le programme de gestion du banc développé sur une plate-forme National Instrument®.




Figure A 1: Banc d'essai 500W.

Condenseurs

DESCRIPTION DU BANC D'ESSAI

Caractéristiques de la pile à combustible PEM de 500W testée

Le banc d'essais est équipé d'une pile à combustible de type Proton Exchange Membrane (membranes GORE) d'une puissance nominale de 500 W. Ce module est fourni par le constructeur allemand (ZSW). Cette pile est composée de 20 cellules élémentaires d'une surface de 100 cm² et elle se caractérise par une tension nominale de 12 V et une puissance maximale d'environ 800 W. Les principales caractéristiques sont regroupées dans le tableau A1.

<i>Caractéristiques d'exploitation</i>	<i>Plages de fonctionnements</i>	<i>Minima/maxima admissibles</i>
Température de fonctionnement	20°C-65°C	Au maximum 75 °C
Pression	Atmosphérique	Au maximum 500 mbar de surpression
Différence de pression anode/cathode (sécurité logicielle)	±50 mbar	±250 mbar si $\Delta P > \pm 250$ mbar, arrêt de la distribution des gaz et coupure de la charge
Humidification cathode	Point de rosée entre 20°C et 45°C	
Tension du stack	10 V – 19 V DC	< 9.6 V nécessité de diminuer le courant de charge < 7.6 V nécessité de couper la charge
Tension cellule unitaire (sécurité logicielle)	500 mV – 980 mV DC	< 500 mV alarme visuelle < 380 mV arrêt de la distribution des gaz et coupure de la charge
Courant	0 A – 80 A DC	Au maximum 80 A

Tableau A 1: Caractéristiques de la pile à combustible ZSW 500W

Ce banc d'essais, en plus du cœur de pile, est composé de trois sous ensemble :

- Un système de gestion du banc (interface homme/machine) qui permet le recueil de l'ensemble des données de mesure. De plus, il permet d'appliquer les actions de l'opérateur et assure la gestion des sécurités.
- Les auxiliaires qui sont les différents actionneurs et capteurs permettant de traduire les consignes du système de gestion du banc en actions physiques et qui renvoient vers ce dernier les différentes mesures prélevées.
- La charge électronique qui est l'élément qui va solliciter directement la pile sur une contrainte de courant ou de puissance. Elle est en liaison directe avec le système de gestion du banc par lequel elle est pilotée.

Le système de gestion du banc

L'implantation du système de gestion du banc a été réalisé sur une plate-forme PXI National Instrument® et développé sous le logiciel Labview®. L'interface logicielle permet à l'utilisateur l'acquisition des différentes grandeurs mesurées, le contrôle des sécurités, la gestion des automatismes et le pilotage des actionneurs à partir des consignes de l'utilisateur, ou de grandeurs de commande lues dans un fichier (suivi de cycle). Les divers paramètres de contrôles ou de mesures du système sont facilement accessibles depuis l'interface graphique (figure A2). Ce programme a été réalisée pour intégrer l'automatisation globale du process : gestion des sécurités logicielles, gestion des régulations (température eau, température et hygrométrie air, suivi de cycle) tout en cherchant à optimiser les temps d'exécution. Dès lors, un fonctionnement en boucle fermé (mode automatique) est possible.




Figure A 2: Interface graphique du système de gestion.

Synoptique détaillé du banc d'essais

Le synoptique (figure A3) représente la structure globale du banc d'essai. Trois circuits annexes de fluide sont en évidence : la distribution d'air et d'hydrogène, le contrôle du taux d'humidification de l'air, la boucle de refroidissement et la régulation de température de l'eau. Il est à noter que le choix des auxiliaires est prépondérant sur le fonctionnement du système car leur plage de variation ne doit pas réduire les conditions de fonctionnement possibles.




Figure A 3: Synoptique détaillé de l'architecture du banc de test

Nature des mesures et commandes sur le banc d'essai

Le contrôle du fonctionnement de la pile à combustible nécessite la prise en compte et la maîtrise d'un grand nombre de paramètres physiques. Le tableau A2 regroupe les paramètres contrôlables et le tableau A3, les paramètres mesurés :

<i>Paramètres contrôlables</i>
Consignes de débit H ₂
Consigne de débit AIR
Consigne de courant
Consigne puissance réchauffeur
Consignes puissance pompe P1 et P2
Consigne électrovanne proportionnelle
Consigne pression H ₂
Consigne pression AIR

Tableau A 2: Paramètres contrôlables

Annexe A

<i>Paramètres mesurés</i>
20 tensions unitaires de cellules
Courant pile
Régulation débit air amont
Débit air aval
Régulation débit H ₂ amont
Débit H ₂ aval
Débit eau
Pression air amont
Pression air aval
Pression H ₂ amont
Pression H ₂ aval
Hygrométrie air
Température amont H ₂
Température aval H ₂
Température amont air
Température aval air
Température amont eau
Température aval eau
Température surface pile
Température bouilleur
Température réchauffeur
Température circuit secondaire eau

Tableau A 3: Paramètres mesurés

Circuits d'air et d'hydrogène

Les circuits d'air et d'hydrogène sont tous deux composés des éléments suivants :

- Régulateurs de débit (RD)
- Déverseurs (D)
- Condenseurs (C)
- Capteurs de pression (P)
- Capteurs de température (T)

Les régulateurs de débits permettent de maîtriser le débit de gaz dans la pile à partir d'une consigne générée par le programme de gestion du banc. Les consignes de débits de gaz sont calculés par le programme à partir des relations liant les fluides gazeux au courant (équations A1 et A2).

Les déverseurs sont des vannes de régulation pneumatiques pilotées. Elles permettent d'assurer la régulation de la pression des gaz en entrée de pile, par l'application d'une contre-pression sur le circuit aval de la pile.

En sortie de pile, les condenseurs permettent de récupérer l'eau contenue dans les gaz. Ils sont constitués comme des échangeurs et refroidissent le gaz avec un circuit secondaire parcouru par de l'eau de ville ($T^{\circ}=15^{\circ}\text{C}$). Les condensats sont récupérés dans un bocal et permettent, après pesée, dévaluer le bilan en eau de la pile. Ils sont également indispensables pour assécher le gaz avant son passage dans les indicateurs de débit (ID).


Les capteurs de pression et température sont placés en amont et en aval de la pile. Les capteurs de pression permettent de fournir les pressions dans les canaux amenant les gaz à la pile et les capteurs de températures permettent de donner la température des gaz.

Grâce aux équipements présents sur ces deux circuits, il est possible de travailler selon trois modes de fonctionnement :

- **Mode ouvert** : les fluides gazeux entrant dans la pile traversent les différents canaux, l'excédent est rejeté à l'atmosphère. Le contrôle des gaz est réalisé en débit.
- **Mode fermé** : le circuit d'évacuation de l'hydrogène est fermé, le circuit d'air est en mode ouvert, tout l'hydrogène entrant dans la pile est consommé. Ce mode nécessite une gestion précise du débit d'hydrogène entrant dans la pile pour satisfaire la demande de courant et contrôler la pression. Ce mode implique aussi de contrôler les purges de l'azote et de l'eau accumulés à l'anode.
- **Mode pression** : une contre pression est réalisée en sortie de pile côté air et hydrogène par des vannes de régulations (déverseurs), de manière à contrôler la pression des gaz en entrée de pile. La stratégie de contrôle des gaz est alors basée sur la régulation des pressions et débits.

Expressions théoriques des débits de gaz en fonction du courant

Les débits de gaz théoriques nécessaires pour faire débiter à la pile un courant I seront calculés à partir des relations suivantes :



Le débit est défini par la relation suivante : $q_{H_2} [mol/s] = Fsa * \frac{I}{2F} * N$

avec Fsa : facteur de stœchiométrie = 1/0.6


N : nombre de cellules = 20

F : constante de Faraday = 96485 Cmol⁻¹

$q_{H_2} [g/s] = Fsa * \frac{I}{2F} * N * M$ avec M : masse molaire $H_2 = 2 * 1.008 \text{ g/mol}$

$q_{H_2} [l/min] = Fsa * \frac{I}{2F} * N * M * 60 * \frac{V}{M}$ (A1)

avec V : volume d'1 mole CNTP = 22.4 l



Le débit est défini par la relation suivante : $qO_2 [mol/s] = F_{sc} * \frac{I}{4F} * N * \frac{1}{0.21}$

avec F_{sc} : facteur de stœchiométrie = $1/0.21$ et $V_{O_2} = 0.21 * V_{air}$

N : nombre de cellules = 20

F : constante de Faraday = 96485 Cmol^{-1}

$$qO_2 [g/s] = F_{sc} * \frac{I}{4F} * N * \frac{1}{0.21} * M \quad \text{avec } M : \text{masse molaire } O_2 = 2 * 16 \text{ g/mol}$$

$$qO_2 [l/min] = F_{sc} * \frac{I}{4F} * N * \frac{1}{0.21} * M * 60 * \frac{V}{M} \quad (A2)$$

Système de régulation de température et de l'hygrométrie de l'air

Les membranes échangeuses de protons qui constituent le cœur PEMFC, nécessitent un maintien en teneur d'eau élevée, principalement à haute température car cela conditionne leur propriété de conduction des espèces ioniques. La maîtrise de l'hygrométrie et de la température de l'air entrant dans la pile est donc un point essentiel du fonctionnement de ce type de pile. Le schéma de principe permettant d'assurer cette fonction est défini par la figure A4. Le système de contrôle de l'hygrométrie coté air est composé d'un bouilleur, d'un échangeur air/eau, du séparateur, d'un système de traçage thermique pour le maintien du point de rosée, du réchauffeur et d'un système de mesure (validation) du point de rosée par hygromètre à miroir.




Figure A 4: Schéma de principe du circuit d'humidification d'air

Un essai a été réalisé afin de valider ce système de contrôle. Lors de cet essai, la pile fonctionnait autour de son point nominal, $T^{\circ}pile = 58^{\circ}C$, $P = 490W$, $FSA = 2$, $FSC = 4$.

Trois points de fonctionnement ont alors été demandés (consignes de point de rosée en rouge et T° entrée air pile en bleu sur la figure A5) :

1: T°rosée=25°C, T°entrée air pile =26°C

2: T°rosée=35°C, T°entrée air pile =36°C

3: T°rosée=45°C, T°entrée air pile =46°C

Soit une hygrométrie relative demandée d'environ 97% pour ces trois points.

Le début de l'enregistrement est réalisé alors que le point correspondant à la première consigne est atteint. Un écart d'environ 2°C entre le point de rosée mesuré sur le banc et la validation par hygromètre apparaît. La deuxième consigne est ensuite demandée (+10°C); le système met environ 500 secondes pour se stabiliser. L'écart sur le point de rosée est ici inférieur à 2°C. La troisième consigne (+10°C) est alors demandée. Le système "banc" met là encore environ 500s pour se stabiliser. La mesure par l'hygromètre est plus lente dans cette partie car le système de traçage rencontre plus de difficultés pour monter en température à ces valeurs élevées. Dans ce cas figure, le point de rosée du banc montant plus vite que la température des traceurs, de l'eau en forme liquide apparaît dans la ligne de mesure, ce qui génère une perturbation entre 1250s et 1700s sur la valeur de l'hygromètre à miroir. Lorsque celui-ci se stabilise, on note un écart d'environ 3° entre le point de rosée du banc et celui de l'hygromètre [HAR03].




Figure A 5: Evolution des températures d'entrée air et de rosée en fonction des consignes

Cet essai a permis de valider le fonctionnement du système de contrôle de l'hygrométrie de l'air.

Système de régulation de température d'eau de la pile

La réaction électrochimique de la pile délivre une puissance électrique et thermique ; afin d'éviter une «surchauffe» de la pile et contrôler la température de fonctionnement, le banc d'essai a été équipé d'un système de régulation de la température de l'eau de refroidissement de pile. La température de l'eau à la sortie de la pile est considérée comme température de fonctionnement et doit être contrôlée pour atteindre une valeur choisie par l'utilisateur selon la puissance fournie par la pile. La plage de variation de la température pour la puissance maximale (500 W) est comprise entre 25°C

et 65°C. Le système peut également chauffer l'eau circulant dans le stack pour accélérer la montée en température en cas de démarrage à froid. Dans ce cas une source chaude doit être disponible sur le banc d'essai ; le bouilleur du système de régulation du taux d'humidification de l'air est utilisé pour réaliser cette tâche. La figure A5 décrit le fonctionnement de la régulation de température.




Figure A 6: Régulation de la température et de l'hygrométrie de l'air

**ANNEXE B : PRESENTATION DU BANC
D'ESSAI HELION 5 KW**

DESCRIPTION DU BANC D'ESSAI

Le L2ES possède un deuxième banc d'essai pile à combustible de plus forte puissance (figure A6). Il est équipé d'une pile à combustible de type PEM d'une puissance nominale de 5 kW et ce banc a été fourni par la société française Héliion.

Pour des raisons de confidentialité, ce banc d'essai ne sera pas décrit de façon détaillée. Les principales caractéristiques et modes de fonctionnement sont donnés dans les paragraphes suivants.



Figure B 1: Banc d'essai Héliion 5 kW.

Domaine de fonctionnement du stack Héliion 5 kW

Dans la zone de fonctionnement normal, les conditions de fonctionnement sont idéales vis-à-vis de la durée de vie des EME du stack. Les conditions de fonctionnement correspondantes sont celles recommandées pour un fonctionnement du stack (figure A7) prolongé au-delà d'un tracé de courbe de polarisation (endurance par exemple). Le tableau A4 regroupe les points de fonctionnement nominal. Le tableau A5 énumère les limites de fonctionnement.




Figure B 2: Cœur de pile Héliion 5 kW.

Point de fonctionnement $I = 170\text{ A}$ et $P = 5000\text{ W}$	
$\text{PH}_2 = 1.8\text{ bars abs}$ Humidité relative $\text{H}_2 = 100\%$ Mode H_2 : ouvert Purge H_2 : - Surstœchiométrie $\text{H}_2 : 1,2$	Pair = 1.8 bars abs Humidité relative Air = 100% Mode Air : ouvert Purge Air : Surstœchiométrie Air = 2,0 Températures cellules stack = 55°C

Tableau B 1: Point de fonctionnement nominal

Point de fonctionnement $100\text{ A} < I < 250\text{ A}$	
$\text{PH}_2 \leq 2\text{ bars abs}$ Humidité relative $\text{H}_2 = 100\%$ Mode H_2 : bouché à ouvert (+ recirculé) Purge H_2 : <u>Si mode bouché ou recirculé</u> 5s - 60s - 15l (durée – période - surdébit) $1 \leq \text{Surstœchiométrie } \text{H}_2 \leq 1,2$	Pair $\leq 2\text{ bars abs}$ Humidité relative Air = 100% Mode Air : ouvert Purge Air : $1,7 \leq \text{Surstœchiométrie Air} \leq 2,5$ $20^\circ\text{C} < \text{Températures cellules stack} < 60^\circ\text{C}$

Tableau B 2: Limites de fonctionnement

Le système de contrôle commande

L'implantation du système de contrôle a été réalisé sur une plate-forme PXI National Instrument et développé sous le logiciel Labview Real Time 6.1®. L'interface logicielle permet à l'utilisateur le choix du mode de fonctionnement de la pile et des paramètres à contrôler. Les diverses mesures du système sont facilement accessibles depuis l'interface graphique. Par exemple, les débits et pressions de gaz d'alimentation, les tensions individuelles de cellules, les différentes températures ou encore le courant sont affichés.

Des sécurités logicielles sont également prévues en cas d'atteinte du seuil minimum des tensions de cellules, d'un dépassement de température sur un des circuits de fluide ou encore de dépassement du seuil de différence de pression entre l'anode et la cathode

Auxiliaires et circuits annexes

Comme pour le banc d'essai 500 W, les auxiliaires et circuits annexes sont nécessaires pour le bon fonctionnement de la pile. Les trois circuits annexes de fluide principaux sont: la distribution d'air et d'hydrogène et la régulation de température de l'eau (figure A8).



Figure B 3: Circuits annexes de fluides

Système de régulation de température

La réaction électrochimique de la pile délivre une puissance électrique et thermique ; afin d'éviter une «surchauffe» de la pile et contrôler la température de fonctionnement, le banc d'essai est équipé d'un système de régulation de la température de l'eau de refroidissement de pile. La température de l'eau à la sortie de la pile est considérée comme température de fonctionnement et doit être contrôlée pour atteindre une valeur choisie par l'utilisateur selon la puissance fournie par la pile. Le système peut chauffer l'eau circulant dans le stack pour accélérer la montée en température en cas de démarrage à froid. La figure A9 décrit le fonctionnement de la régulation de température.




Figure B 4: Régulation de la température de pile

Circuits d'air et d'hydrogène

Les circuits d'air et d'hydrogène sont instrumentés de manière semblable au banc d'essai ZSW 500 W (débitmètres, thermocouples, régulateurs de pression...). Il est possible de travailler selon différents modes de fonctionnement (mode ouvert, mode fermé et mode recirculé grâce à compresseur de recirculation figure A10). La température de ces deux circuits est aussi régulée à l'aide de cordons chauffants.



Figure B 5: Compresseur de recirculation

ANNEXE C : METHODES DU GRADIENT ET DE QUASI NEWTON
--

CALCUL DU GRADIENT DE LA FONCTION COUT DANS UN RESEAU MULTICOUCHE

Pour faciliter la compréhension des calculs du gradient de la fonction coût dans un réseau multicouche, nous allons étudier un réseau à i entrées avec deux couches cachées comportant respectivement j et l neurones et k neurones de sortie.




Figure C 1: Architecture du réseau

Nous considérons pour cette architecture que les fonctions d'activations pour les neurones des deux couches cachées sont des sigmoïdes et que la fonction d'activation de la couche de sortie est linéaire. Nous rappelons que la fonction sigmoïde et sa dérivée sont déterminées par les relations suivantes :

$$\Phi(x) = \frac{2}{1 + e^{-x}} - 1 \quad (A3)$$

$$\Phi'(x) = 2 \cdot \Phi(x)(1 - \Phi(x)) \quad (A4)$$

La mise à jour des poids synaptiques est réalisée en appliquant la méthode de rétropropagation du gradient. Il faut donc réaliser les calculs en partant de la couche de sortie pour aller vers la couche d'entrée.

Calcul du gradient de la fonction coût aux points $w_{uq,2}$

La première étape consiste donc à calculer le gradient entre la couche de sortie et la deuxième couche cachée (équation (A5)) :

$$\Delta w_{uq,2} = \alpha_{u,q} \frac{\partial J}{\partial w_{uq,2}} \quad (A5)$$

avec $J = \frac{1}{2} \|\underline{T} - \underline{\Phi}\|^2$ où $\|\underline{T} - \underline{\Phi}\|^2$ désigne la norme euclidienne.

$$\begin{aligned} \Delta w_{uq,2} &= \alpha_{u,q} \frac{\partial J}{\partial w_{uq,2}} \\ \Delta w_{uq,2} &= \alpha_{u,q} \frac{\partial J}{\partial \Phi_{q,2}} \times \frac{\partial \Phi_{q,2}}{\partial I_{q,2}} \times \frac{\partial I_{q,2}}{\partial w_{uq,2}} \\ \Delta w_{uq,2} &= \alpha_{u,q} \frac{\partial \frac{(T_q - \Phi_{q,2})^2}{2}}{\partial \Phi_{q,2}} \times \frac{\partial \Phi_{q,2}}{\partial I_{q,2}} \times \frac{\partial I_{q,2}}{\partial w_{uq,2}} \end{aligned} \quad (A6)$$

$$\text{avec } \frac{\partial \frac{(T_q - \Phi_{q,2})^2}{2}}{\partial \Phi_{q,2}} = -(T_q - \Phi_{q,2}) \quad (A7)$$

$$\text{et } \frac{\partial \Phi_{q,2}}{\partial I_{q,2}} = 1 \text{ car la fonction d'activation de ce neurone est linéaire} \quad (A8)$$

$$\text{et } \frac{\partial I_{q,2}}{\partial w_{uq,2}} = \Phi_{u,1} \quad (A9)$$

A partir de ces relations, il est aisé de calculer le gradient en remplaçant, (A7, A8 et A9) dans (A6):

$$\Delta w_{uq,2} = -\alpha_{u,q} \times (T_q - \Phi_{q,2}) \times \Phi_{u,1} \quad (A10)$$

D'après la relation de l'algorithme du gradient, la mise à jour des poids synaptiques se réalise suivant la relation (A11) :

$$w_{uq,2}(n+1) = w_{uq,2}(n) - \alpha_{u,q} \times (T_q - \Phi_{q,2}) \times \Phi_{u,1} \quad (A11)$$

Dès que cette première mise à jour est effectuée, il est nécessaire de recalculer l'erreur quadratique sur l'ensemble du réseau.

Calcul du gradient de la fonction coût aux points $w_{pu,l}$

La rétropropagation de l'erreur obtenue à la couche de sortie doit se faire jusqu'à la couche d'entrée. Dans le paragraphe précédent, l'erreur entre la couche de sortie et la deuxième couche cachée a été rétro propagée. Il est maintenant nécessaire de calculer le gradient de la fonction coût appliqués aux poids reliant les deux couches cachées, soit $w_{pu,l}$.

$$\Delta w_{pu,l} = \alpha_{pu} \sum_{u=1}^l \frac{\partial J}{\partial w_{pu,l}} \quad (A12)$$

$$\Delta w_{pu,l} = \alpha_{pu} \sum_{u=1}^l \frac{\partial J}{\partial \Phi_{q,2}} \times \frac{\partial \Phi_{q,2}}{\partial I_{q,2}} \times \frac{\partial I_{q,2}}{\partial \Phi_{u,l}} \times \frac{\partial \Phi_{u,l}}{\partial I_{u,l}} \times \frac{\partial I_{u,l}}{\partial w_{pu,l}}$$

avec $\frac{\partial J}{\partial \Phi_{q,2}} = -(T_q - \Phi_{q,2})$ et $\frac{\partial \Phi_{q,2}}{\partial I_{q,2}} = 1$

$$\frac{\partial I_{q,2}}{\partial \Phi_{u,l}} = w_{uq,k} \quad (A13)$$

$$\frac{\partial \Phi_{u,l}}{\partial I_{u,l}} = 2 \cdot \Phi_{u,l} (1 - \Phi_{u,l}) \quad (A14)$$

$$\frac{\partial I_{u,l}}{\partial w_{pu,l}} = \Phi_{p,0} \quad (A15)$$

$$\text{d'où : } \frac{\partial J}{\partial w_{pu,l}} = -(T_q - \Phi_{q,2}) \times w_{uq,2} \times 2 \cdot \Phi_{u,l} (1 - \Phi_{u,l}) \times \Phi_{p,0} \quad (A16)$$

En remplaçant (A16) dans (A12), la valeur du gradient devient l'équation (A17) et la mise à jour de ces poids est donnée par l'équation (A18) :

$$\Delta w_{pu,l} = -(T_q - \Phi_{q,2}) \times w_{uq,2} \times 2 \cdot \Phi_{u,l} (1 - \Phi_{u,l}) \times \Phi_{p,0} \quad (A17)$$

$$w_{pu,l}(n+1) = w_{pu,l}(n) - \alpha_{pu} \sum_{u=1}^l ((T_q - \Phi_{q,2}) \times w_{uq,2} \times 2 \cdot \Phi_{u,l} (1 - \Phi_{u,l}) \times \Phi_{p,0}) \quad (A18)$$

Comme dans la partie précédente, il faut recalculer l'erreur quadratique sur l'ensemble du réseau après avoir calculé la nouvelle valeur de sortie liée aux nouveaux poids.

Calcul du gradient de la fonction coût aux points $w_{hp,0}$

La dernière étape à réaliser est le calcul du gradient de la fonction coût appliqués aux poids reliant la première couche cachée à la couche d'entrée, soit $w_{hp,0}$.

$$\Delta w_{hp,0} = \alpha_{hp} \sum_{p=1}^j \frac{\partial J}{\partial w_{hp,0}} \quad (A19)$$

$$\Delta w_{hp,0} = \alpha_{hp} \sum_{p=1}^j \frac{\partial J}{\partial \Phi_{q,2}} \times \frac{\partial \Phi_{q,2}}{\partial I_{q,2}} \times \frac{\partial I_{q,2}}{\partial \Phi_{u,1}} \times \frac{\partial \Phi_{u,1}}{\partial I_{u,1}} \times \frac{\partial I_{u,1}}{\partial \Phi_{p,0}} \times \frac{\partial \Phi_{p,0}}{\partial I_{p,0}} \times \frac{\partial I_{p,0}}{\partial w_{hp,0}}$$

$$\text{avec } \frac{\partial J}{\partial \Phi_{q,2}} = -(T_q - \Phi_{q,2}) \quad \text{et} \quad \frac{\partial \Phi_{q,2}}{\partial I_{q,2}} = 1$$

$$\frac{\partial I_{q,2}}{\partial \Phi_{u,1}} = w_{uq,2} \quad \frac{\partial \Phi_{u,1}}{\partial I_{u,1}} = 2 \cdot \Phi_{u,1} (1 - \Phi_{u,1})$$

$$\frac{\partial I_{u,1}}{\partial \Phi_{p,0}} = w_{pu,1} \quad \frac{\partial \Phi_{p,0}}{\partial I_{p,0}} = 2 \cdot \Phi_{p,0} (1 - \Phi_{p,0})$$

$$\frac{\partial I_{p,0}}{\partial w_{hp,0}} = x_h$$

$$\text{d'où } \frac{\partial J}{\partial w_{hp,0}} = -(T_q - \Phi_{q,2}) \times w_{uq,2} \times 2 \cdot \Phi_{u,1} (1 - \Phi_{u,1}) \times w_{pu,1} \times 2 \cdot \Phi_{p,0} (1 - \Phi_{p,0}) \times x_h \quad (A20)$$

La mise à jour des poids reliant les deux couches cachées se réalise alors suivant la relation (A22) après avoir combiné les expressions (A20) et (A21) :

$$\Delta w_{hp,0} = -\alpha_{hp} \sum_{p=1}^j 4(T_q - \Phi_{q,2}) \times w_{uq,2} \times \Phi_{u,1} (1 - \Phi_{u,1}) \times w_{pu,1} \times \Phi_{p,0} (1 - \Phi_{p,0}) \times x_h \quad (A21)$$

$$w_{hp,0}(n+1) = w_{hp,0}(n) + \Delta w_{hp,0} \quad (A22)$$

Ces calculs de gradient et de mises à jour des poids sont à réitérer jusqu'à ce que la fonction coût ait atteint une valeur acceptable. Dès lors l'apprentissage du réseau est réalisé.

BIBLIOGRAPHIE

Bibliographie

- [ALL03.1] : T. Alleau, « *Mémento de l'hydrogène, la pile PEMFC* », rapport d'activités de l'AFH2 (Association Française de l'Hydrogène), avril 2003.
- [ALL03.2] : T. Alleau, « *Mémento de l'hydrogène, les programmes Renault et PSA* », rapport d'activités de l'AFH2 (Association Française de l'Hydrogène), janvier 2003.
- [AMP96] : J.C. Amphlett, R.F. Mann, B.A. Peppley, « *A model predicting transient responses of Proton Exchange Membrane Fuel Cell (PEMFC)* », Journal of Power Sources, vol. 61, pp 183-188, 1996.
- [BAR97] : P. L. Bartlett, « *For valid generalization, the size of the weights is more important than the size of the network* », Neural Information Processing systems, vol. 9, Morgan Kaufman, 1997.
- [BER92] : D.M. Bernardi, M.W. Verbrugge, « *A mathematical model of the solid polymer electrolyte fuel cell* », Journal of Electrochemical Society, vol. 139(9), pp 2477-2491, 1992.
- [BOA92] : B. Boacheng, N.H. Farhat « *Learning networks for extrapolation and radar target identification* », Neural Networks, Vol. 5, Issue 3, pp. 507-529, 1992.
- [BOE01] : D. Boettner, et al., « *Proton Exchange Membrane Fuel Cell system model for automotive vehicle simulation and control* », ASME International Mechanical Engineering Congress and Exposition, vol.41, pp 555-563, New York, novembre 2001.
- [BRO70] : C. G. Broyden, « *The convergence of a class of double-rank minimization algorithms 2 : the new algorithm.* », Journal of the Institute of Mathematics and its Applications, vol. 6, pp 222-231, 1970.
- [BRO01] : A. Browne, « *Representation and extrapolation in multi layer perceptrons* », School of Computing, London Guildhall University, novembre 2001.
- [CHA98] : Chalk S. Chalk, P. Davis, J.A. Milliken, D. Ho, « *Fuel Cell for Transportation* », contractor's annual progress report, FY1998, pp 55-65, novembre 1998.
- [CHA99] : S. Chalk, P. Davis, J.A. Milliken, D. Ho, « *Fuel Cell for Transportation* », Research and development, pp 21-22, juin 1999.
- [BER91] : D.M. Bernardi, M. W. Verbrugge « *Mathematical Model of a Gas Diffusion Electrode Bonded to a Polymer Electrolyte* », AIChE Journal, vol. 37(8), pp 1151-1163, août 1991.
- [CHA00] : S. Chalk, P. Davis, J.A. Milliken, D. Ho, « *Transportation Fuel Cell power systems* », annual progress report, FY2000, pp 127-145, octobre 2000.

Bibliographie

- [CON00] : L. Constant, « *Modélisation de dispositifs électriques par réseaux de neurones en vue de l'émulation temps réel* », Thèse de doctorat de l'Institut National Polytechnique de Toulouse, 2000.
- [CYB89] : G. Cybenko, « *Continuous value neural networks with two hidden layers are sufficient* », Math Control Signals and Systems 2, pp. 303-314, 1989.
- [DEC01] : John M. Decicco, « *Fuel Cell Vehicles, Technology, Market and Policy issues* », SAE Research report, ouvrage paru en 2001.
- [DRE02] : G. Dreyfus, J.M. Martinez, M. Samuelides, « *Réseaux de neurones:méthodologie et applications* », collection Eyrolles, ouvrage paru en 2002.
- [EFR93] : B. Efron, R. J. Tibshirani, « *An introduction to Bootstrap* », Chapman Hall, 1993.
- [ELI97] : F. Elie, « *Conception et réalisation d'un système utilisant des réseaux de neurones pour l'identification et la caractérisation, à bord de satellites, de signaux transitoires de type sifflement* », Thèse de doctorat de l'université d'Orléans, 1997.
- [ERI02] : MA. Erickson, JK Kruschke « *Rule-based extrapolation in perceptual categorization* », Psychon Bull Revue, vol.9 n°1, pp. 160-168, 2002.
- [FAR02] : J. Farenc, « *L'argus de l'automobile* », Août 2002.
- [FLE70] : R. Fletcher, « *A new approach to variable metric algorithms* », The computer journal, vol.13 n°3, pp. 317-322, 1970.
- [FRI99] : D.J. Friedman, « *Maximizing Direct Hydrogen PEM Fuel Cell Vehicle Efficiency. Is Hybridization is necessary?* », Fuel Cell Power for Transportation, SAE Publication paper 1999-01-0530, pp. 9-17, 1999.
- [FRI03] : W. Friede, « *Modélisation et caractérisation d'une pile à combustible du type PEM* », Thèse de doctorat de l'institut national polytechnique de Lorraine, août 2003.
- [FUN89] : K. Funahashi, « *On the approximate realization of continuous mappings by neural networks.* », Neural Networks, vol. 2, pp 183-192, 1989.
- [FUR04] : P. Furon, « *<http://www.ensicaen.isma.fr>* », Maître de conférence à l'ENSICAEN , cours en ligne, octobre 2004.
- [GAL01] : R. Galley et C. Gatignol, « *Les perspectives offertes par la technologie de la Pile à Combustible* », rapport de l'office parlementaire d'évaluation des choix scientifiques et technologiques, juin 2001.

Bibliographie

- [GER96] : L. Gerbaux, « *Modélisation d'une pile à combustible de type hydrogène/air et validation expérimentale* », Thèse de doctorat de l'Institut National Polytechnique de Grenoble, novembre 1996.
- [GOL70] : D. Goldfarb, « *A family of variable metrics methods derived by variational means* », Mathematics of Computation, vol.24, pp. 23-26, 1970.
- [HAI03] : Z. Haiyan, C. Yimin, Shunhua L., « *Hydrogen storage for carbon nanotubes synthesized by the pyrolysis method using lanthanum nickel alloy as catalyst* », Journal of Applied Physics, vol. 94(10), pp 6417-6422, novembre 2003.
- [HAR03] : F. Harel, X. François, S. Jemeï et S. Moratin, « *Conception et réalisation d'un banc d'essai pour piles à combustibles à membrane de faibles puissances* », rapport LTE n° 0310, L2ES-INRETS, mai 2003.
- [HAY99] : S. Haykin, « *Neural Networks, a comprehensive foundation* », 2nd ed. Upper Saddle River, NJ Prentice Hall, 1999.
- [HER03a] : M. Herr, A. Jentys, M. Lang, « *On the potential and limitation of hydrogen storage in microspheres* », Energie-Technologie, Allemagne, 2003.
- [HER03b] : A. Hernandez, « *Neural Network Modeling of the Motor Compressor Group feeding a Hydrogen Fuel Cell* », rapport de DEA, Université de Technologie de Belfort Montbéliard, août 2003.
- [HIS98] : D. Hissel, « *Contribution à la commande de dispositifs électrotechniques par logique floue* », thèse de doctorat de l'Institut National Polytechnique de Toulouse, novembre 1998.
- [HIS02] : D. Hissel, S. Jemeï, M.C. Péra, J.M. Kauffmann, « *Fuzzy diagnosis model of Fuel Cell power generators for automotive applications* », Electrimacs, 7th International Conference on Modeling and Simulation of Electrical Machines, Converters and Systems, Montreal, 2002.
- [IM01] : « <http://eivind.imm.dtu.dk/teaching/04364/04364prac.html> », Informatics and Mathematical Modelling, notes de travaux pratiques, Technical University of Denmark, 2001.
- [JEM01] : S. Jemeï, « *Mise en place et étude expérimentale d'une pile à combustible de type PEM* », rapport de DEA, Université de Franche-Comté, septembre 2001.
- [JEM02] : S. Jemeï, D. Hissel, M.C. Péra, J.M. Kauffmann, « *Black Box Modeling of Proton Exchange Membrane Fuel Cell Generators* », IECON'02, conférence IEEE, Séville, Espagne, novembre 2002.

Bibliographie

- [JEM03a] : S. Jemeï, « *Modélisation neuronale d'un système pile à combustible dédié au transport terrestre* », congrès jeunes chercheurs, JCGE'03, pp. 33-37, Saint Nazaire, France, juin 2003.
- [JEM03b] : S. Jemeï, D. Hissel, M.C. Péra, J.M. Kauffmann, « *On-board fuel cell power supply modeling on the basis of neural network methodology* », Journal of Power Sources, Volume 124 Issue 2, pp 479-486, septembre 2003.
- [JEM04] : S. Jemeï, D. Hissel, M.C. Péra, J.M. Kauffmann, « *Dynamical Recurrent Neural Network towards Modeling of On-board Fuel Cell Power Supply* », ISIE'04, conférence IEEE, pp. 471-476, Ajaccio, France, mai 2004.
- [JOH01] : K. Johansson, P. Alvfors, « *Steady-State Model of a PEMFC for Automotive applications* », Proceeding International Symposium ECOS, pp. 725-736, Pays-Bas, 2001.
- [KAL01] : A. Kalogirou, « *Artificial Neural Networks in renewable energy systems applications: a review* », Renewable and sustainable Energy reviews, pp. 373-401, mars 2001.
- [KIO03] : K. Kinoshita « *Electrochemical uses of carbon* », Electrochemistry Encyclopedia, janvier 2001.
- [KIN01] : L.C. Kiong, M. Rajeswri, M.V.C. Rao, « *Extrapolation detection and novelty-based node insertion for sequential growing multi-experts network* », Applied Soft Computing, vol. 3, Issue 2, pp. 159-175, septembre 2003.
- [LAN90] : K. J. Lang, A.H. Waibel, G.E Hinton, « *A time delay neural network architecture for isolated word recognition* », Neural Networks vol. 3, pp. 23-43, 1990.
- [LAW96] : S. Lawrence, C. Lee Giles, A. Tsoi, « *What size neural network gives optimal generalization? Convergence properties of backpropagation* », Technical report, NEC research institute, University of Maryland Princeton, 1996.
- [LEE03] : W. Y. Lee, G.G. Park, T. H. Yang, Y. G. Yoon, C. S S. Kim, « *Empirical modelling of polymer electrolyte membrane fuel cell performance using artificial neural network* », Journal of Hydrogen Energy, Volume 29 , pp 961-966, janvier 2003.
- [LUT03] : A. Lutz, R. Bradshaw, L. Bromberg, A. Rabinovich, « *Thermodynamic analysis of hydrogen production by partial oxidation reforming* », International Journal of Hydrogen Energy, Volume 29 , pp 809-816, septembre 2003.
- [MAC92] : D.J.C. Mackay, « *Bayesian interpolation* », Neural Computation, vol.4 n°3, pp. 415-447, 1992.

Bibliographie

- [MAS03] : S. Masashi, T. Taishi, « *Recent progress in hydrogen adsorption in single-walled carbon nanotube systems* », AIP conference proceedings, vol. 685(1), pp 573-576, octobre 2003.
- [MOR98] : Y. Morere, « *Les réseaux de neurones récurrents* », rapport bibliographique, Laboratoire d'Automatique, de Mécanique et d'Informatique industrielles et Humaines de Valenciennes, 1998.
- [MOS00] : G. Mostafa, A. Farag, E. Essock « *Multimodality Image Registration and Fusion Using Neural Network* », Computer Vision and Image Processing Laboratory, USA, 2000.
- [NAS90] : J.C. Nash, « *Compact Numerical Methods for Computers: linear algebra and function minimization* », Ed. Adam Hilger, 1990.
- [NGU93] : T. Nguyen, R. White, « *A water and heat management model for Proton Exchange Membrane Fuel Cell* », Journal of Electrochemical Society, vol. 140(8), pp 2178-2186, 1993.
- [OUS98] : Y. Oussard, « *Réseaux d'ondelettes et réseaux de neurones pour la modélisation statique et dynamique de processus* », Thèse de doctorat de l'université Pierre et Marie Curie, 1998.
- [PAC00] : « *Points durs technologiques des générateurs à Pile à Combustible et travaux du réseau PACo* », rapport d'activité du réseau PACo, 2000.
- [PER03] : K.E. Percy, M. Ferretti, « *Air pollution and forest health: toward new monitoring concepts* », Environmental Pollution, vol. 130, pp 113-126, juillet 2004.
- [PES98] : W. Peschka, V. Springer, « *Liquid hydrogen, fuel of the future* », Autriche, 1998.
- [PIC98] : D.E. Picot, « *Etude numérique et expérimentale des écoulements dans une pile à combustible PEM adaptable aux applications embarquées* », Thèse de doctorat de l'école des Mines de Paris, 1998.
- [POW76] : M.J.D. Powell, « *Some global convergence properties of a variable metric algorithm for minimization without exact line searches* », Nonlinear Programming, SIAM-AMS Proceedings 9, 1976.
- [PUL02] : E. Puliafito, M. Guevara, C. Puliafito, « *Characterization of urban air quality using GIS as a management system* », Environmental Pollution, vol. 122, pp 105-117, juin 2002.
- [REU95] : A. Faure, « *Algorithmes génétiques et réseaux de neurones, commande et perception* », ouvrage, édition HERMES, 1998.

Bibliographie

- [ROD00] : P. Rodatz, L. Guzzella, L. Pellizzari « *System Design and Supervisory Controller Development for a Fuel Cell Vehicle* », proceeding First International Federation of Automatic Control Conference on Mechatronic Systems, vol. 1 pp. 173-178, Allemagne, 2000.
- [RUM86] : D. Rumelhart, G. Hinton, R. Williams « *Learning Internal Representations by Error Propagation* », Parallel Distributed Processing, MIT Press, 1986.
- [SAP90] : G. Saporta, « *Probabilités. Analyse des données et statistique* », éditions Technip, 1990.
- [SAR95] : O. Sarzeaud, « *Les réseaux de neurones : Contribution à une théorie* », Ouest éditions, décembre 1995.
- [SCH88] : Z. Schreter, « *Short term memory long term memory interactions in connectionist simulations of physiological experiments on list learning* », nEuro'88, Paris, juin 1988.
- [SCH00] : P. Schott, J.P. Poirot, P. Baurens, « *Modélisation et simulation de la source d'énergie du véhicule HYDRO-GEN* », proceeding colloque Pile à Combustible et interface pour les transports, pp 137-143, France, novembre 2000.
- [SHA70] : D.F. Shanno, « *Conditioning of quasi-newton methods for function minimization* », Mathematics of Computation, vol.24, pp. 641-656, 1970.
- [SHE02] : C. Shen, G. Y. Cao, X. J. Zhu, X. J. Sun, « *Nonlinear modelling and adaptive fuzzy control of MSFC stack* », Journal of Process Control, vol.12, pp. 831-839, 2002.
- [STR00] : M. Stricker, « *Réseaux de neurones pour le traitement automatique du langage : conception et réalisation de filtres d'informations* », thèse de doctorat de l'université Pierre et Marie Curie, Paris VI, décembre 2000.
- [TEK03] : M. Tekin, D. Hissel, M.C. Pera, J.M. Kauffmann « *Energy optimization of a fuel cell generator: modelling and experimental results* », EPE'03 Power Electronics Conference, Toulouse, septembre 2003.
- [TEK04] : M. Tekin, D. Hissel, M.C. Pera, J.M. Kauffmann « *Energy Mangement Strategy for Embedded Fuel Cell System using Fuzzy Logic* », ISIE'04, pp. 501-506, Ajaccio, mai 2004.
- [UNF01] : UNFCC (United Nations Framework on Climate Change), « *The Kyoto Protocol to the Convention on Climate change* », <http://unfccc.int/resource/docs/convkp/kpeng.pdf>.

Bibliographie

- [URB95] : D. Urbani, « *Méthodes statistiques de selection d'architectures neuronales: application à la conception de modèles de processus dynamiques* », thèse de doctorat de l'université de Paris VI, novembre 1995.
- [WEI03] : M. A. Weiss, J. B. Heywood, A. Schafer, « *Comparative assessment of fuel cell cars* », Massachussets Institute of Technology, February 2003.
- [WOL69] : P. Wolfe, « *Convergence conditions for ascent methods* », S.I.A.M. Review, vol.11, pp. 226-235, 1969.
- [ZID03] : R. Zidan, M. Apparao, Ming A., « *Doped carbon nanotubes for hydrogen storage* », Hydrogen Fuel Cells and infrastructure technologies, FY2003 progress report, 2003.
- [ZHA98] : G. Zhang, B.E. Patuwo and M.Y. Hu, « *Forecasting with Neural Networks: The state of the art* », Int. J. Forecast, vol. 14, pp. 35-62, 1998.