

Vers une méthodologie générique de modélisation par réseaux de neurones des systèmes énergétiques dans le bâtiment

Amine Lazrak^{1,2}, Gilles Fraisse², Antoine Leconte¹, Philippe Papillon¹, Bernard Souyri²

¹ Laboratoire des Systèmes Thermiques pour le Bâtiment, INES, CEA,
50, Avenue du Lac Léman, F-73375 Le Bourget-du-Lac,

² Laboratoire Optimisation de la Conception et Ingénierie de l'Environnement, UMR 5271
Polytech Annecy-Chambéry, Campus scientifique, Savoie Technolac, 73376 Le Bourget du Lac,
amine.lazrak@cea.fr; gilles.fraisse@univ-savoie.fr; bernard.souyri@univ-savoie.fr; antoine.leconte@cea.fr;
philippe.papillon@cea.fr

RESUME. L'objectif de cette étude est de développer une méthodologie générique de modélisation du comportement des systèmes énergétiques dans le bâtiment. Une modélisation « boîte noire » fiable par réseaux de neurones (RN) permet d'identifier des modèles complets sans avoir besoin de connaissances avancées sur le fonctionnement interne du système. La connaissance des entrées et des sorties est suffisante. Pour le système solaire combiné (SSC) étudié, les résultats des travaux montrent que le modèle neuronal dynamique est plus performant que le modèle neuronal statique, qui ne reproduit pas fidèlement la dynamique du système, notamment en raison du composant de stockage thermique. Le modèle RN dynamique développé permet de prédire avec une précision très acceptable les performances énergétiques annuelles du système modélisé à partir d'une séquence d'apprentissage de 12 jours. Il est par ailleurs possible de prédire le fonctionnement du SSC dans un environnement autre que celui de l'apprentissage grâce aux capacités de généralisation du RN.

MOTS-CLÉS : Modélisation, Réseaux de neurones, systèmes thermiques pour le bâtiment.

ABSTRACT. The aim of this study is to create a generic methodology to model solar thermal systems for building application. Neural networks (NN) prove to be suitable to tackle such problem. Reliable "black box" NN modeling is able to identify global models of the system without any advanced knowledge about its internal operating principle. Knowing the system global inputs and outputs is sufficient. Results concerning the solar combi-system modeling show that a dynamic NN model is more efficient than a static one. The latter does not learn the dynamic of the solar system especially due to the heat storage component. NN model developed is able to predict, with a good precision degree, the annual energy performance of the system based on a learning sequence of only 12 days. Because of the NN generalization ability, it is possible to predict the solar combi-system operating under an environment different from the one used during learning stage.

KEYWORDS: Modeling, Neural networks, thermal systems for building application.

1. INTRODUCTION

Dans le contexte énergétique français actuel (Albertini & Bottin, 2013), le secteur résidentiel et tertiaire présente un potentiel important d'économies d'énergie, notamment des énergies traditionnelles qui sont disponibles en quantité limitée, et de réduction des émissions de gaz à effet de serre. Les systèmes thermiques intégrant des sources d'énergies renouvelables peuvent jouer un rôle déterminant. Dans ce contexte, le marché des systèmes solaires thermiques a subi dans les dernières années quelques déclins. Les experts en la matière pointent du doigt l'absence de garantie de performances de la part des fabricants, ou de suivi une fois que l'installation est réalisée ; ce constat

résulte en partie de l'absence de méthode satisfaisante pour évaluer au préalable la performance énergétique du matériel.

Les systèmes thermiques pour le bâtiment mêlent de plus en plus plusieurs sources d'énergie, dont certaines sont disponibles par intermittence. Par ailleurs, de plus en plus d'équipements sont multifonctions, intégrant ainsi chauffage et production d'eau chaude sanitaire, mais également la climatisation. L'évaluation de leurs performances devient d'autant plus difficile qu'un nombre grandissant d'équipements est préfabriqué en usine et il devient délicat d'en extraire un composant pour le tester sans dégrader le système. Face à cette complexité croissante, les méthodes d'essais d'un équipement en régime permanent d'une part, et les méthodes d'essais dédiées à un seul composant d'autre part, montrent leurs limites (Leconte, et al. 2012). Il devient obligatoire d'envisager le système dans sa globalité, en intégrant les fonctionnements à charge partielle, ainsi que les logiques de régulation dont le rôle est de plus en plus prépondérant dans la recherche de l'efficacité énergétique.

L'article présente les premiers résultats du développement d'une méthodologie de modélisation générique dans le cas d'un système solaire combiné (SSC). Une telle méthodologie permettra ensuite de caractériser n'importe quel système à partir d'un test de courte durée sur banc d'essai semi-virtuel. *In fine*, grâce à cette technique il sera possible de déterminer les performances du système testé pour l'environnement réel auquel il sera destiné.

2. APPROCHE SCIENTIFIQUE MISE EN ŒUVRE

2.1. PROCEDURE ACTUELLE DE TEST DE COURTE DUREE (SCSPT)

Pour répondre à des contraintes de coûts qui soient acceptables par l'industrie, les essais en banc semi-virtuel doivent être le plus court possible et offrir en retour une richesse d'information convenable pour, d'une part avoir une qualification satisfaisante représentative des performances du système, et d'autre part réussir à prédire, grâce à des modèles simplifiés, ces performances dans d'autres environnements climatiques.

Parmi les procédures de test de systèmes figure la méthode SCSPT (Leconte, et al. 2012) qui est une approche de test global. Elle consiste à réaliser un test réel du système à qualifier dans un banc d'essai semi-virtuel (*Figure 1*). Les sollicitations du système global engendrées par son environnement, telles que les besoins en chauffage, climatisation, eau chaude sanitaire, etc., sont émulées par des modules hydrauliques et des résistances électriques. Ces derniers sont pilotés par un algorithme définissant le climat et les caractéristiques du bâtiment pendant le test. Dans le cas des SSC, la méthode SCSPT utilise un environnement virtuel précis pour évaluer les performances du SSC à partir d'une séquence de 12 jours de test sur le banc semi-virtuel. L'objectif est de rendre proportionnelle la consommation d'énergie auxiliaire du système testé pendant la séquence de 12 jours avec celle correspondant à l'année entière pour couvrir les mêmes besoins et pour le même climat. Le processus de test selon la méthode SCSPT est constitué de quatre phases : i) la détermination de la séquence de test, ii) le test physique, iii) l'acquisition des données et iv) le traitement de ces dernières et l'extrapolation des résultats à l'année. A l'issue du test, il est possible de caractériser avec un bon degré de fiabilité les performances énergétiques du système testé sur une année pour le même environnement. Pourtant, à l'heure actuelle, il n'est pas possible de caractériser complètement les

performances du système à qualifier avec la procédure actuelle de la méthode SCSPT. Les résultats fiables sont limités à des environnements très proches des conditions de tests.

2.2. LA MODELISATION DE TYPE « BOITE NOIRE »

Une amélioration de la procédure SCSPT, dans le cas de figure des SSC avec un appoint chaudière à gaz, a été proposée par (Leconte, et al. 2012). Elle consiste à réaliser une modélisation de type boîte grise combinant des modèles simplifiés (boîte blanche) de comportement et un réseau de neurones (boîte noire). Les résultats ont été prometteurs, dans la mesure où il a été possible de prédire la consommation du SSC testé selon la méthode SCSPT sous d'autres environnements (variétés de climats et de types de bâtiments) que celui du test. Cependant, les résultats de modélisation sont étroitement dépendants de la partie boîte blanche et donc de sa fiabilité.

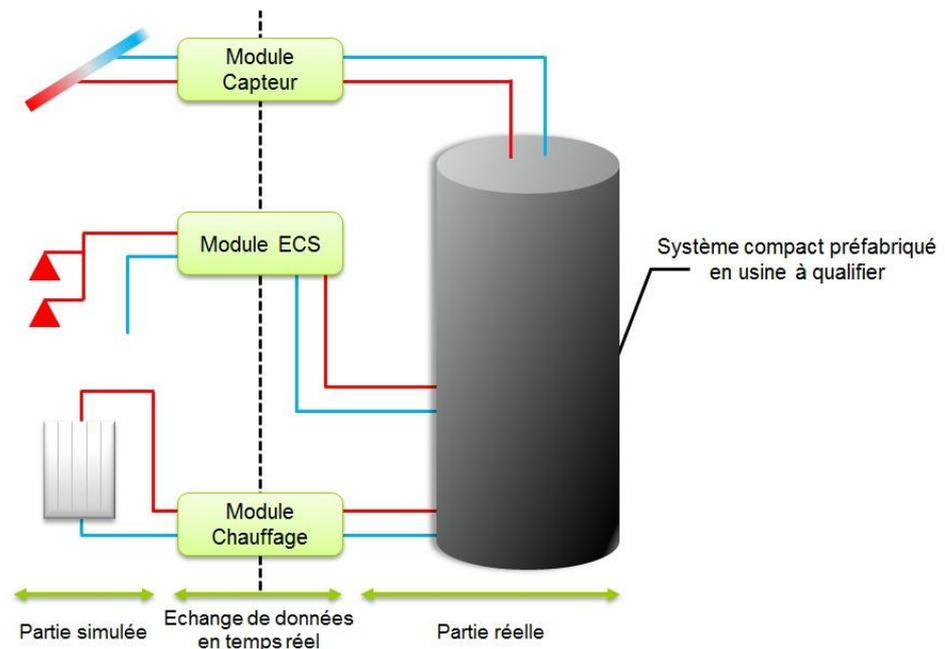


Figure 1 : Illustration du banc d'essai semi-virtuel

L'utilisation d'une modélisation complètement « boîte noire » devient pertinente dans une démarche de développement d'une méthodologie générique. Aussi, l'amélioration proposée dans cet article consiste à remplacer la 4^{ème} phase de la procédure de test SCSPT par une phase d'identification d'un modèle global du système testé en se basant seulement sur les données entrées-sorties récoltées. En effet, une modélisation « boîte noire » fiable par RN permet d'identifier des modèles complets sans avoir besoin de connaissances avancées sur le fonctionnement interne du système global. La modélisation est la représentation d'une réalité visible ou observable. Modéliser un processus consiste donc à lui donner une représentation mathématique semblable à l'équation (1) exprimant les relations entre ses entrées et ses sorties. Les vecteurs réels X et Y représentent respectivement les entrées et sorties du système. L'identification d'un modèle global consiste donc à approximer cette fonction ' F ' définissant le système global.

$$Y = F(X) \quad (1)$$

L'objectif de la modélisation boîte noire est de calculer une fonction \hat{F} approximant F moyennant la connaissance d'un ensemble fini de données d'apprentissage (X_i, Y_i) où $i = 1 \dots N$ et N le nombre d'échantillons disponibles à l'issue d'un test expérimental.

2.3. LES RESEAUX DE NEURONES ET LEURS TECHNIQUES DE CONCEPTION

2.3.1. LES RESEAUX DE NEURONES

Les neurones formels sont des fonctions mathématiques paramétrables mimant le fonctionnement des neurones biologiques. Un neurone, élément de base d'un RN, réalise une fonction d'une sommation pondérée, par des coefficients appelés poids synaptiques w_j^l , de ses entrées x_j pour donner une sortie z_l avec l le numéro du neurone. L'opération réalisée par un neurone est traduite par l'équation (2). La fonction f_l est appelé fonction d'activation du neurone.

$$y_l = \sum_{j=1}^K w_j^l x_j, z_l = f_l(y_l) \quad (2)$$

Des neurones interconnectés forment ce qui est communément appelé un RN. Parmi les différentes architectures neuronales qui existent figure le perceptron multicouche (PMC). Ce dernier est un réseau formé de neurones arrangés en couches : une couche d'entrée, une ou plusieurs couches cachées et une couche de sortie (voir **Figure 2**). Les neurones sont complètement connectés dans un seul sens, des entrées aux sorties. Pour un RN avec E entrées, C neurones dans la couche cachée et S sorties, la sortie numéro s du RN peut être obtenue selon l'équation (3) :

$$y_s = f_s^S \left(\sum_{c=1}^C w_{c,s}^S f_c^C \left(\sum_{e=1}^E w_{e,c}^C x_e \right) \right) \quad (3)$$

Une description détaillée des RN peut être consultée dans l'ouvrage (Dreyfus, 2004).

La raison d'être des PMC réside dans leur faculté d'approximer toute fonction continue et bornée (Cybenko, 1989), voire toute fonction continue par morceaux et bornée (Rastko R. & Frank L., 1999). Il a été montré qu'un PMC, avec une seule couche cachée contenant suffisamment de neurones avec des fonctions d'activation type sigmoïde, et des neurones en sortie linéaires, est un approximateur universel de fonction à un degré de précision arbitraire.

La modélisation par RN est largement appliquée, notamment pour répondre à un besoin toujours croissant concernant la prédiction des performances et le contrôle-commande dans le secteur des énergies renouvelables. Les RN ont montré leur pertinence notamment par leur capacité à résoudre des problèmes complexes, non-linéaires et multi-variables (Gang & Wang, 2013) (Kalogirou, 2001).

Les modèles neuronaux peuvent apprendre à partir d'exemples et tolèrent l'imprécision des mesures et des perturbations, ainsi que les données incomplètes (Kalogirou, 2001). L'apprentissage d'un RN est le processus de détermination des poids synaptiques, moyennant des données expérimentales, de telle sorte que la fonction finale réalisée par ce dernier soit semblable à la vraie relation entrées-sorties définie par le système. Pour tous ces éléments cités ci-dessus, le choix des RN pour réaliser une modélisation boîte noire du système étudié s'avère bien adapté.

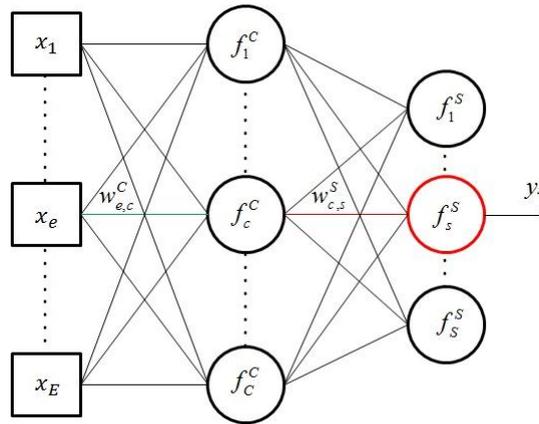


Figure 2 : Exemple d'un perceptron multicouche avec une seule couche cachée située au milieu

2.3.2. PROPOSITION D'UNE NOUVELLE CONFIGURATION ENTREES-SORTIES GENERIQUE

La détermination de la configuration entrées-sorties du modèle est une étape cruciale dans le processus de modélisation car elle fixe les variables d'entrées nécessaires au calcul des sorties. De plus, pour que la méthodologie soit générique, et donc extrapolable à différents systèmes dans le bâtiment, il est indispensable que les entrées et sorties soient valables pour tous les systèmes. Nous avons retenu une approche en « puissances » correspondant aux besoins et sources disponibles. A titre d'exemple dans le cas d'un SSC, les entrées du système sont d'une part les besoins énergétiques du bâtiment (chauffage et eau chaude sanitaire), et d'autre part l'énergie solaire incidente sur le capteur. Evaluer la performance du SSC nécessite de connaître l'énergie d'appoint consommée. Ainsi, la sortie du modèle correspond à l'énergie d'appoint (ressource non renouvelable) nécessaire pour répondre aux besoins. Une telle configuration est donc formée de trois entrées et une sortie (**Figure 3**). La variable de sortie P_{app} représente la puissance de l'appoint. Les variables d'entrée P_{ecs} , P_{sol} , P_{ch} sont respectivement la puissance demandée en eau chaude sanitaire, le flux d'énergie solaire à la surface du capteur et la demande en chauffage du bâtiment.

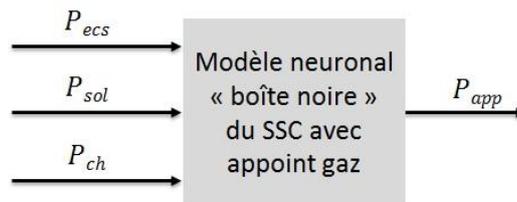


Figure 3 : Configuration entrées-sortie considérée pour la modélisation du SSC

2.3.3. PROCESSUS DE CONCEPTION DU RN

La qualité du RN dépend énormément de la qualité du processus de conception de celui-ci. En l'état actuel, il n'existe aucune technique générique permettant la détermination des paramètres et éléments optimaux qui définissent la formation d'un RN. Les données disponibles pour l'apprentissage étant limitées, l'utilisation d'un algorithme basé sur la régularisation bayésienne (MacKay, 1992) s'avère dans ce cas le plus adapté. Ce dernier consiste à appliquer l'algorithme d'optimisation de Levenberg-Marquardt à la fonction d'erreur combinée avec un terme de régulation des poids synaptiques. Cette régulation permet d'avoir des poids synaptiques régulés de faible amplitude ce qui améliore le pouvoir de généralisation du RN pour des données inconnues sans avoir besoin de partitionner les données disponibles pour l'entraînement.

Le théorème cité ci-dessus stipule qu'une seule couche cachée est suffisante. Selon (Leconte, et al. 2012) il est possible de fixer le nombre maximal de neurones à admettre dans cette dernière. Dans le but d'éviter les minimums locaux il est indispensable de créer plusieurs RN avec différents nombres de neurones et selon plusieurs initialisations. La sélection du modèle optimal est réalisée à la base du critère d'information bayésienne *BIC* (Schwarz, 1978) donné par l'équation (4) et de l'erreur quadratique moyenne *MSE* (q est le nombre de poids synaptiques).

$$BIC = N \ln(MSE) + q \ln(N) \quad (4)$$

Il permet de détecter les RN qui réalisent un bon compromis biais-variance, donc de sélectionner, parmi les RN créés, un RN qui s'est bien adapté à l'échantillon d'apprentissage tout en ayant une bonne capacité de généralisation. Ainsi la qualité d'un modèle est une fonction décroissante du *BIC*.

3. CAS D'UN SYSTEME SOLAIRE COMBINE

3.1. PREPARATION DES DONNEES POUR L'APPRENTISSAGE DU RN

Dans le cadre du développement de cette méthodologie, les données utilisées pour faire apprendre au RN le comportement interne d'un SSC sont issues d'une simulation en 12 jours d'un modèle détaillé fiable du SSC mis en œuvre avec le logiciel TRNSYS. Le modèle TRNSYS étant validé (Leconte, et al. 2012), il peut donc se substituer au test réel du système dans le banc d'essai semi-virtuel. Il est à noter que la méthodologie envisagée une fois finalisée se passera de l'utilisation du modèle détaillé. Ce dernier, dans le présent article, constituera la référence pour la qualification des résultats de prédictions du modèle neuronal. La simulation a été réalisée sous le climat de Zurich avec un bâtiment SFH60 (bâtiment abritant une seule famille avec 60 kWh/m².an de besoin en chauffage pour le climat de Zurich). Une moyenne mobile de 5 pas de temps (de 30 minutes) a été appliquée aux données brutes dans le but d'alléger les pics de mise en marche de la chaudière. Ceci facilite l'apprentissage. Les variables d'entrée et de sortie sont normalisées entre -0,5 et 0,5.

3.2. ANALYSE DES RESULTATS

Deux types de modèles ont été explorés. Le premier est statique (**Figure 3**), tandis que le deuxième utilise un RN dynamique. Ce dernier s'obtient en bouclant la sortie du RN statique à l'entrée avec un retard d'un seul pas de temps. L'entraînement, ainsi que la sélection des deux RN, ont été réalisés selon la procédure décrite dans cet article. Le RN avec 3 neurones dans la couche cachée et issu de la 5^{ème} initialisation est le réseau optimal pour le modèle dynamique. La même stratégie de conception a permis de sélectionner un RN statique avec 3 neurones dans la couche cachée et issu de la 2^{ème} initialisation. Les deux modèles construits ont été utilisés pour prédire l'énergie d'appoint (en kWh/m²/an) que le SSC aurait consommée sur une année s'il était installé dans 9 environnements différents de celui qui a été utilisé pour construire la base d'apprentissage (Zurich). Les résultats de la **Figure 4** permettent de comparer la qualité de prédiction des deux modèles neuronaux avec les valeurs de référence obtenues en se basant sur le modèle développé sous TRNSYS.

Globalement le modèle dynamique prédit avec le degré de précision attendu l'énergie consommée par l'appoint pour tous les environnements. L'erreur relative sur l'énergie consommée est inférieure dans tous les cas à 4%, sauf pour l'environnement de Barcelone SFH30 où l'erreur atteint 40% mais

pour une très faible quantité d'énergie. Le modèle dynamique se montre clairement plus efficace que le modèle statique. En effet, pour le RN statique, l'erreur relative sur l'énergie consommée est inférieure à 5% seulement pour les deux environnements les plus proches des conditions d'apprentissage i.e. Zurich SFH60 et Stockholm SFH60. Dans les autres conditions, l'erreur est comprise entre 10% et 60%.

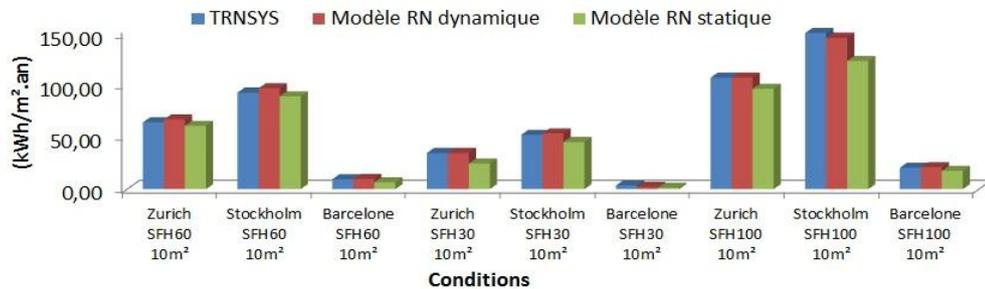


Figure 4 : Consommation annuelle de l'appoint prédite, dans différentes conditions, par les deux modèles neuronaux et calculée par le modèle détaillé TRNSYS de référence du système étudié

La qualité de prédiction du RN dynamique par rapport au modèle statique est explicitée sur la **Figure 5**, qui représente le coefficient de détermination R^2 calculé entre les données prédites par le RN et les données de référence dans différentes conditions. Les coefficients calculés sont généralement supérieurs à 0,9 sauf pour le climat de Barcelone. De telles valeurs montrent que le modèle neuronal dynamique prédit précisément non seulement l'énergie totale consommée, mais aussi l'évolution de l'appel de puissance de la chaudière au fil des jours. La disposition d'une telle information peut s'avérer utile pour comprendre le fonctionnement du système. Ainsi il serait possible d'utiliser le modèle pour un problème de contrôle-commande. Sur la **Figure 6** est représentée l'évolution de la puissance de l'appoint en fonction du temps sur une année (coefficient R^2 de l'ordre de 0,96).

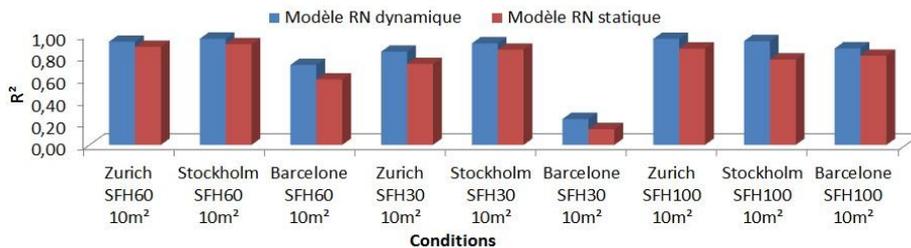


Figure 5 : Comparaison du coefficient R^2 caractérisant la corrélation entre les données prédites et réelles TRNSYS entre le modèle dynamique et statique pour différentes conditions.

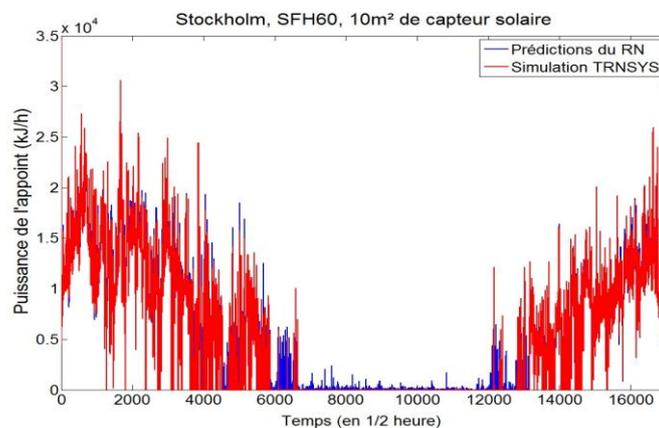


Figure 6 : Puissances de la chaudière prédite par le RN dynamique et calculée par le modèle TRNSYS

La bonne adéquation entre les prédictions du RN et les simulations TRNSYS démontre la pertinence de l'approche de modélisation générique envisagée. Comme les systèmes thermiques actuels sont préfabriqués en usine, il est très difficile d'en concevoir un modèle physique détaillé car des paramètres indispensables sont inconnus tels que coefficients d'échange, rendements, logique de régulation etc. Les RN permettent de pallier cette difficulté car la connaissance des entrées/sortie du système (suite à un test sur banc d'essai) est suffisante pour les développer. Le temps d'une simulation avec un RN est moins de 6s alors qu'une simulation sous TRNSYS prend 10min. Les RN sont donc la solution à la problématique soulevée en introduction et sont moins couteux en temps de calcul.

4. CONCLUSIONS ET PERSPECTIVES

Les résultats de l'étude montrent que le modèle neuronal dynamique est plus performant que le modèle neuronal statique qui ne reproduit pas fidèlement la dynamique du système, notamment en raison du composant de stockage thermique. La configuration entrées-sorties utilisée s'est avérée pertinente et cohérente avec la perspective de développer une méthodologie générique.

Il est par ailleurs possible de prédire le fonctionnement du système étudié dans un environnement autre que celui de l'apprentissage grâce aux capacités de généralisation du modèle neuronal. Le RN développé trouve ses limites pour les environnements très différents de celui de la séquence d'apprentissage comme Barcelone. En perspective, nous allons améliorer la qualité du choix de la séquence d'apprentissage en l'enrichissant avec des données issues de plusieurs environnements. Cela permettra de parfaire la méthodologie proposée en termes d'aptitude à généraliser et éventuellement de réduction de la durée de la séquence d'apprentissage.

Ce travail est financé par l'Agence de l'Environnement et de la Maîtrise de l'Energie et l'Institut National des Sciences et Techniques Nucléaires.

BIBLIOGRAPHIE

- Albertini, J.-P., & Bottin, A. (2013). *Bilan énergétique de la France pour 2012*.
- Cybenko, G. (1989). Approximation by Superpositions of a Sigmoidal Function. *Math. Control Signals Systems*, 2, 303-314.
- Dreyfus, G. (2005). *Neural networks methodology and applications*. Springer.
- Gang, W., & Wang, J. (2013). Predictive ANN models of ground heat exchanger for the control of hybrid ground source heat pump systems. *Applied Energy*.
- Kalogirou, S. (2001). Artificial neural networks in renewable energy systems application: a review. *Renewable and Sustainable Energy Reviews*, 5, 373-401.
- Leconte, A., Achard, G., & Papillon, P. (2012). Global approach test improvement using a neural network model identification to characterise solar combisystem performances. *Solar Energy*, 2001-2016.
- MacKay. (1992). *Proceedings of the International Joint Conference on neural networks*, (pp. 415-447).
- Rastko R., S., & Frank L., L. (2002, May). Neural network approximation of piecewise continuous functions: application to friction compensation. *Ieee Transactions On Neural Networks*, 13(3).
- Schwarz, G. E. (1978). Estimating the dimension of a model. *Analys of statistics*, 461-464.