

Utilisation de machines apprenantes pour la prédiction en thermique du bâtiment

Alexandra Delorme-Costil, Jean-Jacques Bezian, Olivier Farges

► **To cite this version:**

Alexandra Delorme-Costil, Jean-Jacques Bezian, Olivier Farges. Utilisation de machines apprenantes pour la prédiction en thermique du bâtiment. Congrès Français de Thermique, May 2016, Toulouse, France. 2016. <hal-01610890>

HAL Id: hal-01610890

<https://hal.archives-ouvertes.fr/hal-01610890>

Submitted on 5 Oct 2017

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.

Utilisation de machines apprenantes pour la prédiction en thermique du bâtiment.

Alexandra DELORME-COSTIL^{1*}, Jean-Jacques BEZIAN¹, Olivier FARGES¹

¹Université Fédérale de Toulouse Midi-Pyrénées, Mines Albi, UMR CNRS 5302, Centre RAPSODEE, Campus Jarlard, F-81013 Albi CT Cedex 09, France

*(auteur correspondant : adelorme@mines-albi.fr)

Résumé - Nous développons un modèle adaptatif de bâtiments individuels afin de réaliser des prédictions de leur comportement thermique sur un horizon borné. Le modèle développé est un réseau de neurones artificiel. Nous présentons son architecture, ainsi que la méthode appliquée pour l'apprentissage. Ce modèle est testé par simulation sur plusieurs bâtiments représentatifs du parc immobilier français. Cette étude quantifie la fiabilité d'un modèle de réseau de neurones en terme de prédiction de température intérieure du bâtiment, en fonction de sa superficie, de ses performances énergétiques et du climat auquel il est soumis.

Nomenclature

T	Température, °C	<i>Symboles grecs</i>	
P	Puissance de chauffage, W	ϵ	Erreur absolue, °C
\hat{T}	Température prédite, °C	σ	Écart-type, °C
k	instant de calcul, h	τ	durée de la saison de chauffe, h
N_h	Nombre de neurone sur la couche intermédiaire	<i>Indices et exposants</i>	
N_i	Nombre de neurone sur la couche d'entrée	i	intérieur
m	Nombre d'exemple d'apprentissage	e	extérieur

1. Introduction

La prise de conscience sur les changements climatiques et la pénurie de ressources fossiles poussent les gouvernements à réduire l'impact environnemental des populations de leur pays : la question de l'énergie est au cœur des débats. Les deux principales actions sont l'augmentation de la production d'énergies renouvelables et la diminution globale des consommations. Dans ce contexte le bâtiment s'avère être un secteur énergivore. En effet, d'après les études de l'INSEE [8], il représentait, en 2013, en France, 44,8% des consommations d'énergie (tertiaire et résidentiel confondus). C'est pourquoi des dispositions sont mises en place, notamment au niveau européen, afin de répondre aux besoins affirmés de réduire la consommation énergétique des bâtiments. Dans les bâtiments d'habitation, le système de chauffage représente 60% des consommations du bâtiment [8], ce qui en fait un levier important en matière de réduction des consommations énergétiques. Face à cet enjeu, une des solutions identifiées est d'augmenter l'efficacité énergétique des bâtiments.

La régulation des systèmes de chauffage présente des perspectives intéressantes. Par exemple, l'anticipation des consommations permet, via la régulation, de réaliser des économies d'énergie. Les régulations dites prédictives prennent en compte les variations futures des grandeurs impactant la puissance de chauffage, notamment la température intérieure de l'habitat. Pour prédire ces valeurs, ce type de régulation se base sur des modèles du comportement thermique du bâtiment. Ces modèles doivent pouvoir s'adapter à tous types de bâtiment, c'est à dire ne pas

nécessiter une phase de développement particulière pour chaque bâtiment où la régulation est mise en place.

Les réseaux de neurones artificiels (ANN) sont depuis longtemps utilisés pour la modélisation de systèmes physiques dynamiques, en particulier quand ces derniers ne sont pas entièrement connus analytiquement[1]. De plus ils sont intrinsèquement adaptatifs. C'est pourquoi de nombreux travaux traitent de l'utilisation des ANNs comme modèles prédictifs, certains prédisant la température intérieure d'un bâtiment [2],[3], d'autre l'ensoleillement [6]. Lindelof et al. [4] développent une régulation prédictive basée sur des modèles (ANN), mise en place sur 10 bâtiments. Les conclusions annoncent une économie d'énergie de 28%. Toutefois ces modèles ne sont validés que sur des cas particuliers de bâtiments.

Nous nous sommes intéressés à la généralisation des performances des modèles thermiques du bâtiment basés sur des réseaux de neurones. Nous avons développé un modèle et l'avons testé par simulation sur un échantillon de 120 cas représentatifs du parc immobilier français. Nous avons évalué l'influence de trois paramètres sur les performances du modèle : la superficie du bâtiment, les performances énergétiques et le climat auquel il est soumis.

2. Cas étudiés

Les cas étudiés doivent être représentatifs du parc immobilier français, selon les conditions énergétiques normées. La réglementation thermique 2012 [RT2012] identifie les bâtiments selon leurs consommations énergétiques par m^2 et par an (étiquette énergie), compte tenu de la zone climatique à laquelle ils appartiennent comme indiqué sur les figures 1 et 2. La France est découpée en huit zones climatiques H1a, H1b, H1c, H2a, H2b, H2c, H3. Une étude du commissariat général au développement durable [9] indique qu'en 2013, 71% des logements individuels avaient une étiquette énergie entre A et E. Une autre étude effectuée par le CEREN [7] indique que la superficie moyenne des maisons individuelles est de $113 m^2$.

Nous avons ainsi choisi de traiter l'ensemble des huit climats réglementaires, ainsi que les classes énergétiques A, B, C, D et E. Quinze modèles de bâtiments ont été développés sous TRNSYS 3D. Ils ont une superficie de $50 m^2$, $100 m^2$ ou $150 m^2$. Pour chaque superficie, cinq caractéristiques d'isolation ont été définies afin de représenter les consommations des cinq classes énergétiques. Les quinze modèles ont fait l'objet de simulation pour chacun des huit climats réglementaires. Comme le définit la RT2012, la température de consigne est fixée à $18^\circ C$ entre 6h et 22h, et à $16^\circ C$ le reste du temps. Dans le but d'être le plus général possible, seul le besoin de chauffage sera évalué. Nous avons simulé les consommations en chauffage et la température d'air de ces bâtiments sur une saison de chauffe, avec un pas de temps d'une heure. Nous considérons les bâtiments comme mono-zone, c'est à dire une seule zone thermiquement homogène. Cette hypothèse nous place dans la situation d'un thermostat central considéré représentatif de la température de l'ensemble de l'habitat.

3. Présentation du modèle

Un réseau de neurones artificiels, par analogie avec les réseaux de neurones biologiques, est une structure composée de plusieurs neurones organisés en plusieurs couches. Comme représenté sur le figure 3, un neurone produit un signal de sortie unique dépendant de sa fonction d'activation et de ses entrées.




Figure 1 Carte des climats réglementaires




Figure 2 Etiquettes énergétiques




Figure 3 Représentation d'un neurone

$$O_i = f \left[\sum_{j=1}^n x_j \cdot w_j \right] \quad (1)$$

La sortie d'un neurone est calculé comme indiqué sur l'équation 1. Avec O_i la sortie du neurone i , x_j la j^{eme} entrée, w_j le poids lié à la liaison entre l'entrée j et le neurone i , n le nombre d'entrée et f la fonction d'activation du neurone i . Un réseau de neurones compte a minima une couche d'entrée et une couche de sortie. Une ou plusieurs couches intermédiaires peuvent être ajoutées (fig.4). L'ensemble des neurones d'une même couche à la même fonction d'activation. Un neurone prend comme entrées toutes les sorties des neurones de la couche précédente.




Figure 4 Exemple d'architecture de réseau de neurones

La première étape dans la description du modèle est de définir ses entrées et ses sorties. Nous souhaitons prédire uniquement la température intérieure, sur un pas de temps d'une heure. Cette durée est à la fois une caractéristique des évolutions de la température intérieure, et pertinente pour l'utilisation de régulation prédictive. L'unique sortie de notre réseau de neurones sera donc la température intérieure prédite au temps $t+1h$. De multiples choix d'entrées sont disponibles dans la littérature. A titre d'exemple Huang et al. [2], pour leur ANN mono-zone, prennent comme entrées les températures intérieures et extérieures aux pas de temps précédents, ainsi que des variables contrôlables liées au système de chauffage. Moon et al.[5] considèrent les

températures intérieures et extérieures, ainsi que l'ouverture des systèmes de ventilation.

Dans notre cas nous ne souhaitons pas modéliser un type particulier de chauffage, ni prendre en comptes le système de ventilation. Les entrées ont été choisies comme présentées sur la figure 5, où les grandeurs indiquent les valeurs moyennes sur une heure. Les entrées et sorties choisies sont rappelées dans le tableau 1




Figure 5 Architecture du réseau de neurones

$T_i(k)$	Entrée 1	Température intérieure à l'instant k	° C
$T_i(k-1)$	Entrée 2	Température intérieure à l'instant k-1	° C
$T_i(k-2)$	Entrée 3	Température intérieure à l'instant k-1	° C
$T_e(k)$	Entrée 4	Température extérieure à l'instant k	° C
$T_e(k-1)$	Entrée 5	Température extérieure à l'instant k-1	° C
$T_e(k-2)$	Entrée 6	Température extérieure à l'instant k-2	° C
$P(k)$	Entrée 7	Puissance de chauffage fournie à l'instant k	kW
$P(k-1)$	Entrée 8	Puissance de chauffage fournie à l'instant k-1	kW
$P(k-2)$	Entrée 9	Puissance de chauffage fournie à l'instant k-2	kW
$T_i(k+1)$	Sortie 1	Température intérieure à l'instant k+1	° C

Tableau 1 Entrées et sorties du modèle

L'architecture du réseau de neurones a été choisie de manière à reproduire les travaux de Moon et al.[5], c'est à dire une couche intermédiaire composée d'un nombre de neurones respectant l'équation 3. La fonction sigmoïde (eq. 2), a été choisie comme fonction d'activation pour la couche intermédiaire et la couche de sortie. L'utilisation de cette fonction nécessite une normalisation des données. L'algorithme d'apprentissage est l'algorithme de Levenberg-Marquardt. L'objectif de l'apprentissage est de définir les poids optimaux du réseau de neurones pour un jeu de données dont les valeurs pour l'ensemble des entrées et sorties du réseau de neurones sont connues. Ces données sont appelées jeu d'apprentissage. L'apprentissage a été

fait pour chaque cas sur un jeu de 300 exemples pris en début de saison de chauffe. La fonction coût utilisée pour cette optimisation est déterminée à partir de la méthode des moindres carrés (eq.4).

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

$$N_h = 2(N_i + 1) \quad (3)$$

$$J = \frac{1}{2m} \sum_m (\hat{T} - T)^2 \quad (4)$$

4. Résultats

Les performances du modèle sont représentées par deux éléments :

- La moyenne de l'erreur absolue sur la prédiction de la température intérieure pendant une saison de chauffe, notée $\bar{\epsilon}$ (eq.5),
- l'écart-type associé, noté σ (eq.6).

$$\bar{\epsilon} = \frac{1}{\tau} \sum_{t=1}^{\tau} (\hat{T}(t) - T(t)) \quad (5)$$

$$\sigma = \frac{1}{\tau} \sum_{t=1}^{\tau} (\hat{T}(t) - \bar{T})^2 \quad (6)$$

A titre indicatif, les saisons de chauffe varient selon les cas de 2000 heures à 5000 heures, caractérisées par des climats plus ou moins rudes.

Dans un premier temps, nous avons cherché à mettre en avant l'influence de la superficie sur les performances du modèle. La figure 6 représente l'erreur et l'écart-type de chaque cas en fonction de la superficie du cas étudié.




Figure 6 Erreur moyenne et écart-type par superficie (°C)

Dans un premier temps, nous avons cherché à mettre en avant l'influence de la superficie sur les performances du modèle. La figure 6 représente l'erreur et l'écart-type de chaque cas en fonction de la superficie du cas étudié. Nous observons un comportement similaire quelque soit la superficie du cas étudié. Nous concluons que la superficie du bâtiment n'influe pas de façon significative sur les performances du modèle. C'est pourquoi les résultats suivants présentent les erreurs et écart-type moyennés sur les trois superficies.

Les résultats sont présentés pour chaque cas (négligeant la superficie), et regroupés par climat. En abscisse sont notés les classes énergétiques. En ordonnée, nous pouvons lire l'erreur moyenne et l'écart type, en degrés Celsius.

La première observation est une erreur moyenne variant de $0,02^{\circ}\text{C}$ à $1,28^{\circ}\text{C}$ sur l'ensemble des cas. Nous observons également de fortes irrégularités sur la dispersion des erreurs avec des écart-types variant de $0,37^{\circ}\text{C}$ à $2,90^{\circ}\text{C}$.

La représentation de l'erreur nous permet de voir que dans la majorité des cas la température est surestimée. L'influence des performances énergétiques est la plus significative. L'ensemble des indicateurs de performance du modèle se dégradent avec la diminution des performances énergétiques du bâtiment. Nous voyons la surestimation de la température augmenter (augmentation de l'erreur). Plus important encore nous observons cette diminution des performances du modèle sur la dispersion de l'erreur, signifiant qu'un plus grand nombre de prédictions sont fausses.

Toutefois certain cas ne suivent pas cette dynamique, en effet pour le climat H2a les performances des cas de classe énergétique E sont meilleures que ceux de classes énergétiques D, de la même façon pour le climat H1a la classe D a de bien meilleures performances que la classe C.

Pour la majorité des cas étudiés, l'erreur moyenne faite sur la prédiction de température est inférieure à 1°C , ce qui permet d'envisager l'utilisation de ce type de modèle sur une grande variété de bâtiments.




Figure 7 Climat H1a : Moyenne et écart-type de l'erreur ($^{\circ}\text{C}$)




Figure 8 Climat H1b : Moyenne et écart-type de l'erreur ($^{\circ}\text{C}$)




Figure 9 Climat H1c : Moyenne et écart-type de l'erreur (°C)




Figure 10 Climat H2a : Moyenne et écart-type de l'erreur (°C)




Figure 11 Climat H2b : Moyenne et écart-type de l'erreur (°C)




Figure 12 Climat H2d : Moyenne et écart-type de l'erreur (°C)




Figure 13 Climat H3 : Moyenne et écart-type de l'erreur (°C)

5. Conclusion et perspectives

Nous avons développé un modèle adaptatif de bâtiment basé sur un réseau de neurones. Nous l'avons ensuite testé par simulation. Ses performances ont été évaluées sur 120 cas représentatifs du parc immobilier français dans les conditions climatiques de la RT2012. Les performances de ce modèle ont été montrées sur 120 cas aux caractéristiques variées. Nous observons une erreur moyenne allant de $0,02\text{ }^{\circ}\text{C}$ à $1,28\text{ }^{\circ}\text{C}$. Une plus petite dispersion de l'erreur de prédiction est observé pour les bâtiments de classes énergétiques A et B. Ce type de modèle ayant pour but d'équiper des régulations intelligentes, il est très intéressant que ses performances s'améliorent avec les performances énergétiques du bâtiment. L'absence d'influence de la superficie du bâtiment a pu être mise en évidence. Au contraire le climat auquel est soumis le bâtiment semble influencer les performances du modèle, toutefois aucune tendance claire n'a pu être observée.

Pour aller plus loin, le modèle sera amélioré afin de tester des situations moins normées, notamment en terme de température de consigne. Une étude des temps d'apprentissage et de calcul du modèle sera menée. Une optimisation du nombre de données d'entrées et d'apprentissage sera également menée. En conclusion, les résultats obtenus sont prometteurs, cependant une optimisation de certains paramètres pourrait permettre une amélioration des performances.

Références

- [1] Hunt, Neural networks for control systems :a survey.,1992
- [2] Huang, Hao and Chen, Lei and Hu, Eric, A neural network-based multi-zone modelling approach for predictive control system design in commercial buildings, Energy and Buildings, p86–97, vol 97, 2015
- [3] Kusiak, Andrew and Xu, Guanglin, Modeling and optimization of HVAC systems using a dynamic neural network, Energy, vol 42, p241–250, 2012
- [4] Lindelöf, David and Afshari, Hossein and Alisafae, Mohammad and Biswas, Jayant and Caban, Miroslav and Mocellin, Xavier and Viaene, Jean, Field tests of an adaptive, model-predictive heating controller for residential buildings, Energy and Buildings, vol 99, p292–302, 2015
- [5] Moon, Jin Woo and Lee, Ji-Hyun and Chang, Jae. D and Kim, Sooyoung, Preliminary performance tests on artificial neural network models for opening strategies of double skin envelopes in winter, Energy and Buildings, vol 75, p 301–311, 2014
- [6] Argiriou, a. a. and Bellas-Velidis, I. and Balaras, C. a., Development of a neural network heating controller for solar buildings, Neural Networks, vol 13, p 811–820, 2000
- [7] Centre d'Etude et de Recherche sur ENergie, données statistiques du CEREN, 2015
- [8] Institut National de la Statistique et des Etudes Economique, Consommation d'énergie des secteurs résidentiel et tertiaire, 2014
- [9] Commissariat national au développement durable, Bilan énergétique de la France pour 2014, juillet 2015