

Outils de l'intelligence artificielle et méthode inverse pour l'estimation de propriétés thermiques de matériaux de construction

Olivier FAUGEROUX^{1*}, Stéphane GRIEU^{1*}, Adama TRAORE¹, Bernard CLAUDET¹, Jean-Luc BODNAR²

1- Laboratoire PROMES - CNRS UPR 8521, Université de Perpignan-Via Domitia
52 avenue Paul Alduy, 66860 Perpignan Cedex

2- Laboratoire GRESPI, Université de Reims Champagne Ardennes
Campus du Moulin de la Housse - BP 1039, 51687 Reims Cedex 2

*- Auteurs correspondants : faugerox@univ-perp.fr, grieu@univ-perp.fr

Résumé – Dans ce travail, nous proposons de tester des outils issus de l'intelligence artificielle pour l'estimation de la diffusivité thermique de matériaux de construction à partir des réponses à une excitation aléatoire. Dans un premier temps, nous reconstruisons la réponse impulsionnelle à l'aide d'un réseau de neurones et nous estimons la diffusivité par méthode inverse. Dans un deuxième temps, nous estimons la diffusivité directement à l'aide d'un réseau de neurones ou avec un système neuro-flou. Nous comparons les performances de chacune de ces procédures.

Nomenclature

<i>RA</i>	réponse à une excitation aléatoire	p_i	valeur absolue d'une pente
<i>RI</i>	réponse impulsionnelle	Δt_i	durée d'une bascule dans le PRBS (s)
<i>PRBS</i>	Pseudo Binary Random Signal		

1. Introduction

La caractérisation des matériaux fragiles par les méthodes photothermiques classiques (flash ou modulée) est un problème délicat. Avec la méthode flash, l'excitation est trop intense. Avec la méthode modulée, l'information est pauvre car limitée qu'à la fréquence de modulation. L'idée est donc d'utiliser un profil temporel d'excitation aléatoire. Des études précédentes [1] ont montré l'intérêt de ce type de méthode. La reconstruction des réponses impulsionnelles, riches en informations, était alors effectuée par analyse corrélatoire, ceci afin d'en déduire les propriétés des matériaux caractérisés.

L'objet de ce travail est de montrer que des outils empruntés au domaine de l'intelligence artificielle sont aussi adaptés à la reconstruction des réponses impulsionnelles et à l'estimation de propriétés. Ces techniques, les Réseaux de Neurones Artificiels (RNA) et les systèmes neuro-flous, principalement utilisées pour la modélisation et la commande de systèmes non linéaires, présentent en effet des caractéristiques qui leur sont propres et qui sont exploitables pour la caractérisation de matériaux. Les réseaux de neurones artificiels sont des outils de modélisation par apprentissage qui permettent d'ajuster des fonctions non linéaires très générales à des ensembles de points décrivant des phénomènes statiques ou dynamiques. Ce sont des approximateurs universels parcimonieux dont la capacité de généralisation est grande. Les systèmes neuro-flous combinent les principes du raisonnement flou, la capacité d'apprentissage et la structure connexionniste des réseaux de neurones.

Dans ce travail, nous présentons un comparatif de trois méthodes d'estimation de propriété (la diffusivité thermique) de matériaux de construction. La méthode dite « neuro-inverse » s'appuie sur la reconstruction de la réponse impulsionnelle par réseaux de neurones,

l'estimation de la propriété se faisant ensuite par méthode inverse. Dans un second temps, pour estimer la propriété directement à partir de la réponse à l'excitation aléatoire des matériaux, nous utilisons une approche basée sur un réseau de neurones ou sur un système neuro-flou [2].

2. L'expérience photothermique

Il s'agit d'une méthode de contrôle non destructif qui consiste à soumettre l'échantillon à analyser à un flux lumineux dont l'absorption produit une élévation locale de température, puis à observer la variation d'émissance du matériau à l'aide d'une chaîne de détection optique infrarouge. Sous l'hypothèse des faibles échauffements, le signal photothermique ainsi obtenu est proportionnel à la température de la surface observée. Cette dernière dépend des propriétés thermophysiques du matériau analysé, de sa structure, de la présence d'éventuels défauts, etc. Le profil temporel du flux exciteur détermine une caractéristique de l'expérience photothermique. Si le flux est une impulsion, on parle d'une expérience impulsionnelle et de réponse impulsionnelle (RI) de l'échantillon. Cette méthode, bien connue, est très efficace : la réponse contient des informations à toutes les fréquences. Cependant, elle nécessite le dépôt d'une grande quantité d'énergie dans un laps de temps très court. L'analyse de matériaux fragiles est donc exclue. Le flux peut être modulé et l'analyse effectuée à plusieurs fréquences de modulation, on parlera de méthode modulée. Les contraintes énergétiques sont bien moindres mais il faut attendre que le régime permanent soit établi pour exploiter les réponses et la réponse ne contient des informations qu'à une seule fréquence. Si l'excitation est aléatoire, les contraintes énergétiques sont faibles et la réponse du matériau en fréquence est aussi riche que la réponse impulsionnelle. La difficulté est de réussir à créer une excitation la plus aléatoire possible.

Après avoir testé plusieurs types d'excitation aléatoire, c'est un signal appelé PRBS (Pseudo Binary Random Signal) qui a été retenu. Il s'agit d'un signal valant 0 ou 1, la durée de bascule entre ces deux états étant quasi-aléatoire. Le GRESPI [1] a mis au point un modèle de réponse d'un matériau à une excitation de type PRBS. Nous disposons donc d'un moyen de simulation de réponse à une excitation aléatoire (RA).

3. Estimation de la diffusivité thermique

3.1. Base de données

La base de données utilisée est composée des RA, des RI et des propriétés thermophysiques de 7 matériaux de construction : la laine de verre, le béton, la brique, le verre, le plâtre, le granit et l'acier inoxydable.

3.2. Reconstruction de la réponse impulsionnelle et estimation par méthode inverse

3.2.1. Principe de la méthode

Les réseaux de neurones sont des approximateurs universels parcimonieux. Ils présentent donc des capacités d'apprentissage et de généralisation particulièrement intéressantes. L'estimation de la diffusivité s'effectue en deux temps : la reconstruction de la RI par réseaux de neurones à partir de la RA et l'estimation, proprement dite, par méthode inverse à partir de la RI ainsi reconstruite. Nous appellerons cette procédure d'estimation la méthode « neuro-inverse ».

Afin de pouvoir reconstruire une RI à partir d'une RA, les réseaux de neurones ont besoin d'être entraînés. Ainsi, nous avons choisi d'entraîner un réseau récurrent de Elmann [3], un type de réseau particulièrement adapté à la modélisation de phénomène dynamiques, à l'aide des couples RA(entrée)-RI(cible) de la laine de verre, du béton, du verre et de l'acier inoxydable. Cette étape permet de définir et d'optimiser le réseau. Le nombre de neurones de la couche cachée, le taux d'apprentissage et les nombres d'itérations réalisés au cours de la phase d'entraînement ont été optimisés empiriquement. Le réseau optimal est constitué de 8 neurones sur sa couche cachée, 35 itérations ont été accomplies durant la phase d'entraînement et son taux d'apprentissage a été fixé à 0,3. Il s'agit ensuite de valider le modèle obtenu. Les couples RA-RI de validation sont alors ceux de la brique, du plâtre et du granit.

Les RI reconstruites sont ensuite utilisées dans un algorithme d'estimation de paramètres par méthode inverse (méthode de Gauss-Newton ou de Box-Kanemasu) [4]. La figure 1 présente le synoptique de la méthode neuro-inverse.

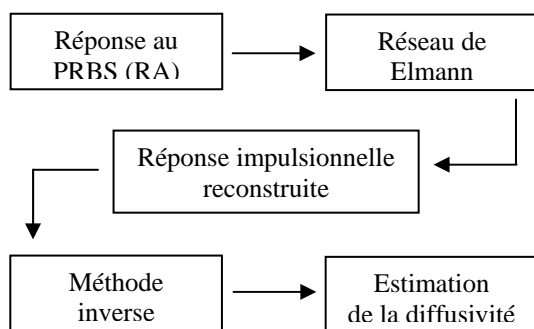


Figure 1 : La méthode neuro-inverse

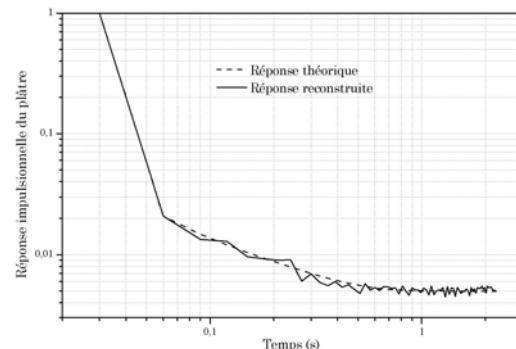


Figure 2 : Une RI cible et une RI reconstruite

3.2.2. Résultats obtenus

Le tableau suivant présente un récapitulatif des résultats obtenus.

Matériaux	RI reconstruite		Estimation par méthode inverse		
	EMR %	FIT %	Cible m^2/s	Estimée m^2/s	Ecart relatif %
Brique	0,7	96,5	$5,17.10^{-7}$	$4,63.10^{-7}$	10,4
Plâtre	0,5	96,6	$6,00.10^{-7}$	$5,06.10^{-7}$	15,7
Granit	0,1	99,1	$1,1.10^{-6}$	$1,11.10^{-6}$	< 1

Tableau 1 : Résultats de la méthode neuro-inverse

Nous devons tout d'abord nous intéresser à la qualité de la reconstruction. Pour cela, nous avons comparé les RI reconstruites aux RI théoriques à l'aide de deux critères : l'erreur relative moyenne (ERM) et le FIT. Le premier doit être le plus petit possible, le critère FIT, quant à lui, est un critère de ressemblance, il doit donc être le plus près possible de 100. Pour chacun des matériaux de validation on constate que le réseau de Elmann produit des reconstructions de RI vraiment très proches des RI cibles.

Bien que les RI soient bien reconstruites, l'estimation de la diffusivité thermique par méthode inverse est décevante. Cela s'explique par le fait que nous cherchons à estimer la diffusivité à l'aide de RI pauvres en points dans les zones de sensibilité fortes [5].

3.3. Estimation à l'aide des réseaux de neurones

L'objectif est ici de déterminer directement la diffusivité thermique d'un échantillon à partir de sa RA à l'aide d'un réseau de neurones.

3.3.1. Principe de la méthode

Notre cible étant une valeur fixée (la diffusivité), nous avons utilisé un perceptron multi-couche [6]. De la même façon que précédemment, avant d'utiliser le réseau, il faut l'entraîner, l'optimiser et valider ses résultats. Le réseau a été entraîné avec le couple RA(entrée)-diffusivité(cible) de la laine de verre, du béton, du verre et de l'acier inoxydable. Le nombre de neurones de la couche cachée, le taux d'apprentissage et le nombre d'itérations réalisées au cours de la phase d'entraînement ont à nouveau été optimisés empiriquement. Ici, la couche cachée est composée de 10 neurones, 30 itérations ont été accomplies durant la phase d'entraînement et le taux d'apprentissage a été fixé à 0,3.

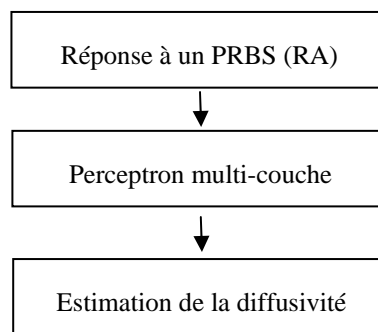


Figure 3 : La méthode neuronale

3.3.2. Résultats obtenus

Le tableau 2 présente le résultat des estimations de diffusivité thermique faites directement à partir des RA par un perceptron multi-couche.

Matériaux	Cible m^2/s	Estimée m^2/s	Ecart relatif %
Brique	$5,17.10^{-7}$	$4,85.10^{-7}$	6,2
Plâtre	$6,00.10^{-7}$	$5,6.10^{-7}$	6,7
Granit	$1,1.10^{-6}$	$1,15.10^{-6}$	4,5

Tableau 2 : Résultats obtenus à l'aide de l'approche neuronale (perceptron multi-couche)

Les écarts relatifs entre les cibles et les valeurs estimées sont faibles : ils sont tous aux alentours de 5 %. Ces résultats sont particulièrement intéressants puisqu'ils nous permettent de conclure qu'un outil issu de l'intelligence artificielle est tout à fait capable de faire de l'estimation de propriété thermique, et ceci sans avoir recours à la reconstruction de la RI.

3.4. Estimation à l'aide d'un système neuro-flou

3.4.1. Principe de la méthode

Les systèmes neuro-flous combinent la structure connectioniste et la capacité d'apprentissage des réseaux de neurones à la connaissance experte du domaine dans lequel ils

sont utilisés [7]. Ainsi, pour qu'un tel système (un ANFIS – Adaptive Neural Fuzzy Inference System-, dans notre cas) puisse à partir de la RA d'un matériau nous donner sa diffusivité, il est indispensable de se poser une question : qu'est-ce qui dans la RA est véritablement caractéristique de la diffusivité ? Répondre à cette question nous permettra de définir l'entrée ou les entrées du système, la sortie étant la diffusivité thermique.

Nous avons donc examiné en parallèle une RI et une RA (figure 4) et nous avons choisi d'utiliser deux vecteurs en entrée : un vecteur constitué des durées Δt_i des changements d'état du PRBS et un vecteur constitué des valeurs absolues des pentes p_i des droites ($S_i M_i$) avec S_i le point de la RA correspondant au changement d'état du PRBS et M_i le point de la RA situé au milieu de deux changements d'état. En sortie, le système a pour cible la diffusivité (figure 5). Le système a été à nouveau entraîné avec les données de la laine de verre, du béton, du verre et de l'acier inoxydable, la validation étant effectuée avec celles de la brique, du plâtre et du granit.




Figure 4 : Un PRBS (haut) et une RA(bas)

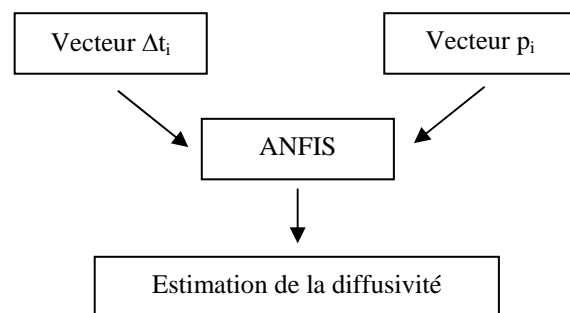


Figure 5 : La méthode neuro-floue

3.4.2. Résultats obtenus

Le tableau 3 présente les résultats obtenus à l'aide du système neuro-flou.

Matériaux	Cible m^2/s	Estimée m^2/s	Ecart relatif %
Brique	$5,17.10^{-7}$	$5,32.10^{-7}$	2,9
Plâtre	$6,00.10^{-7}$	$5,73.10^{-7}$	4,5
Granit	$1,1.10^{-6}$	$1,09.10^{-6}$	1,1

Tableau 3 : Résultats obtenus à l'aide du système neuro-flou

Nous observons que le système neuro-flou estime remarquablement bien la diffusivité thermique. Un système neuro-flou correctement entraîné présente donc toutes les qualités d'un outil d'estimation de propriétés thermiques.

3.5. Discussion des résultats obtenus

Le tableau suivant présente une synthèse des résultats obtenus à l'aide des différentes façons de procéder. Dans l'ensemble, les meilleures estimations sont obtenues par le système neuro-flou. Cependant, la meilleure estimation est fournie par la méthode neuro-inverse.

Les performances des outils de l'intelligence artificielle sont remarquables là où l'estimation par méthode inverse montre des faiblesses. En effet, l'approche neuronale et le système neuro-flou ne paraissent que peu affectés par le manque de points dans la zone de sensibilité forte. A contrario, dès que ce nombre de points est suffisant, l'estimation par

méthode inverse est particulièrement performante. Notons toutefois que le système neuro-flou reste très proche du niveau de performance de la méthode neuro-inverse quel que soit le cas.

Matériaux	Méthode neuro-inverse	Approche neuronale	Système neuro-flou
Brique	10.4	6.2	2.9
Plâtre	15.7	6.7	4.5
Granit	< 1	4.5	1.1

Tableau 4 : Synthèse des résultats, écarts relatifs (%) par rapport à la valeur cible

4. Conclusion et Perspectives

Nous avons testé trois procédures d'estimation de la diffusivité à partir des réponses à une excitation aléatoire. Une première consiste à reconstruire les RI des échantillons à l'aide d'un réseau de Elmann et d'estimer la diffusivité par méthode inverse. Dans un deuxième temps, nous estimons la diffusivité directement à partir d'une RA à l'aide d'un réseau de type perceptron multi-couche. La troisième façon de faire est d'utiliser un système neuro-flou de type ANFIS pour faire l'estimation de la diffusivité. Notre étude montre les immenses possibilités des outils de l'intelligence artificielles, et plus particulièrement des ANFIS, dans des cas où l'estimation par méthode inverse montre ses limites.

Prochainement, nous allons commencer à appliquer ces procédures à des données expérimentales. A terme, nous voulons utiliser ces méthodes pour traiter des images enregistrées par caméra infrarouge et faire apparaître des défauts au sein d'une structure. Les ANFIS semblent être les meilleurs candidats, compte tenu des résultats obtenus dans cette étude. En effet, ils s'affranchissent complètement des exigences des méthodes inverses. De plus, l'exploitation de ces outils ne nécessite pas de temps de calcul importants.

Références

- [1] J.L. Bodnar, S.Brahim, A. Boutemy, J.C. Cantone, P. Grossel, Contrôle non destructif par radiométrie photothermique sous excitation aléatoire : principe et exemple d'application, *SFT 2005 (Reims)*
- [2] S. Grieu, O. Faugeroux, A. Traoré, B. Claudet, J.L. Bodnar, Artificial intelligence tools and inverse methods for estimating the thermal diffusivity of building materials, *Energy and Building* (2010), doi :10.1016/j.enbuild.2010.10.020
- [3] J.L. Elmann, Finding structures in time, *Cognitive Sciences*, 14 (1990), 179-211
- [4] J.V. Beck, K.J. Arnold, *Parameters Estimation in Engineering and Sciences*, John Wiley Sons Ltd. (1977)
- [5] Ecole d'Hiver METTI '99, *Métrologie thermique et techniques inverses*, Presses Universitaires de Perpignan (1999)
- [6] K. Hornik, M. Stinchcombe, H. White, Multi-layer feedforward networks are universal approximation, *Neural Networks*, 2 (1989), 359-366
- [7] J.S.R. Jang, C.T. Sun, Neuro-fuzzy modeling and control, *IEEE Proceedings*, 83(3) (1995), 378-406