



**Les Cahiers de la Société Française de  
Thermique**

**Numéro 1**

**L'I.A. et la Thermique**

# Les Cahiers de la Société Française de Thermique



## L'I.A. et la Thermique

Réflexions suscitées à l'issue de la journée du 8 juin 2023 « Inversion de données faisant appel à un modèle en thermique : quels apports de l'intelligence artificielle ? » organisée par le groupe thématique METTI (Mesures Thermiques et Techniques Inverses) de la SFT.

Le programme et les présentations effectuées à l'occasion de cette journée sont accessibles sur le site de la SFT<sup>1</sup>. Le présent document propose une introduction générale à la thématique puis un résumé des principaux résultats et des principales références proposés par tous les participants à cette journée, qu'ils soient ici chaleureusement remerciés.

Cette journée SFT et le présent numéro des Cahiers de la SFT ont été coordonnés par Jean-Luc Battaglia (Université de Bordeaux), Denis Maillet (Université de Lorraine) et Fabrice Rigollet (Aix Marseille Université)

INSB :

---

<sup>1</sup> Lien actuel vers la rubrique « Journées SFT » : <https://www.sft.asso.fr/document.php?pagendx=10442>

## **Avant-propos**

Nous inaugurons la série des cahiers de la SFT par une thématique relativement moderne, à savoir les outils d'intelligence artificielle et leur apports à la thermique et plus particulièrement à la résolution de problèmes inverses en thermique (même si le domaine d'application est évidemment bien plus large).

Cette série de cahiers est une initiative nouvelle de la SFT pour contribuer à la diffusion du savoir au niveau national avec un prisme assez généraliste. En effet, les informations collectées doivent servir aux mondes académique et industriel, tous deux étant représentés significativement au sein de notre société savante.

Ainsi, ces cahiers n'ont pas pour vocation de rentrer dans des détails mathématiques ou technologiques trop avancés mais de faire plutôt un état des lieux sur une thématique en lien avec la thermique. Nous proposons ainsi de regrouper quelques idées phares, les avancées les plus significatives du domaine et les références bibliographiques majeures qui permettent de couvrir l'ensemble de ce domaine sans avoir à recourir à une construction et un examen bibliographique exhaustif. Étant donné l'importance des codes de calculs dans nos applications, des informations seront données, lorsque cela est possible, sur l'existence de codes open-source en lien avec la thématique.

## Introduction

L'intelligence artificielle est aujourd'hui largement médiatisée et de nombreuses applications ont vu le jour. Il est néanmoins assez complexe de faire la part entre ce qui est réellement nouveau et ce qui est utilisé depuis bien longtemps par les scientifiques mais que l'IA pourrait présenter avec une terminologie différente de celle sous laquelle nous les connaissons.

Ce premier cahier a donc pour but de faire un point sur les méthodes issues de l'IA et qui ont de potentielles applications dans le domaine de la thermique. Outre un examen minutieux des applications existantes au travers de la base de données de la SFT, nous avons aussi utilisé l'outil GPT-3.5 dans ce travail bibliographique, ce qui est d'ailleurs assez cohérent avec la thématique du cahier.

L'intelligence artificielle (IA) trouve de nombreuses applications à travers divers domaines. Voici quelques-unes des principales applications de l'IA :

- Le traitement du langage naturel (NLP) : Chatbots et assistants virtuels, traduction automatique, analyse de sentiments et de tonalité, résumé automatique de texte, génération de texte ;
- La vision par ordinateur : reconnaissance d'objets et de visages, détection et suivi d'objets, diagnostic médical basé sur des images, véhicules autonomes et systèmes d'aide à la conduite ;
- L'apprentissage automatique (Machine Learning) : classification et prédiction, recommandations personnalisées, détection d'anomalies, optimisation de processus industriels ;
- L'IA dans la santé : diagnostic médical assisté par ordinateur et analyse d'images tomographiques, développement de médicaments, suivi des patients et personnalisation des traitements ;
- L'IA dans la finance : analyse de risques et de crédits, trading algorithmique, détection de fraudes ;
- La robotique et l'automatisation : contrôle de robots industriels, automatisation des tâches répétitives ;
- Les jeux et divertissement : jeux vidéo intelligents et adversaires virtuels, création de contenu artistique ;
- Les systèmes de recommandation de produits et de contenus en ligne ;
- L'Industrie manufacturière : contrôle de la qualité, maintenance prédictive ;
- L'Énergie et environnement : gestion intelligente de l'énergie, prévision de la demande énergétique ;
- L'agriculture : optimisation des récoltes, surveillance des cultures ;
- L'Éducation : personnalisation de l'apprentissage, évaluation automatique des élèves ;
- La recherche scientifique : analyse de données complexes, modélisation et simulation.

Tous ces domaines d'applications ont été répertoriés en 2018 dans le rapport d'une commission nationale coordonnée par C. Villani<sup>2</sup>. Mais bien sûr quantités d'ouvrages traitent de l'IA et notamment de ses applications en ingénierie<sup>3</sup>.

Le domaine de la thermique, par nature transverse, doit donc trouver des possibilités d'application par le biais de l'IA. Néanmoins, elle le fait depuis bien longtemps même si cela n'était pas répertorié comme une technique relative à l'IA. En effet, le traitement de grande quantités de données, l'identification et la réduction de modèles, l'optimisation au sens de l'identification de paramètres ou de la résolution de problèmes inverses sont autant de domaines d'applications qui ont été traités depuis plus de 30 ans par de nombreux chercheurs.

Les applications industrielles en lien avec ces applications existent elles aussi depuis bien longtemps. Il est donc utile ici de bien mettre en évidence quels sont les domaines de l'IA qui sont réellement source de nouvelles originalités pour la thermique. Il apparaît alors clairement que ce sont bien les méthodes d'apprentissage (automatique ou profond) qui sont vecteurs de nouveautés et nous allons en donner quelques illustrations dans la suite.

L'apprentissage profond peut être utilisé pour améliorer les prévisions météorologiques<sup>4</sup>, ce qui a un impact direct sur les prévisions de demande en énergie. En utilisant des données historiques et en temps réel, les modèles peuvent prédire la demande en énergie et les besoins de refroidissement ou de chauffage. Les techniques d'apprentissage profond peuvent aider à optimiser l'utilisation de l'énergie dans les bâtiments<sup>5</sup> en ajustant automatiquement les systèmes de chauffage, de ventilation et de climatisation en fonction des conditions en temps réel et des prévisions. Dans les réseaux de distribution d'énergie thermique (comme les réseaux de chauffage urbain), l'apprentissage profond peut être utilisé pour optimiser la répartition de la chaleur en prédisant la demande des utilisateurs et en ajustant la distribution en conséquence. L'apprentissage profond peut aider à surveiller en temps réel les

---

<sup>2</sup> « Donner un sens à l'IA, pour une stratégie Nationale et Européenne », <https://www.enseignementsup-recherche.gouv.fr/fr/rapport-de-cedric-villani-donner-un-sens-l-intelligence-artificielle-ia-49194> .

<sup>3</sup> "Artificial Intelligence for Engineering Design, Analysis and Manufacturing" par T. O. Ting et J. S. Gero. "Machine Learning for Dummies" par John Paul Mueller et Luca Massaron. "Applied Artificial Intelligence: A Handbook For Business Leaders" par Mariya Yao, Adelyn Zhou et Marlene Jia. "AI in Practice: A Commonsense Guide to Building AI Applications" par Bernard Marr. "Artificial Intelligence in Engineering" par Paolo S. Varshney et E. Clayton Teague.

<sup>4</sup>"Deep Learning for Weather Prediction" par Romain Hérault et Jacques-André Ndione. "Artificial Intelligence in Meteorology and Oceanography" par Lars Peter Riishojgaard et Eric P. Gritmit. "Weather and Climate Prediction" par Stefan Emeis et C. G. Helmig (celui-ci peut couvrir des méthodes avancées incluant l'IA pour la prédiction météorologique).

<sup>5</sup>"Deep Energy Retrofit: A Primer for Engineers" par Svetlana Ushakova, Ulrich Knaack et Marcel Bilow. "Energy Efficient Buildings with Solar and Geothermal Resources" par Ursula Eicker. "Machine Learning and AI for Building Energy Analysis" par Asif Hassan, Francesco Reda et David Anderson.

performances des systèmes thermiques<sup>6</sup>, détecter les anomalies<sup>7</sup>, prédire les pannes potentielles et recommander des mesures de maintenance<sup>8</sup> pour minimiser les temps d'arrêt.

Dans la conception de matériaux destinés à la gestion de la chaleur, l'apprentissage profond peut accélérer la découverte et l'optimisation des propriétés thermiques en modélisant la structure et les performances des matériaux<sup>9</sup>. De même, l'apprentissage profond peut réduire le temps nécessaire à la simulation numérique de phénomènes thermiques complexes<sup>10</sup> en utilisant des modèles qui approximent les solutions des équations de la chaleur.

De manière générale, l'intégration de principes physiques dans l'apprentissage profond<sup>11</sup>, aussi connue sous le nom de "Deep Learning Informed by Physics" (DLIP), ou encore "Physics-Informed Neural Networks" (PINN), permet de combiner les avantages de l'apprentissage automatique avec la connaissance des lois physiques sous-jacentes. Cela peut aider à améliorer la généralisation des modèles et à réduire les besoins en données d'entraînement, en incorporant des contraintes physiques dans l'apprentissage. Par exemple, dans la vision par ordinateur, on peut utiliser des modèles qui respectent la cohérence géométrique des objets dans l'espace.

L'approche de l'apprentissage profond informé par la physique présente plusieurs avantages pour l'ingénierie. En effet, en incorporant des lois physiques dans les modèles d'apprentissage, on peut réduire le besoin en grandes quantités de données d'entraînement, ce qui est souvent coûteux et chronophage dans le domaine de l'ingénierie. Les modèles DLIP ont tendance à généraliser plus efficacement sur de nouvelles situations, car ils sont guidés par des contraintes physiques. Cela les rend plus fiables lorsque les données sont limitées ou bruitées. Les modèles basés sur des principes physiques sont généralement plus compréhensibles, car ils s'appuient sur des concepts familiers. Cela facilite la confiance des ingénieurs dans les prédictions et permet de déduire des informations utiles. Dans de nombreux domaines de l'ingénierie, il s'agit de résoudre des problèmes inverses, c'est-à-dire de déduire des paramètres non observables à partir de données observées. Les contraintes physiques

---

<sup>6</sup>"Machine Learning for Predictive Modeling in Engineering" par A.H. Tan et X. Zhu. "Machine Learning and IoT for Smarter Energy Management Systems" par Aboul Ella Hassanien et S. G. Ponnambalam. "Energy Management in Smart Buildings" par Stamatis Karnouskos et Thomas Messervey.

<sup>7</sup>"Anomaly Detection Principles and Algorithms" par Kishan G. Mehrotra, Chilukuri K. Mohan et Sanjay Ranka. "Introduction to Anomaly Detection" par Anna X. Sun et Galit Shmueli. "Machine Learning for Anomaly Detection" par Chandola et al.

<sup>8</sup>"Practical Machine Learning for Computer Vision" par Martin Görner, Ryan Gillard et Valliappa Lakshmanan. "Machine Learning and AI for Healthcare" par Arjun Panesar et Shubhranshu Singh. "AI for Predictive Maintenance" par Eric H. Chiou et Gopal G. Choudhari.

<sup>9</sup>"Machine Learning for Materials Science" par Turab Lookman et Alex. "Data-Driven Computational Materials Science" par Turab Lookman et Alex Zunger. "Data Science for Materials Discovery and Design" par Turab Lookman et al. "Introduction to Data Science for Engineers" par Mete Yıldız et Fikret Sivrikaya.

<sup>10</sup>"Reduced Order Methods for Modeling and Computational Reduction" par Alfio Quarteroni et Gianluigi Rozza.

"Machine Learning and Data Mining for Computer Security" par Marcus A. Maloof. "Machine Learning for Multiscale Physics" par Efstratios Skordos, Gilles Lubineau et George Karniadakis

<sup>11</sup>"Physics-Informed Machine Learning: Data-Driven Models, Data-Driven Discoveries" par Maziar Raissi. "Deep Learning for Physical Sciences" par James T. Ziegenhein et Matthias Stuber. "Machine Learning and Physics: Principles and Applications for the Natural Sciences" par Yoshua Bengio, Martin Grant et Naftali Tishby.

"Machine Learning Methods in the Environmental Sciences: Neural Networks and Kernels" par William W. Hsieh. "Handbook of Physics in Medicine and Biology" par Robert Splinter.

peuvent aider à stabiliser et à améliorer ces processus. L'incorporation de contraintes physiques dans les modèles d'apprentissage peut aider à guider l'optimisation de la conception de produits et de systèmes en respectant des critères physiques tels que la résistance des matériaux ou l'efficacité énergétique. Ainsi, en combinant l'expertise en ingénierie avec les avancées de l'apprentissage profond informé par la physique, on peut créer des solutions plus performantes, efficaces et fiables dans divers domaines tels que l'aérospatiale, la médecine, l'énergie et bien d'autres.

Il existe des applications des modèles DLIP en thermique et en science des matériaux<sup>12</sup>. En effet, les modèles DLIP peuvent être utilisés pour prédire les transferts thermiques dans des systèmes complexes, comme les échanges de chaleur dans les moteurs, les systèmes de refroidissement, les circuits électroniques, etc. En combinant des modèles physiques avec des techniques d'apprentissage profond, il est possible d'optimiser la conception de dispositifs thermiques tels que les échangeurs de chaleur, en tenant compte des contraintes physiques et des performances thermiques. L'apprentissage profond informé par la physique peut aider à détecter les défauts thermiques dans les systèmes en analysant les variations de température et en comparant les données observées avec les prédictions basées sur les lois thermiques. En utilisant des modèles basés sur les principes physiques, on peut caractériser les propriétés thermiques des matériaux de manière plus précise en analysant leurs réponses thermiques dans différentes conditions. Les simulations numériques traditionnelles pour les problèmes thermiques peuvent être coûteuses en termes de temps de calcul. Les modèles DLIP peuvent accélérer ce processus en fournissant des approximations rapides et précises des comportements thermiques. Les systèmes de contrôle thermique peuvent bénéficier de l'apprentissage profond pour optimiser les stratégies de régulation en temps réel, en tenant compte des variations thermiques et des contraintes physiques.

Lorsque l'on souhaite améliorer l'efficacité des systèmes thermiques, tels que les échangeurs de chaleur ou les composants électroniques, le choix des matériaux et des revêtements thermiques est crucial. L'apprentissage profond peut être utilisé pour accélérer le processus de découverte et d'optimisation de revêtements thermiques. Les modèles d'apprentissage profond peuvent être construits sur une base de données de matériaux existants avec leurs propriétés thermiques connues. En incorporant des caractéristiques structurales et chimiques, ainsi que des propriétés thermiques, ces modèles peuvent prédire la conductivité thermique, la capacité thermique et d'autres propriétés des matériaux et des revêtements. Une fois formés, ces modèles peuvent être utilisés pour explorer rapidement de nouvelles combinaisons de matériaux et de revêtements en prédisant leurs performances thermiques. Cela peut réduire considérablement le besoin de tests expérimentaux coûteux et de simulations numériques longues, accélérant ainsi le processus d'optimisation des matériaux thermiques.

Citons ici quelques exemples.

---

<sup>12</sup> "Machine Learning for Predictive Modeling in Engineering" par A.H. Tan et X. Zhu. "Machine Learning for Multiscale Physics" par Efstathios Skordos, Gilles Lubineau et George Karniadakis. "Machine Learning for Materials Scientists and Engineers" par Weimin Liu, Shyue Ping Ong et Zi-Kui Liu. "Data-Driven Computational Materials Science" par Turab Lookman et Alex Zunger.

## **Prédiction des performances d'un échangeur de chaleur**

Les échangeurs de chaleur sont largement utilisés dans de nombreux domaines, tels que l'industrie chimique, la production d'énergie et la climatisation. L'objectif est d'optimiser leur conception pour maximiser les transferts de chaleur tout en minimisant les pertes d'énergie. Dans ce cas, l'apprentissage profond peut être utilisé pour créer un modèle qui prédit les performances d'un échangeur de chaleur en fonction de ses paramètres de conception, des propriétés des fluides impliqués et des conditions opérationnelles. Ce modèle serait informé par les lois physiques régissant les transferts thermiques. L'avantage de cette approche est qu'elle permettrait de rapidement évaluer différentes configurations de conception, en évitant d'avoir à réaliser des simulations numériques coûteuses pour chaque cas. Le modèle pourrait également fournir des informations sur les zones critiques à améliorer pour optimiser l'efficacité thermique de l'échangeur de chaleur.

## **Diagnostic des défaillances dans un système de refroidissement**

Dans les systèmes de refroidissement industriels ou dans les véhicules, les problèmes de défaillance ou de performance réduite peuvent être coûteux et critiques. L'apprentissage profond peut jouer un rôle crucial dans le diagnostic rapide et précis de ces problèmes. En utilisant des données de température, de pression et d'autres paramètres collectées en temps réel, ainsi que des modèles physiques qui décrivent les comportements thermiques attendus du système, un modèle d'apprentissage profond peut être formé pour identifier les anomalies ou les déviations par rapport aux performances normales. Par exemple, si un système de refroidissement présente des fluctuations inhabituelles de température ou une baisse de pression, le modèle d'apprentissage profond pourrait détecter ces anomalies en comparant les données observées avec les prédictions basées sur les lois thermiques et les comportements attendus du système. Cela permettrait de signaler rapidement les problèmes potentiels, aidant ainsi à prendre des mesures correctives avant qu'ils ne deviennent plus graves ou coûteux.

## **Détection de fissures dans des matériaux**

Le contrôle non destructif (CND) est utilisé pour inspecter des matériaux et des structures sans les endommager. La détection de fissures ou d'autres défauts internes est une tâche cruciale dans des secteurs tels que l'aérospatiale, l'industrie manufacturière et la construction. En utilisant des données provenant de techniques de CND telles que les ultrasons, les rayons X ou la thermographie infrarouge, combinées à des modèles basés sur les lois physiques de la propagation des ondes et des signaux, l'apprentissage profond peut être utilisé pour créer un modèle de détection de fissures. Le modèle peut apprendre à détecter les caractéristiques subtiles associées aux fissures à partir des données recueillies. En intégrant des informations physiques sur la façon dont les fissures affectent la propagation des ondes ou les distributions de température, le modèle peut identifier et localiser avec précision les défauts dans les matériaux. Cela permet d'améliorer la précision de la détection par rapport aux méthodes traditionnelles, tout en réduisant le besoin d'experts hautement spécialisés pour interpréter les résultats. L'apprentissage profond informé par la physique offre ainsi une approche plus rapide et plus automatisée pour le CND, avec des avantages potentiels en termes de rapidité, de fiabilité et de coûts.



## Détection de fuites dans des canalisations

La détection de fuites dans les canalisations est un exemple concret d'application de l'apprentissage profond pour la détection d'anomalies et de défauts à l'aide de la thermographie. Dans l'industrie, les fuites dans les canalisations peuvent entraîner des pertes d'énergie et de ressources, ainsi que des risques potentiels pour la sécurité. L'apprentissage profond peut être utilisé pour détecter ces fuites à partir d'images thermiques. Le modèle d'apprentissage profond peut être formé à partir d'un ensemble de données d'images thermiques qui inclut à la fois des images de canalisations normales et des images avec des fuites simulées. Le modèle apprendra à identifier les motifs thermiques caractéristiques des fuites, tels que des zones de température plus élevée par rapport à l'environnement. Lorsqu'il est appliqué à de nouvelles images thermiques, le modèle peut détecter les zones potentielles de fuites en identifiant les régions anormalement chaudes. Cela permet de repérer rapidement les anomalies et les défauts, aidant ainsi les équipes de maintenance à prendre des mesures préventives avant que les problèmes ne s'aggravent.

## Prédiction de la production d'énergie solaire

L'efficacité de la production d'énergie solaire dépend de nombreux facteurs tels que la position du soleil, l'inclinaison des panneaux, la couverture nuageuse et d'autres conditions environnementales. Prédire avec précision la production d'énergie solaire est crucial pour une utilisation efficace de l'énergie solaire. En utilisant des données historiques de production d'énergie solaire, ainsi que des données météorologiques en temps réel, un modèle d'apprentissage profond informé par les lois physiques de la conversion d'énergie solaire peut être formé pour prédire la production future d'énergie solaire. Le modèle pourrait prendre en compte des variables telles que l'angle d'incidence du soleil, la température ambiante et la couverture nuageuse pour estimer la production attendue. En incorporant ces informations dans le modèle, il serait capable de fournir des prévisions plus précises, aidant ainsi à optimiser la gestion de l'énergie solaire, à planifier l'utilisation de l'énergie et à éviter les fluctuations inattendues de la production.

Pour ce qui concerne plus spécifiquement la résolution des problèmes inverses dans divers domaines de l'ingénierie, où on cherche à déduire les paramètres internes d'un système à partir des données observées, cette approche peut aider de plusieurs manières<sup>13</sup>. En incorporant des connaissances physiques, les modèles d'apprentissage profond peuvent contrôler la stabilité numérique des solutions pour les problèmes inverses, évitant ainsi les solutions non physiques ou instables. Les contraintes physiques agissent comme des « régularisateurs » naturels, aidant à restreindre l'espace des solutions possibles et à prévenir le surajustement aux données. Les connaissances physiques peuvent permettre de réduire la dimensionnalité de l'espace des paramètres, facilitant ainsi la recherche de solutions optimales dans un espace plus restreint. Les modèles DLIP peuvent obtenir des résultats

---

<sup>13</sup> "Deep Learning" par Ian Goodfellow, Yoshua Bengio et Aaron Courville. "Machine Learning: A Bayesian and Optimization Perspective" par Sergios Theodoridis et Konstantinos Koutroumbas. "Deep Learning for Inverse Problems in Imaging" par Mathews Jacob et Joyita Dutta. "Computational Inverse Problems in Electrocardiology" par Mark Potse et Matthijs Cluitmans. "Deep Learning for Medical Image Analysis" par S. Kevin Zhou et Hayit Greenspan.

fiables même avec des ensembles de données limités ou bruités, en exploitant la structure sous-jacente du problème. Lorsque l'on dispose de plusieurs types de données observées, l'intégration des lois physiques peut aider à combiner ces informations de manière cohérente pour obtenir une solution plus précise. En utilisant des modèles informés par la physique, on peut souvent réduire la nécessité d'effectuer de coûteuses simulations numériques itératives, ce qui accélère la résolution des problèmes inverses.

Pour ce qui concerne le traitement de grandes quantités de données<sup>14</sup> que l'on obtient par l'utilisation de méthodes de mesures de champ telle que la thermographie IR, l'apprentissage profond présente plusieurs avantages. Les modèles d'apprentissage profond sont capables d'extraire automatiquement des caractéristiques pertinentes à partir de données brutes, ce qui est particulièrement utile lorsque les données sont complexes ou contiennent des informations cachées. Les réseaux de neurones profonds peuvent être mis à l'échelle pour gérer des volumes massifs de données tout en maintenant des performances élevées, ce qui les rend adaptés aux mégadonnées. L'apprentissage profond peut capturer des relations complexes et non linéaires entre les variables, ce qui est important lorsque les données présentent des interactions subtiles ou multifactorielles. Les modèles d'apprentissage profond peuvent identifier des motifs subtils ou cachés dans les données, ce qui peut mener à de nouvelles découvertes ou à des informations précieuses. L'apprentissage profond est efficace pour traiter des données non structurées telles que des images, du texte ou de l'audio, ce qui élargit considérablement la portée des applications. Les modèles d'apprentissage profond peuvent s'adapter à de nouvelles données, ce qui permet de maintenir leur pertinence et leur performance au fil du temps. Contrairement à certaines méthodes traditionnelles, l'apprentissage profond peut parfois réduire la nécessité de prétraiter les données de manière extensive, ce qui accélère le processus d'analyse. Les modèles d'apprentissage profond peuvent apprendre à reconstruire des champs physiques à partir de données brutes, en utilisant des relations complexes qui peuvent être difficiles à modéliser analytiquement. Cela peut améliorer la précision des mesures et des prédictions. Les données de mesures sont souvent sujettes au bruit et aux erreurs de mesure. Les techniques d'apprentissage profond peuvent filtrer le bruit et améliorer la qualité des mesures en reconstruisant les champs sous-jacents à partir des données bruitées. L'apprentissage profond peut être utilisé pour interpoler des données manquantes ou extrapoler au-delà des limites de mesure, ce qui est utile pour obtenir des mesures complètes et continues des champs. Les modèles d'apprentissage profond peuvent s'adapter à des conditions environnementales variables, ce qui peut être bénéfique dans des situations où les champs sont susceptibles de changer rapidement. Enfin, l'apprentissage profond peut aider à optimiser l'alignement et la calibration des dispositifs de mesure en apprenant à compenser les imperfections et les décalages.

Il est cependant important de noter que l'apprentissage profond peut nécessiter des ressources computationnelles importantes et des ensembles de données de qualité pour fonctionner efficacement sur de grandes quantités de données. Une expertise en modélisation et en réglage des hyperparamètres est également essentielle pour obtenir de bons résultats.

---

<sup>14</sup> "Deep Learning" par Ian Goodfellow, Yoshua Bengio et Aaron Courville. "Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow" par Aurélien Géron. "Deep Learning for Computer Vision" par Rajalingappaa Shanmugamani. "Python Machine Learning" par Sebastian Raschka et Vahid Mirjalili. "Practical Deep Learning for Cloud, Mobile, and Edge" par Anirudh Koul, Siddha Ganju et Meher Kasam.

L'apprentissage profond a des applications très pertinentes en thermographie<sup>15</sup>, qui est une technique de mesure de température sans contact basée sur la détection de rayonnement infrarouge émis par les objets. Les modèles d'apprentissage profond peuvent apprendre à reconnaître les motifs thermiques caractéristiques associés à des défauts ou des anomalies dans des objets ou des structures. Cela peut être utilisé pour détecter des problèmes tels que des fuites thermiques, des surchauffes ou des dégradations dans des systèmes industriels, des bâtiments, etc. En analysant les images thermographiques, l'apprentissage profond peut aider à évaluer la qualité des produits manufacturés en détectant des variations de température ou des irrégularités qui pourraient indiquer des défauts. Les modèles d'apprentissage profond peuvent apprendre à prédire quand des composants ou des machines risquent de tomber en panne en détectant des changements subtils de température qui pourraient indiquer des problèmes imminents. L'apprentissage profond peut être utilisé pour localiser des objets dans une image thermographique, par exemple pour repérer des personnes ou des animaux dans l'obscurité. En utilisant des images thermographiques, l'apprentissage profond peut être employé pour reconstruire des scènes en 3D, permettant ainsi de mieux comprendre la distribution thermique dans un environnement. Les images thermographiques peuvent être influencées par des facteurs tels que les conditions d'éclairage ou les réflexions. Les modèles d'apprentissage profond peuvent aider à corriger ces problèmes pour obtenir des images plus claires et plus précises. En effet, lors de la capture d'images thermiques, les surfaces métalliques peuvent provoquer des réflexions thermiques qui perturbent la précision des mesures de température. Cela peut rendre difficile l'obtention d'informations fiables à partir de ces images, en particulier dans les environnements industriels. L'apprentissage profond peut être utilisé pour corriger ces réflexions thermiques indésirables. Le modèle peut être formé à partir d'un ensemble de données d'images thermiques comportant à la fois des réflexions et des images corrigées. En apprenant les motifs et les relations entre les réflexions et les zones réelles, le modèle peut prédire et soustraire les réflexions des images thermiques, laissant ainsi des images corrigées plus claires et plus précises. Cette correction améliore considérablement l'utilité des images thermiques en fournissant des informations plus fiables sur les températures réelles des objets sous-jacents, ce qui est crucial pour la détection des défauts, la surveillance de l'équipement industriel et d'autres applications où la précision des mesures est primordiale.

Bien que l'identification de modèles thermiques, c'est-à-dire la détermination des relations sous-jacentes entre les variables dans un ensemble de données expérimentales, soit un domaine déjà bien connu et riche d'applications, l'apprentissage profond peut y jouer un rôle important<sup>16</sup>. En effet, l'apprentissage profond est capable de capturer des relations complexes et non linéaires entre les variables, ce qui permet de modéliser des phénomènes plus sophistiqués et précis. Les modèles d'apprentissage profond peuvent automatiquement extraire les caractéristiques les plus pertinentes des données brutes, ce qui permet d'identifier les variables les plus influentes pour le modèle. L'apprentissage profond peut s'adapter à

---

<sup>15</sup> Plusieurs sources (conférences, articles, sites de codes) peuvent être trouvées en tapant les mots clés suivants sur un moteur de recherche : "Deep Learning for Image Analysis", "Thermography and Machine Learning", "Applications of Deep Learning in Non-Destructive Testing"

<sup>16</sup>"Deep Learning" par Ian Goodfellow, Yoshua Bengio et Aaron Courville. "Pattern Recognition and Machine Learning" par Christopher M. Bishop. "Machine Learning: A Probabilistic Perspective" par Kevin P. Murphy. "Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow" par Aurélien Géron. "Machine Learning: The Art and Science of Algorithms that Make Sense of Data" par Peter Flach. "Machine Learning: A Bayesian and Optimization Perspective" par Sergios Theodoridis et Konstantinos Koutroumbas.

différents types de données, qu'il s'agisse de séries temporelles, d'images, de textes, etc. Cela permet d'identifier des modèles dans une grande variété de domaines. Les techniques d'apprentissage profond peuvent être utilisées pour réduire la dimensionnalité des données, ce qui facilite la gestion et la modélisation de jeux de données massifs. En utilisant des méthodes d'apprentissage non supervisé, l'apprentissage profond peut aider à découvrir des modèles cachés ou des structures sous-jacentes dans les données. Dans certains cas, l'apprentissage profond peut être utilisé pour identifier des relations causales entre les variables, ce qui peut être crucial pour la prise de décision. Les modèles identifiés grâce à l'apprentissage profond peuvent être utilisés pour faire des prédictions précises sur de nouvelles données et généraliser à des scénarios inconnus.

La réduction de modèles thermiques est assez proche de celui de l'identification en termes d'objectifs mais les méthodes mathématiques sont très différentes. L'apprentissage profond peut apporter des avantages significatifs à la réduction de modèle<sup>17</sup>, qui consiste à simplifier des modèles complexes tout en conservant leurs caractéristiques importantes. En effet, les méthodes traditionnelles de réduction de modèle se concentrent souvent sur des approximations linéaires. L'apprentissage profond peut capturer des relations non linéaires complexes, ce qui permet de représenter de manière plus précise des systèmes complexes. L'apprentissage profond peut être utilisé pour trouver des modèles directement à partir de données d'entraînement, ce qui est particulièrement utile lorsque les équations exactes du modèle sont difficiles à obtenir. Les techniques d'apprentissage profond peuvent être utilisées pour réduire la dimensionnalité des données tout en conservant les informations essentielles, ce qui peut être utile pour simplifier des modèles trop complexes. Les modèles d'apprentissage profond peuvent identifier automatiquement les caractéristiques les plus pertinentes dans les données, ce qui peut aider à réduire la complexité du modèle en se concentrant sur les variables les plus influentes. Les modèles réduits grâce à l'apprentissage profond peuvent fournir des prédictions précises sur de nouvelles données, ce qui est essentiel pour garantir que la réduction de modèle n'entraîne pas une perte significative d'information. Dans les systèmes complexes où les modèles détaillés sont coûteux à résoudre, l'apprentissage profond peut fournir des modèles réduits plus rapides à évaluer, tout en maintenant des performances raisonnables.

## Logiciels et codes de calculs

Le meilleur moyen de comprendre étant d'appliquer, il existe une quantité incroyable de codes, libres ou payants, qui permette de se familiariser assez rapidement avec les méthodes d'apprentissage et à commencer à traiter des applications complexes. Parmi les codes libres de droits voici une liste non exhaustive des plus populaires :

- TensorFlow : Développé par Google, TensorFlow est l'un des environnements d'apprentissage les plus populaires. Il prend en charge le développement de modèles pour une variété d'applications, y compris l'apprentissage profond.  
Site officiel de TensorFlow : <https://www.tensorflow.org/>

---

<sup>17</sup>"Deep Learning" par Ian Goodfellow, Yoshua Bengio et Aaron Courville. "Machine Learning: A Probabilistic Perspective" par Kevin P. Murphy. "Machine Learning: The Art and Science of Algorithms that Make Sense of Data" par Peter Flach. "Deep Learning for Computer Vision" par Rajalingappaa Shanmugamani. "Data Science for Business" par Foster Provost et Tom Fawcett.

- Code source sur GitHub : <https://github.com/tensorflow/tensorflow>
- PyTorch : Développé par Facebook, PyTorch est un autre environnement d'apprentissage très populaire. Il est apprécié pour sa flexibilité et son approche dynamique du graphique computationnel.  
Site officiel de PyTorch : <https://pytorch.org/>  
Code source sur GitHub : <https://github.com/pytorch/pytorch>
  - Keras : Keras est une interface haut niveau pour la création et l'entraînement de modèles en deep learning. Il peut s'exécuter sur TensorFlow, Theano ou Microsoft Cognitive Toolkit (CNTK).  
Site officiel de Keras : <https://keras.io/>  
Code source sur GitHub : <https://github.com/keras-team/keras>
  - Caffe : Caffe est un environnement d'apprentissage rapide et modulaire, principalement utilisé pour la vision par ordinateur.  
Site officiel de Caffe : <http://caffe.berkeleyvision.org/>  
Code source sur GitHub : <https://github.com/BVLC/caffe>
  - MXNet : MXNet est un environnement d'apprentissage flexible et efficace, particulièrement adapté aux réseaux de neurones récurrents (RNN) et aux réseaux de neurones convolutionnels (CNN).  
Site officiel de MXNet : <https://mxnet.apache.org/>  
Code source sur GitHub : <https://github.com/apache/incubator-mxnet>
  - Chainer : Chainer est un environnement d'apprentissage qui adopte une approche de programmation impérative, facilitant le débogage et le prototypage rapide.  
Site officiel de Chainer : <https://chainer.org/>  
Code source sur GitHub : <https://github.com/chainer/chainer>
  - Theano : Bien que Theano ne soit plus activement développé, il a joué un rôle important dans le développement précoce de bibliothèques de deep learning. Il est toujours utilisé dans certains projets.  
Code source sur GitHub : <https://github.com/Theano/Theano>
  - Deeplearning4j : Deeplearning4j est un environnement d'apprentissage pour Java et Scala, avec un accent sur le déploiement sur des systèmes distribués.  
Site officiel de Deeplearning4j : <https://deeplearning4j.org/>  
Code source sur GitHub : <https://github.com/eclipse/deeplearning4j>

Nous donnons dans la suite quelques exemples d'illustrations. Les courtes synthèses qui suivent, accompagnées chacune par quelques références majeures, ont été produites par les personnes qui ont présenté leurs résultats lors de la journée SFT du 8 juin 2023 « Inversion de données faisant appel à un modèle en thermique : quels apports de l'intelligence artificielle ? » organisée par le groupe thématique METTI (Mesures Thermiques et Techniques Inverses) de la SFT.

## **Quel apport de l'IA dans l'obtention et le traitement des données expérimentales ?**

**Emmanuelle ABISSET-CHAVANNE, Marie-Marthe GROZ**  
**Laboratoire I2M, UMR 5295, Université de Bordeaux, Talence**

L'augmentation rapide des capacités de calcul ces dernières années a ouvert la porte à l'utilisation de l'IA\* dans tous les domaines où les données expérimentales ou synthétiques sont présentes. La thermique en est un bon exemple. On rencontre aujourd'hui deux principales applications de l'IA pour le traitement de données thermiques expérimentales : 1) la détection de « pattern » (défauts, zones d'intérêt) ou de dérive en continu [1-6]. ; 2) l'extraction de paramètres pertinents pour la réduction de dimensionnalité des données [7-8].

La détection de « pattern » se place en général dans un contexte de temps réel avec une excitation thermique active ou passive et une instrumentation adaptée. On y retrouve l'utilisation de l'apprentissage profond entraîné sur une grande quantité de données labellisée, l'instrumentation thermique pouvant générer des To de données en quelques minutes. Mais l'introduction de l'expertise scientifique en thermique, que ce soit par une modification de l'instrumentation ou par un prétraitement adéquat de la donnée, permet d'améliorer considérablement les résultats par rapport à une approche force brute [9-10].

L'extraction de paramètres permet quant à elle une reconstruction des champs thermiques à partir d'une quantité de données limitée, ce qui peut être intéressant dans un certain nombre d'applications industrielles. Toutefois, cette approche est souvent limitée par la difficile explicabilité des paramètres extraits, diminuant de fait la confiance dans la méthode.

Ainsi, l'IA appliquée dans le traitement des données expérimentales permet une détection de défauts automatique en continu et en temps réel ainsi que l'extraction de paramètres pour la réduction de modèles. Toutefois ces méthodes nécessitent une labellisation coûteuse dans le cas de l'apprentissage supervisé et l'expertise thermique reste très importante pour garantir une performance égale ou supérieure à ce que les méthodes « traditionnelles » permettent d'atteindre.

Reste enfin la question de la qualité de la donnée qui est fondamentale pour ces méthodes, que ce soit en thermique ou dans d'autres domaines.

En théorie une « bonne donnée » est une donnée : i) intelligente -- c'est-à-dire qu'elle est cohérente et contient de l'information--, ii) que l'on peut mesurer, et iii) qui permet de répondre à la problématique posée. Ainsi, parce que ces méthodes s'affranchissent des modèles physiques basés sur une certaine représentation des systèmes, un des principaux apports de l'IA dans l'obtention de la mesure expérimentale est de ramener le focus sur la définition de la problématique et de réfléchir à une instrumentation intelligente et agile dédiée à cette problématique et à la « bonne donnée » associée (et non à la caractérisation du « modèle support »).

Reste que dans la pratique, la quantité de données disponibles (labellisée ou non) peut parfois être limitée. Ainsi l'hybridation ou la combinaison des modèles physiques et de l'IA est aujourd'hui un axe de recherche de fort intérêt. Cela peut se faire via l'augmentation de la donnée (données synthétiques et curriculum learning), via l'hybridation de l'approche en

combinant par exemple l'IA pour la détection des défauts et les modèles physiques pour leur caractérisation ou via l'hybridation directe des modèles. Ces approches permettent d'introduire dans les approches d'IA les connaissances et compétences des communautés scientifiques afin de s'enrichir mutuellement pour répondre au mieux aux objectifs.

*\*Par IA, nous considérerons toutes les méthodes entrant dans le champ du Machine learning ou du Deep learning.*

## Références

- [1] Yousefi, B., Kalhor, D., Usamentiaga Fernández, R., Lei, L., Castanedo, C. I., & Maldague, X. P. (2018). Application of deep learning in infrared non-destructive testing. *QIRT 2018 Proceedings*.
- [2] Shi, J., Chang, Y., Xu, C., Khan, F., Chen, G., & Li, C. (2020). Real-time leak detection using an infrared camera and Faster R-CNN technique. *Computers & Chemical Engineering, 135*, 106780.
- [3] Özdil, A., & Yilmaz, B. (2023). Medical infrared thermal image based fatty liver classification using machine and deep learning. *Quantitative InfraRed Thermography Journal*, 1-18.
- [4] Mohanraj, M., Jayaraj, S., & Muraleedharan, C. (2015). Applications of artificial neural networks for thermal analysis of heat exchangers—a review. *International Journal of Thermal Sciences, 90*, 150-172.
- [5] Ngarambe, J., Yun, G. Y., & Santamouris, M. (2020). The use of artificial intelligence (AI) methods in the prediction of thermal comfort in buildings: Energy implications of AI-based thermal comfort controls. *Energy and Buildings, 211*, 109807.
- [6] Helvig, K., Trouvé-Peloux, P., Gaverina, L., Abeloos, B., & Roche, J. M. (2023). Automated crack detection on metallic materials with flying-spot thermography using deep learning and progressive training. *Quantitative InfraRed Thermography Journal*, 1-20.
- [7] Kirchgässner, W., Wallscheid, O., & Böcker, J. (2023). Thermal neural networks: Lumped-parameter thermal modeling with state-space machine learning. *Engineering Applications of Artificial Intelligence, 117*, 105537.
- [8] Küfner, T., Uhlemann, T. H. J., & Ziegler, B. (2018). Lean data in manufacturing systems: Using artificial intelligence for decentralized data reduction and information extraction. *Procedia CIRP, 72*, 219-224.
- [9] Groz, M. M., Sommier, A., Abisset, E., Chevalier, S., Battaglia, J. L., Batsale, J. C., & Pradere, C. (2021). Thermal resistance field estimations from IR thermography using multiscale Bayesian inference. *Quantitative InfraRed Thermography Journal, 18*(5), 332-343.
- [10] Grieu, S., Faugeron, O., Traoré, A., Claudet, B., & Bodnar, J. L. (2011). Artificial intelligence tools and inverse methods for estimating the thermal diffusivity of building materials. *Energy and Buildings, 43*(2-3), 543-554.

## Identification de systèmes thermiques linéaires et non linéaires par des structures mathématiques d'intégration d'ordre non entier

Jean-Luc BATTAGLIA

Laboratoire I2M, UMR 5295, Université de Bordeaux, Talence

Les méthodes d'identification de systèmes linéaires sont bien connues de la communauté scientifique et plus particulièrement des automaticiens. Les thermiciens se sont approprié ces techniques car elles permettent de répondre de manière assez simple à la modélisation de systèmes thermiques complexes où de nombreux paramètres sont mal connus. Ainsi, par exemple, un système fortement hétérogène, constitué de plusieurs matériaux différents et faisant donc intervenir de nombreuses propriétés thermiques. Mais c'est aussi le cas lorsque la localisation de capteurs thermiques au sein du système est mal connue. Tout ceci conduit rapidement à rechercher une approche plus simple que la fastidieuse caractérisation de toutes les propriétés inconnues. L'approche d'identification de systèmes consiste à identifier les paramètres d'une structure de modèle liant plusieurs entrées (flux, températures) à plusieurs sorties (températures mesurées par différents types de capteurs) à partir d'une expérience unique consistant à mesurer les sorties pour des évolutions quelconques des entrées. La structure de modèle choisie est généralement une succession des dérivées temporelles des fonctions d'entrées et de sorties. Ces méthodes s'apparentent donc totalement à des pratiques d'apprentissage d'un modèle à partir de mesures. Au fil du temps, des développements de ces approches à des comportements non-linéaires des systèmes ont été élaborées. Des structures de modèles faisant intervenir des dérivées d'ordre non entier des entrées et des sorties ont aussi été développées afin de se rapprocher des modèles de connaissances, notamment dans le domaine de la diffusion de la chaleur. Enfin, nous avons montré l'intérêt d'utiliser préférentiellement l'opérateur d'intégration plutôt que la dérivation afin de ne pas amplifier les erreurs de mesures.

En dehors de l'aspect purement lié à la simulation des systèmes pour des évolutions quelconques des entrées, cette approche d'identification de systèmes trouve une application fondamentalement intéressante pour la résolution de problèmes inverses, à savoir l'identification des entrées à partir du modèle identifié et des mesures aux capteurs.

### Références incontournables

- Ljung, L., *System identification. Theory for the user*, Prentice – Hall, inc., Englewood Cliffs, New Jersey, 1986.
- Walter, E., Pronzato, L., *Identification de modèles paramétriques à partir de données expérimentales*, Collection Modélisation Analyse Simulation et Commande, Éditions Masson, 1994.
- Karel J. Keesman, *System Identification, An Introduction*, Advanced Textbooks in Control and Signal Processing, Springer-Verlag London Limited 2011.
- T. Söderström and P. Stoïca, *System Identification*, Prentice Hall International, Series in Systems and Control Engineering, 1989.
- J.R. Raol, G. Girija and J. Singh, *Modelling and Parameter Estimation of Dynamic Systems*, The Institution of Engineering and Technology, London, United Kingdom First edition, 2004.
- M. Verhaegen and V. Verdult, *Filtering and System Identification, A Least Squares*



*Approach*, Cambridge University Press 2007.

- Oldham K. B., Spanier J., *A general solution of the diffusive equation for semi-infinite geometries*, Journal of Mathematical Analysis and Applications 39 (1972) 655-669.

## Couplages entre modélisation physique et apprentissage statistique appliqués à la modélisation des propriétés radiatives d'atmosphères non uniformes

Frédéric ANDRE<sup>1</sup>, Cindy DELAGE<sup>1</sup>, Loic GUILMARD<sup>1</sup>, Mathieu GALTIER<sup>1</sup>, Céline CORNET<sup>2</sup>

<sup>1</sup>Laboratoire CETHIL, UMR 4008, Université Claude-Bernard Lyon 1, Villeurbanne

<sup>2</sup>Laboratoire LOA, UMR 8518, Université Lille 1, Villeneuve d'Ascq

Il existe différentes façons d'introduire des contraintes physiques dans un processus d'apprentissage statistique [1] : 1/ augmenter le jeu de données d'entraînement, de façon à forcer le modèle à rendre compte de la façon la plus fidèle possible d'un plus grand nombre de configurations, 2/ imposer des contraintes au modèle en modifiant la fonction coût à optimiser (en ajoutant des termes sur les dérivées, par exemple), 3/ en travaillant directement sur la structure du modèle de façon à réduire significativement l'espace de recherche de la solution.

Dans le problème qui nous intéresse (modéliser les propriétés d'absorption d'atmosphères gazeuses dans un contexte d'inversion de données satellitaires), nous avons choisi de suivre la troisième voie (démarche inductive). Pour ce faire, nous sommes partis d'un modèle physique intuitif [2,3] auquel nous avons ajoutés différentes hypothèses statistiques et physiques réalistes permettant d'identifier une structure de réseau dans lequel un certain nombre de paramètres sont inconnus [4,5]. L'apprentissage consiste alors à identifier ces paramètres inconnus par ajustement sur des données de référence dites raies-par-raies (spectres à hautes résolutions spectrales issus de modélisations physiques). L'intérêt de la méthode est que les paramètres ajustés peuvent être interprétés (dans la mesure où ils ont la même signification que ceux introduits lors de la phase de modélisation physique et statistique), évitant de fait le côté « boîte noire » de nombreux modèles fondés uniquement sur l'apprentissage machine.

De plus, la structure récurrente proposée s'écrit comme la composée de transformées de Laplace et de fonctions de Bernstein (ou exposants de Laplace de subordinateurs de Lévy), rendant l'analyse des propriétés du modèle (et de ses dérivées successives) particulièrement simple en s'appuyant sur la théorie des copules Archimédéennes [7]. Ceci permet notamment, presque sans aucun calcul, d'assurer que le modèle proposé est respectueux de la physique du transfert radiatif lorsqu'il est utilisé pour l'évaluation de flux nets échangés. Enfin, le modèle obtenu après régression se met assez simplement sous une forme tabulée, permettant de précalculer à l'avance la totalité des paramètres utiles aux calculs. Ceci offre la possibilité de produire des approximations des transmissivités de trajets non-uniformes à la fois précises, respectueuses de la physique et très peu coûteuses en temps CPU, et donc bien adaptées à des calculs opérationnels d'inversion de données satellitaires.

### Références directement citées dans ce résumé

[1] G. E. Karniadakis, I. G. Kevrekidis, L. Gu, P. Perdikaris, S. Wang, L. Yang, "Physics-informed machine learning", *Nature Review Physics*, vol. 3, pp. 422-440, 2021.

[2] W.L. Godson, "The evaluation of infra-red radiative fluxes due to atmospheric water vapour", *Q. Journal Royal Meteorological Society*, vol. 79, pp. 367-379, 1953.

- [3] S. J. Young, *Band Model Theory of Radiation Transport*, The Aerospace Press, 2013.
- [4] F. André, C. Cornet, C. Delage, Ph. Dubuisson, M. Galtier, "On the use of recurrent neural networks for fast and accurate non-uniform gas radiation modeling", *J. Quant. Spectr. Rad. Transfer*, vol. 293, 108371, 2022.
- [5] F. André, C. Delage, L. Guilnard, M. Galtier, C. Cornet, « Bridging physics and statistical learning methodologies for the accurate modeling of the radiative properties of non-uniform atmospheric paths », soumis pour publication dans *Journal of Quantitative Spectroscopy and Radiative Transfer*, 2023.

**Références importantes utilisées dans ce travail (les [8-10] sont plus teintées Statistical Learning / Neural Network)**

- [6] G. R. Schorack, *Probability for statisticians*, Springer text in statistics, Springer, 2000.
- [7] R. B. Nelsen, *An introduction to copulas*, Second Edition, Springer series in statistics, Springer, 2006.
- [8] T. Hastie, R. Tibshirani, J. Friedman, *The Elements of Statistical Learning: Data mining, Inference and Prediction*, Second Edition, Springer Series in Statistics, 2017.
- [9] A. D. Jagtap, G. E. Karniadakis, "How important are activation functions in regression and classification? A survey, performance comparison, and future directions", arXiv, 2209.02681, 2022.
- [10] D. P. Kingma, J. L. Ba, "Adam: a method for stochastic optimization", in: *Int Conf. Learn. Represent.*, 2015.

## Réseaux neuronaux convolutifs pour la thermographie quantitative en environnement complexe

**Marie-Hélène AUMEUNIER, Alexis JUVEN**  
**CEA/IRFM, Saint Paul-lez- Durance**

La thermographie infrarouge est un diagnostic essentiel dans les machines de fusion nucléaire pour contrôler la température des composants face au plasma soumis à d'importants flux de chaleur (de 10 à 20 MW/m<sup>2</sup>). Cependant, l'estimation de la température de surface à partir d'une image infrarouge reste problématique dans un environnement radiatif chaud et entièrement réfléchissant. Cela nécessite de traiter un problème multiparamétrique et de résoudre l'émissivité variable des cibles observées, les réflexions multiples ajoutant des flux parasites, la résolution spatiale des caméras, etc.

Une technique prometteuse pour la thermographie quantitative inverse consiste à utiliser des algorithmes d'apprentissage automatique, entraînés exclusivement à partir d'images de synthèse (ou simulées). Les images simulées sont le résultat d'un diagnostic synthétique, également appelé "jumeau numérique", capable de modéliser tous les phénomènes impliqués dans la chaîne de mesure - de la source de plasma (charges thermiques sur les composants à l'intérieur du récipient) à la caméra, y compris l'interaction photon-paroi [1]. Contrairement à la stratégie d'inversion itérative basée sur la minimisation entre les images expérimentales et les images prédites par le modèle direct [2], les méthodes supervisées d'apprentissage profond sont basées sur un ensemble de données d'entraînement qui permet de calibrer les poids des réseaux neuronaux. Dans notre cas, l'inversion IA est réalisée à partir d'un vaste ensemble de données de 160 000 images simulées et le réseau utilisé est un réseau neuronal à convolution (CNN – Convolution Neural Network), particulièrement adapté pour traiter des images en entrée et sortie du réseau. Le réseau calibré après la phase d'apprentissage est alors prêt pour traiter des images de caméra (en radiance ou température apparente) et prédire les températures réelles de surface associées à chaque pixel. Éprouvée sur le jumeau numérique de la machine de fusion nucléaire française WEST, l'inversion IA donne la vraie température des composants avec une erreur inférieure à 10 %, sans connaître la valeur de l'émissivité [3, 4, 5].

Cette méthode est maintenant prête à être testée et utilisée avec des données expérimentales mais de nombreux défis sont encore à relever. L'élément clé de ces méthodes est l'obtention d'une base de données d'entraînement étendue d'images infrarouges simulées couvrant tous les scénarios possibles et éviter les « hallucinations » (mauvaises prédictions sans que l'utilisateur ne puisse le vérifier). Cela signifie la gestion et la propagation des incertitudes à la fois du modèle d'inversion IA et des données expérimentales, l'obtention de données de sorties probabilistes, i.e. avec un niveau de confiance sur les températures prédites tenant compte des incertitudes des modèles et expériences.

### Références

[1] M.-H. Aumeunier, et al., Nuclear Materials and Energy, vol. 26, p. 100879, 2021. [2] C.Talatizi et al., FED, 171 (2021), 112570

- [2] A. Juven et al., *Temperature Estimation in Fusion Devices using Machine Learning techniques on Infrared Specular Synthetic Data*, 2022 IEEE 14th Image, Video, and Multidimensional Signal Processing Workshop
- [3] M.-H. Aumeunier, et al., *Surface temperature measurement from infrared synthetic diagnostic in preparation for ITER operation*, proceeding of IAEA FEC 2023, London
- [4] A. Juven, M.-H. Aumeunier and J. Marot, *"U-Net for temperature prediction from simulated infrared images in tokamaks,"* Nuclear Materials Energy, under review.

## Réseaux de neurones évolutifs et modèles d'erreur d'approximation pour la résolution de problèmes inverses

Jasmin L. LOUZADA<sup>1</sup>, Nirupam CHAKRABORTI<sup>1</sup>, Helcio R. B. ORLANDE<sup>1</sup>, Raphael C. CARVALHO<sup>1</sup>, Marcelo J. COLAÇO<sup>2</sup> et Italo M. MADEIRA<sup>3</sup>

<sup>1</sup> Department of Mechanical Engineering, Politécnica/COPPE, UFRDJ, Brazil

<sup>2</sup> CENPES Research and Development Center, PETROBRAS S. A., Brazil

<sup>3</sup> Faculty of Mechanical Engineering, Czech Technical University, Czech Republic

En ingénierie, les modèles haute-fidélité sont généralement construits sous des hypothèses appropriées et sont basés sur des principes physiques (lois de conservation et équations constitutives). Les modèles haute-fidélité sont souvent non linéaires, multidimensionnels et multiphysiques, afin de représenter les phénomènes analysés avec le moins d'incertitude possible. Le coût de calcul requis pour la résolution d'un modèle haute-fidélité est beaucoup trop important pour permettre son utilisation pour la résolution de problèmes inverses, en particulier avec des simulations stochastiques via des méthodes de Monte Carlo par chaîne de Markov [1,2]. Par conséquent, une application importante de l'intelligence artificielle est d'obtenir des modèles de substitution pour le remplacement de modèles haute-fidélité lors de la résolution de problèmes inverses.

Dans [3], un modèle de substitution obtenu avec l'algorithme de réseau neuronal évolutif (EvoNN) [4] a été appliqué pour la solution d'un problème inverse impliquant le phénomène des coups de bélier en mécanique des fluides. Ce phénomène peut provenir de la fermeture rapide d'une vanne ou de changements soudains du point de fonctionnement d'une pompe dans une canalisation, ce qui peut provoquer des ondes de pression de grande amplitude et de vitesse autour de 1000 m/s. EvoNN applique un algorithme évolutif multi-objectif sur une population de réseaux de neurones de topologie et d'architecture flexibles. Une couche cachée est utilisée. La partie inférieure du réseau est soumise à des opérations de croisement et de mutation spécialement conçues et la convergence est obtenue en soumettant la couche supérieure à une procédure des moindres carrés linéaires (LLSQ). L'algorithme évolutionnaire multi-objectifs tente d'optimiser simultanément la précision et la complexité de la population du réseau neuronal, ce qui conduit finalement à une frontière de Pareto contenant un ensemble de modèles optimaux montrant les meilleurs compromis possibles entre ces objectifs conflictuels. EvoNN recommande un modèle de substitution à partir du front de Pareto optimal en utilisant un critère d'information.

Malgré le fait qu'EvoNN ait fourni un substitut très précis du modèle haute-fidélité aux points d'entraînement, il n'était pas capable de représenter complètement les effets les plus significatifs résultant du phénomène des coups de bélier dus à des transitoires très rapides. En conséquence, les solutions du problème inverse, en remplaçant le modèle haute-fidélité par le modèle EvoNN, étaient biaisées. L'approche du modèle d'erreur d'approximation (AEM) a ensuite été mise en œuvre, et les erreurs de modélisation ont été représentées sous forme de variables gaussiennes [1,5]. Les échantillons des paramètres utilisés pour calculer les erreurs d'approximation avec les simulations de Monte-Carlo étaient différents de ceux utilisés pour l'entraînement des EvoNNs. Avec le modèle EvoNN et l'approche AEM, des chaînes de Markov avec  $10^6$  états pourraient être générées avec un faible coût de calcul, fournissant ainsi des échantillons qui pourraient représenter de manière appropriée les

distributions a posteriori des paramètres du modèle. Par conséquent, il a été montré dans [3] que même les modèles de substitution précis comme les EvoNN nécessitent la modélisation des erreurs d'approximation pour la solution non biaisée des problèmes inverses liés au phénomène des coups de bélier.

### **Références**

- [1] J. Kaipio, P. Somersalo, Computational and Statistical Methods for Inverse Problems, Springer, Berlin, 2004.
- [2] M. N. Ozisik, H. R. B. Orlande, Inverse Heat Transfer: Fundamentals and Applications, Second ed., CRC Press, Boca Raton, 2021.
- [3] R. Carvalho et al. Parameter estimation with the Markov Chain Monte Carlo method aided by evolutionary neural networks in a water hammer model. Computational and Applied Mathematics, v. 42, n. 1, p. 35, 2023.
- [4] M. Helle, F. Petterson, N. Chakraborti, H. Saxen, Modelling Noisy Blast Furnace Data using Genetic Algorithms and Neural Networks, Steel Research International. 77 (2), 2006.
- [5] A. Nissinen, Modelling errors in electrical impedance tomography, Dissertation in Forestry and Natural Sciences, University of Eastern Finland, 2011.

## Apport des modèles réduits pour la mesure thermique indirecte en temps réel dans un four rayonnant

Benjamin GAUME, Yassine ROUIZI, Frédéric JOLY, Olivier QUEMENER  
Laboratoire LMEE, EA 3332, Université Paris-Saclay, Évry

La résolution de problèmes inverses non linéaires est en général effectuée par des procédures itératives, qui sont naturellement longues et ne permettent pas un traitement en temps réel. Lorsque l'on est conduit à discrétiser finement la géométrie complexe d'un dispositif dont on veut suivre l'évolution de température, une des approches utilisées est la réduction de modèle. Dans ce domaine, la méthode modale a déjà fait la preuve de sa pertinence dans le cas de problèmes de diffusion thermique avec ou sans termes de transport [1]. Le principe de cette méthode est de décomposer le champ de température recherché sur une base modale. On montre alors qu'un nombre réduit de vecteurs propres  $\tilde{V}_i$  de cette base (ou reconstruits à partir de cette base) permet de reconstituer de façon satisfaisante le champ de température  $T$ . Le problème résolu initialement caractérisé par  $N$  degrés de liberté ne dépend alors que d'un faible nombre d'inconnues  $\tilde{N}$  et la durée de simulation en est fortement réduite.

Une étude récente a adapté le modèle modal à ordre réduit d'amalgame (AROMM) afin d'incorporer le rayonnement thermique (par la méthode des radiosités) pour les simulations directes [2]. On utilise ici le fait que ces méthodes ne dégradent pas la géométrie, et donnent accès à l'ensemble du champ de température, ce qui est obligatoire pour une modélisation correcte du rayonnement. Les méthodes modales ont par ailleurs déjà montré leur capacité à identifier des paramètres pour des transferts de chaleur en l'absence de la prise en compte du rayonnement [3-4].

Nous proposons une extension de la méthode AROMM pour l'identification de paramètres et l'obtention en temps réel l'intégralité du champ de température d'un four chauffé par une source thermique rayonnante [5], à partir de quelques points de mesure. La température de la source thermique rayonnante est d'abord identifiée via un modèle réduit d'ordre faible qui permet la régularisation du problème et agit comme un filtre à haute fréquence, en utilisant pour le problème inverse un algorithme de régions de confiance. A partir de cette température identifiée, l'intégralité du champ thermique est alors récupérée par simulation directe grâce à un modèle réduit de rang supérieur afin d'obtenir une meilleure précision. L'application traitée est une pièce complexe en titane chauffée par deux panneaux radiants placés dans un four. A partir de deux points de mesure, la température de l'ensemble de la pièce chauffée est récupérée en temps réel, avec une erreur maximum de 6% et une erreur moyenne de 2K pour une plage de travail de l'ordre de 500K sur la pièce.

Les résultats initiaux ouvrent la voie à son utilisation dans une boucle de contrôle, éventuellement en incluant davantage de paramètres non linéaires et leurs incertitudes. Cette étude souligne l'intérêt de la méthode AROMM pour les problèmes inverses impliquant à la fois le rayonnement et la conduction.

### Références :

[1] O. Quémener, F. Joly, A. Neveu, The generalized amalgam method for modal reduction, *International Journal of Heat and Mass Transfer*, Volume 55, Issue 4, 2012, Pages 1197-1207, DOI: <https://doi.org/10.1016/j.ijheatmasstransfer.2011.09.043>.



- [2] B. Gaume, F. Joly, O. Quéméner, Modal reduction for a problem of heat transfer with radiation in an enclosure, *International Journal of Heat and Mass Transfer*, Volume 141, 2019, Pages 779-788, DOI: <https://doi.org/10.1016/j.ijheatmasstransfer.2019.07.039>.
- [3] S. Carmona, Y. Rouizi, O. Quéméner, Spatio-temporal identification of heat flux density using reduced models. Application to a brake pad, *International Journal of Heat and Mass Transfer*, 128 (2019), p 1048-1063, <https://doi.org/10.1016/j.ijheatmasstransfer.2018.09.043>.
- [4] A.G. Chavez Castillo, B.Gaume, Y.Rouizi, ,P.Glouannec, Identification of insulating materials thermal properties by inverse method using reduced order model, *International Journal of Heat and Mass Transfer*, Volume 166, February 2021, 120683, <https://doi.org/10.1016/j.ijheatmasstransfer.2020.120683>
- [5] B. Gaume, Y. Rouizi, F. Joly, O. Quéméner, On-line indirect thermal measurement in a radiant furnace by a reduced modal model, *International Journal of Heat and Mass Transfer*, Volume 179, 2021, 121678, <https://doi.org/10.1016/j.ijheatmasstransfer.2021.121678>.

## **Modélisation du transfert radiatif dans des milieux participants, par réseaux de neurones bayésiens et méthode de Monte Carlo**

**Olivier FARGES, Alex ROYER, Pascal BOULET, Daria BUROT**  
**Laboratoire LEMTA, UMR 7563, Université de Lorraine, Nancy**

La problématique du transfert de chaleur par rayonnement dans le contexte des applications de combustion est de première importance, notamment pour des applications de type motorisation aéronautique. Dans des environnements présentant des températures et des concentrations en espèces participatives (CO, CO<sub>2</sub>, H<sub>2</sub>O, ...) élevées, le transfert de chaleur radiatif prédomine et doit être correctement modélisé. Une analyse thermique par le recours à une simulation numérique précise permet de concevoir des systèmes optimaux, de réduire le poids des systèmes de propulsion et la consommation de carburant, de modéliser de manière plus précise la formation de polluants, d'augmenter la durée de vie des moteurs ou d'améliorer la planification de la maintenance.

Cependant, la modélisation précise du transfert radiatif nécessite de nombreuses ressources informatiques alors qu'elle ne représente d'une partie d'une modélisation multiphysique complexe. En effet, la plupart des ressources sont utilisées pour la résolution de la dynamique des fluides et les calculs de combustion. Les réseaux de neurones artificiels (ANN) [1] ont déjà été utilisés dans des applications de transfert de chaleur en général et pour la modélisation du transfert radiatif en particulier [2].

Dans ce travail, la proposition consiste à utiliser des réseaux de neurones pour prédire directement la divergence du flux radiatif. Pour cela, une méthode de couplage entre un algorithme de Monte Carlo pour la génération de points d'entraînement et une méthode bayésienne [3,4] pour déterminer la topologie du réseau et l'entraîner sont couplées. Cela permet de réduire la taille du réseau de neurones ainsi que le temps d'apprentissage, éliminant ainsi la phase d'optimisation de la topologie généralement nécessaire.

Le modèle de combustion dans des environnements participants est complexe en raison de phénomènes multi-échelles et multi-physiques à prendre en compte, et le transfert de chaleur radiatif en est un aspect critique. L'objectif est de réduire le temps de calcul sans compromettre la précision. Les réseaux de neurones sont des approximateurs complexes et non linéaires qui ont montré leur capacité à généraliser des fonctions multi-variantes. Ils sont utilisés ici en conjonction avec un algorithme de Monte Carlo à collision nulle [5] pour prédire le flux de chaleur radiatif et sa divergence sur un champ entier.

Cette approche vise à démontrer les capacités de régression multivariée des réseaux de neurones pour prédire un champ complet de valeurs d'intérêt à partir d'un nombre réduit de points d'entraînement. Les résultats, basés sur un cas d'étude bien connu dans la communauté du transfert radiatif [6], servent de base pour le développement de nouvelles méthodologies de modélisation du rayonnement précises et efficaces [7].

## Références

- [1] F. Rosenblatt. « The perceptron: A probabilistic model for information storage and organization in the brain. » en. In: *Psychological Review* 65.6 (1958), p. 386-408. <10.1037/h0042519>.
- [2] F. André, C. Cornet, C. Delage, P. Dubuisson, M. Galtier, On the use of recurrent neural networks for fast and accurate non-uniform gas radiation modeling, *J. Quant. Spectrosc. Radiat. Transf.* 293 (2022).
- [3] M. T. Hagan et al. *Neural Network Design*. 2e éd. Boston: PWS Publishing Co., 1996.
- [4] D. J. C. MacKay. « Bayesian Interpolation ». In: *Neural Computation* 4.3 (1992), p. 415-447
- [5] M. Galtier, S. Blanco, C. Caliot, C. Coustet, J. Dauchet, M. El-Hafi, V. Eymet, R.A. Fournier, J. Gautrais, A. Khuong, B. Piaud, G. Terrée, Integral formulation of null-collision Monte Carlo algorithms, *J. Quant. Spectrosc. Radiat. Transf.* 125 (2013) 57–68, <10.1016/j.jqsrt.2013.04.001>. <hal-01688110>
- [6] P.J. Coelho, P. Perez, M. El Hafi, Benchmark numerical solutions for radiative heat transfer in two-dimensional axisymmetric enclosures with nongray soot-ing media, *Numer. Heat Transf. Part B Fundamentals* 43 (5) (2003) 425–4.
- [7] A. Royer, O. Farges, P. Boulet, D. Burot. A new method for modeling radiative heat transfer based on Bayesian artificial neural networks and Monte Carlo method in participating media. *International Journal of Heat and Mass Transfer*, 2023, 201, pp.123610. <10.1016/j.ijheatmasstransfer.2022.123610>. <hal-03947238>.

## Réseaux de neurones informés par la physique pour les problèmes inverses en sciences de l'ingénieur

Yoann CHENY, Mickaël DELCEY

Laboratoire LEMTA, UMR 7563, Université de Lorraine, Nancy

La classe des méthodes d'apprentissage automatique informé par la physique [1] regroupe les différentes tentatives d'intégration d'informations physiques dans le flux de travail traditionnel d'apprentissage profond. Selon la taxonomie de l'apprentissage automatique basée sur la physique proposée par Kim et al. [2], les réseaux de neurones informés par la physique (PINN) [3] correspondent à un pipeline « ANN-EDP-régularisation » : un réseau de neurones artificiels (ANN) est utilisé comme modèle de substitution pour les champs d'écoulement et les équations sous-jacentes, souvent des équations aux dérivées partielles (EDP), sont exploitées pour concevoir une fonction de perte enrichie qui est minimisée pendant le processus d'entraînement. Cette nouvelle classe de méthodes d'apprentissage profond intègre de manière transparente les données d'observation aux équations gouvernantes et a été appliquée avec succès pour résoudre de nombreux problèmes directs et inverses en sciences de l'ingénieur, voir [4] pour une revue récente.

Les raisons du succès des PINN sont doubles : la solution du problème est approchée par des ANN dotés d'une expressivité illimitée [5] et les opérateurs temporels et spatiaux dans les équations gouvernantes sont calculés efficacement à la précision machine par différenciation automatique [6].

Le paradigme PINN représente une approche révolutionnaire dans l'étude expérimentale des courants gravitationnels : il permet de reconstruire l'ensemble du champ hydrodynamique, crucial pour la compréhension des mécanismes de mélange [7, 8]. Nous étudions actuellement le potentiel de l'approche PINN pour modéliser les milieux granulaires comme un continuum. Nos premiers résultats montrent qu'ils peuvent être utilisés pour identifier les paramètres de rhéologie  $\mu(I)$  [9] à partir d'expériences simples et peu coûteuses.

### Références

- [1] G. E. Karniadakis et al. "Physics-informed machine learning". In: *Nature Reviews Physics* 3.6 (2021), pp.422–440.
- [2] S. W. Kim et al. "Knowledge Integration into deep learning in dynamical systems: An overview and taxonomy". In: *Journal of Mechanical Science and Technology* 35.4 (2021), pp. 1331–1342.
- [3] M. Raissi and G. E. Karniadakis. "Hidden physics models: Machine learning of nonlinear partial differential equations". In: *Journal of Computational Physics* 357 (2018), pp. 125–141.
- [4] S. Cuomo et al. "Scientific Machine Learning through Physics-Informed Neural Networks: Where we are and What's next". In: *Journal of Scientific Computing* 92.88 (2022).
- [5] K. Hornik, M. Stinchcombe, and H. White. "Multilayer feedforward networks are universal

- approximators". In: *Neural networks 2.5* (1989), pp.359–366.
- [6] A. G. Baydin et al. "Automatic differentiation in machine learning: a survey". In: *Journal of Machine Learning Research* 18 (2018), pp. 1–43.
- [7] M. Delcey, Y. Cheny, and S. Kiesgen de Richter. "Physics-informed neural networks for gravity currents reconstruction from limited data". In: *Physics of Fluids* (2022).
- [8] Mickaël Delcey et al. "Enhancing Gravity Currents Analysis through Physics-Informed Neural Networks: Insights from Experimental Observations". In: *arXiv preprint arXiv:2307.14794* (2023).
- [9] P. Jop, Y. Forterre, and O. Pouliquen. "A constitutive law for dense granular flows". In: *Nature* 441.7094 (2006), pp. 727–730.

## Construction de modèles convolutifs transitoires ou paramétriques (ARX) pour une utilisation ultérieure directe ou inverse en thermique

Denis MAILLET, Benjamin RÉMY, Adrien BARTHÉLÉMY  
Laboratoire LEMTA, UMR 7563, Université de Lorraine, Nancy

Les modèles convolutifs transitoires sont génériques dans des configurations thermiques impliquant une ou plusieurs sources de puissance et des réponses en température (sorties) en des points d'un système matériel. Ces modèles réduits font intervenir des réponses impulsionnelles correspondantes et sont aussi exacts que des modèles numériques, quelle que soit la dimensionnalité géométrique et l'hétérogénéité du domaine, pourvu qu'un certain nombre d'hypothèses soient respectées. Cette structure de modèle est légitime si, i) avant le début de l'excitation, le champ de température dans le domaine considéré est permanent, ii) si la source peut être décrite en séparant (produit) son support spatial de la variation de son intensité temporelle (l'entrée) et enfin, iii) si l'équation de la chaleur et ses conditions aux limites sont invariantes en temps sur l'horizon considéré.

Ceci concerne des milieux éventuellement hétérogènes (composites par exemple), soumis à la fois à de la conduction (solide) et, éventuellement, à de l'advection interne fluide (milieu poreux ou échangeur par exemple) à condition que les propriétés thermophysiques des constituants et les coefficients d'échange soient non thermo-dépendants. Il faut aussi que le champ des vitesses, éventuellement turbulent, soit invariant en temps mais pas nécessairement en espace<sup>1</sup>.

L'identification de la réponse impulsionnelle, une fonction du temps, peut s'effectuer par calibration, c'est-à-dire par déconvolution temporelle, à partir de mesures à la fois de l'entrée en puissance (perturbation par rapport à un régime permanent préexistant impliquant éventuellement plusieurs autres sources qui restent également invariantes sur la durée de l'expérience) et d'une sortie, c'est-à-dire de la variation de température en un point d'intérêt. Ce problème d'inversion linéaire est en général mal-conditionné, du fait du grand nombre d'inconnues et du bruit de mesure, et nécessite donc une régularisation appropriée<sup>2</sup>.

Une alternative efficace est d'utiliser, pour la même configuration et pour les mêmes hypothèses, un modèle paramétrique particulier très parcimonieux, ici un modèle Autorégressif à Variables Exogènes (ARX), basé lui aussi sur la notion de produit de convolution et dont le nombre de paramètres à identifier est très faible. En cas de multiplicité des sources- (configuration MISO = Multiple Input, Single Output) ils présentent de plus l'intérêt de ne nécessiter qu'une seule expérience globale de calibration et non une calibration par source active. Notons enfin que ces modèles commencent à être utilisés en thermique de l'habitat et dans des configurations industrielles<sup>3,4</sup>.

### Références

- [1] W. Al Hadad, D. Maillet, Y. Jannot, Modeling unsteady diffusive and advective heat transfer for linear dynamical systems: A transfer function approach, *International Journal of Heat and Mass Transfer* 108 (2017) 115, Part A, December 2017, Pages 304-313, <https://doi.org/10.1016/j.ijheatmasstransfer.2017.07.009>

- [2] W. Al Hadad, D. Maillet, Y. Jannot, Experimental transfer functions identification: Thermal impedance and transmittance in a channel heated by an upstream unsteady volumetric heat source, *International Journal of Heat and Mass Transfer*, 116 (2018) 931–939, <https://doi.org/10.1016/j.ijheatmasstransfer.2017.09.079>
- [3] W. Al Hadad, V. Schick, D. Maillet, Fouling detection in a shell and tube heat exchanger using variation of its thermal impulse responses: Methodological approach and numerical verification, *Applied Thermal Engineering*, Volume 155 (2019) 612–619, <https://doi.org/10.1016/j.applthermaleng.2019.04.030>
- [4] C. Zacharie, V. Schick, B. Rémy, G. Bergin, R. Egal, T. Mazet: Identification de fonctions de transfert pour un four de brasage sous vide et sa charge. *Congrès de la Société Française de Thermique 2018*, 2018, page 536. <https://www.sft.asso.fr/actes-2018.html>

Quatrième de couverture

Illustration de première page intitulée « phi »  
Réalisée par Véronique Legros Sosa, artiste peintre.  
<https://www.veroniquelegrossosa.com/>