



## SOCIÉTÉ FRANÇAISE DE THERMIQUE

*Groupe « Mesures en Thermique et Techniques Inverses »*

Journée thématique organisée par :  
*Fabrice Rigollet (IUSTI), Jean-Luc Battaglia (I2M), Denis Maillet (LEMTA),*

***Jeudi 8 juin 2023***

Accueil à partir de 9h30 à  
**FIAP, 30 rue Cabanis, Paris 14 - Métro Glacière**

\*\*\*\*\*

### ***Inversion de données faisant appel à un modèle en thermique, quels apports de l'intelligence artificielle ?***

Le développement de méthodes d'identification de modèles à partir de mesures, ou de réduction de modèles analytiques ou numériques détaillés, correspondent à des préoccupations très actuelles en thermique. Ces modèles sont indispensables en caractérisation thermique ou radiative de matériaux ou systèmes ou pour l'estimation de conditions aux limites en des endroits non instrumentés de ces derniers (inversion). La prévision, ou la simulation pour la conception optimale (procédés, matériaux, systèmes) constitue une autre classe d'application. En parallèle les outils de l'intelligence artificielle (IA), et en particulier de l'apprentissage supervisé, se développent très rapidement dans de nombreux domaines. Ils reposent sur une régression qui intègre une base d'apprentissage (modèle ou mesures) disponible au préalable. L'objectif de la journée est donc de voir si et comment ces techniques peuvent aider l'inverseur en thermique dans sa démarche évoquée plus haut, en particulier dans le cas où l'on traite des données quantitatives de grande taille (big data), ou de problèmes inverses mal-posés. Par exemple, si le modèle entrée/sortie utilisé a la structure d'un réseau neuronal, est-il possible d'intégrer la physique dans son calibrage (cas d'un PINN = Physically Informed Neural Network) ? De même, quel est le lien entre ces PINN et les méthodes bayésiennes où une information a priori est prise en compte dans l'estimation des grandeurs recherchées ? La journée s'articulera autour de présentations de ces outils dans des applications variées (thermique instationnaire, rayonnement de surface, rayonnement en milieux participatifs, mécanique des fluides, mécanique).

**Contacts** : [fabrice.rigollet@univ-amu.fr](mailto:fabrice.rigollet@univ-amu.fr), [jean-luc.battaglia@u-bordeaux.fr](mailto:jean-luc.battaglia@u-bordeaux.fr), [denis.maillet@univ-lorraine.fr](mailto:denis.maillet@univ-lorraine.fr)

**Programme – Sauf mention particulière, une présentation est composée de 15 minutes d'exposé et 10 minutes de questions (voir les résumés pages suivantes).**

09:30 Accueil

10:00 - 10:15 **Fabrice Rigollet (IUSTI, Marseille), Jean-Luc Battaglia (I2M, Bordeaux), Denis Maillet (LEMMA, Nancy) - Introduction de la journée.** Pages 5 - 19

10:15 - 10:40 **Emmanuelle Abisset-Chavanne, Malo Lecorgne, Morgane Suhas, Marie Marthe Groz, Thomas Lafargue, Christophe Pradère (I2M, Bordeaux) - Quel apport de l'IA dans l'obtention et le traitement des données expérimentales ?** Pages 20 - 45

**Résumé :** Dans cet exposé, sera tout d'abord abordé la question de la génération de données massives que ce soit dans les laboratoires de recherche ou dans l'industrie. Une illustration sera proposée via la tomographie multi-spectrale développée pour obtenir une cartographie des matériaux présents dans les pièces et les systèmes. Puis, un rapide retour sur l'IA, ses définitions et surtout ses spécificités dans son utilisation sera proposé. Différents exemples d'utilisation de l'IA pour le traitement de ces données massives seront ensuite présentés dans le cas de l'identification inverses de propriétés ou de la détection de défauts, permettant d'aborder la question de la pertinence de ces outils comparés aux méthodes plus « physiques ». Dans un second temps, l'apport de l'IA dans la génération des données pertinentes sera abordé, non pas par les algorithmes d'automatisation et/ou d'apprentissage, mais par l'approche « finalité ». Ainsi, une réflexion autour du pilotage de la mesure par la finalité sera proposée pour alléger les contraintes de stockage et de traitement.

10:40 - 11:05 **Jean-Luc Battaglia (I2M, Bordeaux) - Identification de systèmes thermiques linéaires et non linéaires par des structures mathématiques d'intégration d'ordre non entier.** Pages 46 - 64

**Résumé :** La présentation va consister à montrer l'intérêt d'identifier des modèles thermiques de systèmes complexes, linéaires et non-linéaires, en se basant sur des structures mathématiques faisant appel à l'opérateur d'intégration d'ordre non entier et des mesures réalisées sur des bancs expérimentaux permettant de contrôler et mesurer les grandeurs d'entrées et de sortie du modèle. L'application à la résolution de problèmes inverses est particulièrement intéressant et sera aussi montré dans la présentation.

11:05 - 11 :35 Café (30 min)

11:35 - 12 :15 **Frédéric André (Partie 1) et Cindy Delage (partie 2) (CETHIL, Lyon) – Combinaison de modèles physiques et d'outils d'apprentissage statistique pour l'approximation des propriétés radiatives d'atmosphères non-uniformes** Pages 65- 102

**Résumé :** **Partie 1.** La théorie des modèles de bande, utilisée pour le transfert radiatif dans les atmosphères gazeuses, repose en grande partie sur des représentations statistiques des spectres d'absorption des gaz. Des travaux récents ont permis d'établir une formulation exacte des propriétés radiatives d'atmosphères non-uniformes sous la forme de copules en grandes dimensions. Sous certaines hypothèses physiques réalistes, cette copule peut être écrite sous une forme analytique. La forme fonctionnelle obtenue peut être interprétée comme un réseau récurrent, ouvrant la voie à l'exploitation d'outils issus de l'apprentissage statistique (combinaison de statistique et de machine learning) afin d'extraire les paramètres inconnus du modèle de jeux de données "exactes" issus de l'approche dite raie-par-raie. **Partie 2.** Ajustement des paramètres du modèle sur des données d'apprentissage - cas de la bande A de l'oxygène (EPS-SG 3MI)

12:15 - 12 :40 **Marie-Hélène Aumeunier, Alexis Juven (CEA, Cadarache) – Réseaux neuronaux convolutifs pour la thermographie quantitative en environnement complexe.** Pages 103 - 122

**Résumé :** La thermographie infrarouge est un diagnostic essentiel dans les centrales 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 la mesure de température de surface reste problématique dans un environnement tout métallique et chaud (i.e. entièrement réfléchissant et rayonnant). Nous présentons ici une méthode d'inversion pour retrouver les températures de surface à partir des images de caméra (en radiance W/m<sup>2</sup>/sr), capable de résoudre la contribution du flux réfléchi et les incertitudes sur les propriétés optiques des matériaux. Cette méthode se base sur la construction d'un réseau neuronal convolutif, appris sur une base de données d'images synthétiques très réalistes. Des premiers résultats très encourageants ont été obtenus à partir d'un prototype numérique avec des erreurs inférieures à 10% sur les températures. Le prochain défi est le passage aux images expérimentales à partir de ce même type de réseau.

12:40 – 14 :20 Repas (1h40)

14:20 – 14 :45 **Helcio Orlando (COPPE, Rio de Janeiro) et al. – Metamodel based on evolutionary neural networks for the solution of inverse problems within the Bayesian framework of statistics.** [Pages 123 - 146](#)

**Abstract :** This presentation is aimed at the reduction of the computational time of the inverse problem solution with the Markov Chain Monte Carlo method, by using the Evolutionary Neural Network Algorithm (EvoNN). EvoNN attempts to simultaneously optimize the accuracy and complexity of the neural network metamodel. Modelling errors are formally accounted for with the Approximation Error Model (AEM) Approach. The method is illustrated on a fluid dynamics problem.

14:45 – 15 :10 **Benjamin Gaume, Yassine Rouizi, Frédéric Joly, Olivier Quéméner (LMEE, Evry Val d'Essone) - Apport des modèles réduits pour la mesure thermique indirecte en temps réel dans un four rayonnant**

[Pages 147 - 176](#)

**Résumé :** Nous proposons ici d'utiliser une méthode de modélisation par modèle réduit modal (AROMM), afin d'identifier une source radiative variable dans le temps à partir de quelques points de mesures et de reconstruire la scène thermique complète. L'exemple traité ici porte sur un four industriel dans lequel une pièce en titane est chauffée par deux tubes radiants ayant une température variable dans le temps comprise entre 293 et 1173K.

L'utilisation de ce type de modèle permet une reconstruction en ligne du champ de température complet de la scène thermique, avec une erreur moyenne de 0.1% (<1°C) et une erreur maximum de l'ordre de 3% (~25K sur une échelle de 880°C).

15:10 – 15 :35 **Olivier Farges, Alex Royer, Pascal Boulet (LEMETA, Nancy), Daria Burot (Safran Aircraft Engine) – Modélisation du transfert radiatif dans des milieux participants, par réseaux de neurones bayésiens et méthode de Monte Carlo.** [Pages 177 - 254](#)

**Résumé :** La capacité prédictive des réseaux neuronaux artificiels Feedforward (FANN) est utilisée pour estimer la divergence du flux radiatif dans un cas de chambre de combustion académique utilisée comme cas de référence. Des bases de données d'entraînement et de validation ont été construites grâce à un algorithme de Monte Carlo à collision nulle utilisant un modèle SNB-CK pour représenter les propriétés des gaz. L'objectif principal de ce travail est de combiner les avantages des modèles spectraux en termes de précision et l'efficacité de calcul des réseaux neuronaux afin de rendre possible la modélisation précise du transfert de chaleur radiatif. En conséquence, les réseaux neuronaux sont capables de modéliser la divergence du flux radiatif sur la base de données d'entraînement.

15:35 – 16 :00 **Yoann Cheny, Mickaël Delcey, Adrien Ganz, Sébastien K. de Richter (LEMETA, Nancy) – Réseaux de neurones informés par la physique (PINNs) pour la reconstruction de courants de gravité.** [Pages 255 - 272](#)

**Résumé :** Ce travail porte sur la reconstruction de courants de gravité instationnaires par réseaux neuronaux informés par la physique (PINNs). Les champs d'intérêt sont reconstruits par entraînement d'un réseau de neurones dont la fonction objectif : (i) pénalise l'écart entre les prédictions du réseau et les données d'observation, et (ii) intègre les équations sous-jacentes en utilisant la différentiation automatique. Notre approche est éprouvée sur le cas test de lock-exchange à partir de données synthétiques obtenues par méthode spectrale. Cela nous permet d'évaluer quantitativement les erreurs de reconstruction pour différentes bases de données d'entraînement conçues pour imiter les techniques de mesure expérimentale pour mesurer la densité et/ou la vitesse. En outre, nous présentons des résultats récents obtenus à partir de mesures expérimentales réalisées au laboratoire.

16:00 – 16 :25 **Denis Maillet, Benjamin Rémy, Adrien Barthélemy (LEMETA, Nancy) – Construction de modèles convolutifs transitoires ou paramétriques (ARX) pour une utilisation ultérieure directe ou inverse en thermique**  
[Pages 273 – 290](#)

**Résumé :** Les modèles dynamiques à structure temporelle convolutive continue, basés sur la notion de réponse impulsionnelle en un point du domaine étudié, et liant excitation thermique transitoire unique séparable temps/espace (une variation de puissance thermique, d'un flux de chaleur ou d'une température), et sa réponse en variation de température en ce point (un modèles « SISO), ont une structure aussi exacte que les modèles détaillés basés sur la résolution analytique ou numérique de l'équation de la chaleur munie de ses conditions aux limites spatiales. Ceci est rigoureusement exact si ces dernières sont linéaires à coefficients invariants en temps (« LTI » PDE models) et si le régime thermique initial, avant imposition de l'excitation à l'instant initial, est permanent, sans être nécessairement uniforme. Nous montrons ici que la version échantillonnée (en sortie) et paramétrée en fonction temporelle constante par morceaux (pour l'entrée et pour la réponse impulsionnelle) de ces modèles peut être écrite à l'aide d'une matrice de sensibilité faisant intervenir des matrices de Toeplitz triangulaires inférieures et des vecteurs des doses de ces 2 dernières fonctions, et non de leurs seules valeurs échantillonnées. Le problème principal de l'identification expérimentale (calibration) d'un tel modèle SISO par moindres carrés ordinaires, à partir de mesures de l'entrée et de la sortie intégrant toutes deux un bruit d'écart type connu, est de déterminer le support temporel fini de la réponse impulsionnelle, ici une impédance ou une transmittance. Enfin, on montre que les modèles ARX (Autorégressifs à Variable eXogène) sont liés à la version paramétrée du modèle convolutif correspondant, par la prise en compte simultanée de la source (entrée originale) et d'une multiplicité de « pseudo-sources ».

16:25 – 16 :40 Conclusion, 15 min [Pages 291–292](#)

16:40 Fin





Journée SFT du 8 Juin 2023

Groupe « *Mesures Thermiques et Techniques Inverses* » (METTI)

# ***Inversion de données faisant appel à un modèle en thermique: quels apports de l'intelligence artificielle ?***

Introduction et présentation de la journée

*Fabrice Rigollet<sup>1</sup>, Denis Maillet<sup>2</sup>, Jean-Luc Battaglia<sup>3</sup>*

<sup>1</sup>IUSTI (Aix-Marseille Univ. & CNRS, Marseille), <sup>2</sup>LEMETA (U. de Lorraine & CNRS, Nancy), <sup>3</sup>I2M (U. Bordeaux & CNRS, Bordeaux)

*1995 : 1<sup>ère</sup> école thématique METTI – Septembre 2023 : 8<sup>ème</sup> édition, Ile d'Oléron*

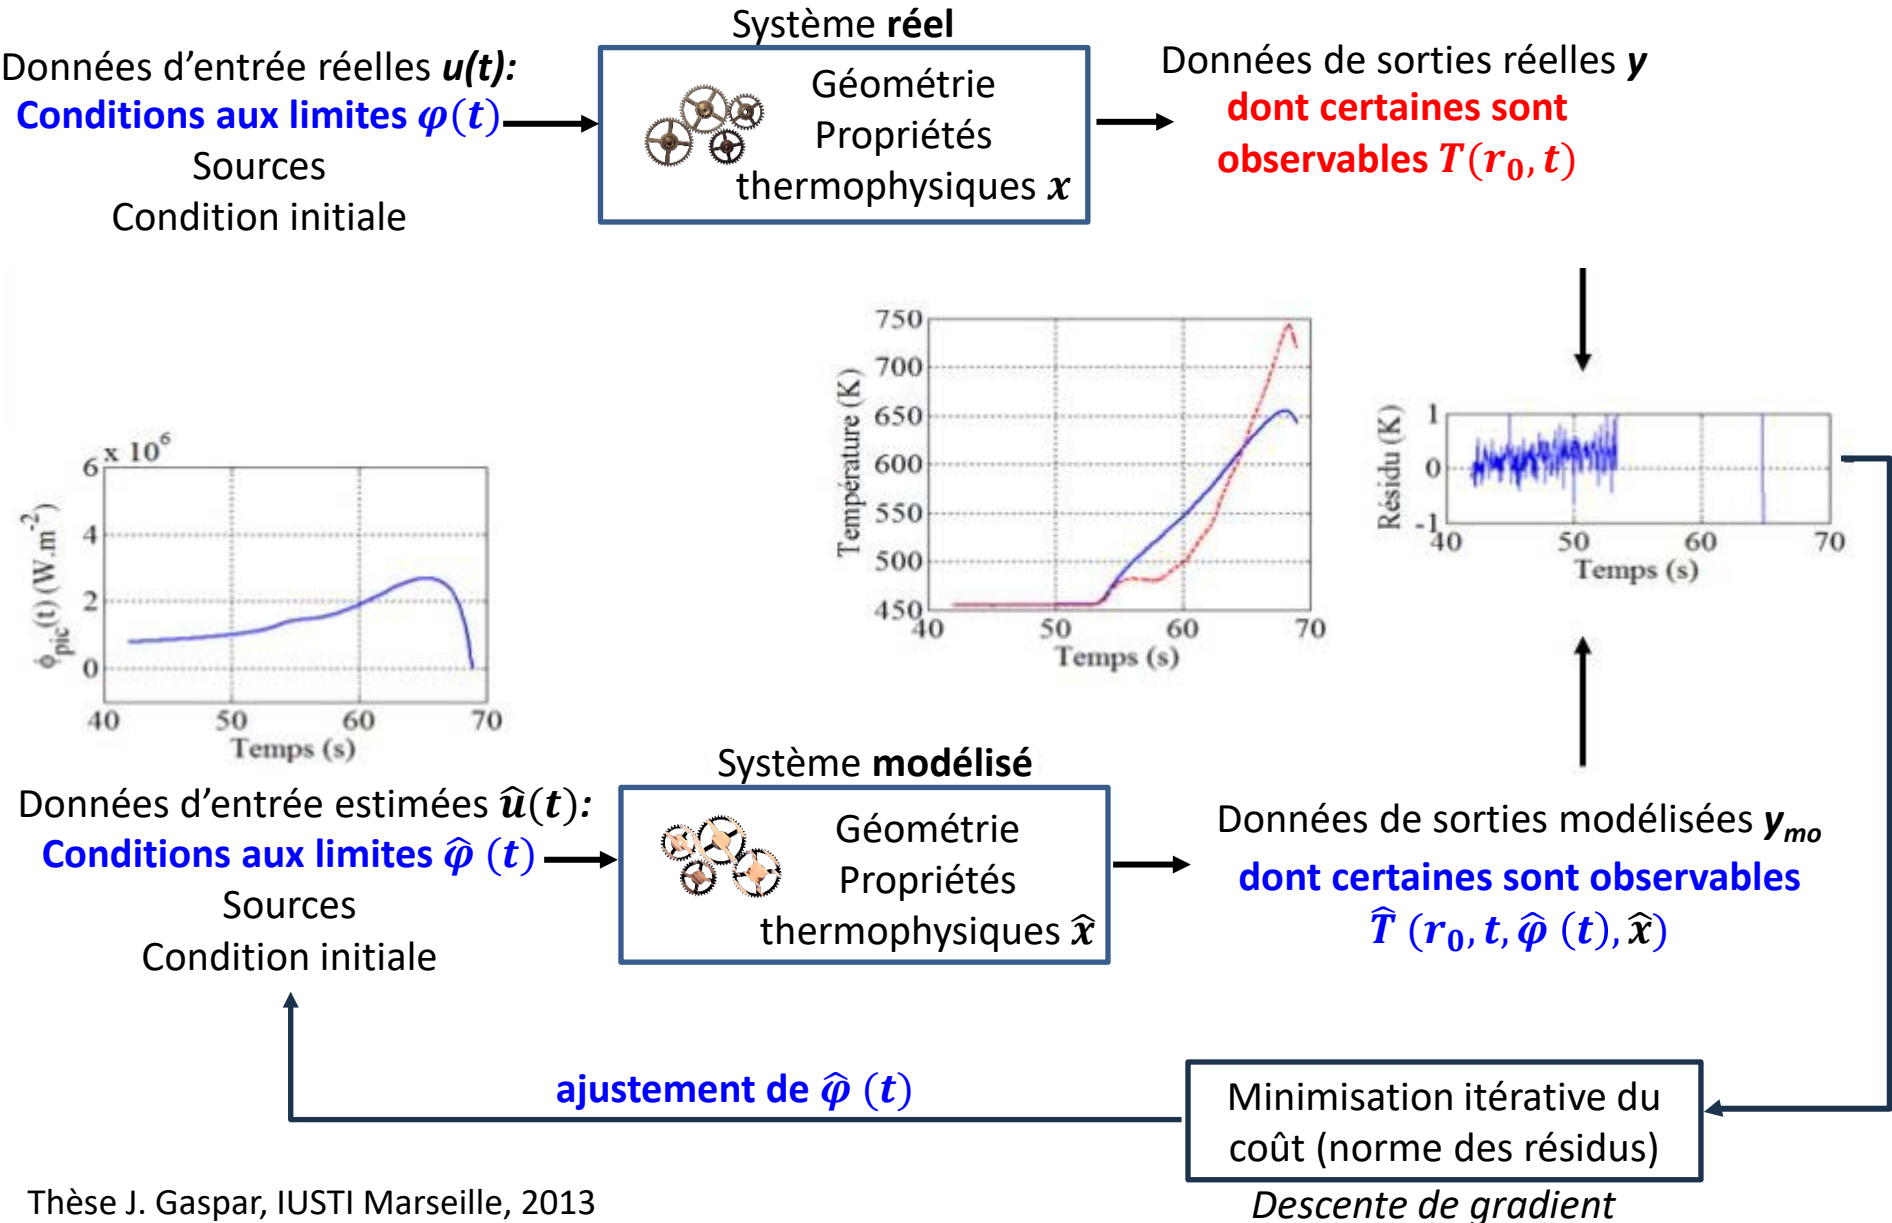
**Metti<sup>8</sup>**

Sept. 24th / 29th, Oléron (France) 2023

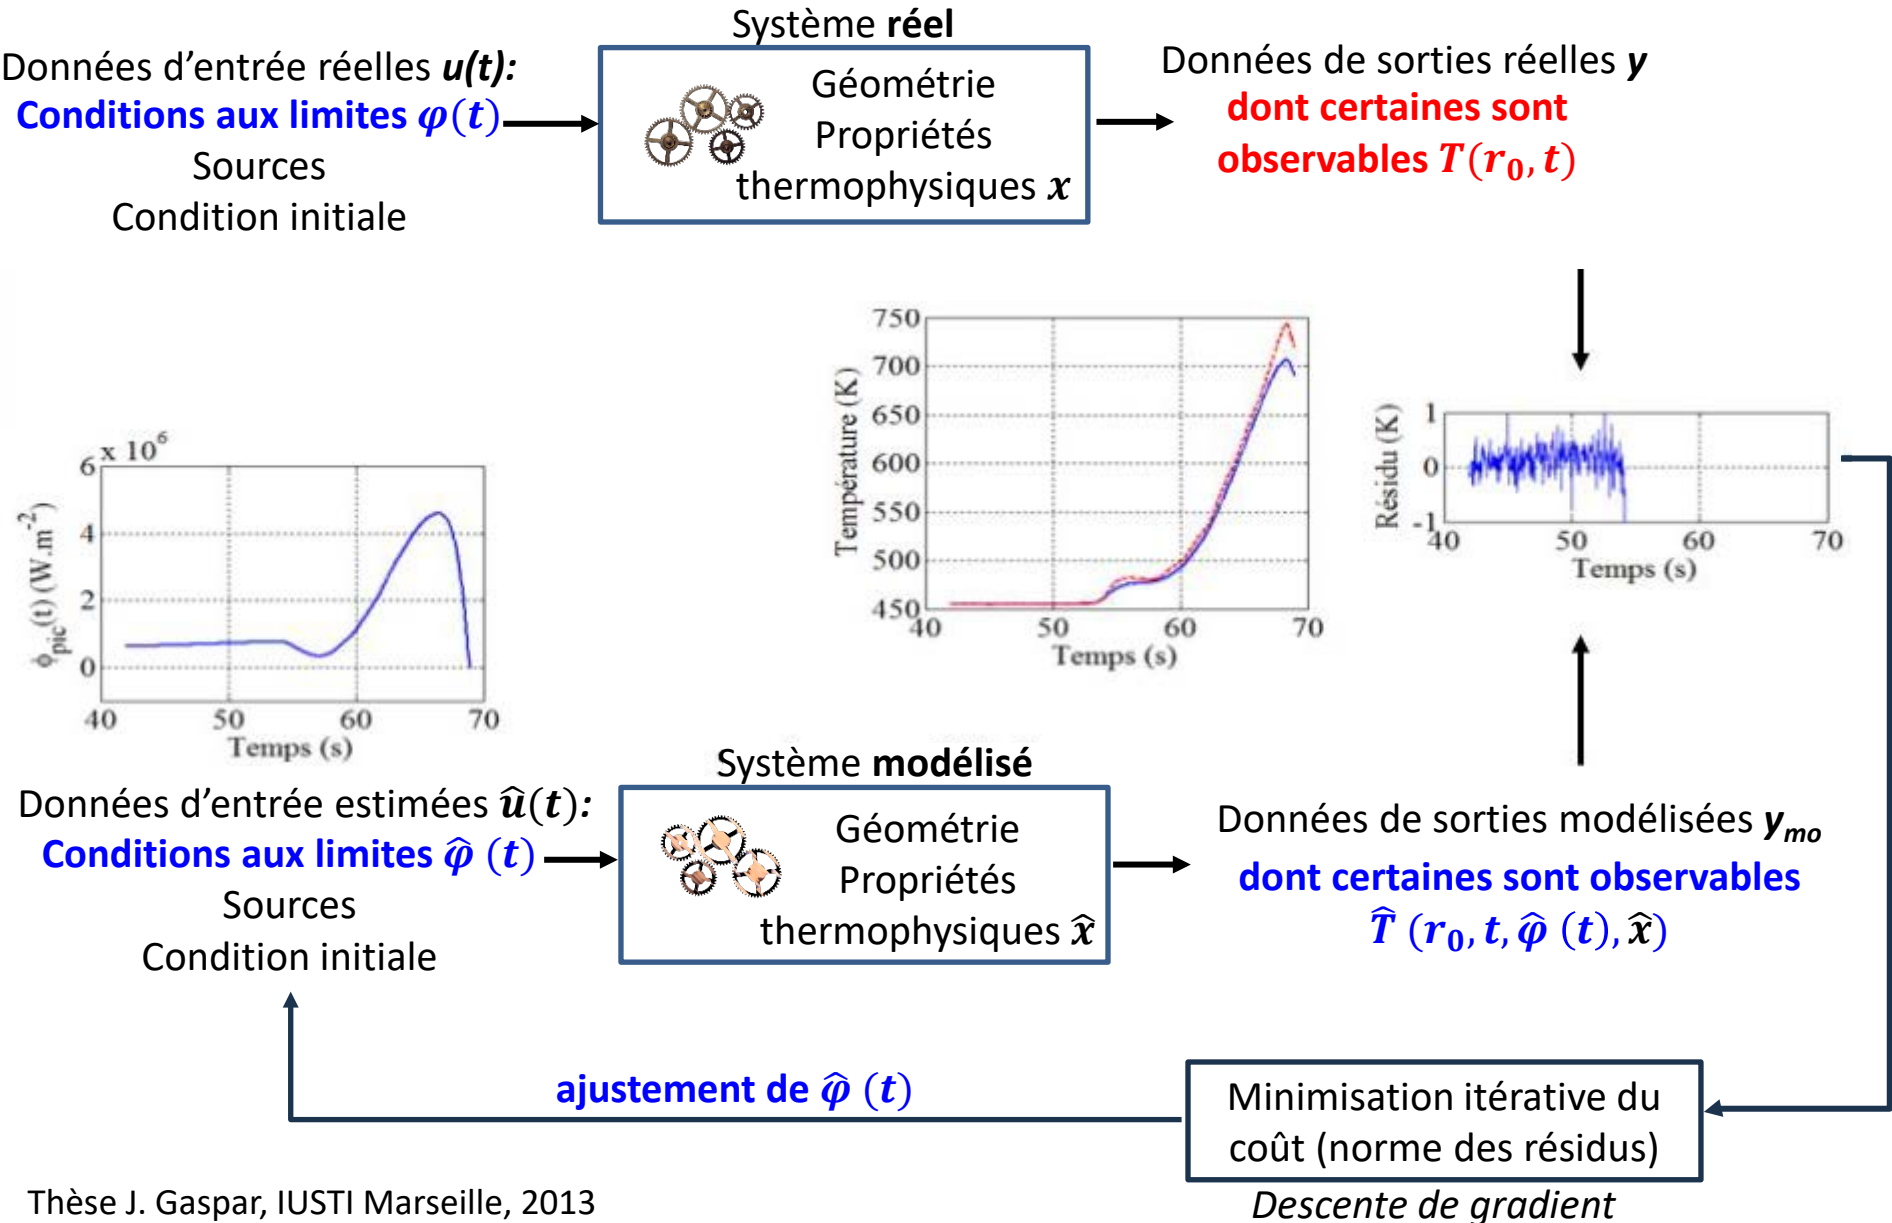
*Advanced Autumn School in  
Thermal Measurement &  
Inverse Techniques*

<https://metti8.sciencesconf.org/>

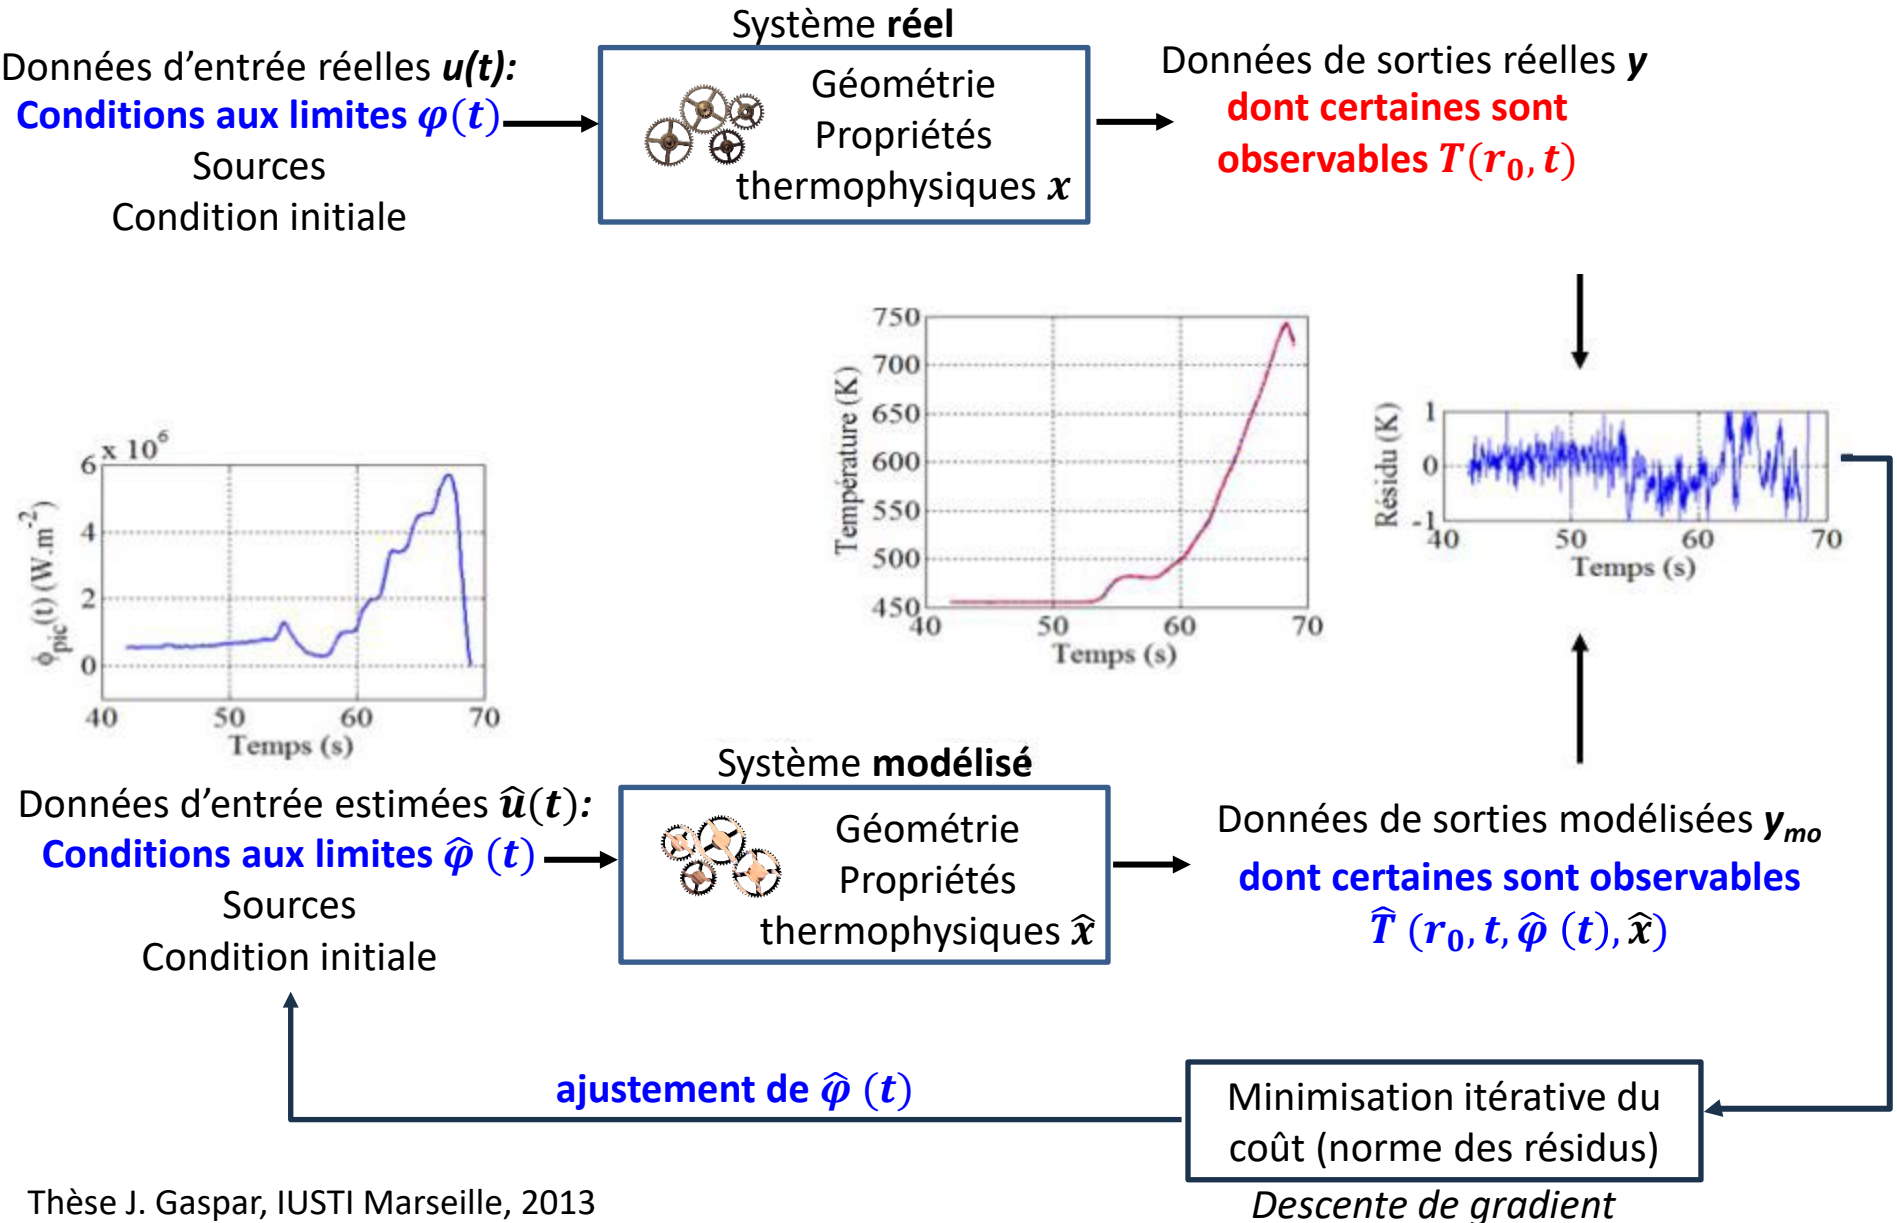
## Exemple d'inversion de mesures en thermique : recherche d'un flux surfacique à partir de mesures d'échauffements enfouies



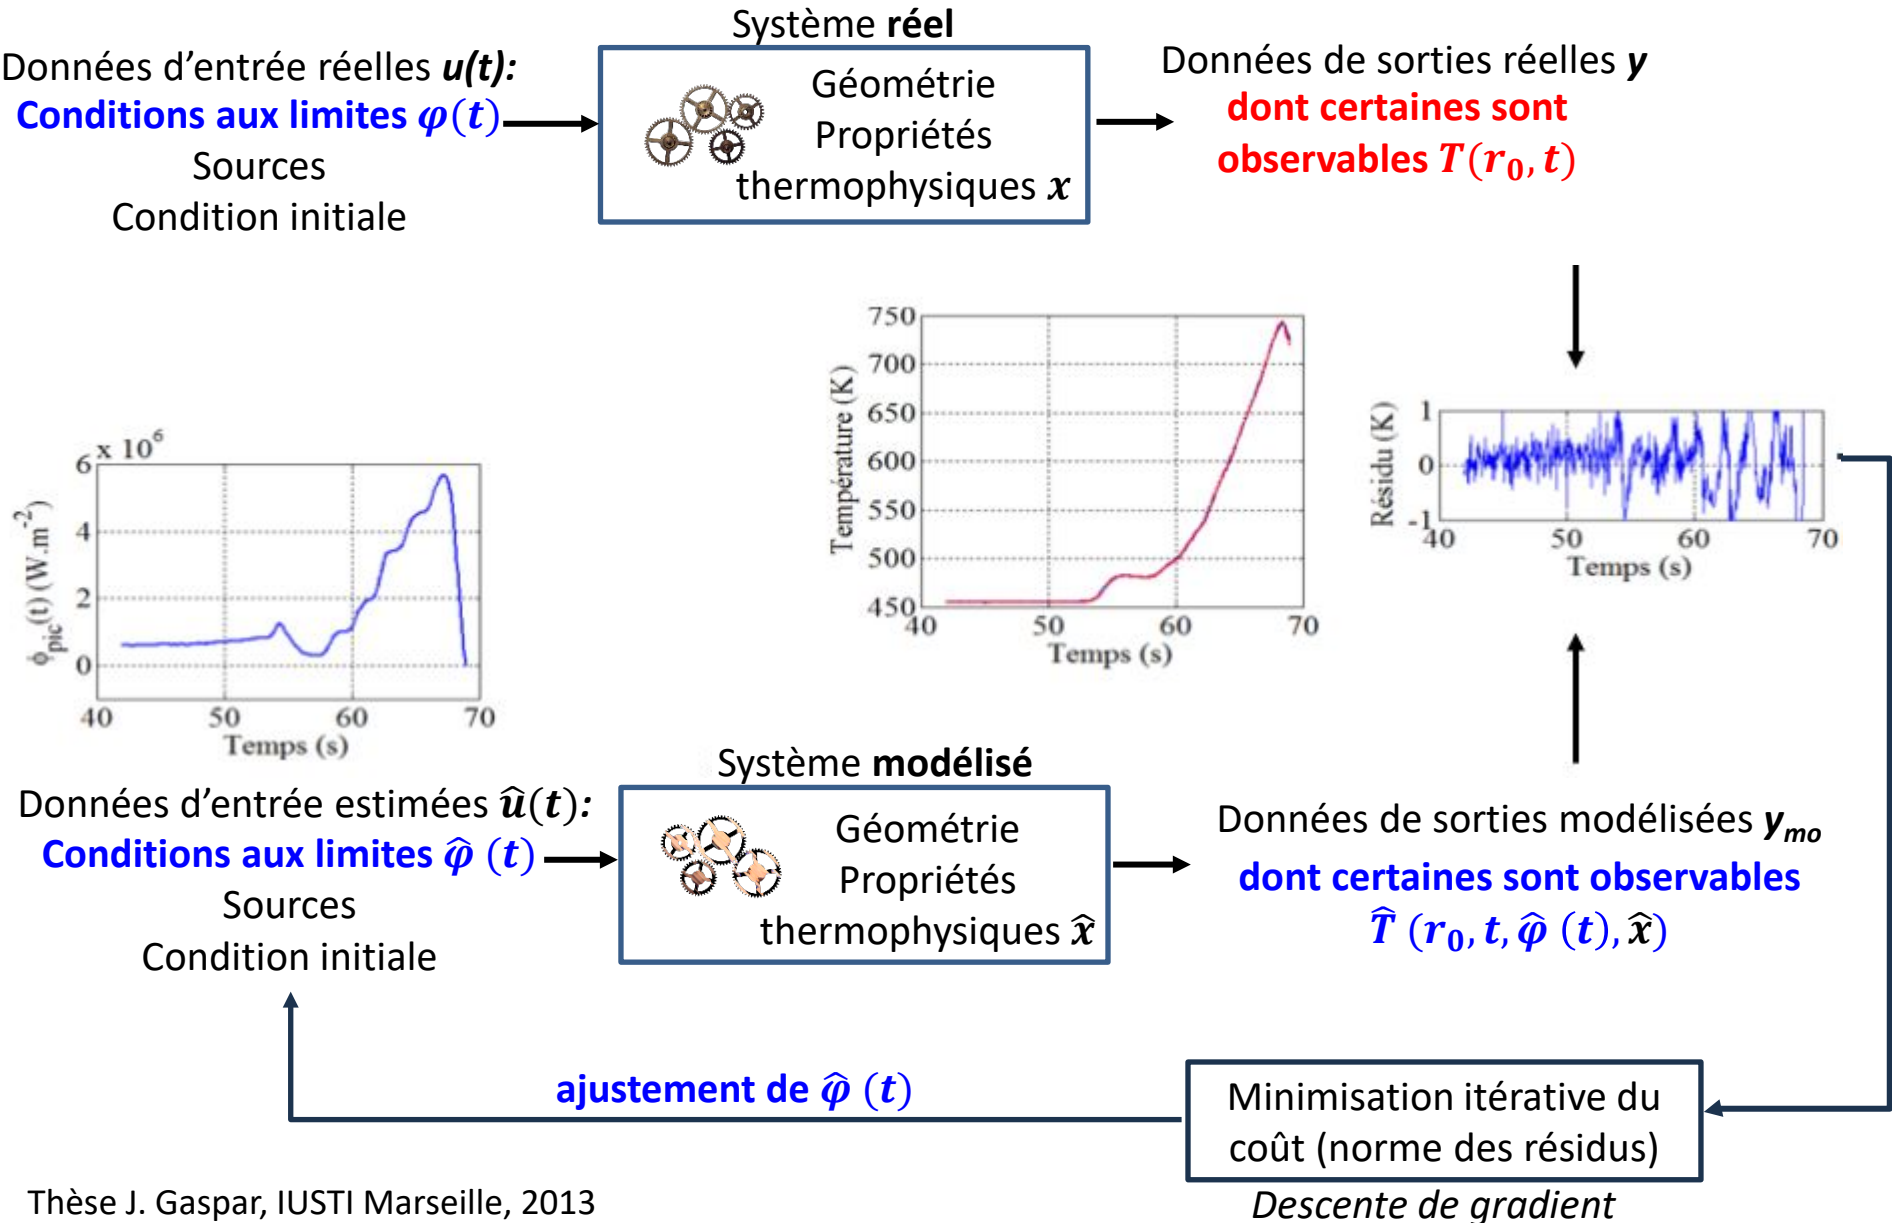
## Exemple d'inversion de mesures en thermique : recherche d'un flux surfacique à partir de mesures d'échauffements enfouies



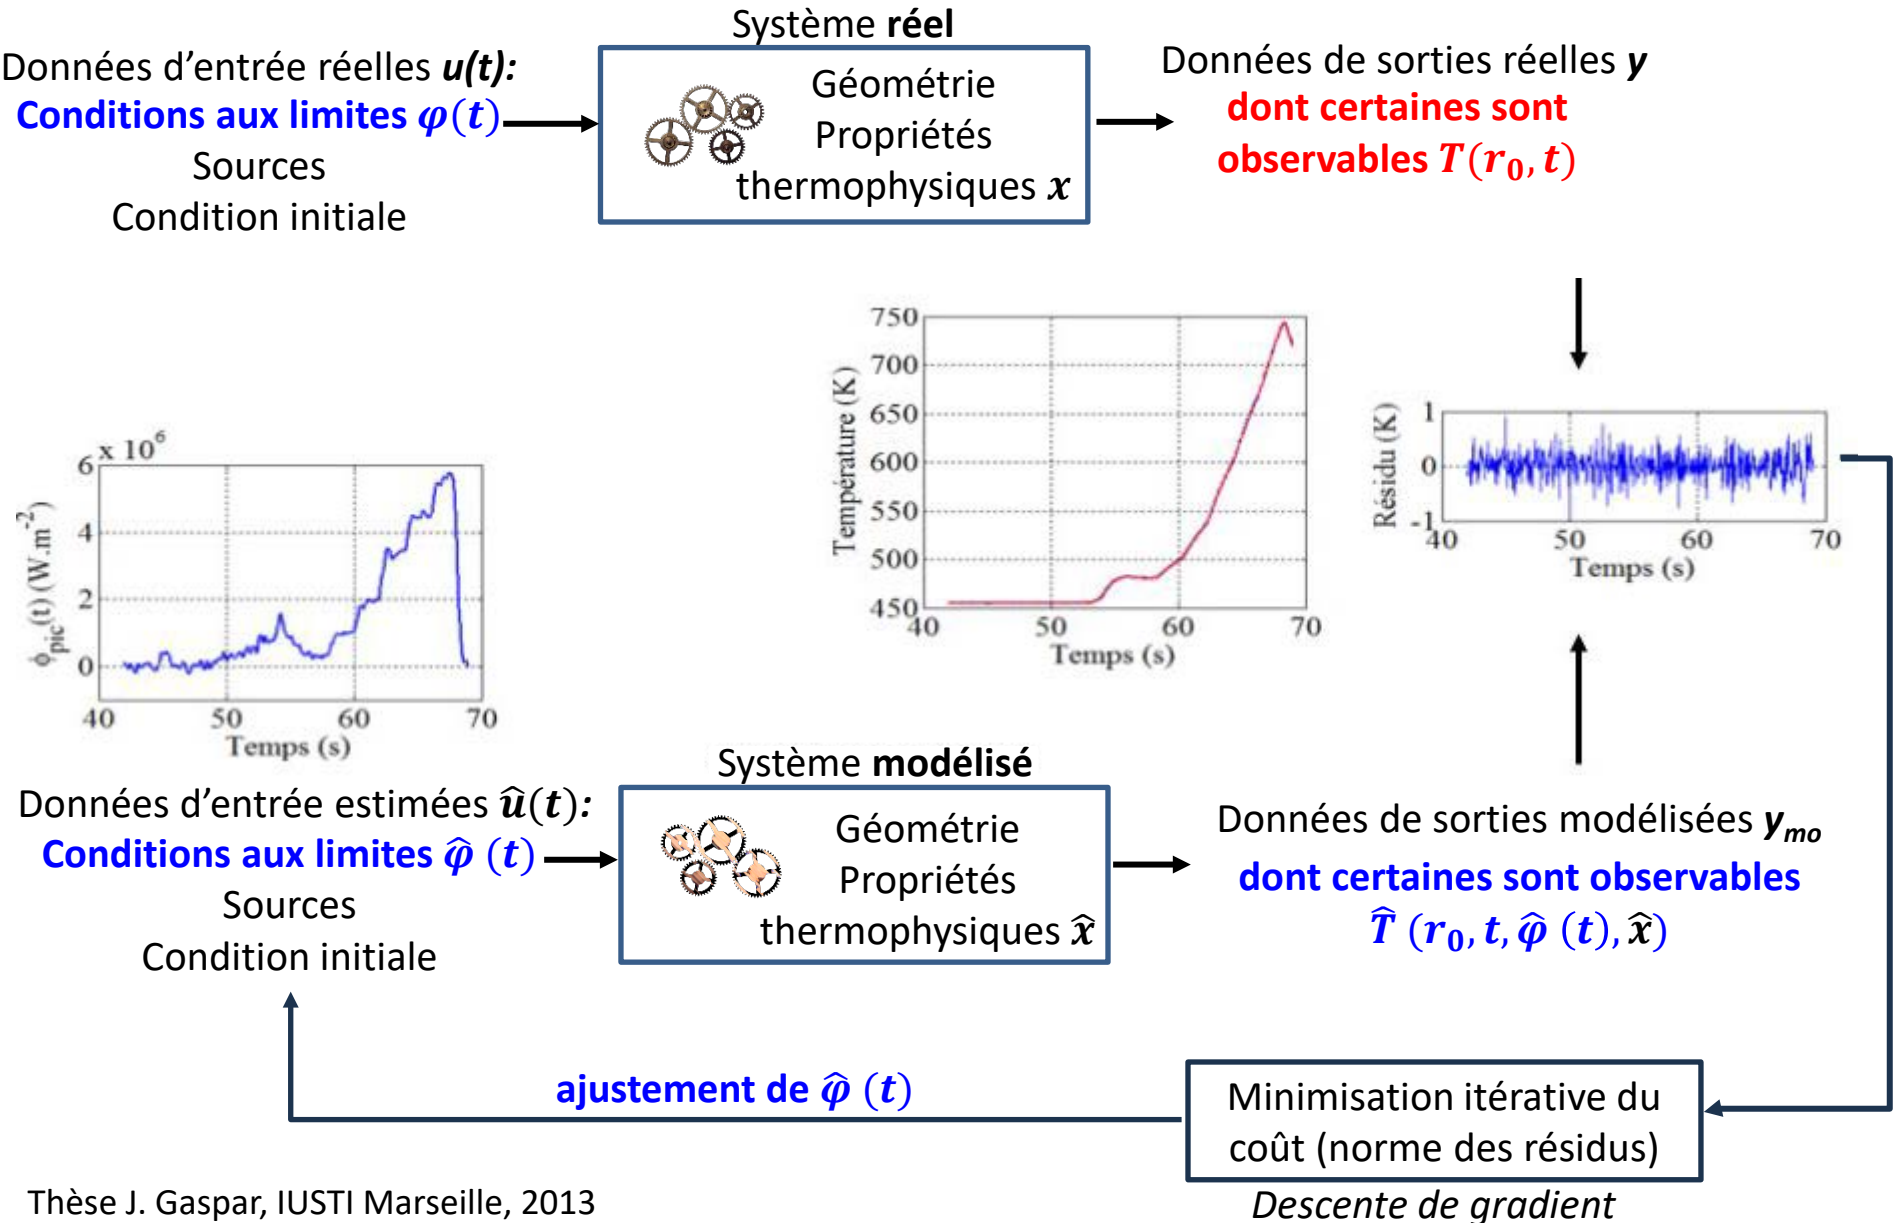
## Exemple d'inversion de mesures en thermique : recherche d'un flux surfacique à partir de mesures d'échauffements enfouies



## Exemple d'inversion de mesures en thermique : recherche d'un flux surfacique à partir de mesures d'échauffements enfouies



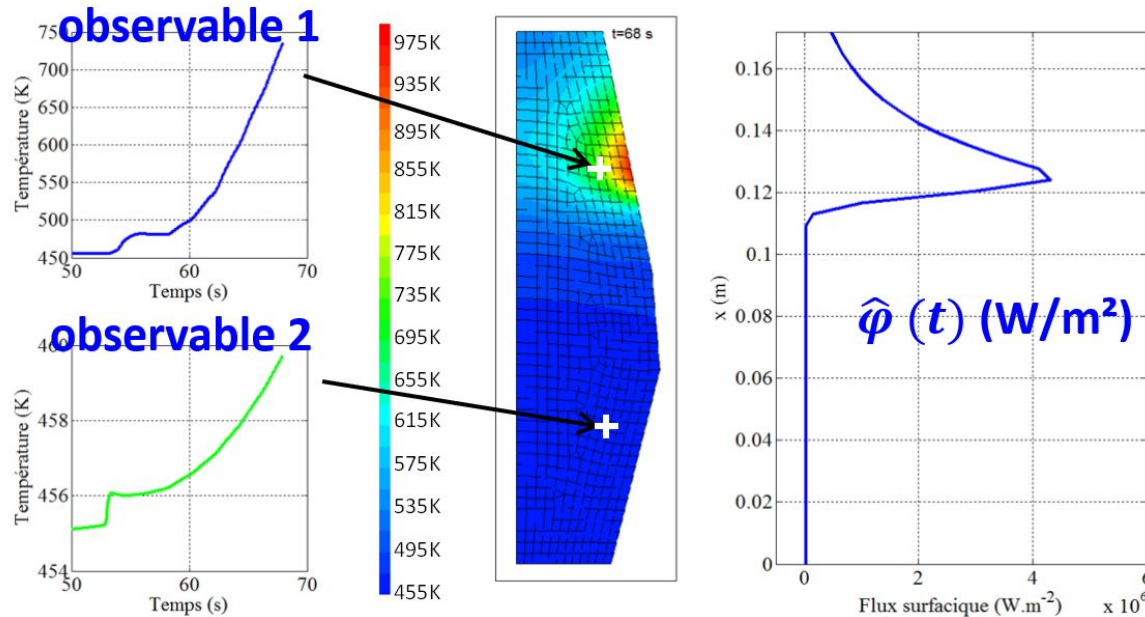

## Exemple d'inversion de mesures en thermique : recherche d'un flux surfacique à partir de mesures d'échauffements enfouies





## Précisions sur le modèle :

- « **mécanisme, structure** » = transfert de chaleur instationnaire non linéaire dans un solide 2D
- **Modèle de connaissance** : les équations qui lient toutes les entrées  $\hat{\varphi}(t)$ ,  $\hat{x}$  aux observables sont connues et résolues ici numériquement
- Pour accéder aux observables (locaux), il faut calculer la solution partout : peut-être **'lourd'**





## Précisions sur le modèle :

- « **mécanisme, structure** » = transfert de chaleur instationnaire non linéaire dans un solide 2D
- **Modèle de connaissance** : les équations qui lient toutes les entrées  $\hat{\varphi}(t)$ ,  $\hat{x}$  aux observables sont connues et résolues ici numériquement
- Pour accéder aux observables (locaux), il faut calculer la solution partout : peut-être **'lourd'**

## Autrement dit dans cet exemple :

- **La structure du modèle** n'est pas cherchée, mais seulement ses « paramètres » au sens large
- Elle est **donnée par la physique**
- Le **modèle** direct est **appelé plusieurs fois** pour résoudre le problème inverse de mesure

## Précisions sur le modèle :

- « **mécanisme, structure** » = transfert de chaleur instationnaire non linéaire dans un solide 2D
- **Modèle de connaissance** : les équations qui lient toutes les entrées  $\hat{\varphi}(t)$ ,  $\hat{x}$  aux observables sont connues et résolues ici numériquement
- Pour accéder aux observables (locaux), il faut calculer la solution partout : peut-être **'lourd'**

## Autrement dit dans cet exemple :

- **La structure du modèle** n'est pas cherchée, mais seulement ses « paramètres » au sens large
- Elle est **donnée par la physique**
- Le **modèle direct** est **appelé plusieurs fois** pour résoudre le problème inverse de mesure

### *Rappel :*

**Le modèle direct** répond à la question :

« si on impose des causes ( $\hat{\varphi}(t)$ ,  $\hat{x}$ ), quels sont les effets (**observables**  $T(r_0, t)$ ) ? »

On peut symboliser le modèle direct par une fonction  $T(r_0, t) = G(\hat{\varphi}(t), \hat{x})$

**La démarche d'inversion** de mesure répond à la question :

« si on mesure des effets (**observables**  $T(r_0, t)$ ) peut-on deviner les causes ( $\hat{\varphi}(t)$ ,  $\hat{x}$ ) qui les ont engendrés ? »

## Précisions sur le modèle :

- « **mécanisme, structure** » = transfert de chaleur instationnaire non linéaire dans un solide 2D
- **Modèle de connaissance** : les équations qui lient toutes les entrées  $\hat{\varphi}(t)$ ,  $\hat{x}$  aux observables sont connues et résolues ici numériquement
- Pour accéder aux observables (locaux), il faut calculer la solution partout : peut-être **'lourd'**

## Autrement dit dans cet exemple :

- **La structure du modèle** n'est pas cherchée, mais seulement ses « paramètres » au sens large
- Elle est **donnée par la physique**
- Le **modèle direct** est **appelé plusieurs fois** pour résoudre le problème inverse de mesure

### *Rappel :*

**Le modèle direct** répond à la question :

« si on impose des causes ( $\hat{\varphi}(t)$ ,  $\hat{x}$ ), quels sont les effets (**observables**  $T(r_0, t)$ ) ? »

On peut symboliser le modèle direct par une fonction  $T(r_0, t) = G(\hat{\varphi}(t), \hat{x})$

**La démarche d'inversion** de mesure répond à la question :

« si on mesure des effets (**observables**  $T(r_0, t)$ ) peut-on deviner les causes ( $\hat{\varphi}(t)$ ,  $\hat{x}$ ) qui les ont engendrés ? »

- Le **modèle direct** travaille donc dans le sens « naturel » causes  $\rightarrow$  effets
- On parle de 'démarche inverse' plutôt que d'un '**modèle inverse**' (effets  $\rightarrow$  causes). Quoique?...

## Les problématiques de la journée

- **Méthodes d'identification de modèle à partir de mesures.** Si on ne se donne « pas du tout » ou « pas complètement » la physique pour construire le modèle
  - Dérivées non entières, modèle convolutif (ARX)
  - Outils de l'IA pour relier les données observées (entrées, sorties)
  - Outils de l'IA « Informés par la Physique »
  - Ces outils visent-ils finalement à construire un « modèle inverse », ou en tout cas un outil qui travaille dans le sens effets → causes ?

## Les problématiques de la journée

- **Méthodes d'identification de modèle à partir de mesures.** Si on ne se donne « pas du tout » ou « pas complètement » la physique pour construire le modèle
  - Dérivées non entières, modèle convolutif (ARX)
  - Outils de l'IA pour relier les données observées (entrées, sorties)
  - Outils de l'IA « Informés par la Physique »
  - Ces outils visent-ils finalement à construire un « modèle inverse », ou en tout cas un outil qui travaille dans le sens effets → causes ?
- **Réduction de modèles analytiques ou numériques détaillés.**
  - Sans IA : méthode AROM en rayonnement de surface
  - Avec IA : différents types de réseaux de neurones selon les applications

## Les problématiques de la journée

- **Méthodes d'identification de modèle à partir de mesures.** Si on ne se donne « pas du tout » ou « pas complètement » la physique pour construire le modèle
  - Dérivées non entières, modèle convolutif (ARX)
  - Outils de l'IA pour relier les données observées (entrées, sorties)
  - Outils de l'IA « Informés par la Physique »
  - Ces outils visent-ils finalement à construire un « modèle inverse », ou en tout cas un outil qui travaille dans le sens effets → causes ?
- **Réduction de modèles analytiques ou numériques détaillés.**
  - Sans IA : méthode AROM en rayonnement de surface
  - Avec IA : différents types de réseaux de neurones selon les applications

Remarque : le thème du « Design par les outils de l'IA » n'est pas abordé aujourd'hui, Voir Denis Rochais, GdR Tamarys « Matériaux numériques »

Les questions qui peuvent être abordées à cette journée :

- Confiance dans les résultats : les outils de l'IA fournissent-ils une évaluation de cette confiance (« covariance »)?
- Points communs dans les méthodes utilisées en descente de gradient et dans l'estimation des paramètres d'un réseau de neurones?
- Les cas pathologiques en estimation de paramètres/fonction : paramètres corrélés ou faiblement sensibles → quels symptômes avec l'IA?
- IA utile pour remplacer les lookup tables, abaques? IA = « super-interpolateur »?
- lien entre PINN (Physic Informed Neural Network) et méthodes bayésiennes : information a priori prise en compte dans l'estimation des grandeurs recherchées?
- Dans quelles situations l'IA est à privilégier? « Grand » nombre d'entrées et de sorties?
- Les signaux instationnaires posent-ils un problème particulier?
- ... ?

Conclusion : Valorisation de cette journée, Jean-Luc Battaglia



# Programme

<b>E. Abisset-Chavanne</b> (I2M, Bordeaux) - Quel apport de l'IA dans l'obtention et le traitement des données expérimentales ?	Mécanique, IA, nombreuses data
<b>J.-L. Battaglia</b> (I2M, Bordeaux) - Identification de systèmes thermiques linéaires et non linéaires par des structures mathématiques d'intégration d'ordre non entier.	Thermique Instationnaire, identification de modèle
<b>F. André (CETHIL, Lyon)</b> – Combinaison de modèles physiques et d'outils d'apprentissage statistique pour l'approximation des propriétés radiatives d'atmosphères non-uniformes. Partie 1 : Principe et fondements théoriques	Rayonnement gaz, IA, réduction de modèle?
<b>C. Delage (CETHIL, Lyon)</b> – Partie 2 : Ajustement des paramètres du modèle sur des données d'apprentissage - cas de la bande A de l'oxygène (EPS-SG 3MI)	Rayonnement gaz, IA, réduction de modèle?
<b>M.-H. Aumeunier</b> (CEA, Cadarache) – Réseaux neuronaux convolutifs pour la thermographie quantitative en environnement complexe.	Rayonnement de surface, IA, réduction de modèle?
<b>H. Orlande</b> (COPPE, Rio de Janeiro) – Metamodel based on evolutionary neural networks for the solution of inverse problems within the Bayesian framework of statistics	Hydraulique, IA, réduction de modèle
<b>B. Gaume</b> , Y. Rouizi, F. Joly, O. Quéméner (LMEE, Evry Val d'Essone) - Apport des modèles réduits pour la mesure thermique indirecte en temps réel dans un four rayonnant	Rayonnement de surface instationnaire, réduction de modèle
<b>O. Farges</b> (LEMETA, Nancy) – Modélisation du transfert radiatif dans des milieux participants, par réseaux de neurones bayésiens et méthode de Monte Carlo.	Rayonnement gaz, IA, réduction de modèle?
<b>Y. Cheny</b> (LEMETA, Nancy) – Reconstruction de courants de gravité par réseaux de neurones informés par la physique (PINNs)	Mécanique des fluides, IA, Réduction de modèle?
<b>D. Maillet</b> , B. Rémy, A. Barthélemy (LEMETA, Nancy) – Construction de modèles convolutifs transitoires ou paramétriques (ARX) pour une utilisation ultérieure directe ou inverse en thermique	Thermique Instationnaire, identification de modèle

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

M. Lecorgne, M Suhas, MM Groz, T. Lafargue,  
C. Pradere, E. Abisset-Chavanne

A&M Bordeaux Talence, I2M

Contact : [emmanuelle.abisset-chavanne@ensam.eu](mailto:emmanuelle.abisset-chavanne@ensam.eu)

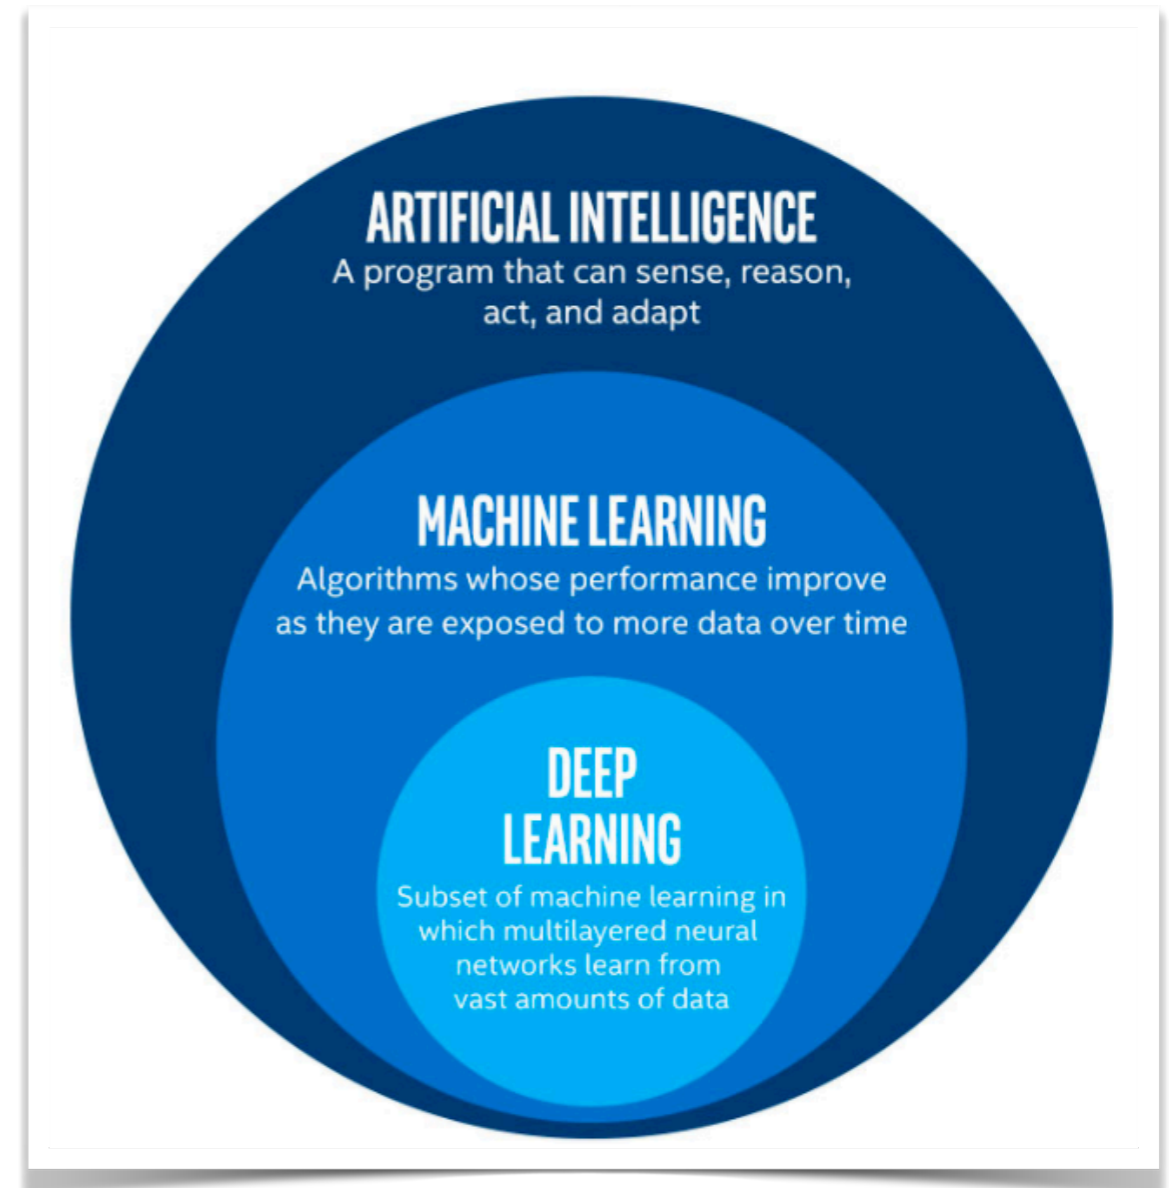
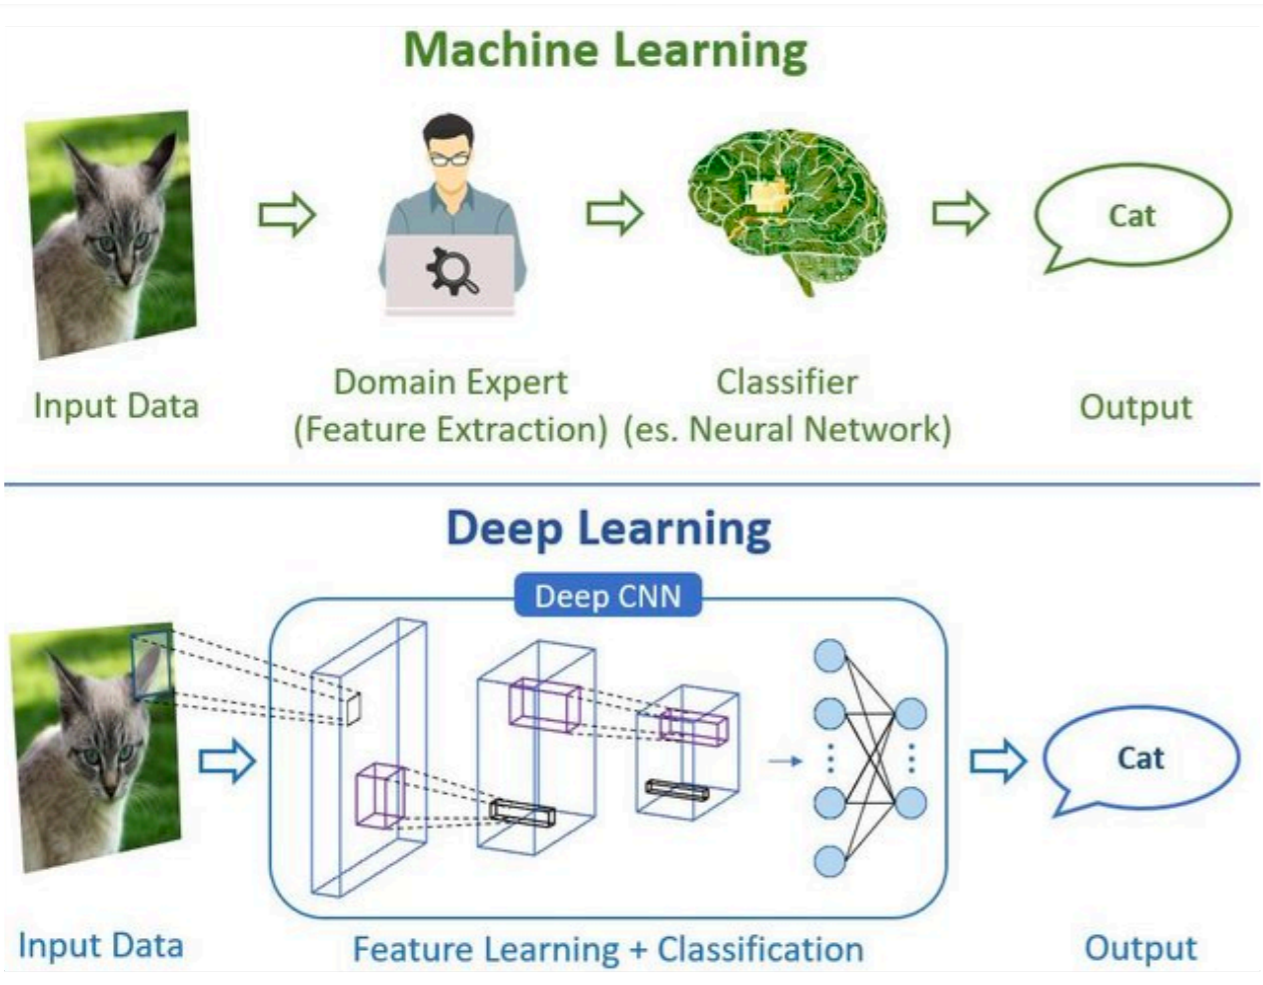
# Plan

- **Utilisation de l'IA dans le traitement de la donnée**
- **Qu'est-ce qu'une bonne base de données ?**
- **Hybridation Physique et IA**

# Plan

- **Utilisation de l'IA dans le traitement de la donnée**
- Qu'est-ce qu'une bonne base de données ?
- Hybridation Physique et IA

# Intelligence Artificielle



Que peut apporter l'IA dans le traitement des données expérimentales ?



# Intelligence Artificielle et CND thermique

Exemple de travaux en thermique  
(QIRT 2022)

11:00-12:40		Session 1-1 - Artificial Intelligence I		Bogusław Więcek
11:00-11:20	CT	<b>Liangliang Cheng</b>		Irt-gan: a gan framework for automated defect segmentation in composites using infrared thermography
11:20-11:40	CT	<b>Tout Karim</b>		Defect detection on inductive thermography images using convolutional neural networks
11:40-12:00	CT	<b>Kaczmarek Mariusz</b>		The use of machine learning for face regions detection in thermograms
12:00-12:20	CT	<b>Vardasca Ricardo</b>		Infrared thermal imaging: a dataset definition towards decision making and intelligence
12:20-12:40	CT	<b>Toullier Thibaud</b>		Toward the development of intelligent wayside hot bearings detector system : combining the thermal vision with the strength of yolo-v4
11:00-12:40		Session 2-a - Artificial Intelligence II		Bogusław Więcek
11:00-11:20	CT	<b>Helvig Kevin</b>		Toward deep learning fusion of flying spot thermography and visible inspection for surface cracks detection on metallic materials
11:20-11:40	CT	<b>Albert-Weiss Dominique</b>		Multitask learning approach for fruit ripeness prediction using a dual band thermal camera
11:40-12:00	CT	<b>Albert-Weiss Dominique</b>		Continual learning to study the ripening of agricultural commodities using infrared thermography
12:00-12:20	CT	<b>Pareek Kaushal Arun</b>		Development of an intelligent failure analysis system based on infrared thermography and finite element modelling supported data augmentation for deep learning
12:20-12:40	CT	<b>Urbaś Sebastian</b>		Simulation of single-pixel ir camera with cnn reconstruction algorithm

# Intelligence Artificielle et CND thermique

## Exemple de travaux en thermique (QIRT 2022)

11:00-12:40		Session 1-1 - Artificial Intelligence I		Bogusław Więcek
11:00-11:20	CT	Liangliang Cheng		Irt-gan: a gan framework for automated defect segmentation in composites using infrared thermography
11:20-11:40	CT	Tout Karim		Defect detection on inductive thermography images using convolutional neural networks
11:40-12:00	CT	Kaczmarek Mariusz		The use of machine learning for face regions detection in thermograms
12:00-12:20	CT	Vardasca Ricardo		Infrared thermal imaging: a dataset definition towards decision making and intelligence
12:20-12:40	CT	Toullier Thibaud		Toward the development of intelligent wayside hot bearings detector system : combining the thermal vision with the strength of yolo-v4
11:00-12:40		Session 2-a - Artificial Intelligence II		Bogusław Więcek
11:00-11:20	CT	Helvig Kevin		Toward deep learning fusion of flying spot thermography and visible inspection for surface cracks detection on metallic materials
11:20-11:40	CT	Albert-Weiss Dominique		Multitask learning approach for fruit ripeness prediction using a dual band thermal camera
11:40-12:00	CT	Albert-Weiss Dominique		Continual learning to study the ripening of agricultural commodities using infrared thermography
12:00-12:20	CT	Pareek Kaushal Arun		Development of an intelligent failure analysis system based on infrared thermography and finite element modelling supported data augmentation for deep learning
12:20-12:40	CT	Urbaś Sebastian		Simulation of single-pixel ir camera with cnn reconstruction algorithm



### Principales applications :

- Détection de pattern (défauts, zone d'intérêt...) / dérives
- Extraction de paramètres pertinents



# Détection de défauts : Rockwool

Détection de défaut sur une ligne de production de plaque de laine de roche



<https://www.distriartisan.fr/blog/isolant-laine-de-roche-rockwool/>

Journées IA et CND - 08/06/22

# Detection de défauts

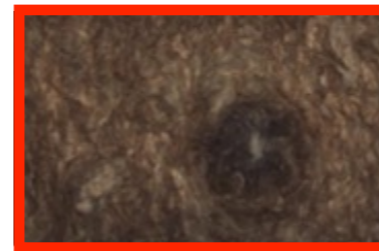

Image caméra visible



Rognage en volumes d'intérêt  
-> un millier d'images pour  
l'apprentissage

3 classes de matériaux :

- Sain
- Lave
- Chewing Gum



Lave




Sain




Chewing gum



Sain



Sain



Chewing gum



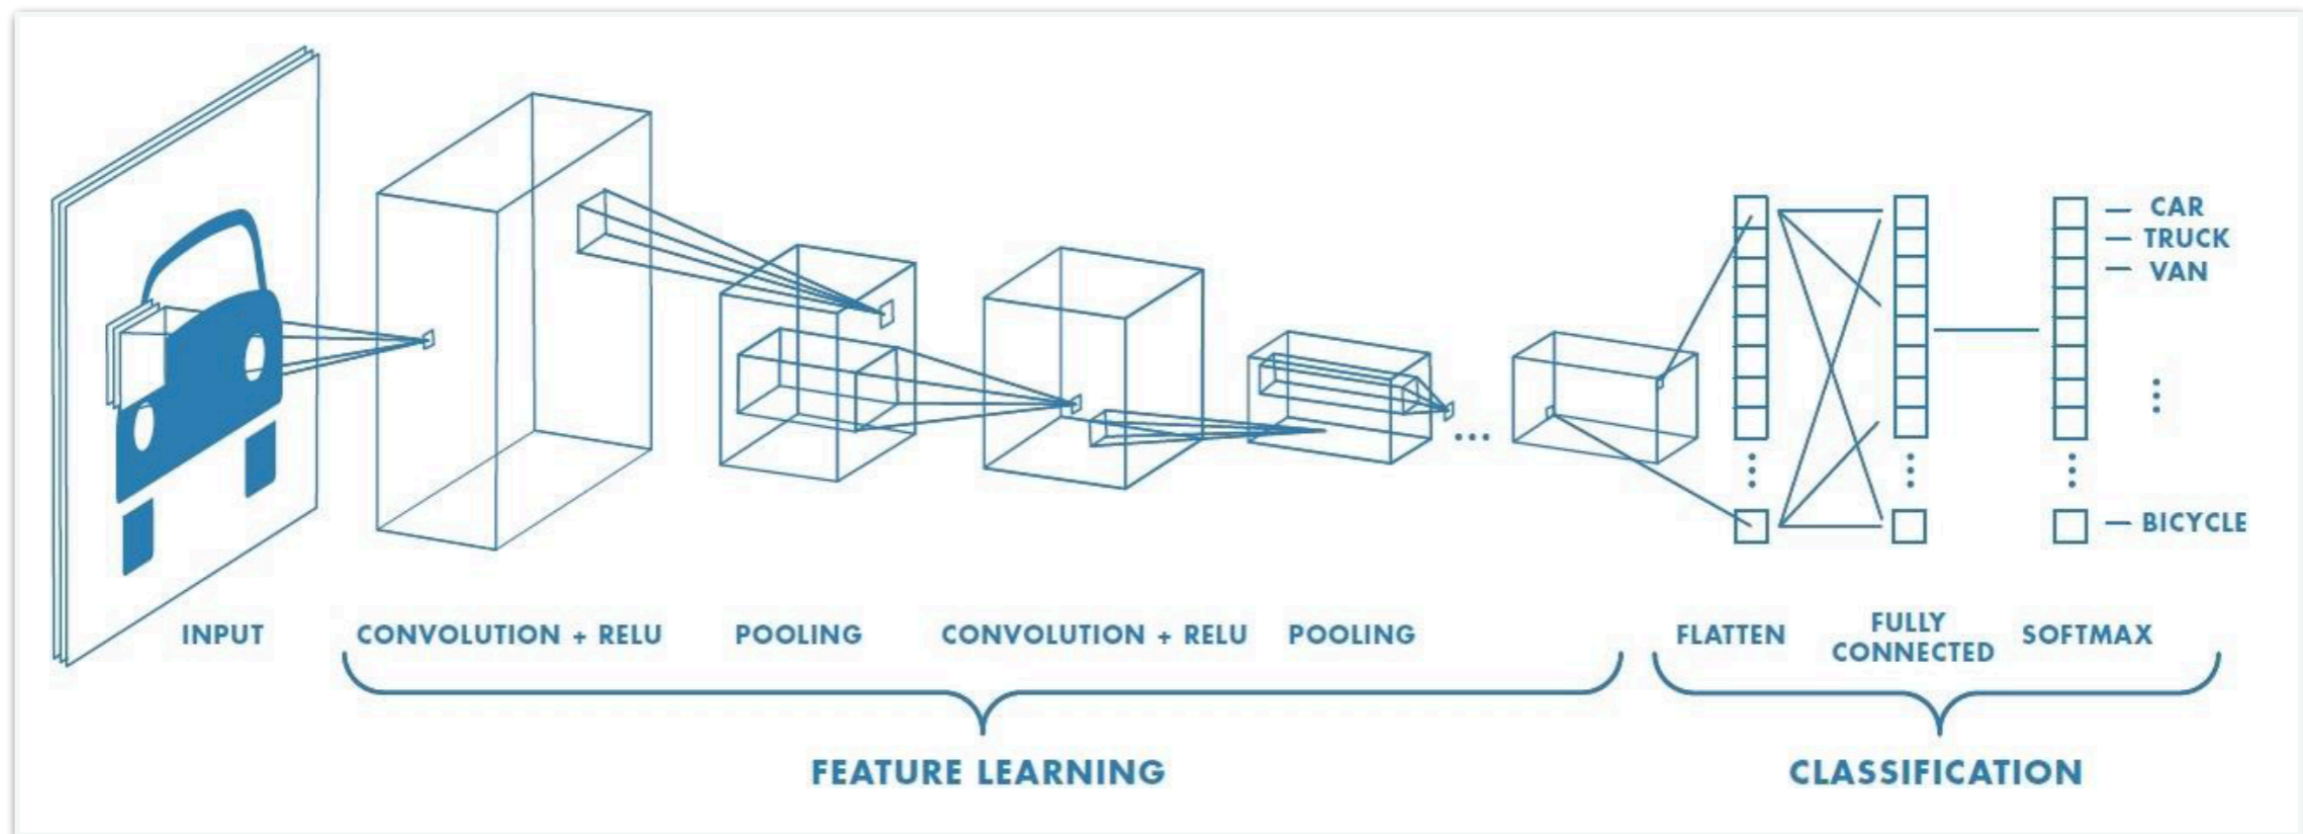
# Apprentissage d'un CNN

Convolutional Neural Network (Matlab)

3 couches de convolution + relu + pooling  
3 classes en sortie : Chewing gum, Lave, Sain

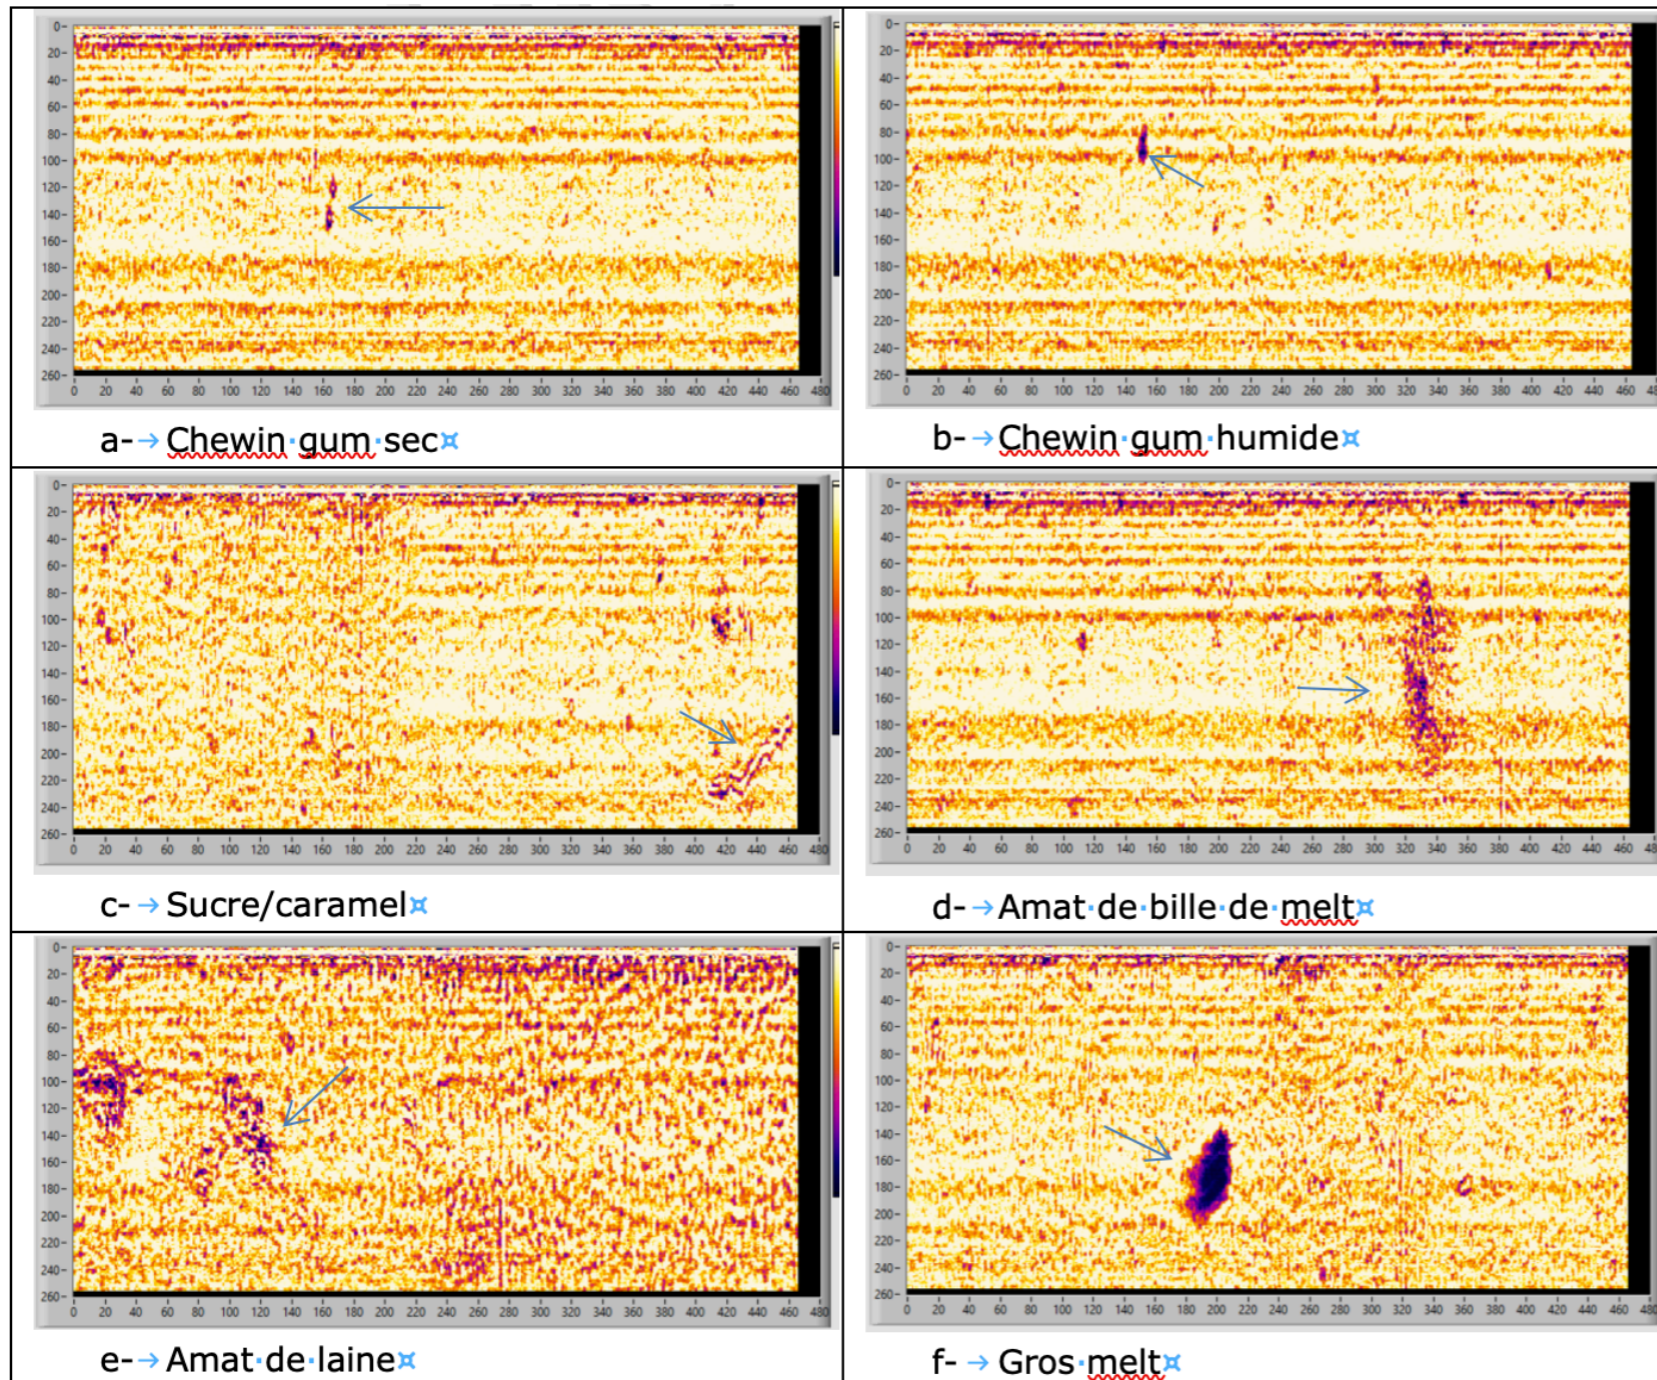
Performances brutes :

- Les images Saines reconnues à 100%
- Les images de Lave à 70%.
- Chewing gum < 70%





# Détection de défauts : passage au THz



Performances brutes :


- Saines reconnues à 100%
- Lave à 90%.
- Chewing gum 90%

Bilan:

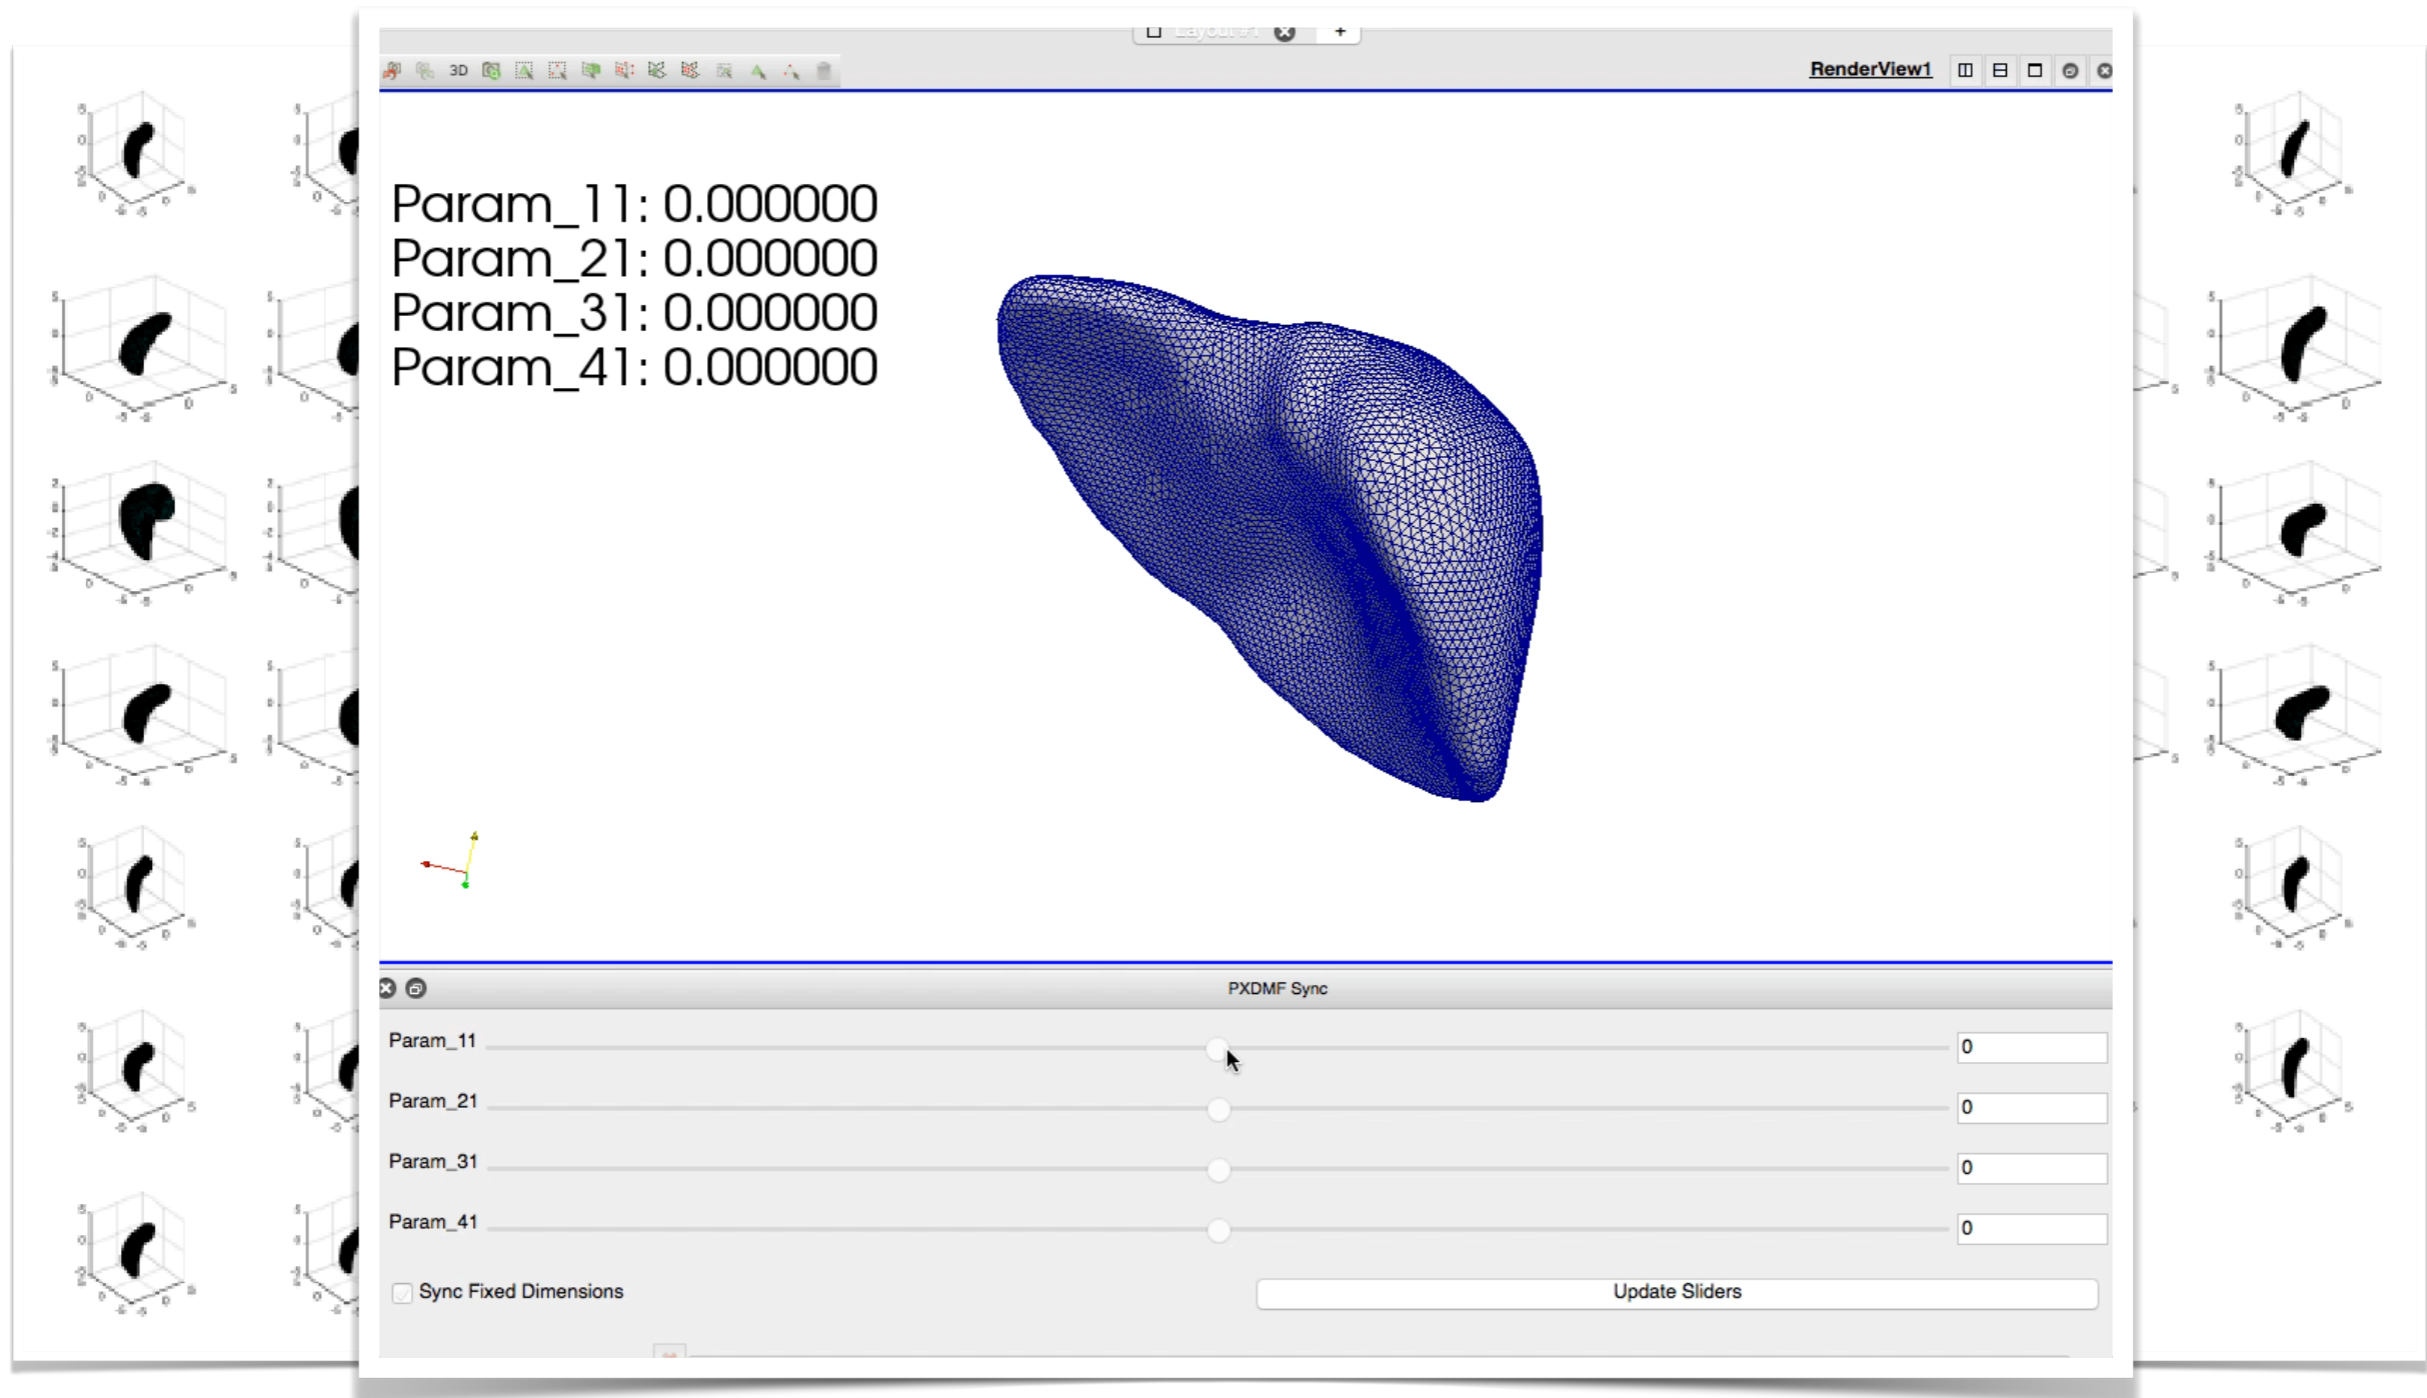
- Besoin de beaucoup d'images représentatives
- Apprentissage supervisé
- L'expertise a permis d'améliorer les résultats
- Marche en temps réel



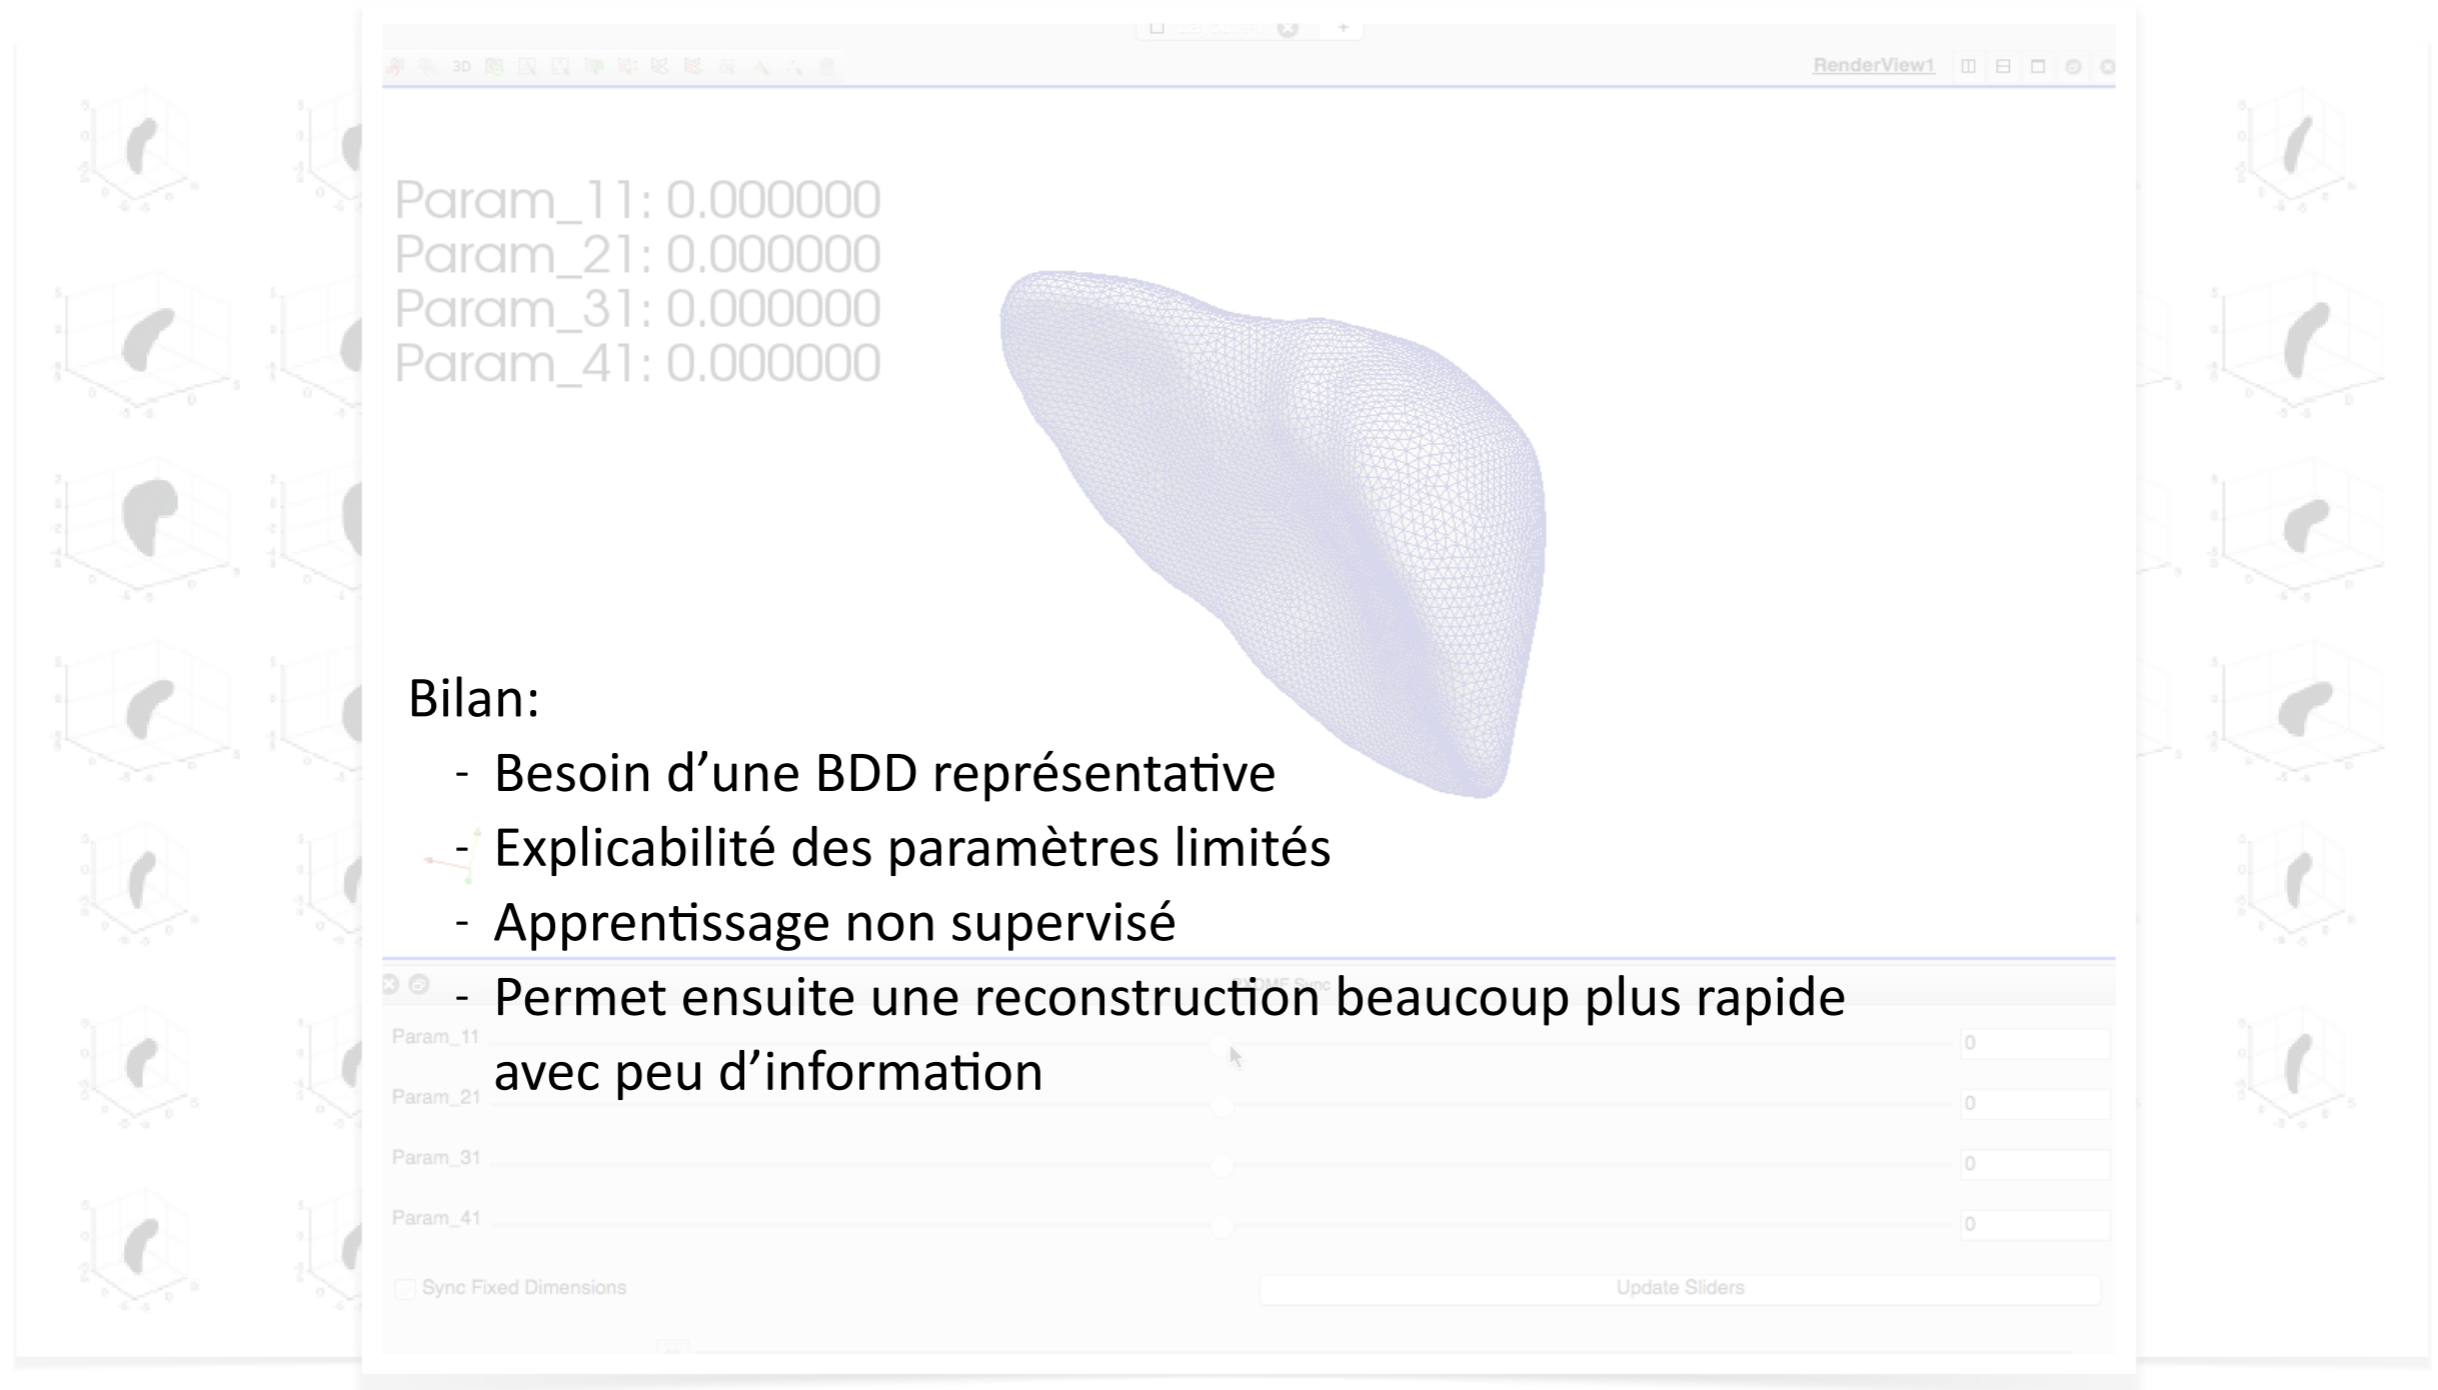
# Extraction de paramètres : reconstruction de foies



# Extraction de paramètres : reconstruction de foies



# Extraction de paramètres : reconstruction de foies



The screenshot displays a 3D reconstruction software interface. In the center, a blue wireframe model of a liver is shown. To the left and right are vertical columns of small 3D preview thumbnails. The top panel shows the following parameters:

```
Param_11: 0.000000
Param_21: 0.000000
Param_31: 0.000000
Param_41: 0.000000
```

**Bilan:**

- Besoin d'une BDD représentative
- Explicabilité des paramètres limités
- Apprentissage non supervisé
- Permet ensuite une reconstruction beaucoup plus rapide avec peu d'information

At the bottom, there are four sliders for Param\_11, Param\_21, Param\_31, and Param\_41, each with a value of 0. A checkbox for "Sync Fixed Dimensions" is also present, along with an "Update Sliders" button.



# Bilan

## Apports

- Détection de défauts automatique et en continu
- Fonctionnement en temps réel possible
- Extraction de paramètres pertinents et corrélation avec paramètres matériaux / process
- Extraction de paramètres pour la reconstruction / les méthodes de réduction de modèle

# Bilan

## Apports

- Détection de défauts automatique et en continu
- Fonctionnement en temps réel possible
- Extraction de paramètres pertinents et corrélation avec paramètres matériaux / process
- Extraction de paramètres pour la reconstruction / les méthodes de réduction de modèle

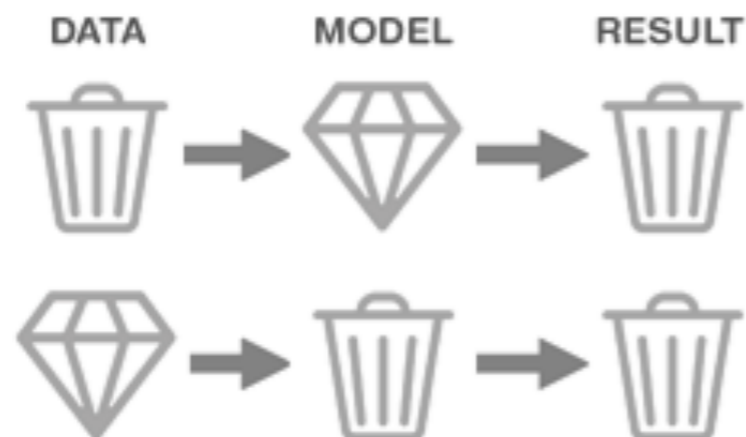

## Difficultés

- Besoin d'une labellisation dans le cas de l'apprentissage supervisé
- L'expertise reste très importante
- Besoin d'un grand nombre de données pertinentes / représentatives
- Qu'est-ce qu'une bonne BDD ?

# Bilan

## Apports

- Detection de défauts automatique et en continu
- Fonctionnement en temps réel possible
- Extraction de données et corrélation avec le process
- Extraction de données pour la reconstruction et la réduction de coûts




## Difficultés

- Besoin d'une labellisation dans le cas de l'apprentissage supervisé
- L'expertise reste très importante
- Besoin d'un grand nombre de données pertinentes / représentatives
- Qu'est-ce qu'une bonne BDD ?


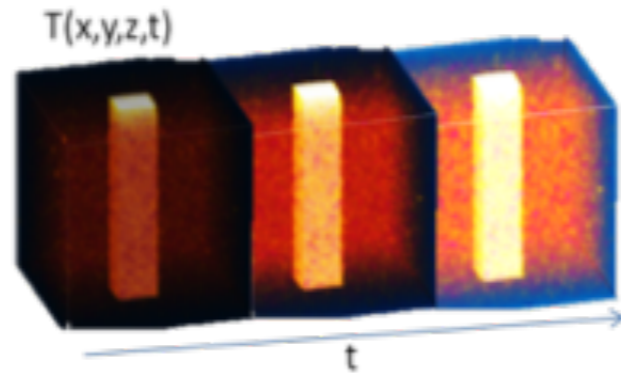
# Plan

- Utilisation de l'IA dans le traitement de la donnée
- **Qu'est-ce qu'une bonne base de données ?**
- Hybridation Physique et IA

# Génération de données massives



<i>Transient Thermal (65 Mo)</i> <b>3D</b>	<i>Transient Thermal Tomography (16 Go)</i> <b>4D</b>	<i>Transient Spectroscopy (26 Go)</i>	<i>Transient Spectral Tomography (6 To)</i> <b>5D</b>
---	--	---------------------------------------	--




Un cube de 5.8 million pixels, créé à 200 fps avec 100 longueur d'onde dans le spectre

**C'est plus de 1.65 TB de données à stocker toutes les 3 minutes**

# Point DD&RS

Evolution du stockage de la données

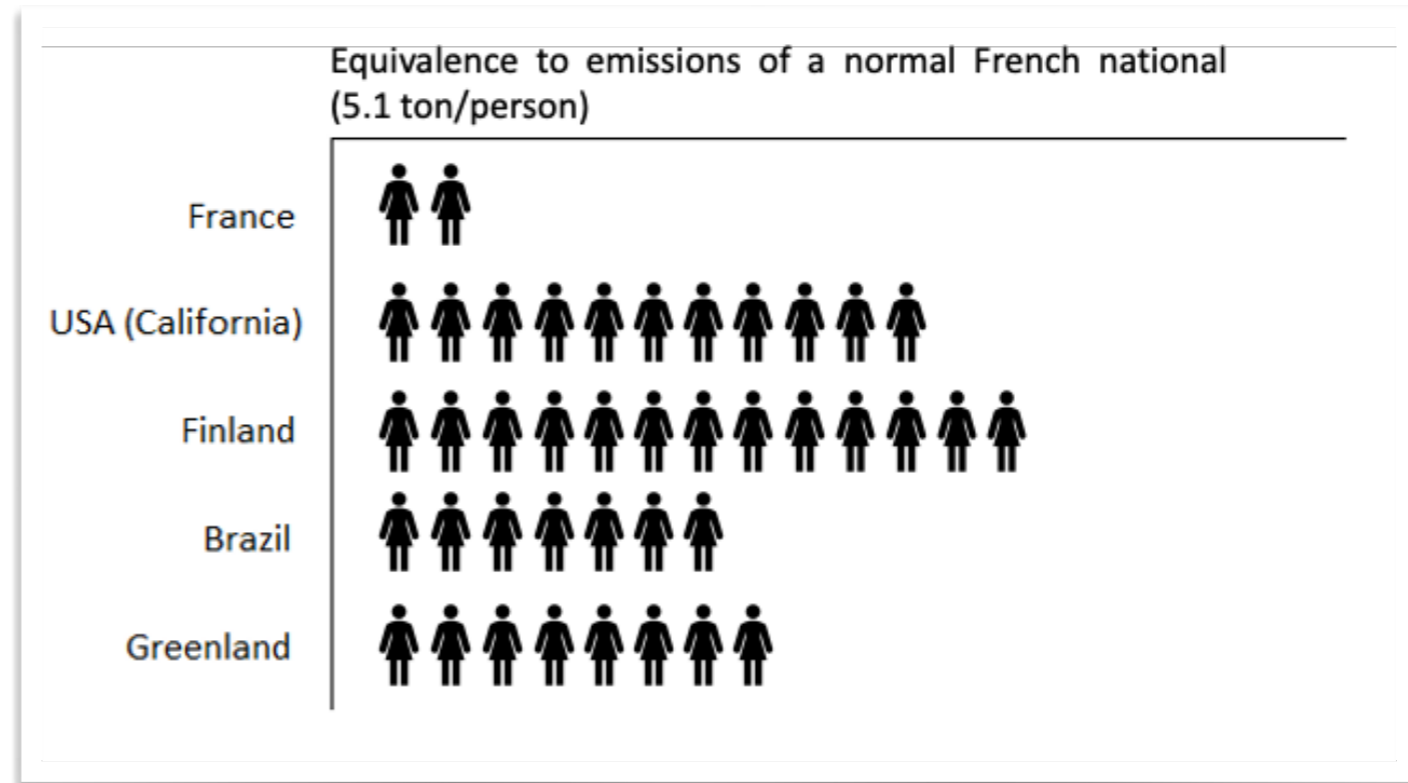
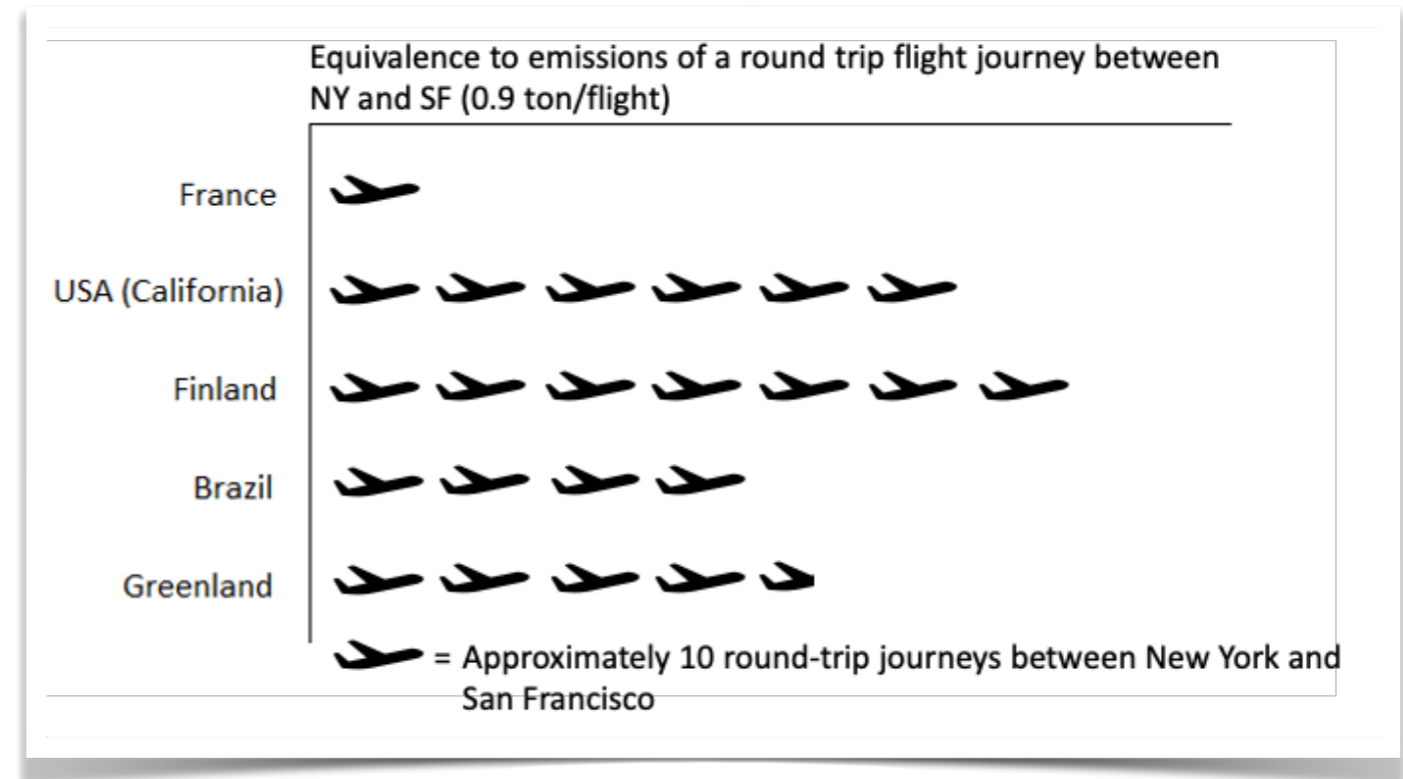


<https://www.statista.com/statistics/638613/worldwide-data-center-storage-used-capacity/>



# « Poids » de la data


Bilan carbone pour le stockage de 1000 To de données pendant 1 an





Wine  
• IS THE ANSWER •  
Wait,  
WHAT WAS  
THE QUESTION?

# Big vs Smart data



Cohérentes et contenant  
le plus d'information

Étape numéro 1 !

Définir quelles seront les données intelligentes à collecter pour répondre à la problématique posée

que l'on peut mesurer

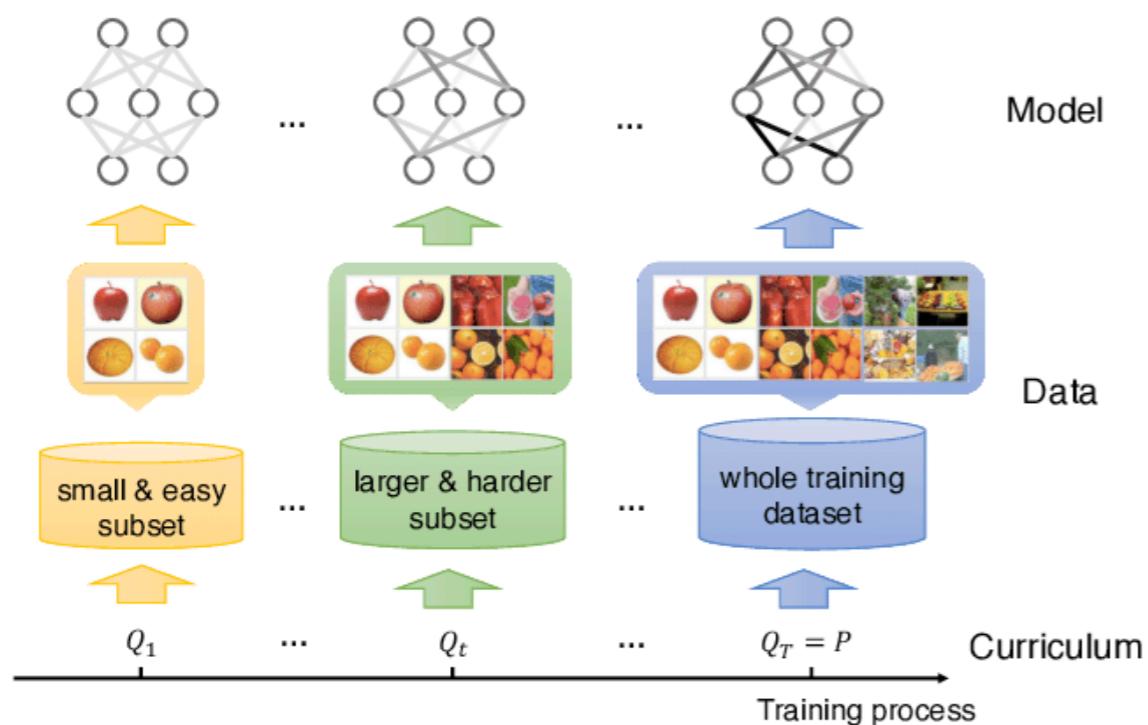
# Plan

- Utilisation de l'IA dans le traitement de la donnée
- Qu'est-ce qu'une bonne base de données ?
- **Hybridation Physique et IA**

# Hybridation / combinaison physique et IA

## Augmentation de la donnée

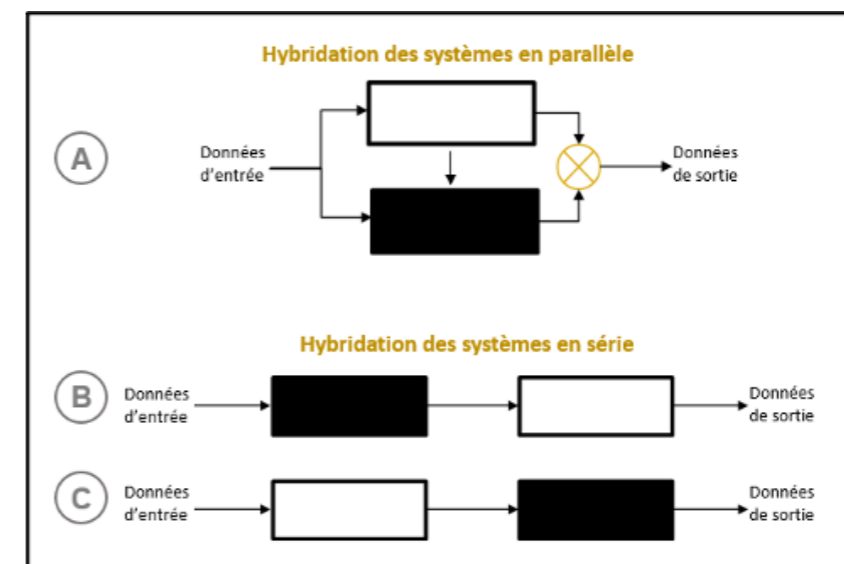
- Données synthétiques
- Curriculum learning



Wang & al. (2021). A Survey on Curriculum Learning. IEEE Transactions on Pattern Analysis and Machine Intelligence. PP. 10.1109/TPAMI.2021.3069908.

## Hybridation de l'approche

- Combinaison dans le processus de CND : IA pour la détection et la physique pour la caractérisation
- Hybridation dans les modèles : combinaison des modèles physiques et des modèles basés sur les données



M. von Stosch, & al « Hybrid semi-parametric modeling in process systems engineering : Past, present and future », Computers and Chemical Engineering, vol. 60 (2014) 86–101, 2013

# Conclusions

- **Apport de l'IA pour un certain nombre de cas d'application détection temps réel sur images**

*Dérive sur signaux*

- **Importance de la construction de la base de données**

*Définition précise du besoin*

*Besoin des experts*

- **Vers le smart data et l'hybridation**

*Agilité de l'instrumentation*

*Hybridation IA et modèles physiques, données expérimentales et données numériques*



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

*« Le choix de la méthode dépendra de la nature de la pièce métallique, de la taille des fissures recherchées, de la sensibilité requise et des contraintes spécifiques de l'application.*

*Il est recommandé de consulter des experts en contrôle non destructif thermique pour déterminer la méthode la plus appropriée dans un contexte donné. » Chat GPT.*

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

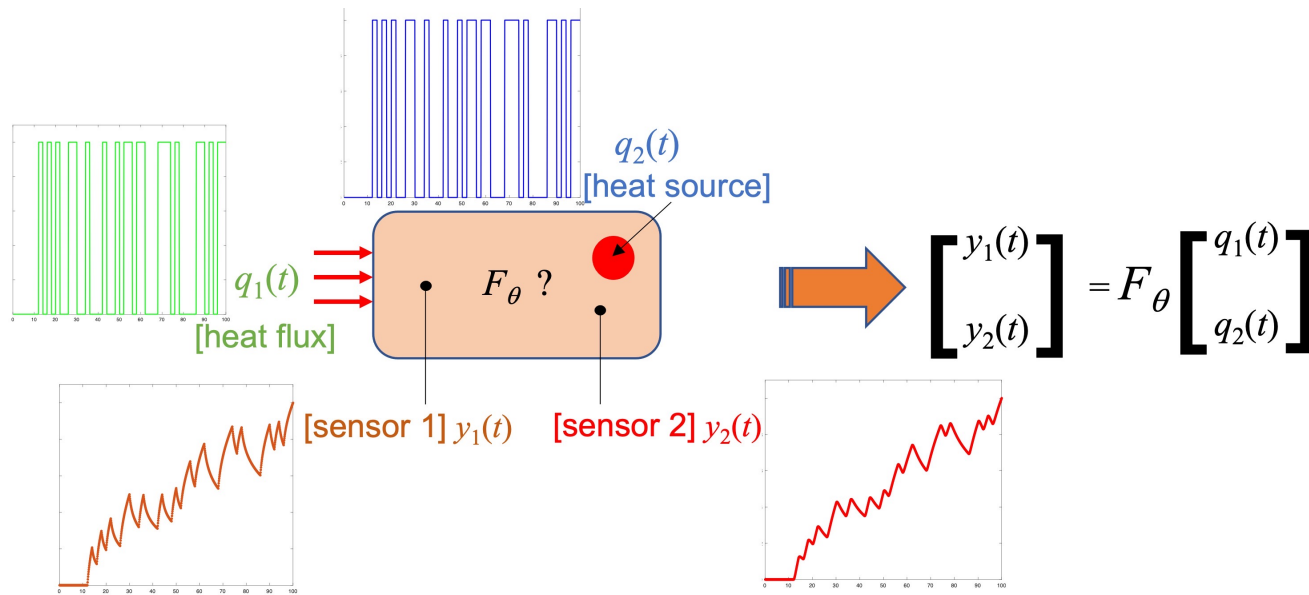
Identification of linear and non linear thermal systems from non integer integral mathematical structures

Jean-Luc Battaglia (Lab I2M, Université de Bordeaux, jean-luc.battaglia@u-bordeaux.fr)

Journée SFT : Inversion de données faisant appel à un modèle en thermique, quels apports de l'intelligence artificielle ?



# System identification




A model  $F_\theta$  that relates the temperature change  $y_j(t)$ ,  $j=1, \dots, N_c$ , of sensors to the thermal BC  $q_i(t)$ ,  $i=1, \dots, N_q$  (can be either a temperature, a heat flux or a source) is **identified** from measurements of those quantities.

The model « learns » from the data

# Potential applications

- Simulation
- Control
- Estimation of  $q(t)$  (IHCP)
- ...



# $F_\theta$ model structure (monovariable system)


$$\sum_{k=0}^{\infty} a_k D^k \{y(t)\} = \sum_{k=0}^{\infty} b_k D^k \{q(t)\} + \varepsilon(t), a_0 = 1$$

$$D^k \{f(t)\} = d^k f(t) / dt^k$$

Using finite difference discretization for the derivatives, the relation is equivalent to the family of exogenous auto-regressive structures (AR, ARMA, ARMAX, OE, etc.)

$$\sum_{k=0}^{\infty} \alpha_k y(t-k) = \sum_{k=0}^{\infty} \beta_k q(t-k) + \varepsilon(t), a_0 = 1$$

# Heat diffusion in a semi-infinite medium



$$\theta(x, p) = H(x, p) Q(p)$$

$$H(x, p) = \frac{e^{-\frac{x}{\sqrt{\alpha}}\sqrt{p}}}{\lambda \sqrt{p/\alpha}} = \frac{e^{-\frac{x}{\sqrt{\alpha}}\sqrt{p}}}{E \sqrt{p}}$$

At  $x = 0$  
$$H(0, p) = \frac{1}{E \sqrt{p}}$$

Let us recall that the solution is:  $T(0, t) = \frac{1}{E \sqrt{\pi} \sqrt{t}} * q$

# The non integer derivative

$$\mathcal{L} \left( \frac{d^v f(t)}{dt^v} \right) = s^v F(s) - \sum_{k=0}^{n-1} s^{n-k-1} \frac{d^k f(0)}{dt^k}$$

Liouville demonstrated that this definition remains exact when  $v$  is a real and even more generally a complex number

$$D^v \{f(t)\} = D^n \{I^{n-v} \{f(t)\}\}, n \in \mathbb{N}, \operatorname{Re}(v) > 0, n - 1 \leq \operatorname{Re}(v) < n \quad \boxed{\text{Non-integer derivative}}$$

$$I^v \{f(t)\} = \frac{1}{\Gamma(v)} \int_0^t (t-u)^{v-1} f(u) du, \operatorname{Re}(v) > 0 \quad \boxed{\text{Non-integer integral}}$$


$$\Gamma(v) = \int_0^\infty u^{v-1} \exp(-u) du$$

Convolution product of  $f(t)$  with  $t^{v-1}$  (infinite memory)

# New expression of the solution using the non-integer model structure

$$\mathcal{L}^{-1} \left( \frac{1}{\sqrt{p}} F(p) \right) = I^{1/2} \{f(t)\}$$

$$H(0, p) = \frac{1}{E \sqrt{p}}$$



$$T(0, t) = \frac{1}{E} I^{1/2} q$$

$$T(x, t) = \sum_{n=0}^{\infty} b_n I^{n/2} \{q(t)\}$$

If one wants to use the integer structure, an infinite number of terms must be considered

Optimal model structure for this configuration:

$$y = \beta_1 I^{1/2} q + \varepsilon$$

$$\beta_{1,th} = 1/E$$

# How to calculate the non integer integral ?

Several discretization schemes (Grünwald for instance)

$$D^\nu f(t_0) \sim \frac{1}{h^\nu} \sum_{k=0}^{n-1} (-1)^k \binom{\nu}{k} f(t_0 - kh), \quad \nu > 0 \quad \binom{\nu}{k} = \frac{\nu(\nu-1)\cdots(\nu-k+1)}{k!}$$

Another way:

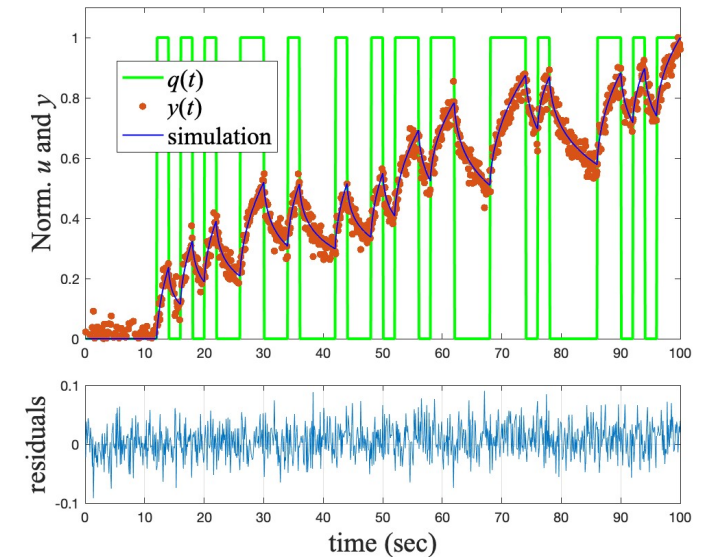


$$I^\nu \{f(t)\} = \frac{1}{\Gamma(\nu)} \int_0^t (t-u)^{\nu-1} f(u) du, \quad \operatorname{Re}(\nu) > 0 \quad \longrightarrow \quad I^\zeta \{f(t)\} = \mathcal{L}^{-1} \left( \frac{1}{p^\zeta} \right) * f(t) = \frac{t^{\zeta-1}}{\Gamma(\zeta)} * f(t), \quad \zeta \geq 0$$

FFT is fast

$$\frac{t^{\zeta-1}}{\Gamma(\zeta)} * f(t) = \text{FFT}^{-1} \left[ \text{FFT} \left[ \frac{t^{\zeta-1}}{\Gamma(\zeta)} \right] \times \text{FFT} [f(t)] \right]$$



# Illustration



$$y(t) = T(0, t) + \varepsilon N(t) \quad (\text{simulated from the exact solution})$$

Noise amp.	$\beta_{1,\text{id}}$ (LS, RLS)	$\beta_{1,\text{th}} = 1/E$
$\varepsilon = 0$	$1.26 \times 10^{-4} \pm 1.82 \times 10^{-14}$	$1.26 \times 10^{-4}$
$\varepsilon = 5\%$	$1.26 \times 10^{-4} \pm 1.0 \times 10^{-7}$	$1.26 \times 10^{-4}$
$\varepsilon = 10\%$	$1.26 \times 10^{-4} \pm 2 \times 10^{-7}$	$1.26 \times 10^{-4}$

The parameter identification is based on the linear least squares (recursive RLS or not LS)

What happens if the sensor is located at  $x > 0$

$$\exp(z) = \sum_{n=0}^{\infty} z^n/n! \quad \Rightarrow \quad H(x, p) = \sum_{n=0}^{\infty} \frac{\left(-\frac{x}{\sqrt{\alpha}}\sqrt{p}\right)^n}{n! E \sqrt{p}} = \frac{1}{E \sqrt{p}} \left( 1 + \sum_{n=1}^{M \rightarrow \infty} \frac{-x^n}{\alpha^{n/2} n!} p^{n/2} \right)$$

$$x = 1 \text{ mm}$$

$$M = 2$$

$$H(x, p) = \frac{1}{\sqrt{p}} (b_0 + b_1 p^{1/2} + b_2 p), \quad b_0 = \frac{1}{E}, \quad b_1 = -\frac{x}{\sqrt{\alpha} E}, \quad b_2 = \frac{x^2}{2 \alpha E}$$

$$H(x, p) = \frac{b_0 p^{-1} + b_1 p^{-1/2} + b_2}{p^{-1/2}}$$

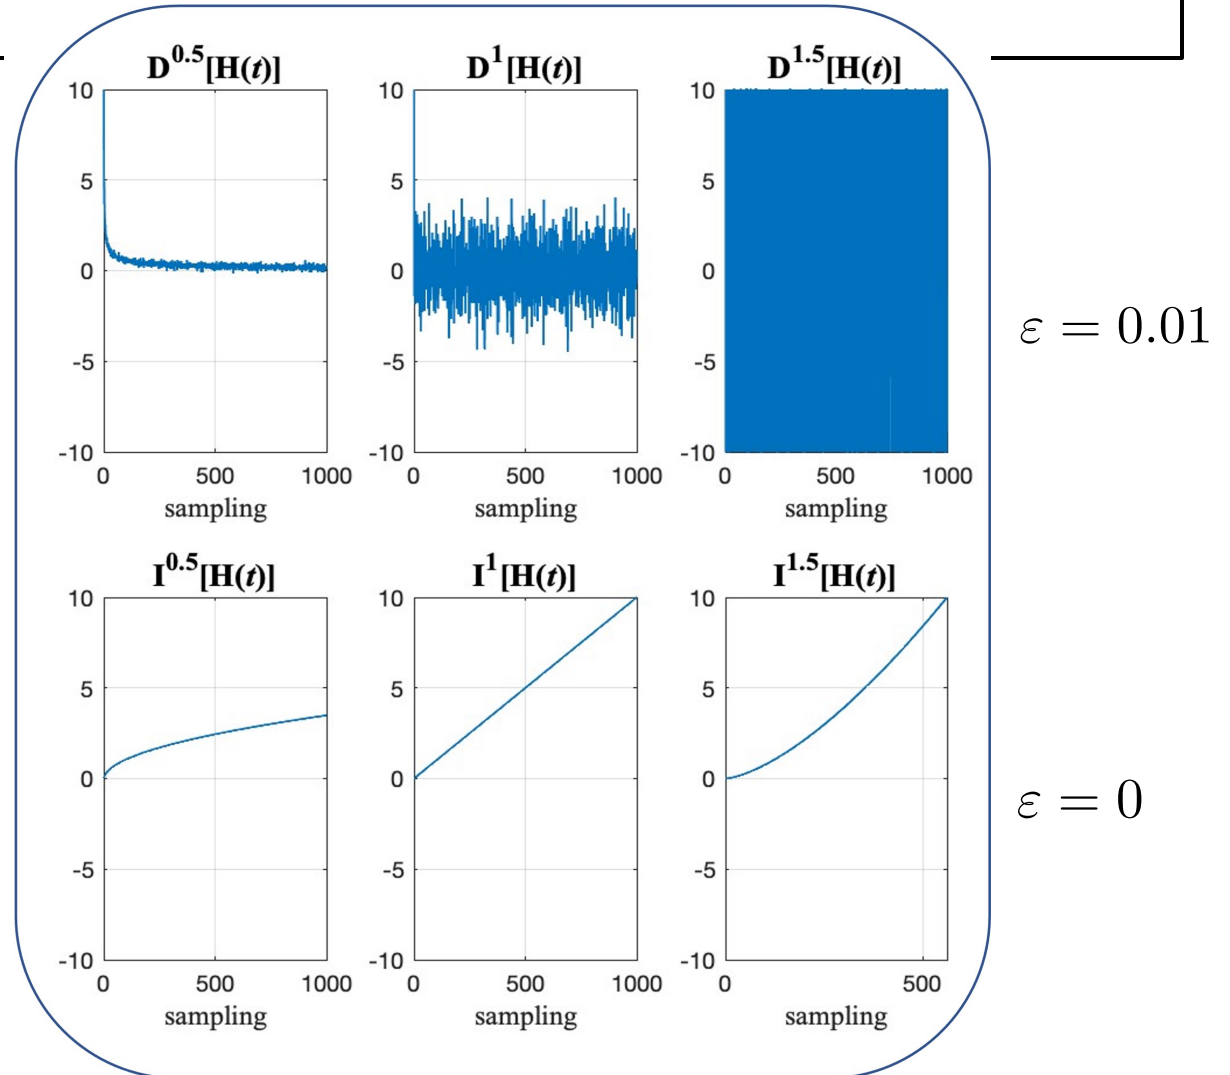


$$\mathbb{I}^{1/2} y = \beta_0 \mathbb{I} q + \beta_1 \mathbb{I}^{1/2} q + \beta_2 q + \mathbb{I}^{1/2} \varepsilon$$



# Why using the NI integral instead of the NI derivative ?

$U(t) = H(t)$  is the Heaviside function

$$U_\varepsilon(t) = U(t) + \varepsilon N(t)$$




# Illustration





$$y(t) = T(0, t) + \varepsilon N(t) \quad (\text{simulated from the exact solution})$$

Noise amp.	$\beta_0$	$\beta_1$	$\beta_2$
theoretical values	$1.261 \times 10^{-4}$	$-6.67 \times 10^{-5}$	$1.76 \times 10^{-5}$
id. values, $\varepsilon = 0$	$1.255 \times 10^{-4} \pm 1.67 \times 10^{-5}$	$-9.523 \times 10^{-5} \pm 1.27 \times 10^{-4}$	$1.3 \times 10^{-5} \pm 1.67 \times 10^{-4}$
id. values, $\varepsilon = 10\%$	$1.265 \times 10^{-4} \pm 1.65 \times 10^{-5}$	$-10.37 \times 10^{-5} \pm 1.27 \times 10^{-4}$	$1.7 \times 10^{-5} \pm 1.66 \times 10^{-4}$

# Loss of the semi-infinite behaviour



$x = 3\text{mm}, e = 1\text{ cm}$




The best optimal structure is:  $y + \alpha_1 Iy = \beta_0 I^2 q + \beta_1 I^3 q + \beta_2 I^4 q$


Can be derived from the exact solution of the transfer function:  $H(x, p) = \frac{\cosh(\sqrt{p/\alpha}(e-x))}{\lambda \sqrt{p/\alpha} \sinh(\sqrt{p/\alpha}e)}$

# Real application

## System identification for Sensor 1




## System identification for Sensor 2



Learning

validating







# Identified models


$y_1 = \beta_1 I^{0.5}q + \beta_2 I^1q + \beta_3 I^{1.5}q + \beta_4 I^2q + \beta_5 I^{2.5}q + \beta_6 I^3q + \beta_7 I^{3.5}q + \varepsilon(t)$							
parameter	$\beta_0$	$\beta_1$	$\beta_2$	$\beta_3$	$\beta_4$	$\beta_5$	
value	-0.9	3.04	-1.92	0.61	-0.1	0.007	
std	0.004	0.006	0.005	0.002	0.0004	$3.5 \times 10^{-5}$	
$y_1 + \alpha_1 I^1y + \alpha_2 I^2y = \beta_1 I^2q + \beta_2 I^3q + \beta_3 I^4q + \beta_4 I^5q + \beta_5 I^6q + \varepsilon(t)$							
parameter	$\alpha_1$	$\alpha_2$	$\beta_1$	$\beta_2$	$\beta_3$	$\beta_4$	$\beta_5$
value	1.31	0.45	0.13	0.007	$3.2 \times 10^{-5}$	$-8.5 \times 10^{-6}$	$2.67 \times 10^{-7}$
std	0.021	0.004	0.0017	0.0003	$2.55 \times 10^{-5}$	$1.84 \times 10^{-6}$	$6.27 \times 10^{-8}$

# The case of non-linear heat diffusion


sensor  $T(0,t)$



# System identification



$$T + \alpha_1 I^1 q + \alpha_2 I^{1.5} q = \beta_0 I^{0.5} q + \beta_1 I^1 q + \beta_2 I^{1.5} q$$



# Justification

Volterra series decomposition

$$T(t) = \sum_{j=1}^{\infty} T_j(t) = T_1(t) + T_2(t) + \dots + T_j(t) + \dots$$

$$T_j(t) = \int_0^{\infty} \dots \int_0^{\infty} h_j(\tau_1, \dots, \tau_j) \prod_{i=1}^j q(t - \tau_i) d\tau_i$$

$\uparrow$   
 $j^{\text{th}}$  order Volterra kernel

In practice the number of kernels can be limited to 2


$$\begin{aligned} T(t) &= T_1(t) + T_2(t) = T_L(t) + T_{NL}(t) \\ &= \int_0^{\infty} h_1(\tau) q(t - \tau) d\tau + \int_0^{\infty} \int_0^{\infty} h_2(\tau_1, \tau_2) q(t - \tau_1) q(t - \tau_2) d\tau_1 d\tau_2 \end{aligned}$$

We propose to introduce a **generalized transfer function**:

$$T(t) = \int_0^{\infty} h_{NL}(\tau) q(t - \tau) d\tau$$

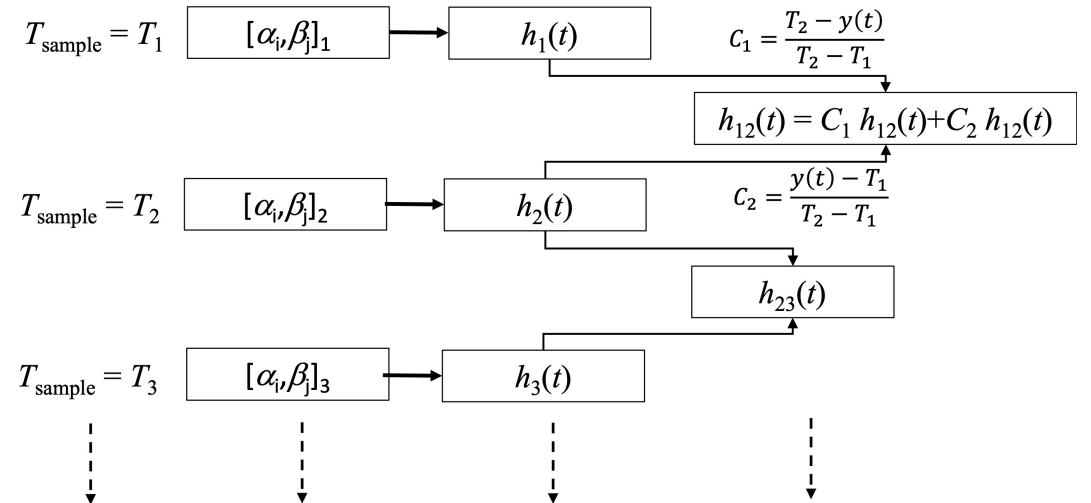
# Justification

Since the non integer integral involves all the time history of the integrand function, it is well suited with the introduction of a generalized transfer function that accounts with non-linearities.



Increasing  $q_0$  leads to involve larger non linearities and thus to limit the range of temperature investigated by the model

$$T + \alpha_1 I^1 q + \alpha_2 I^{1.5} q = \beta_0 I^{0.5} q + \beta_1 I^1 q + \beta_2 I^{1.5} q$$



# BRIDGING PHYSICS AND STATISTICAL LEARNING METHODOLOGIES FOR THE ACCURATE MODELING OF THE RADIATIVE PROPERTIES OF NON-UNIFORM ATMOSPHERIC PATHS

---

F. André<sup>1</sup>, C. Delage<sup>1</sup>, L. Guilmard<sup>1</sup>, M. Galtier<sup>1</sup>, C. Cornet<sup>2</sup>

<sup>1</sup>Univ. Lyon, CNRS, UMR 5008 – CETHIL, Lyon, France

<sup>2</sup>Univ. Lille, CNRS, UMR 8518 – LOA, Lille, France

Corresponding Authors: [frederic.andre@insa-lyon.fr](mailto:frederic.andre@insa-lyon.fr) , [cindy.delage@insa-lyon.fr](mailto:cindy.delage@insa-lyon.fr)



# BRIDGING PHYSICS AND STATISTICAL LEARNING METHODOLOGIES FOR THE ACCURATE MODELING OF THE RADIATIVE PROPERTIES OF NON-UNIFORM ATMOSPHERIC PATHS

---

F. André<sup>1</sup>, C. Delage<sup>1</sup>, L. Guilmard<sup>1</sup>, M. Galtier<sup>1</sup>, C. Cornet<sup>2</sup>

<sup>1</sup>Univ. Lyon, CNRS, UMR 5008 – CETHIL, Lyon, France

<sup>2</sup>Univ. Lille, CNRS, UMR 8518 – LOA, Lille, France

Corresponding Author: [frederic.andre@insa-lyon.fr](mailto:frederic.andre@insa-lyon.fr).

# INTRODUCTION (1/7)

---

The concept of transmissivity is fundamental in radiative transfer in participating media, including gases.

## Transmissivities:

- Represent the fraction of an incident radiative intensity that travels a distance  $L$  inside a medium without being absorbed.
- Appear naturally in the integral form of the RTE (here averaged over a spectral band  $\Delta\nu$  – no scattering):

$$I^{\Delta\nu}(L) = I_b^{\Delta\nu}(0) \cdot \tau^{\Delta\nu}(0, L) + \int_0^L \frac{\partial \tau^{\Delta\nu}(s', L)}{\partial s'} \cdot I_b^{\Delta\nu}(s') ds'$$

# INTRODUCTION (2/7)

As LBL data are usually provided in absorption coefficient form, calculation of transmissivities requires evaluating:

$$\tau^{\Delta\nu}(0, L) = \tau^{\Delta\nu}(L) = \frac{1}{\Delta\nu} \cdot \int_{\Delta\nu} \exp(-\kappa_\nu L) d\nu$$

which can be computationally expensive even in uniform isothermal cases (Ex: O<sub>2</sub> A-band, 10748 coefficients\*).

\* Ex : POLDER O<sub>2</sub> A-band

Used to characterize the macrophysical properties of cloud (altitude, geometrical length)  
ex : Ferlay et al. 2010 ; Desmons et al. 2013  
LBL => 10748 coefficients d'absorption




FIG. 1. Atmospheric transmission in the region of the oxygen A band at a resolution of 5 cm<sup>-1</sup> (≈0.3 nm) and filter transmission in the narrow (10 nm) and wide (40 nm) POLDER bands centered at 763 and 765 nm, respectively.

# INTRODUCTION (3/7)

---

Providing **accurate values of transmissivities** is usually said to be **difficult because gas spectra are made of many thin and overlapping spectral lines**.


This statement is **mostly irrelevant** because this problem was solved almost a century ago (even before the availability of data and codes for LBL calculations).

In reality, the **MAIN DIFFICULTY** concerns the **TREATMENT OF PATH NON-UNIFORMITIES** as encountered in almost all applications.

Standard non-uniform methods provide in reasonable cases an accuracy of a few percents that may be sufficient in some applications (in combustion for instance) but not in other ones (as in remote sensing).

**THIS PROBLEM IS STILL UNSOLVED IN A GENERAL FRAME.**

# INTRODUCTION (4/7)




pp. 711-713\*:

« ...radiance error magnification problem for the two-cell configuration, and highly nonuniform optical paths in general, is one of the biggest problems remaining in theoretical band model developments.

(...)

**No solution to this problem is likely to be found **STRICTLY** within the framework of band models. »**

Is it possible to propose a solution based on an appropriate combination of physics ( $\varphi$ ), statistics ( $\sigma$ ) and statistical learning ( $\mu$ )?



# INTRODUCTION (5/7)

---

For this purpose, we propose in this work to use the formalism introduced in the  $\ell$ -distribution approach which is founded on the following property:

$$\frac{1}{\Delta v} \cdot \int_{\Delta v} \exp(-\kappa_v L) dv = \mathbb{P}[\ell(\xi) > L] = \int_0^1 H[\ell(\xi) - L] d\xi$$
$$\tau^{\Delta v}[\ell(\xi)] = \xi, \quad \xi \in [0, 1] \quad \text{Used as the definition of } \ell$$

Path sampling strategies in Monte Carlo method are founded on the same result. But it has not been used apparently as the building block of methods other than Monte Carlo:  $\ell$ -distribution theory fills this gap.



# INTRODUCTION (6/7)

---

Modeling the inverses  $\ell$  of transmissivities  $\tau$  can be tricky\*. However, their combination takes in some cases very simple forms:

$$\text{state 1} = \text{state 2: } \ell_1 \circ \tau_1^{\Delta\nu} (L) = L$$

$$\text{Scaled spectra } \kappa_{\nu,2} = u \cdot \kappa_{\nu,1} \text{ where } u \text{ is a constant: } \ell_1 \circ \tau_2^{\Delta\nu} (L) = u \cdot L$$


**Question:** what is the form of the function when (**definition of quasi-scaled spectra**)?




$$\kappa_{\nu,2} = u_{\nu} \cdot \kappa_{\nu,1} \text{ where: } \begin{cases} u_{\nu} \text{ and } \kappa_{\nu,1} \text{ are statistically independent} \\ 0 \leq u_{\nu} - u_{\min} \ll u_{\min} \end{cases}$$

# INTRODUCTION (7/7) – Main result, where {1, 2} is a couple of states.

Lévy - Khintchine representation of  $\ell_1 \circ \tau_2^{\Delta v}$

$$\ell_1 \circ \tau_2^{\Delta v} (L) \approx u_{\min} L + \int_0^1 \frac{1 - \exp[-s(0) \cdot v(\xi) L]}{s(0)} d\xi$$



	$\varphi$	Physical component of the model
	$\sigma$	Statistical component of the model
	$\mu$	Statistical Learning component of the model


# OUTLINE OF THE PRESENTATION

---

- ~~I. *The physical component of the model: the s function*~~
- II. Analysis of the two-layer problem
- III. Generalization ( $\ell$ -distribution and LBL training processes)
- III'. Case of the 3MI 7 O<sub>2</sub> A-band (C. Delage)*



## CONCLUSION




*Comment:* I have decided not to talk about the statistical component that relates to copula theory, due to limited time, but additional slides are available if you have questions.



# I. The physical component of the model: the $s$ function (1/5)

All (most of) the physics lies in the definition of  $s(0)$  as:

$$s(0) = s(L=0) \text{ where } s(L) = \frac{\partial}{\partial L} \left( \ln \left[ -\frac{1}{k_{P,2}} \frac{\partial \ln \tau_2^{\Delta\nu}(L)}{\partial L} \right] \right)$$



$\varphi$

Physical component of the model



$\sigma$

Statistical component of the model



$\mu$

Statistical Learning component of the model

## II. Analysis of the two-layer problem (1/6)

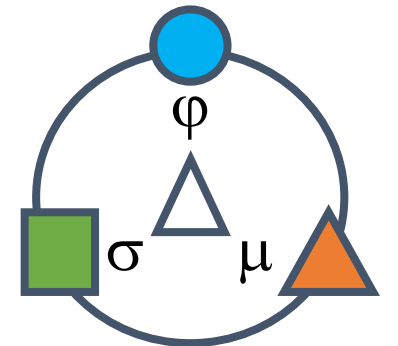
3 equivalent formulations (where  $u_{\min}$ ,  $\bar{u}$  and  $v(\xi) = u(\xi) - u_{\min}$  are « scaling » coefficients):

$$\ell_1 \circ \tau_2^{\Delta v}(L) \approx u_{\min} L + \int_0^1 \frac{1 - \exp[-s(0) \cdot v(\xi) L]}{s(0)} d\xi$$

$$\ell_1 \circ \tau_2^{\Delta v}(L) \approx u_{\min} L + (\bar{u} - u_{\min}) \cdot \int_0^1 \frac{1 - \exp[-s(0) \cdot v^*(\xi) L]}{s(0) \cdot v^*(\xi)} d\xi$$

$$\ell_1 \circ \tau_2^{\Delta v}(L) = u(L) \cdot L$$

$$u(L) \approx u_{\min} + (\bar{u} - u_{\min}) \cdot \int_0^1 \int_0^1 \exp[-s(0) \cdot v(\xi) t L] dt d\xi$$



## II. Analysis of the two-layer problem (2/6)

---

**Step 1.** integral is written in a discrete form:

$$\ell_1 \circ \tau_2^{\Delta v}(L) \approx u_{\min} L + (\bar{u} - u_{\min}) \cdot \int_0^1 \frac{1 - \exp[-s(0) \cdot v^*(\xi) L]}{s(0) \cdot v^*(\xi)} d\xi$$

$$\ell_1 \circ \tau_2^{\Delta v}(L) \approx u_{\min} L + (\bar{u} - u_{\min}) \cdot \sum_{i=1}^N \frac{\omega_i}{s(0) \cdot v^*(x_i)} \cdot \left(1 - \exp[-s(0) \cdot v^*(x_i) L]\right)$$

$x_i$  and  $\omega_i$  are the nodes and weights of a Gauss-Legendre quadrature over  $[0,1]$ .

The choice of this formulation for training is due to the existence of a simple method to initialize the model's coefficients (André et al, JQSRT, 2022).



## II. Analysis of the two-layer problem (3/6)

---

**Step 2.** a loss function  $\mathcal{L}$  is defined:

$$\mathcal{L} = \mathcal{L} \left[ u_{\min}, v^*(x_1), \dots, v^*(x_N) \right] = \int_0^{+\infty} \left[ \tau_2^{\Delta\nu}(L) - \tau_1^{\Delta\nu}(\ell_1 \circ \tau_2^{\Delta\nu}(L)) \right]^2 d\tau_2^{\Delta\nu}(L)$$

$$\ell_1 \circ \tau_2^{\Delta\nu}(L) \approx u_{\min} L + (\bar{u} - u_{\min}) \cdot \sum_{i=1}^N \frac{\omega_i}{s(0) \cdot v^*(x_i)} \cdot \left( 1 - \exp \left[ -s(0) \cdot v^*(x_i) L \right] \right)$$

$x_i$  and  $\omega_i$  are the nodes and weights of a Gauss-Legendre quadrature over  $[0, 1]$ .

## II. Analysis of the two-layer problem (4/6)

---

**Step 3.** the loss function  $\mathcal{L}$  is discretized:

$$\mathcal{L} = \mathcal{L} \left[ u_{\min}, v^*(x_1), \dots, v^*(x_N) \right] = \frac{1}{P} \cdot \sum_{p=1}^P \left[ Y_p - \tau_1^{\Delta v} \left( \ell_1 \circ \tau_2^{\Delta v} \left( L_p \right) \right) \right]^2$$

$$Y_p = \frac{p}{P}, \quad L_p = \ell_2 \left( Y_p \right) \text{ where } \ell_2 \circ \tau_2^{\Delta v} \left( L \right) = L$$

**Important comment:** in the logic of our methodology, the proposed developments come after an evaluation of both a CKD model and a « standard »  $\ell$ -distribution model. The **corresponding model parameters** are thus known but the models are not considered accurate enough to justify an improvement stage (described in this work).

## II. Analysis of the two-layer problem (5/6)

**Step 4.** the loss function  $\mathcal{L}$  is minimized (using explicit gradients).

Published as a conference paper at ICLR 2015


### ADAM: A METHOD FOR STOCHASTIC OPTIMIZATION

Diederik P. Kingma\*  
University of Amsterdam, OpenAI  
dpkingma@openai.com

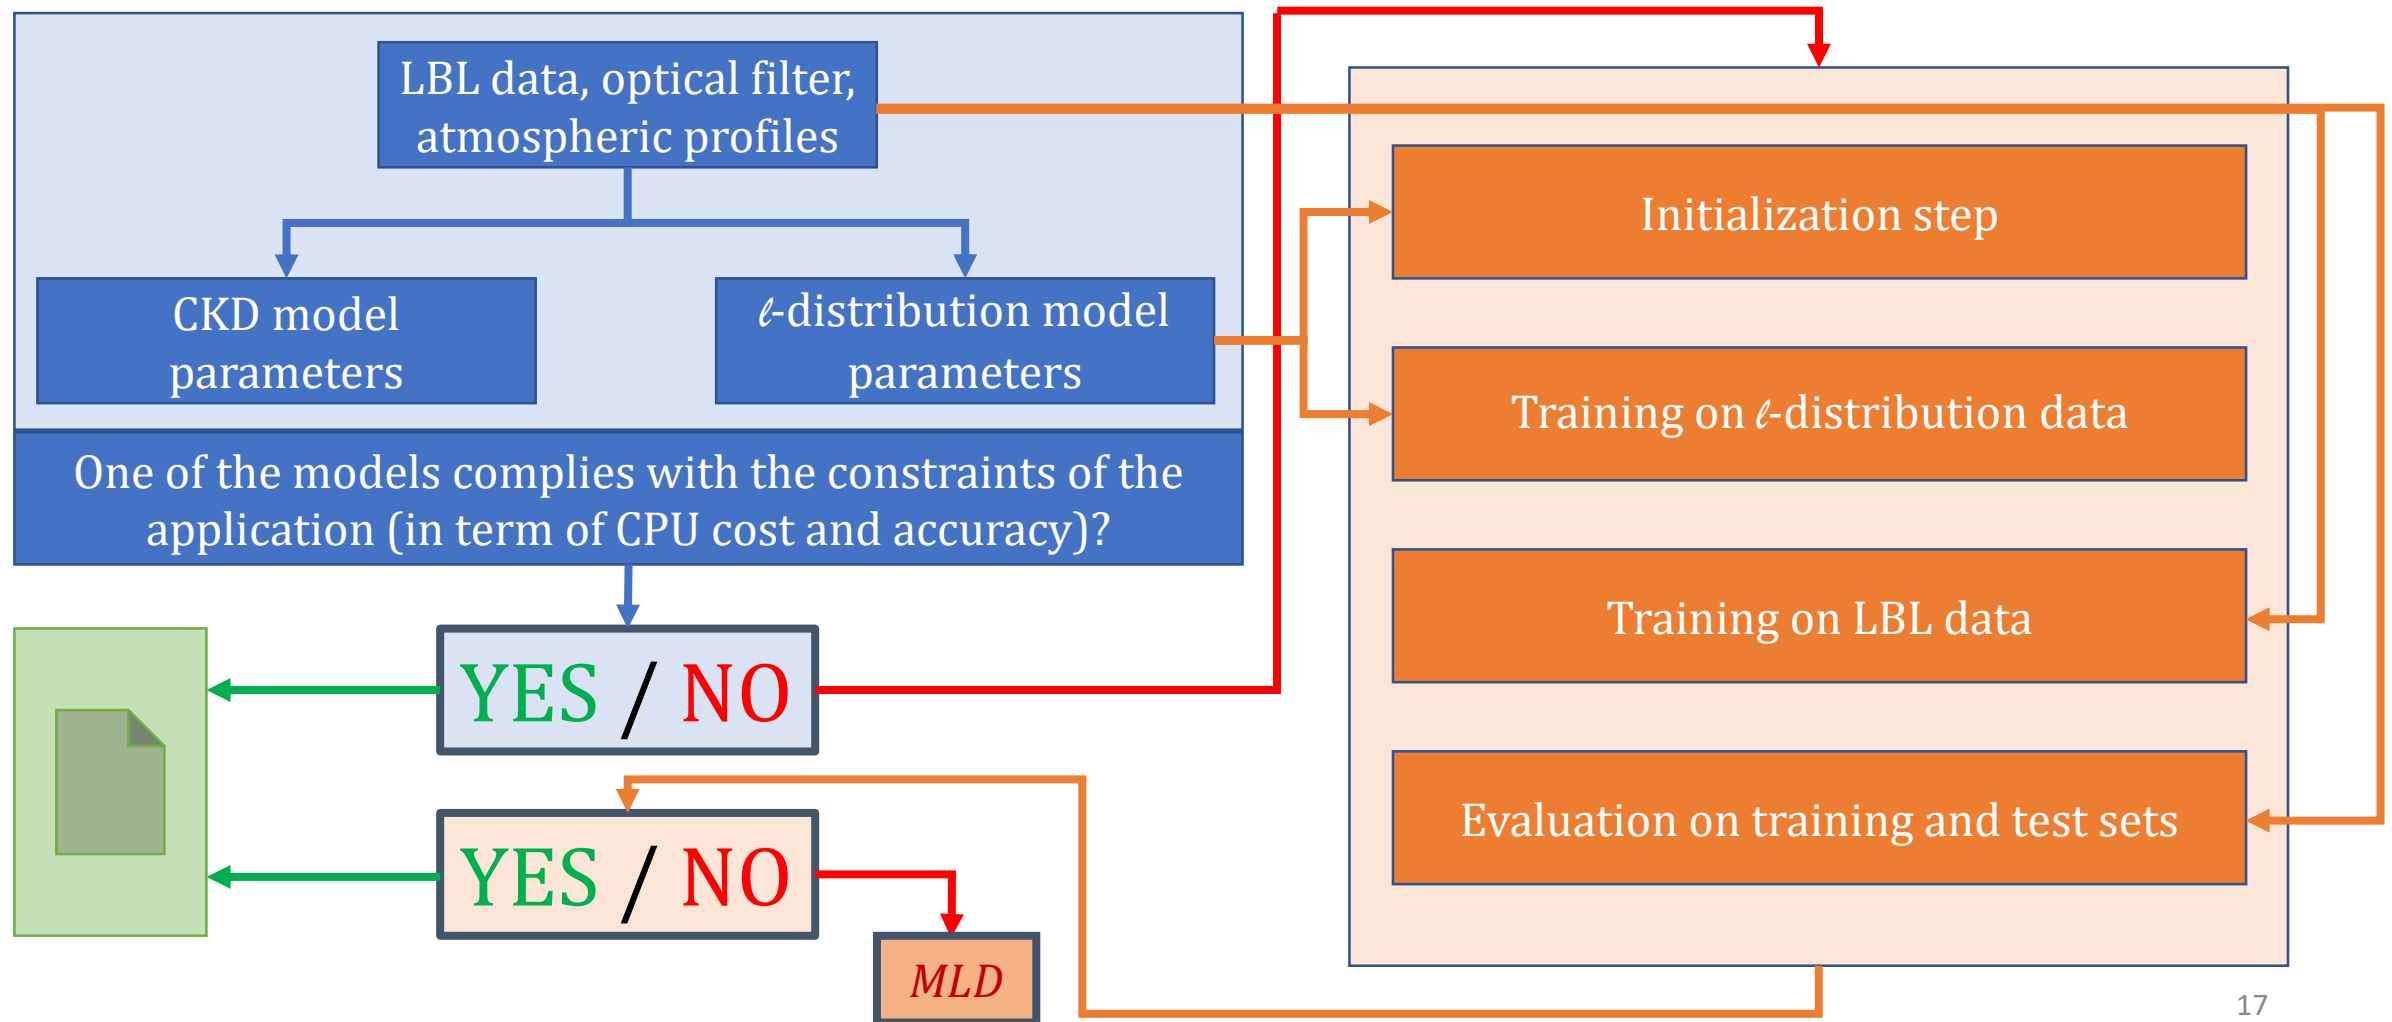
Jimmy Lei Ba\*  
University of Toronto  
jimmy@psi.utoronto.ca

#### ABSTRACT

We introduce *Adam*, an algorithm for first-order gradient-based optimization of stochastic objective functions, based on adaptive estimates of lower-order moments. The method is straightforward to implement, is computationally efficient, has little memory requirements, is invariant to diagonal rescaling of the gradients, and is well suited for problems that are large in terms of data and/or parameters. The method is also appropriate for non-stationary objectives and problems with very noisy and/or sparse gradients. The hyper-parameters have intuitive interpretations and typically require little tuning. Some connections to related algorithms, on which *Adam* was inspired, are discussed. We also analyze the theoretical convergence properties of the algorithm and provide a regret bound on the convergence rate that is comparable to the best known results under the online convex optimization framework. Empirical results demonstrate that *Adam* works well in practice and compares favorably to other stochastic optimization methods. Finally, we discuss *AdaMax*, a variant of *Adam* based on the infinity norm.



### III. Generalization ( $\ell$ -distribution and LBL training processes)



### III. Generalization ( $\ell$ -distribution and LBL training processes) (1/6)

---



The first step consists of an analysis of two-layers combinations, as discussed previously.

As already noticed, the use of results from (André et al, JQSRT, 2022) allows simplifying the initialization of the **regression process on two-layers systems.**

### III. Generalization ( $\ell$ -distribution and LBL training processes) (2/6)

---



The second step consists of an analysis of the non-uniform  $\ell$ -distribution solution.

In order to gain CPU time, the parameters for the two layer problems are not fully optimized (only improved compared to initialization).

This stage is used to correct partially this problem (**case dependent**). **The full atmosphere is considered for the training.**



### III. Generalization ( $\ell$ -distribution and LBL training processes) (3/6)

---



The third step consists of an analysis of non-uniform LBL solutions (**case dependent**).

This step is roughly the same as the previous one but consists of an improvement of the coefficients due to an **adjustment on LBL solutions**.

**The full atmosphere is considered for the training.**

### III. Generalization ( $\ell$ -distribution and LBL training processes) (4/6)

---




The fourth step consists of a **set of tests**.

It can be followed by an **update of the mapping functions** in the standard  $\ell$ -distribution formalism **to minimize the CPU cost of the method**.

New mapping functions are then constructed with the help of the optimized solutions obtained after LBL training.


The training set consists of full atmospheres for RAM = 1, 2, 4, 8, 19 and 24.  
The test set adds RAM = 3, 5, 6, 7, 10, 12, 14 and 20.

### III. Generalization ( $\ell$ -distribution and LBL training processes) (5/6)



This case corresponds to the one **treated in the RAD paper** (limited to the first two steps). Clearly, adding a LBL training stage (lowest plot) allows improving significantly the accuracy of the method (at fixed CPU cost – see “poster”).

### III. Generalization ( $\ell$ -distribution and LBL training processes) (6/6)




This case is treated in depth with additional technical details hereafter.

Clearly, adding a LBL training stage (lowest plot) allows improving significantly the accuracy of the method (at fixed CPU cost – see poster).

### III' Case of the 3MI 7 O<sub>2</sub> A-band (A/G)

Figure: O<sub>2</sub> Midlatitude summer (MLS) Profile




We focus here on one particular application test, widely used in cloudy atmospheres: the **O<sub>2</sub> A-band**. Channel 7 of the **3MI instrument** is treated. This channel is designed to study, among other, cloud top heights.

This case illustrates the **main steps** of the methodology.

### III' Case of the 3MI 7 O<sub>2</sub> A-band (B/G)

Figure: The Exponential Linear Unit (ELU)



The **ELU (Exponential Linear Unit)** is rather natural in our case since it appears in the Lévy-Kintchine formula.

$$\varphi_{\alpha}(x) = \begin{cases} x & \text{if } x > 0 \\ \alpha(\exp(x) - 1) & \text{if } x \leq 0 \end{cases}$$


A **recurrent network** is also natural considering the propagative scheme used in  $\ell$ -distribution model.

$$\begin{cases} L_{nn} = L_n \\ L_{i..n} = L_i + \ell_i \circ \tau_{i+1}^{\Delta V}(L_{i+1..n}) \end{cases}$$



### III' Case of the 3MI 7 O<sub>2</sub> A-band (C/G)

Figure: Training data for the O<sub>2</sub> A-band (MLS) Channel 7 3MI



The training process is made using  $\ell$ -distribution (2nd step) and LBL (3rd step) data.


**RAM 1, 2, 4, 8, 16, 24** are used as inputs for the training process.

For this purpose, transmissivities are plotted with respect to « Points », referring to data obtained through a combination of lengths and RAMs.

In order to reduce memory and computational costs, **one point every 500 meters** is used for the training process.

### III' Case of the 3MI 7 O<sub>2</sub> A-band (D/G)

Figure: O<sub>2</sub> A-Band, Augmented  $\ell$ -distribution




The main purpose of the Augmented  $\ell$ -distribution is to **reduce maximum relative errors of the  $\ell$ -distribution model, at fixed CPU cost.**

In the case of the O<sub>2</sub> A-Band, maximum relative errors for the standard  $\ell$ -distribution model is about 0.75%. With augmented model, this error can be **divided by at least two.**

### III' Case of the 3MI 7 O<sub>2</sub> A-band (E/G)

Figure: O<sub>2</sub> A-Band, Augmented  $\ell$ -distribution



Since the Augmented  $\ell$ -distribution are based on a minimisation of a loss function written in a summation or mean form, its main result is the **reduction of the mean relative error** of the model.

In the case of the O<sub>2</sub> A-Band, mean relative errors for the standard  $\ell$ -distribution model is between 0.1 and 0.2%. With augmented version, this error can be **divided by a factor from three up to ten**.

# III'. Case of the 3MI 7 O<sub>2</sub> A-band (F/G)




Figure : LBL training **without update** of mapping functions




Figure : LBL training **with update** of mapping functions

### *III'. Case of the 3MI 7 O<sub>2</sub> A-band (G/G)*

---

Once optimization is complete, the mapping functions are updated. This step ensures a **gain in terms of CPU cost** compared to the model trained on LBL data, **while preserving the accuracy** of the LK formulation.

Original  $\ell$ -distribution model **provides a result in 0,1 ms for a full atmosphere** calculation (1200 values of non-uniform path transmissivities).

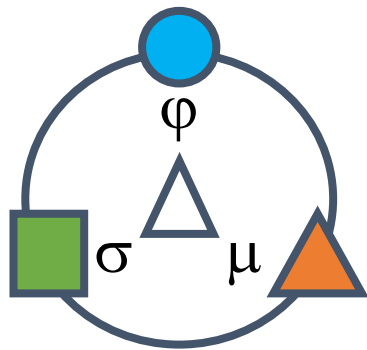
Augmented  $\ell$ -distribution leads to a **numerical gain of 1 % (not significant but the model remains highly competitive in terms of CPU cost)**.

# CONCLUSION (1/3)

---

The present work is dedicated to the description of a method that combines physics ( $\varphi$ ), statistics ( $\sigma$ ) and statistical learning ( $\mu$ ) to produce accurate transmissivities of non-uniform atmospheric paths.

Each component of the model is equally important to the whole methodology, but is used to treat a distinct part of the model.



Lévy - Khintchine representation of  $\ell_1 \circ \tau_2^{\Delta\nu}$

$$\ell_1 \circ \tau_2^{\Delta\nu} (L) \approx u_{\min} L + \int_0^1 \frac{1 - \exp[-s(0) \cdot v(\xi) L]}{s(0)} d\xi$$



# CONCLUSION (2/3)

---

More than the result itself (it obviously works otherwise I would not be here today...), an **interesting part of the work is its philosophy.**

Indeed, **coupling band model theory with statistical learning** has required:

- Identifying **what are the key component(s) in band model theory** required to obtain a solution / bridge.
- Identifying in **band model theory, why it fails** at some point.
- **Once the diagnostics is made, delete / add components to treat the sources of failure** (this requires ensuring that what you add complies with existing theory i.e. that your new components contain existing methods as particular cases – this part is the most time consuming).
- **Use SL to learn the components you have added from LBL data.**



# CONCLUSION (3/3)

---

But this is however not the only interest:

- **First general solution** of Godson / scaled- $k$  implicit equation (even if some restrictions due to quasi-scaling are added).
- **First formal proof** that Godson's method (1953) actually provides relevant approximations of non-uniform path transmissivities (up to know, only verifications).
- Indirectly, may modernize the (mostly dying) field of band model theory, by opening it to modern numerical methods.

# Thank you for your attention!



After update of the mapping functions, CPU cost is minimum (0.1 ms / atm) but accuracy is high!

# STATISTICAL INTERMEZZO (1/4)



From a set of models for the transmissivities and their inverses, various methods can be proposed based on:

$$\tau^{\Delta\nu} (L_1, \dots, L_n) = \frac{1}{\Delta\nu} \cdot \int_{\Delta\nu} \exp(-\kappa_\nu^1 L_1 - \dots - \kappa_\nu^n L_n) d\nu = C_{1..n} [\tau_1^{\Delta\nu} (L_1), \dots, \tau_n^{\Delta\nu} (L_n)]$$

where (notice that here we have an exact calculation):

$$C_{1..n} (X_1, \dots, X_n) = \frac{1}{\Delta\nu} \cdot \int_{\Delta\nu} \exp[-\kappa_\nu^1 \ell_1 (X_1) - \dots - \kappa_\nu^n \ell_n (X_n)] d\nu$$

**This function  $C_{1..n}$  has some interesting properties**

# STATISTICAL INTERMEZZO(2/4)



$$C_{1..n} (X_1, .., X_i = 0, .., X_n) = 0$$

This property ensures the proper model behavior at the « *optically thick limit* ».


$$C_{1..n} (1, 1, .., X_i, .., 1) = X_i$$

This property ensures the proper model behavior at the « *optically thin limit* ».

$$(-1)^n \frac{\partial^n C_{1..n} (X_1, .., X_i, .., X_n)}{\partial X_1 \dots \partial X_n} \geq 0$$

This property is closely related to the *sign of net exchanges* between distinct elements along a non-uniform path.

Function  $C_{1..n}$  is mathematically called a **copula**.



$C(X, Y)$

More details in:

F. André, C. Cornet, M. Galtier, Ph. Dubuisson, "Radiative transfer in the O<sub>2</sub> A-band – a fast and accurate forward model based on the  $\ell$ -distribution approach", *J. Quant. Spectrosc. Radiat. Transfer*, vol. 260, 107470, 2020.

# STATISTICAL INTERMEZZO (3/4)



In the  $\ell$ -distribution method (the same technique is used here), the true copula is approximated by a hierarchical structure (called Archimedean, HAC):

$$\tau^{\Delta v} (L_1, \dots, L_n) \approx C_{11} \left[ \tau_1^{\Delta v} (L_1), C_{22} \left( \tau_2^{\Delta v} (L_2), C_{33} \left( \tau_3^{\Delta v} (L_3), \dots \right) \right) \right]$$

where:

$$C_{ii} (X, Y) = \frac{1}{\Delta v} \cdot \int_{\Delta v} \exp \left[ -\kappa_v^i \ell_i (X) - \kappa_v^i \ell_i (Y) \right] dv = \tau_i^{\Delta v} \left[ \ell_i (X) + \ell_i (Y) \right]$$

It can be shown that the hierarchical structure is a copula (as the true one) if the generators of the HAC are compatible. This is the case if (sufficient nesting condition):

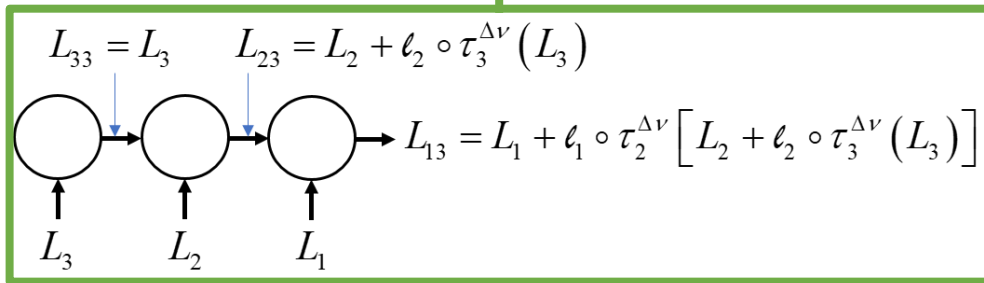
$$\ell_i \circ \tau_{i+1}^{\Delta v} (L) \approx u_{\min, i} L + \int_0^1 \frac{1 - \exp \left[ -s_{i+1} (0) \cdot v_{i, i+1} (\xi) L \right]}{s_{i+1} (0)} d\xi$$

The HAC is in this case called Lévy-subordinated (LS-HAC).

# STATISTICAL INTERMEZZO (4/4)





The hierarchical structure of the previous slide can be equivalently formulated as a recurrent structure (similar to a recurrent neural network with ELU activation functions) – See André et al, JQSRT, 2022 for more details:



$$L_3 = \ell_3 \circ C_{33} [0, \tau_3^{\Delta_V}(L_3)]$$

$$L_{23} = \ell_2 \circ C_{22} [\tau_2^{\Delta_V}(L_2), \tau_3^{\Delta_V}(L_3)] = L_2 + \ell_2 \circ \tau_3^{\Delta_V}(L_3)$$

$$L_{13} = \ell_1 \circ C_{11} [\tau_1^{\Delta_V}(L_1), \tau_2^{\Delta_V}(L_{23})] = L_1 + \ell_1 \circ \tau_2^{\Delta_V}(L_{23})$$



$$\ell_i \circ \tau_{i+1}^{\Delta_V}(L) \approx u_{\min,i} L + \int_0^1 \frac{1 - \exp[-s_{i+1}(0) \cdot v_{i,i+1}(\xi) L]}{s_{i+1}(0)} d\xi$$

$$= \varphi(u_{\min,i} L) - \frac{1}{s_{i+1}(0)} \cdot \int_0^1 \varphi[-s_{i+1}(0) \cdot v_{i,i+1}(\xi) L] d\xi$$






irfm



EUROfusion



# Réseaux neuronaux convolutifs pour la thermographie quantitative en environnement complexe




M-H. Aumeunier, A. Juven

[marie-helene.aumeunier@cea.fr](mailto:marie-helene.aumeunier@cea.fr)

**Journée thématique SFT**  
*Inversion de données faisant appel à un modèle en thermique, quels apports de l'intelligence artificielle ?*  
**8 Juin 2023**

# La mesure de température par imagerie infrarouge dans les machines de fusion nucléaire

- ❑ Un diagnostic clef pour la surveillance des composants face au plasma
- ❑ Un large réseau de camera déployé dans les tokamak
  - ✓ 12 caméras [3-5  $\mu\text{m}$ ] installées dans WEST, 50% du mur couvert,  $T=[100-2000^\circ\text{C}]$
  - ✓ 21 caméras [3-5  $\mu\text{m}$ ] installées dans ITER,  $>70\%$  du mur couvert,  $T=[200-3600^\circ\text{C}]$
- ❑ 2 principales fonctions
  - ✓ Opérationnelle: assurer la protection de la machine
  - ✓ Physique: étude des interactions plasma-paroi



# Le problème de la mesure infrarouge dans les tokamaks


A fully metallic environment

- ❑ Low and changing radiative properties of materials  $\epsilon(\lambda, T_{\text{surf}}, \text{surface properties})$  ( $\epsilon \sim 0.1 - 0.3$ )
- ❑ Multiple reflections adding parasitic signals
- ❑ Variable and heterogeneous radiative surrounding  $T_i(x,y,z,t)$
- ❑ Co-deposited layers

→ multi-parametric problem

This will have consequences both:


- ✓ **Qualitative analysis:** presence of false hot spot in the image
- ✓ **Quantitative analysis:** high surface temperature error



# Une approche numérique pour résoudre le problème de mesure IR ?

Basée sur


- Une **modélisation directe**: de l'observable à la mesure IR
- Un **traitement inverse**: de l'image IR à la température






# Le modèle direct

## 1 3D THERMAL SCENE





## 2 MATERIALS OPTICAL PROPERTIES

EMISSION, REFLECTIVITY




## 3 CAMERA MODEL




Un jumeau numérique capable de reproduire très fidèlement l'image IR d'un tokamak en opération, en intégrant l'ensemble des phénomènes physiques intervenant dans la chaîne de mesure: de la scène observée à la caméra

## 4 PHOTON TRANSPORT MODEL



## INFRARED SYNTHETIC IMAGE



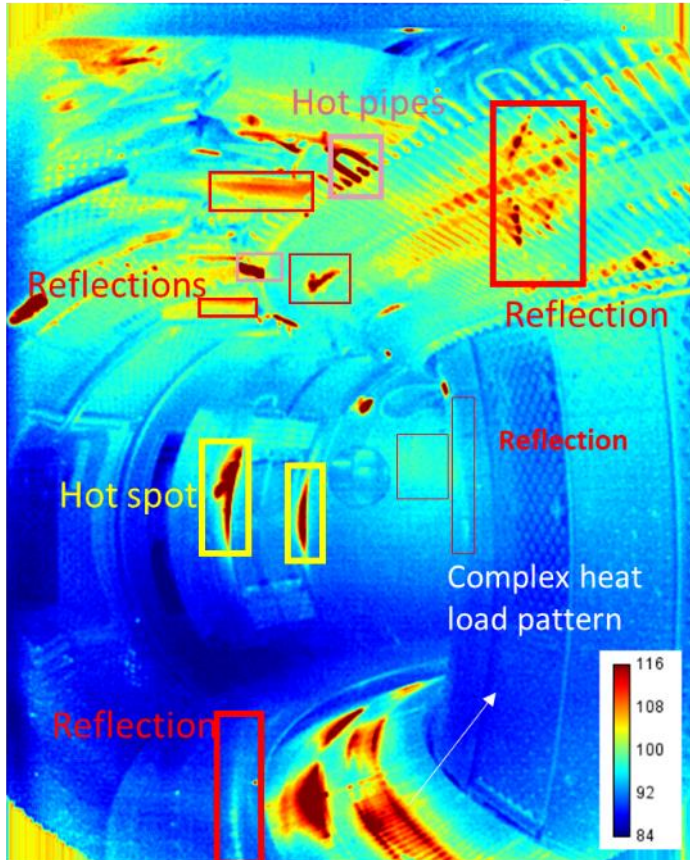
...es faisant appel à un modèle en thermique,  
quels apports de l'intelligence artificielle ?”

# Resultat du modèle direct sur camera grand angle de WEST

WEST wide angle TG view



Experimental IR Image

#Pulse 55210 @ 7s(Ip=500 kA, 4.4MW LH + 0.7MW FCI)  
Brightness T° Map



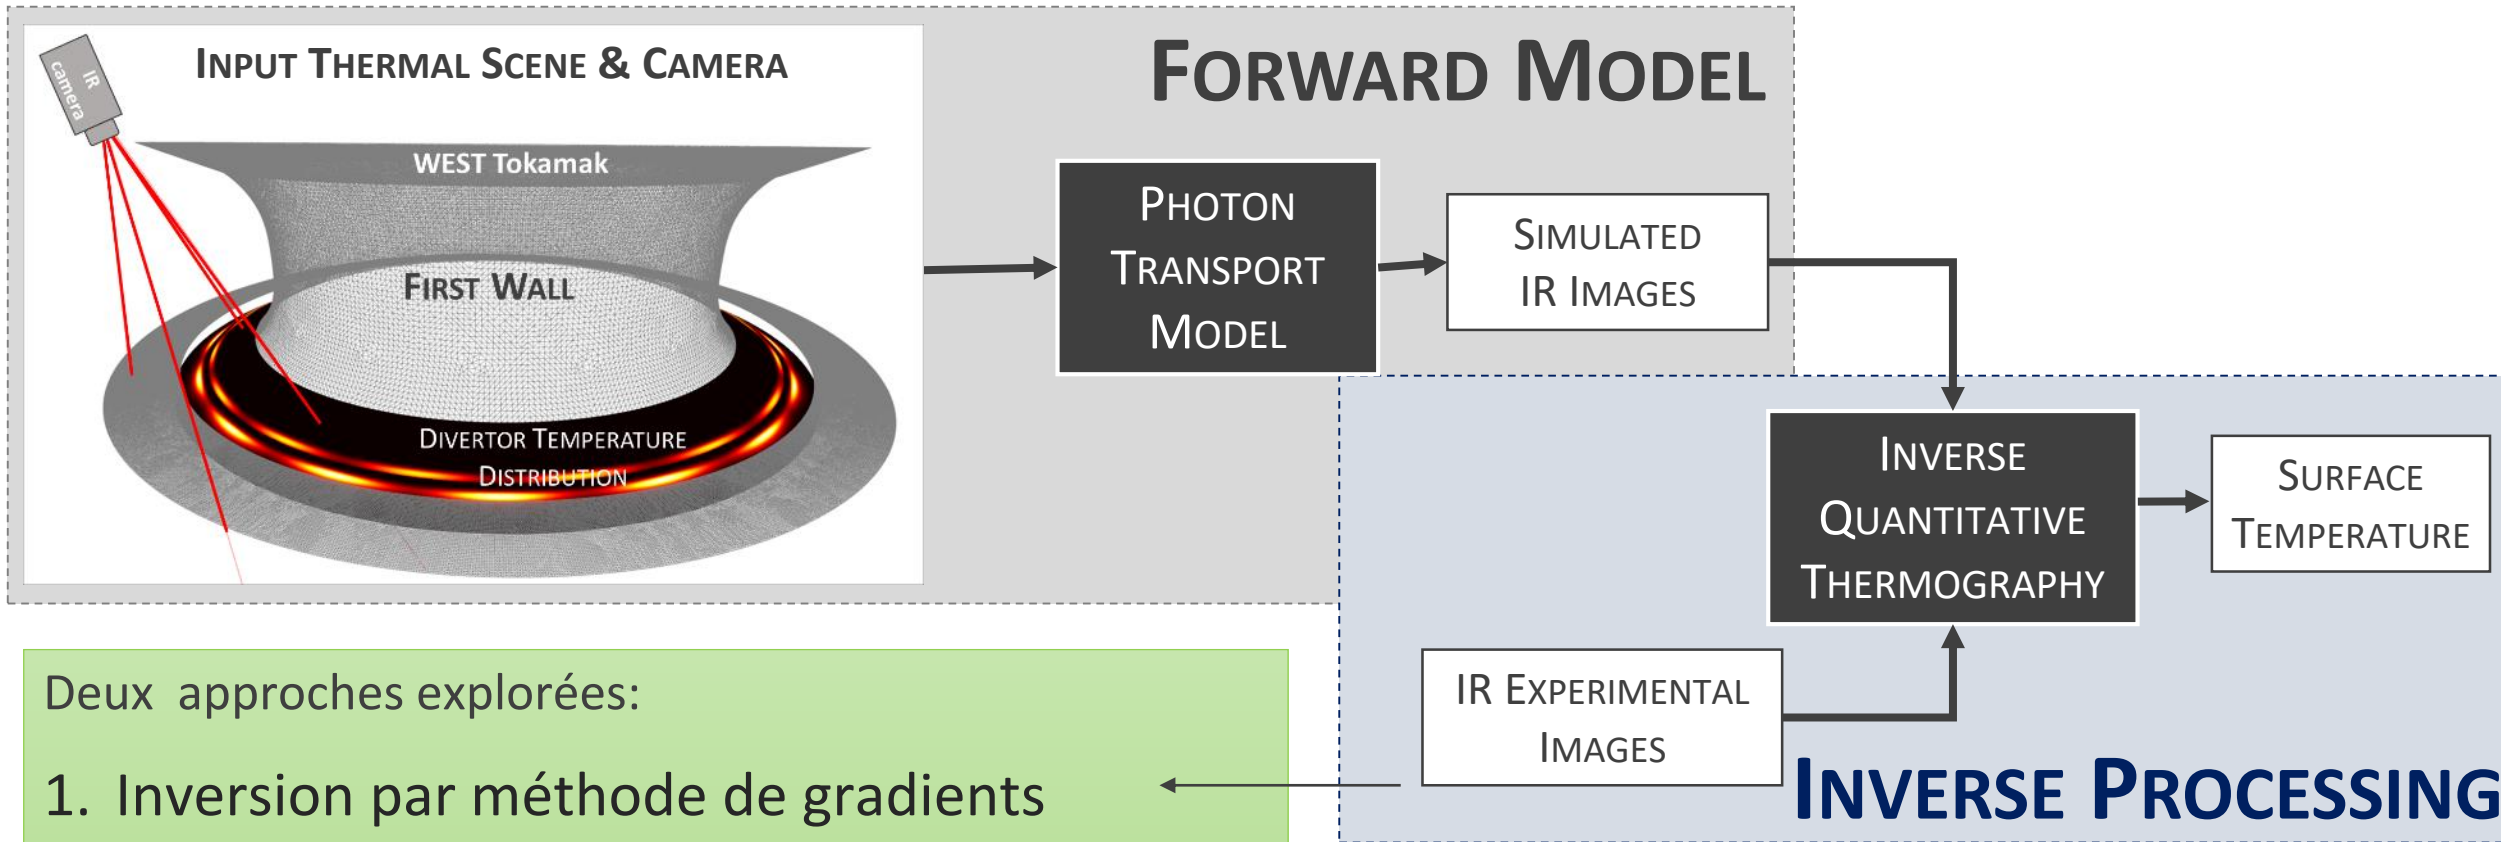
Simulated IR Image

Brightness T° Map





# Le traitement inverse: 2 approches étudiées



Deux approches explorées:

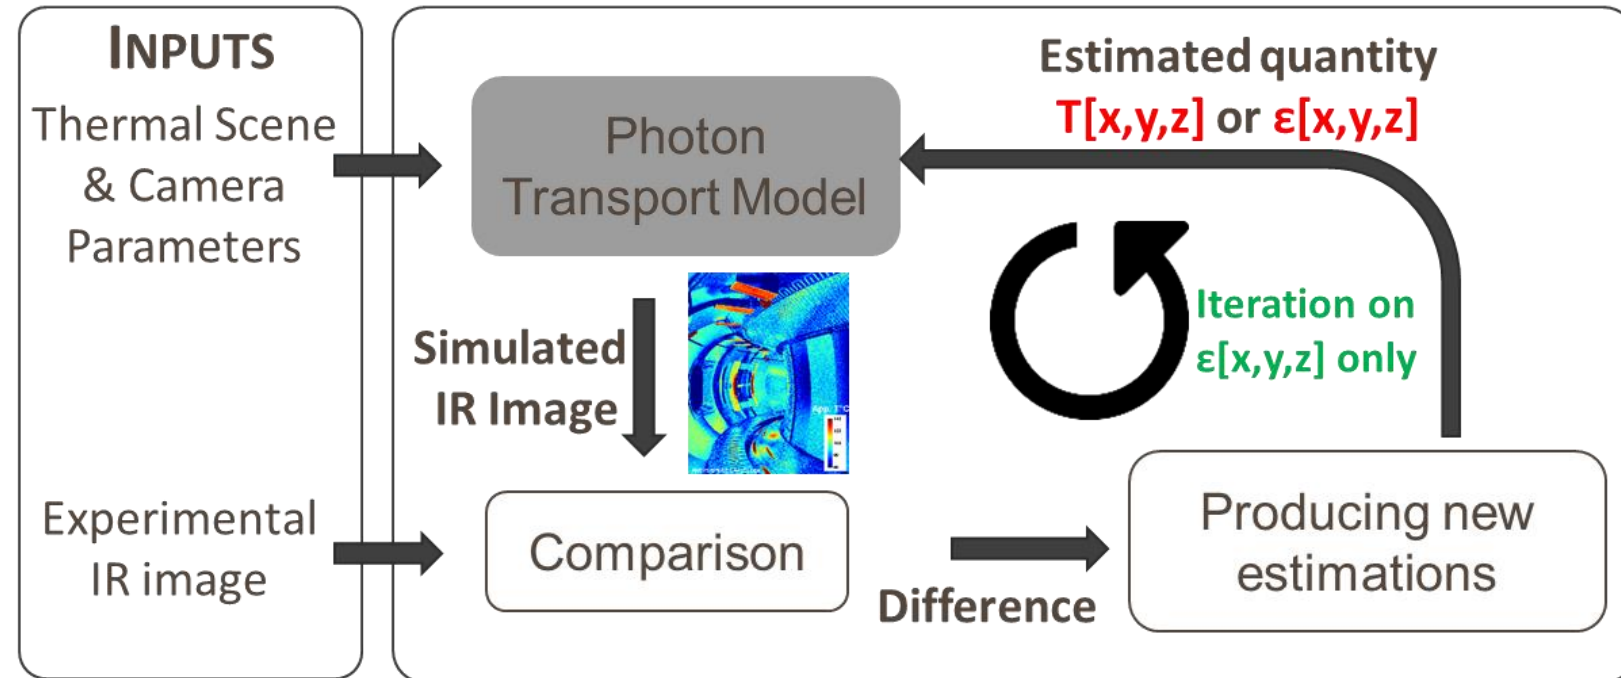
1. Inversion par méthode de gradients
2. Inversion par réseau de neurones (Apprentissage Automatique)



# Première approche: Inversion paramétrique par méthode des gradients

## Principe

- Trouver les paramètres du modèle afin de faire correspondre la sortie du modèle aux observations (image IR expérimentale)



## Points clef d'étude:

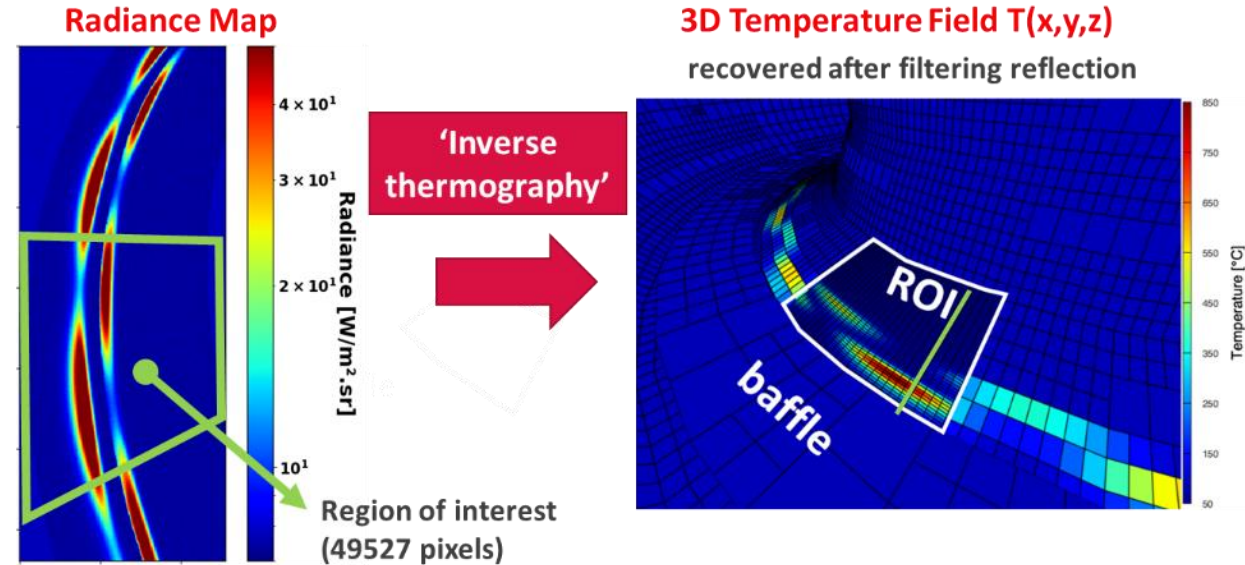
1. Le choix du modèle de transport de photons appelé dans la boucle itérative
2. Algorithme d'optimisation pour converger vers une solution unique

# Première approche: Inversion paramétrique par méthode des gradients

- De bons résultats obtenus sur géométrie simplifiée du tokamak avec l'hypothèse de surface diffuse
- Estimation des températures et des émissivités séparément
  - ✓ Emissivités estimées, en amont des opérations, sur des scènes de  $T^\circ$  uniformes et connues (entre pulses, phase de conditionnement)
- Estimation des températures ramenée à un problème inverse linéaire (sans itération)
- Estimation des paramètres sur les éléments 3D (et non sur les pixels)
- Pas d'a priori sur la distribution des températures

## Limites

- Hypothèses de surface diffuse
- Inversion matricielle de l'opérateur de transport de dimension  $m \times p$  avec  $m$  nombre de mesures (pixels) et  $p$  nombre de paramètres à estimer



$$L^o(T^\circ C) = (S^T S)^{-1} S^T Y$$

Opérateur de transport

Luminance de l'objet liée à la  $T^\circ$  cherchée en  $(x,y,z)$

Mesures (luminance/pixel)

Thèse C.Talatizi (2017-2021) co encadré avec IUSTI (F. Rigollet) + M. Le Bohec post doc


# Deuxième approche: Inversion par réseau de neurones

## Principe:

- Apprentissage automatique d'un système à partir de données (sans programmation explicite)
- Architecture de réseau neuronal

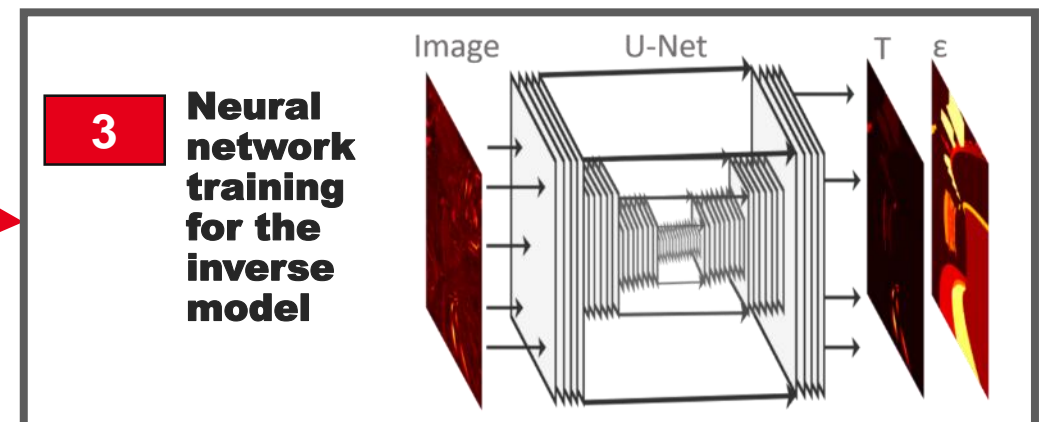

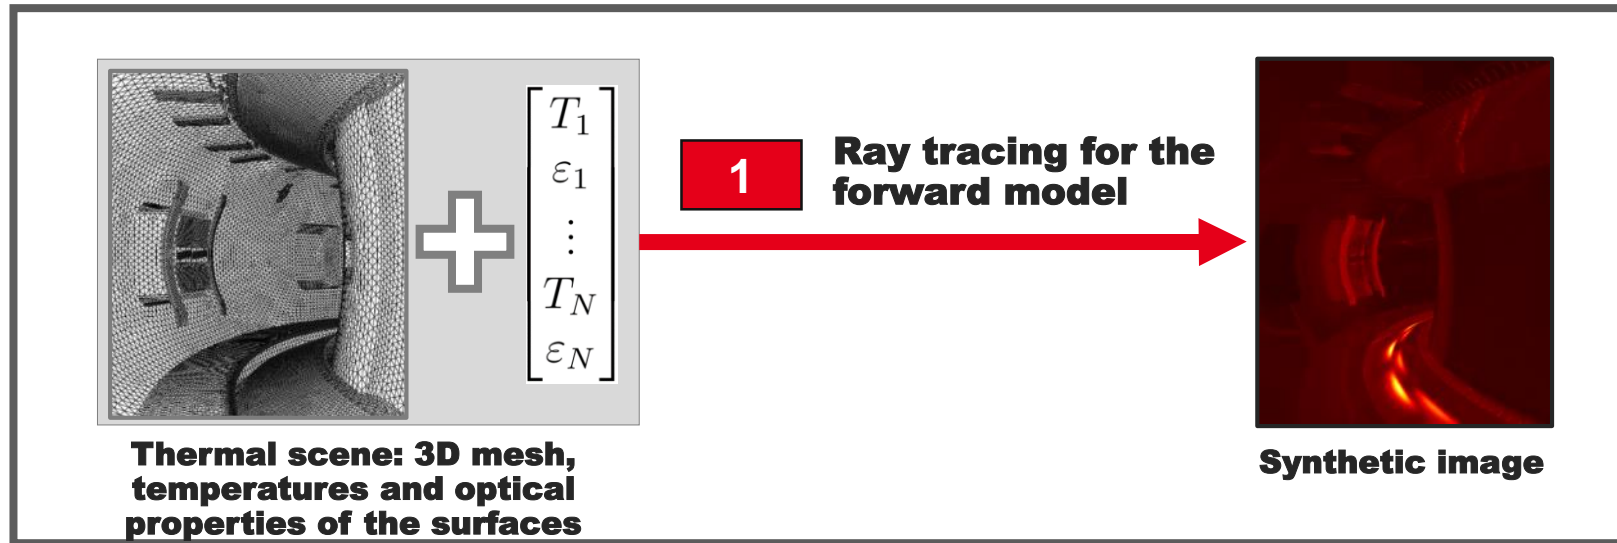
## Points clefs d'étude:

1. La construction d'une base de données simulées d'entraînement optimal → **à priori sur la scène thermique**
2. Le modèle d'apprentissage profond (architecture du réseau de neurones)



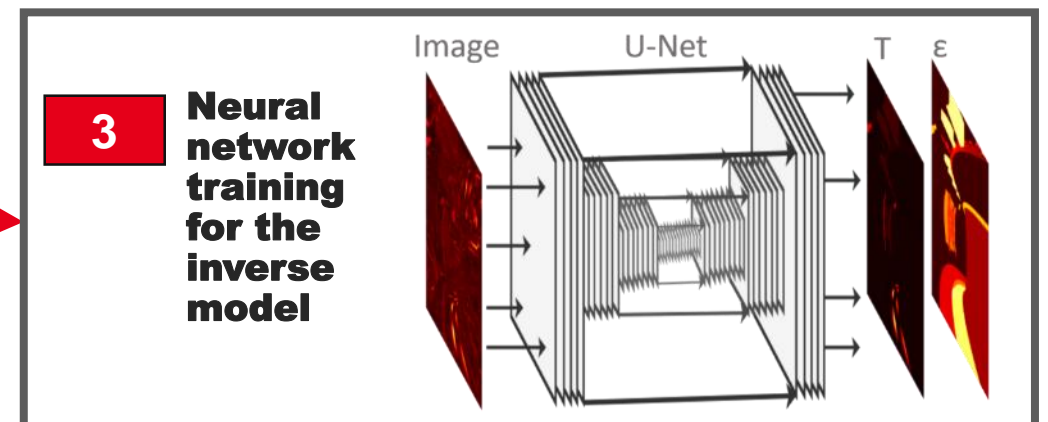
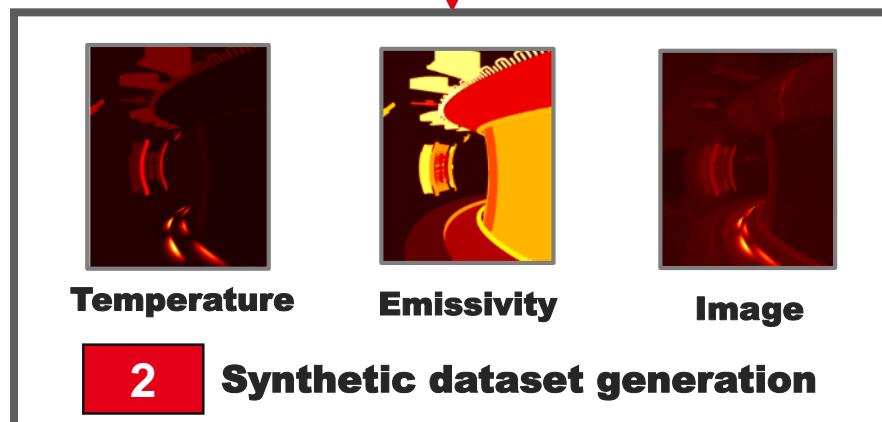

Thèse A. Juven (2021-2024) +  
R. Brunet post-doc

# Model inversion from simulation-assisted machine learning






# Model inversion from simulation-assisted machine learning



# Gratiis: a fast GPU ray tracer

Able to simulate infrared images taking into account complex surface properties (emissivity and reflectivity models – through BRDF\*).



Based on Monte Carlo ray-tracing solving the rendering equation, requiring high number of iterations to converge towards realistic synthetic image

Fast implementation enabling large datasets suitable for machine learning.


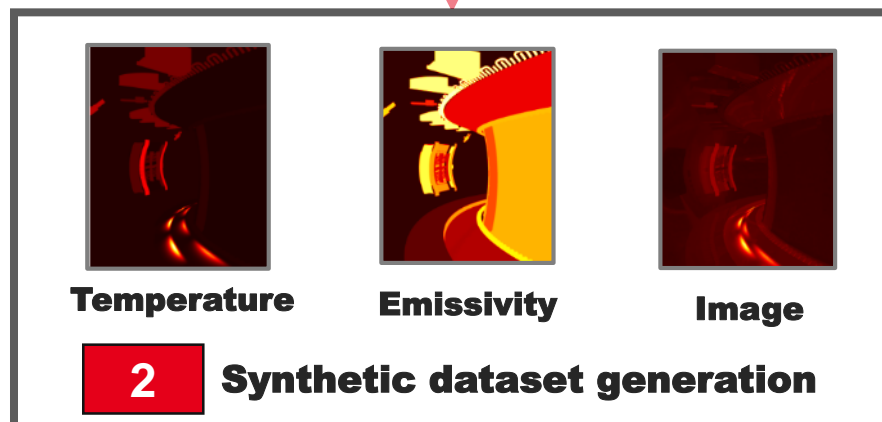
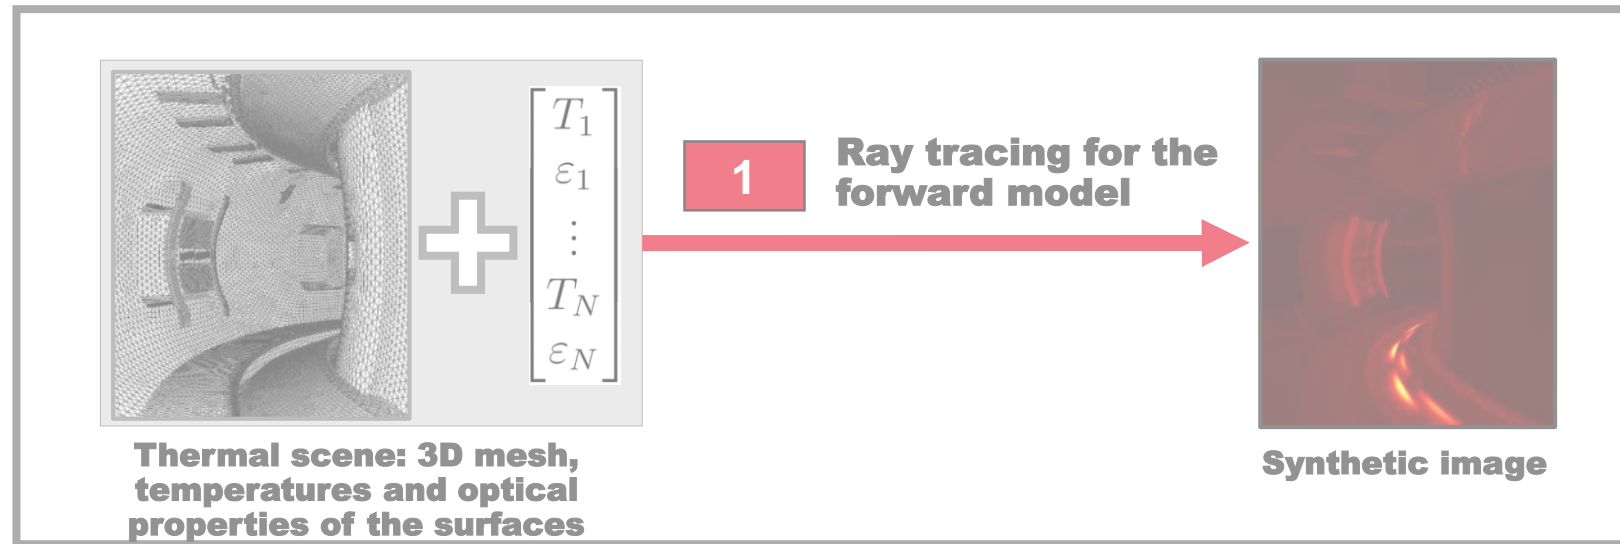
- One to ten minutes per image.
- Implementation on the GPU (x40 speedup compared to CPU).

\* *BRDF Bidirectional Reflectivity Distribution Function*



**Simulation of a simple scene: the Cornell Box**

# Model inversion from simulation-assisted machine learning





# Generation of the synthetic dataset


Generation of large dataset ( ~ 50 000 images) by changing thermal and optical scenarios.

A detailed 3D mesh of the tokamak was created (36 different components, ~2M triangles of ~2cm width).


Hypothesis for the surface properties:

- **Phong reflection** : 4 parameters (diffuse part, specular part, mirror part, specular Gaussian width).
- Uniform temperature and reflection property (BRDF) for each main in-vessel component, **with texture noise applied** and **random Gaussian heat points**.
- Non-uniform temperature on the lower divertor (parameterized function).
- Real **experimental heat patterns** used for heating antennas.

Small camera parameter variations between each image.

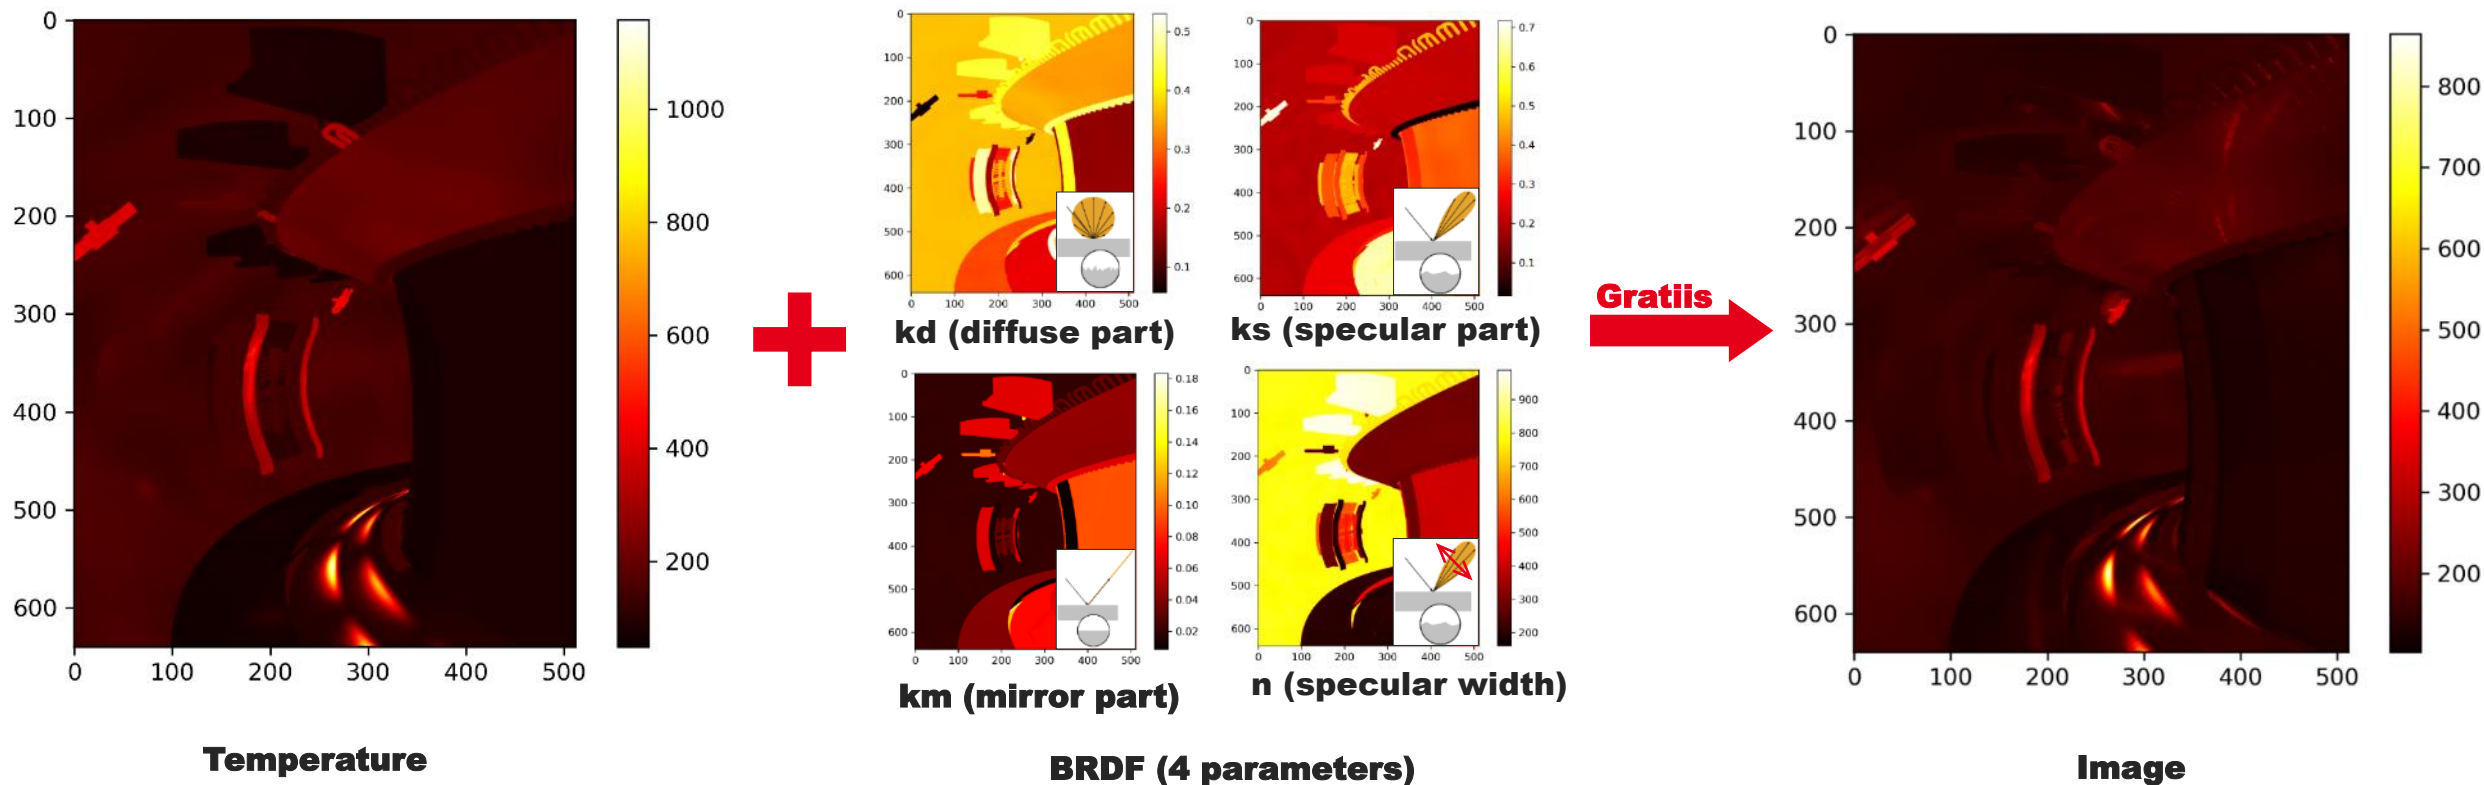


3D model

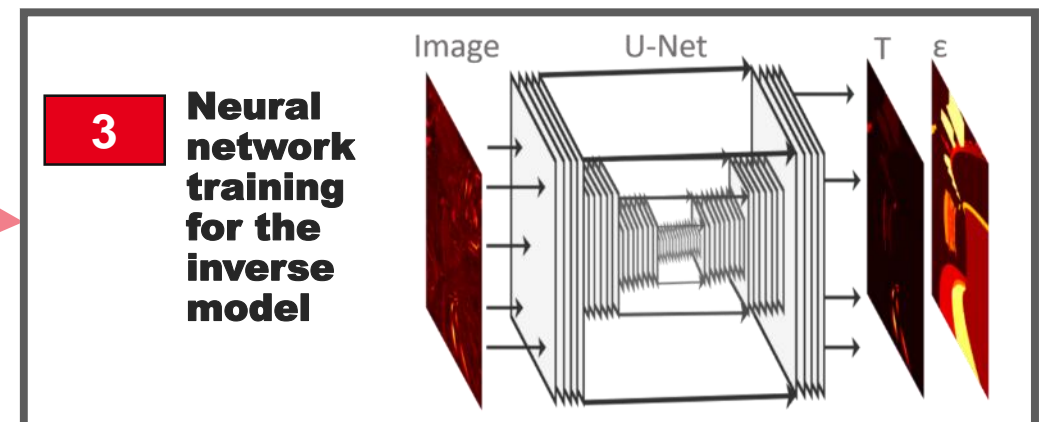
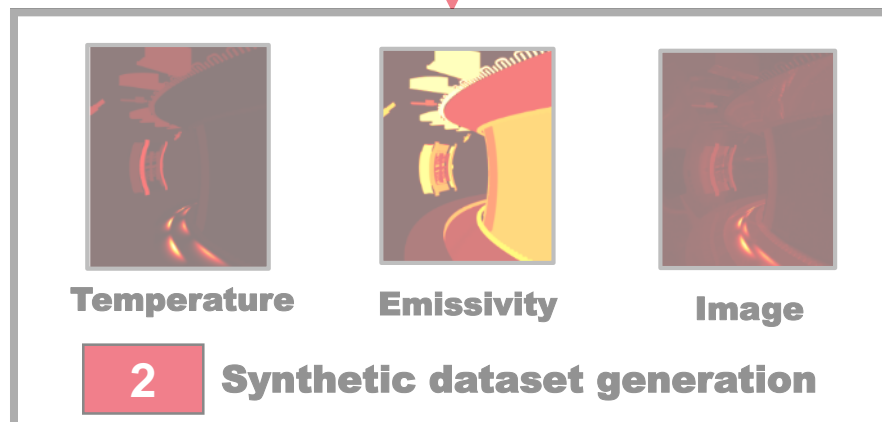
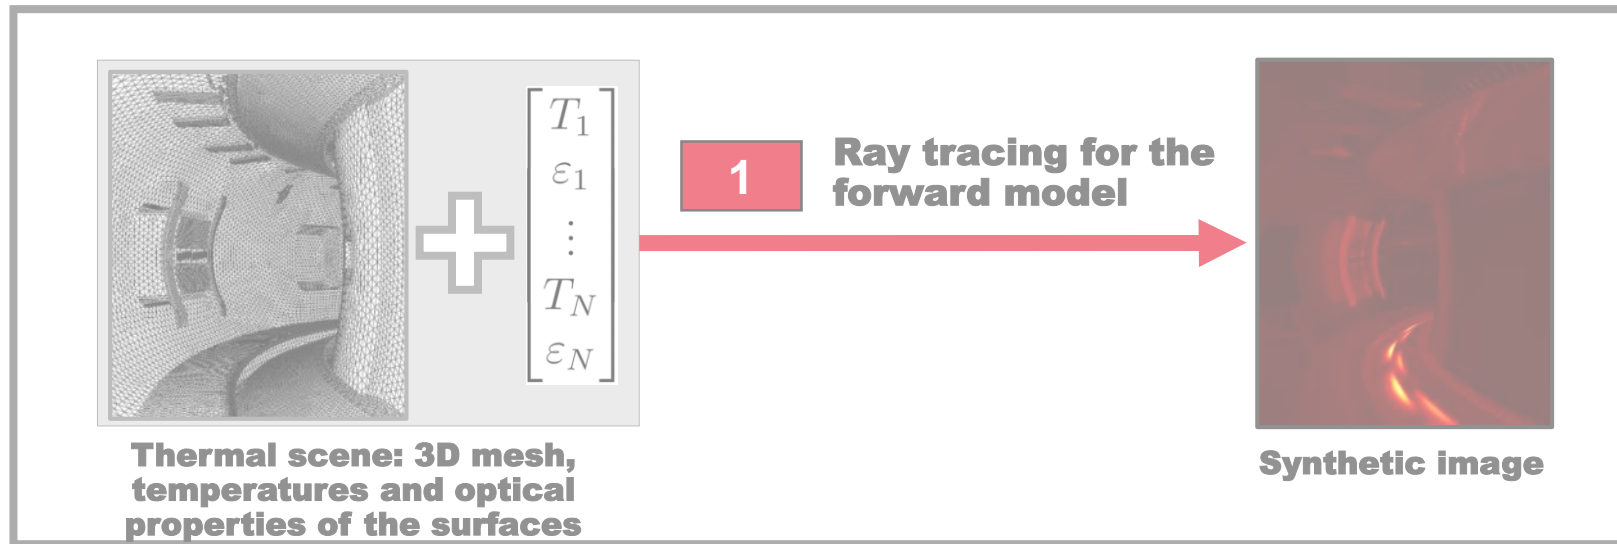


Random noise field

# Example of generated sample in the dataset



# Model inversion from simulation-assisted machine learning





# Learning phase of inverse neural network



Implementation of a U-Net,  
« image to image »  
convolutional neural network

The network takes the IR  
image as input and returns  
the temperature map

The learning is performed on  
10000 examples from the  
synthetic dataset



# Error on the testing set



**Mean ( $\pm\sigma$ ) temperature prediction error in function of the real temperature**

# Conclusion

Encouraging results to improve surface  $T^\circ$  measurement in reflective environment with ML

- ✓ Proven on tokamak digital twin (WEST-like) on wide angle TG view
- ✓ Able to solve entire image (512x640 pixels)
- ✓ Surface temperature estimated with an accuracy  $<5\%$  **without knowing emissivity/brdf values (but with a-priori on spatial distribution)**
- ➔ **Requires to get a “good idea” of thermal scene model (temperature, emissivity distribution)**

Under investigation:

- ✓ **how much we are dependent to a-priori distribution**
- ✓ **Illness problem: how to discriminate hot spot ( $T^\circ$  increase) from surface change (emissivity increase)**



# METAMODEL BASED ON EVOLUTIONARY NEURAL NETWORKS FOR THE SOLUTION OF INVERSE PROBLEMS WITHIN THE BAYESIAN FRAMEWORK OF STATISTICS

Raphael C. Carvalho<sup>1</sup>, Iasmin Louzada<sup>1</sup>, Helcio R. B. Orlande<sup>1</sup>,  
Marcelo J. Colaço<sup>1</sup>, Italo M. Madeira<sup>2</sup>, Nirupam Chakraborti<sup>3</sup>

<sup>1</sup>Department of Mechanical Engineering, Politécnica/COPPE  
Federal University of Rio de Janeiro, UFRJ, 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.

Corresponding author : [helcio@mecanica.coppe.ufrj.br](mailto:helcio@mecanica.coppe.ufrj.br)





# 1. Introduction and Motivation

- In nowadays complex hydraulic systems, transients in pumps and valves may induce significant variations in pressures and flow rates.
- For example, if the liquid velocity is suddenly reduced by the closure of a valve, pressure waves with large magnitudes and large velocities propagate through the pipelines.
- Such a phenomenon is known as **water hammer** and can seriously affect the pipeline integrity.
- **This work deals with the estimation of parameters of a water hammer model.**



Source: Lüdecke, H. J., Kothe, B., KSB  
Know-how: Water Hammer Volume 1, KSB,  
2006.



Source: Chaudhry, M.H., 2014, Applied  
Hydraulic Transients, New York, USA,  
Springer.

## 2. Mathematical Formulation

- $\mathbf{U}$  = vector of state variables
- $\mathbf{F}$  = flux
- $\mathbf{B}$  = source term
- $p$  = pressure
- $q$  = mass flow rate
- $u$  = velocity
- $\rho$  = density
- $A$  = cross-section area of the pipe
- $D$  = pipe diameter
- $f$  = friction coefficient (Darcy-Weisbach)
- $f_u$  = transient friction coefficient
- $a$  = sound velocity (celerity)

$$\frac{\partial \mathbf{U}}{\partial t} + \frac{\partial \mathbf{F}(\mathbf{U})}{\partial x} = \mathbf{B}(\mathbf{U})$$

$$\mathbf{U} = \begin{pmatrix} p \\ q \end{pmatrix}$$

$$\mathbf{F}(\mathbf{U}) = \begin{pmatrix} \frac{qa^2}{A} \\ Ap + \frac{q^2}{\rho A} \end{pmatrix}$$

$$\mathbf{B}(\mathbf{U}) = \begin{pmatrix} \frac{q}{\rho A} \frac{\partial}{\partial x} (\rho a^2) \\ \frac{-f|q|q}{2\rho AD} - \rho A g \sin \theta + P \frac{\partial A}{\partial x} - f_u \left( \frac{\partial q}{\partial t} - a \frac{\partial q}{\partial x} \right) + \sum_{b=1}^B \Delta P_b \delta(x - x_B) \end{pmatrix}$$

## 2. Mathematical Formulation

Sound velocity (celerity):

$$a = \sqrt{\frac{K}{\rho \left( 1 + \left( \frac{K}{E} \right) \psi \right)}}$$

where  $E$  is the Young's modulus of the pipe and  $K$  is the elastic modulus of the fluid.

➤  $\psi$  is a nondimensional parameter that depends on the elastic properties of the pipe including its supports:

• Rigid pipe:  $\psi = 0$

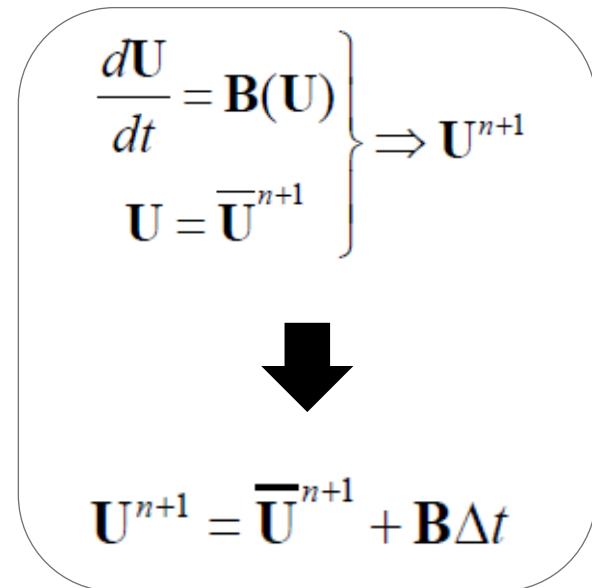

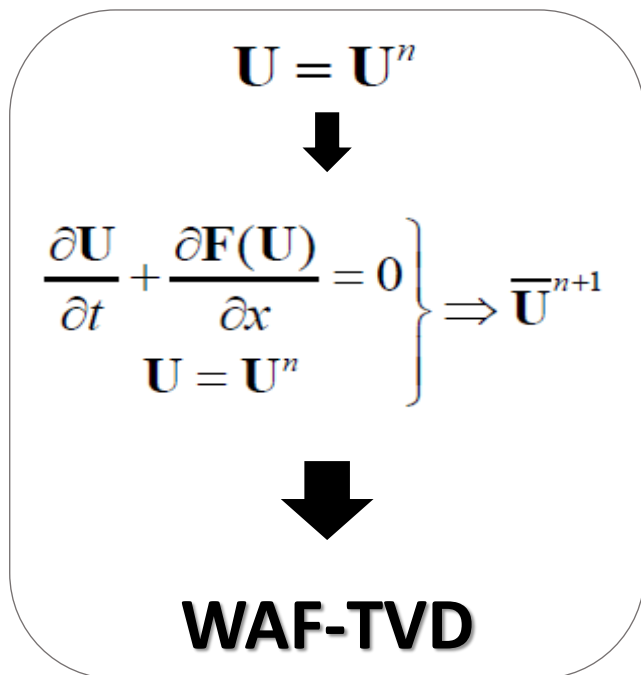
• Thick-wall elastic pipe with frequent expansion joints:  $\psi = 2 \left( \frac{R_o^2 + R_i^2}{R_o^2 - R_i^2} + \nu \right)$

• Thin-wall elastic pipe with frequent expansion joints:  $\psi = \frac{D}{e}$

### 3. Solution of Direct Problem

The system of equations is split at each time step  $\Delta t$  with the initial condition given by the solution at the previous time instant.

$$\frac{\partial \mathbf{U}}{\partial t} + \frac{\partial \mathbf{F}(\mathbf{U})}{\partial x} = \mathbf{B}(\mathbf{U})$$



# 4. Solution of the Inverse Problem

## BAYES' THEOREM

$$\pi_{posterior}(\mathbf{P}) = \pi(\mathbf{P}|\mathbf{Y}) = \frac{\pi_{prior}(\mathbf{P})\pi(\mathbf{Y}|\mathbf{P})}{\pi(\mathbf{Y})}$$

$\pi_{posterior}(\mathbf{P})$  = posterior probability density (conditional probability of the parameters  $\mathbf{P}$  given the measurements  $\mathbf{Y}$ )

$\pi_{prior}(\mathbf{P})$  = prior density (information about the parameters prior to the measurements)

$\pi(\mathbf{Y}|\mathbf{P})$  = likelihood function (expresses the likelihood of different measurement outcomes  $\mathbf{Y}$  with  $\mathbf{P}$  given)

$\pi(\mathbf{Y})$  = probability density of the measurements, evidence (normalizing constant)

*posterior  $\propto$  prior  $\times$  likelihood*

# 4. Solution of the Inverse Problem

## Markov Chain Monte Carlo (MCMC) methods

### Metropolis-Hastings Algorithm

1. Sample a *Candidate Point*  $\mathbf{P}^*$  from a proposal distribution  $q(\mathbf{P}^* | \mathbf{P}^{(t-1)})$ .
2. Calculate the acceptance factor:

$$\alpha = \min \left[ 1, \frac{\pi(\mathbf{P}^* | \mathbf{Y}) q(\mathbf{P}^{(t-1)} | \mathbf{P}^*)}{\pi(\mathbf{P}^{(t-1)} | \mathbf{Y}) q(\mathbf{P}^* | \mathbf{P}^{(t-1)})} \right]$$

3. Generate a random value  $U$  that is uniformly distributed on  $(0,1)$ .
4. If  $U < \alpha$ , set  $\mathbf{P}^{(t)} = \mathbf{P}^*$ . Otherwise, set  $\mathbf{P}^{(t)} = \mathbf{P}^{(t-1)}$ .
5. Return to step 1.

## 4. Solution of the Inverse Problem

- Vector of model parameters:  $\mathbf{P}^T = [f_u, \psi, D, e, E, K, \rho_0]$
- The parameters  $[D, e, E, K, \rho_0]$  are fairly known with small uncertainties from other experiments or even tabulated data. Hence, they were modeled with truncated Gaussian priors.
- $[f_u, \psi]$  depend on the construction characteristics of the pipeline, as well as on the fluid and flow conditions. These parameters were modeled with uniform priors, with bounds provided by positivity constraints and expressions available in the literature for their calculations.
- Measurement errors were additive, Gaussian, with zero mean, uncorrelated and with known variances.



# 4. Solution of the Inverse Problem

## Parallel version of the Metropolis-Hastings algorithm

Cui, T., Fox, C., Nicholls, G. K., O'Sullivan, M. J., 2019, Using Parallel Markov Chain Monte Carlo to Quantify Uncertainties in Geothermal Reservoir Calibration, International Journal for Uncertainty Quantifications, vol. 9, pp 295-310

- **This algorithm parallelizes the Markov chain, taking advantage from the fact that rejection of candidates generated with the Metropolis-Hastings algorithm is much more often than their acceptance as samples of the posterior distribution.**
- Theoretical results available in the literature revealed that the optimal acceptance rate with Gaussian random-walk proposals is 23.4% for a large number of parameters.
- Although the statistical efficiency of the algorithm is considered high with acceptance rates between 10% and 60%, numerical experiments are commonly used to obtain acceptance rates around 30%.

# 4. Solution of the Inverse Problem

## Metamodel

- **Evolutionary Neural Network Algorithm (EvoNN)** applies a multi-objective evolutionary algorithm on a population of Neural Networks of flexible topology and architecture. One hidden layer is used.
- **The multi-objective evolutionary algorithm attempts to simultaneously optimize the accuracy and complexity of the neural net population, which ultimately leads to a Pareto frontier containing a set of optimum models showing the best possible tradeoffs between these conflicting objectives.**
- The complexity of the EvoNN is measured with the **Modified Akaike's Information Criterion (AICc)** based on the total number of connections (C) between neurons in the network:

$$AIC_C = 2C + N_{tr} \ln \left( \frac{S_{LS}}{N_{tr}} \right) + \frac{2C(C + 1)}{N_{tr} - C - 1}.$$

$$S_{LS} = \sum_{i=1}^{N_{tr}} (y_i - y_{tr,i})^2$$

- Helle M, Petterson F, Chakraborti N, Saxen H (2006) Modelling noisy blast furnace data using genetic algorithms and neural networks. Steel Res Int 77(2):75–81.
- PyRVEA (2019) Research Group in Industrial Optimization. <https://github.com/industrial-optimization-group/pyRVEA/tree/master/pyrvea>.

# 4. Solution of the Inverse Problem

## APPROXIMATION ERROR MODEL

- **Kaipio, J. and Somersalo, E.,** *Statistical and Computational Inverse Problems*, Applied Mathematical Sciences 160, Springer-Verlag, 2004
- **Kaipio, J., and Somersalo, E.,** *Statistical Inverse Problems: Discretization, Model Reduction and Inverse Crimes*, *Journal of Computational and Applied Mathematics*, vol. 198, pp. 493–504, 2007.

In the approximation error model (AEM) approach, the statistical model of the approximation error is constructed and then represented as additional noise in the measurement model [1,19-23]. With the hypotheses that the measurement errors are additive and independent of the parameters  $\mathbf{P}$ , one can write

$$\mathbf{Y} = \mathbf{T}_c(\mathbf{P}) + \mathbf{e} \quad (16)$$

where  $\mathbf{T}_c(\mathbf{P})$  is the sufficiently accurate solution of the complete model given by equations (1.a-h). The vector of measurement errors,  $\mathbf{e}$  are assumed here to be Gaussian, with zero mean and known covariance matrix  $\mathbf{W}$ .

# 4. Solution of the Inverse Problem

## APPROXIMATION ERROR MODEL

$$\mathbf{Y} = \mathbf{T}(\mathbf{P}) + [\mathbf{T}_c(\mathbf{P}) - \mathbf{T}(\mathbf{P})] + \mathbf{e}$$

By defining the error between the complete and the surrogate model solutions as

$$\boldsymbol{\varepsilon} = [\mathbf{T}_c(\mathbf{P}) - \mathbf{T}(\mathbf{P})]$$

equation (17) can be written as

$$\mathbf{Y} = \mathbf{T}(\mathbf{P}) + \boldsymbol{\eta}$$

where

$$\boldsymbol{\eta} = \boldsymbol{\varepsilon} + \mathbf{e}$$

# 4. Solution of the Inverse Problem

## APPROXIMATION ERROR MODEL

$\eta$  is modeled as a Gaussian variable


Enhanced error model: 
$$\left\{ \begin{array}{l} \bar{\eta} \approx \bar{\varepsilon} \\ \tilde{W} \approx W_{\varepsilon} + W \end{array} \right.$$

## Modified Likelihood

$$\tilde{\pi}(\mathbf{Y} | \mathbf{P}) \propto \exp \left\{ -\frac{1}{2} [\mathbf{Y} - \mathbf{T}(\mathbf{P}) - \bar{\eta}]^T \tilde{W}^{-1} [\mathbf{Y} - \mathbf{T}(\mathbf{P}) - \bar{\eta}] \right\}$$

# 5. Results

- Transient flow of water.
- Hydraulic circuit with total length of 150 m.
- Measurements of pressure and flow rate at the inlet and outlet of the circuit.




R. Carvalho, I. Louzada Herzog, H. Orlande, M. Colaço, I. Madeira, N. Chakraborti, Parameter estimation with the Markov Chain Monte Carlo method aided by evolutionary neural networks in a water hammer model, *Computational and Applied Mathematics* (2023) 42:35, <https://doi.org/10.1007/s40314-022-02162-0>

# SIMULATED MEASUREMENTS


**x = 4.59 m**

**inlet sensor**




**x = 148.16 m**


**outlet sensor**



**inlet sensor**











**outlet sensor**






# Reduced sensitivity coefficients: Parameters are linearly independent.




# 5. Results


## WAF-TVD AND PARALLEL METROPOLIS-HASTINGS




(a)



(b)




(c)




(d)

## 5. Results


- High-fidelity WAF-TVD solution of the water hammer model took about 3 minutes with a compiled C computer code: Markov chains with 8000 states were generated in at least 70 hours by using the parallel computation version of the Metropolis-Hastings algorithm
- EvoNN metamodel took 0.001 s of computational time with a Python computer code: serial Metropolis-Hastings with the EvoNN metamodel took 12 minutes to generate a Markov chain with  $10^6$  states.
- The calculation of the 2000 solutions of the high-fidelity model (1500 required for training the EvoNN and 500 for calculating the approximation error) took 101.7 hours.
- The training of the EvoNN and the calculation of the statistics of the approximation error took 128 minutes and 20 minutes, respectively.



(a)



(b)







(c)

Figure 7. Comparison of the high-fidelity and metamodel solutions for pressure at  $x = 148.16$  m with the parameter set A: (a) Whole-time domain; (b) Time interval when the water hammer effects are significant (c) Mean of the approximation error.

# 5. Results

## EVONN AND SERIAL METROPOLIS-HASTINGS



# **5. Conclusions**

- A comparison of the high-fidelity solution and the output of the EvoNNs revealed that this metamodel was not capable of completely representing the most significant effects resulting from the water hammer phenomenon. **As a result, the solutions of the inverse problem by replacing the high-fidelity model with the metamodel were biased.**
- **The Approximation Error Model (AEM) approach was then implemented**, and the modeling errors were represented as Gaussian variables.
- **The samples of the parameters used for computing the approximation errors with Monte Carlo simulations were different from those used for the training of the EvoNNs.**
- With the EvoNN metamodel and the AEM approach used in this paper, **Markov chains with  $10^6$  states could be generated with small computational cost**, thus providing samples that could appropriately represent the posterior distributions of the model parameters.
- **Even accurate metamodels like EvoNNs, as a replacement of high-fidelity models, might require the modeling of the approximation errors for the unbiased solution of inverse problems related to the water hammer phenomenon.**

# ACKNOWLEDGEMENTS

- **Fabrice Rigollet, Denis Maillet et Jean-Luc Battaglia**
- Support provided by **CNPq, CAPES and FAPERJ**, Brazilian agencies for the fostering of science.



- Support provided by **Petrobras**.





# Consider publishing your work in:

## Computational Thermal Sciences: An International Journal

Editor-in-Chief: Wilson Chiu, Helcio R. B. Orlande

Associate Editor: David Carrington, Arun Kumar Nayak

Founding Editor: Darrell Pepper, Graham de Vahl Davis

Clarivate Analytics Eigenfactor: 0.00025

Clarivate Analytics JCI: 0.3

SJR: 0.29

SNIP: 0.475

CiteScore™: 2.5

H-Index: 17

### Indexed in

Clarivate  
Clarivate ESCI

Scopus Preview  
Scopus (Preview)

Engineering Village  
Engineering Village

INSPEC  
Inspec

Google  
Google Scholars (USA)

Ulrichsweb™  
Ulrich's

CNKI  
CNKI (China)

Portico (Digital Preservation Agency) (USA)

Copyright Clearance Center  
Copyright Clearance Center (USA)

iThenticate  
iThenticate (USA)

Scilit  
Scilit (Switzerland)

ISSN Print: 1940-2503

ISSN Online: 1940-2554

COMPUTATIONAL  
THERMAL  
SCIENCES  
AN INTERNATIONAL JOURNAL

Volume 14, Issue 2, 2023  
Editors-in-Chief:  
Wilson Chiu  
Helcio Orlande  
Founding Editors:  
Graham de Vahl Davis  
Darrell Pepper

ASTFE  
Association of Thermal Engineers

begell  
New York • Connecticut

**Mark Your Calendar: 11-ICIPE ([icipe2024.org](http://icipe2024.org))**

**11<sup>th</sup> INTERNATIONAL CONFERENCE ON  
INVERSE PROBLEMS IN ENGINEERING**

**June 23-28, 2024**

**Atlântico Búzios Convention & Resort, Búzios  
Rio de Janeiro, Brazil**



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

Benjamin GAUME, Yassine ROUIZI, Frédéric JOLY, Olivier QUEMENER

LMEE, Univ Evry, Université Paris-Saclay, 91020 Evry, France.


Auteur coorespondant : [b.gaume@iut.univ-evry.fr](mailto:b.gaume@iut.univ-evry.fr)



- 1. Problématique**
- 2. Problème inverse**
- 3. Réduction de modèle**
- 4. Identification de la source de chaleur et reconstruction du champ de température**

# PROBLÉMATIQUE


**Position du problème : obtenir le suivi en  $T^\circ$  de toute la pièce à partir de quelques points de mesure au niveau du four en temps réel**



**Utilisation de problèmes inverses**

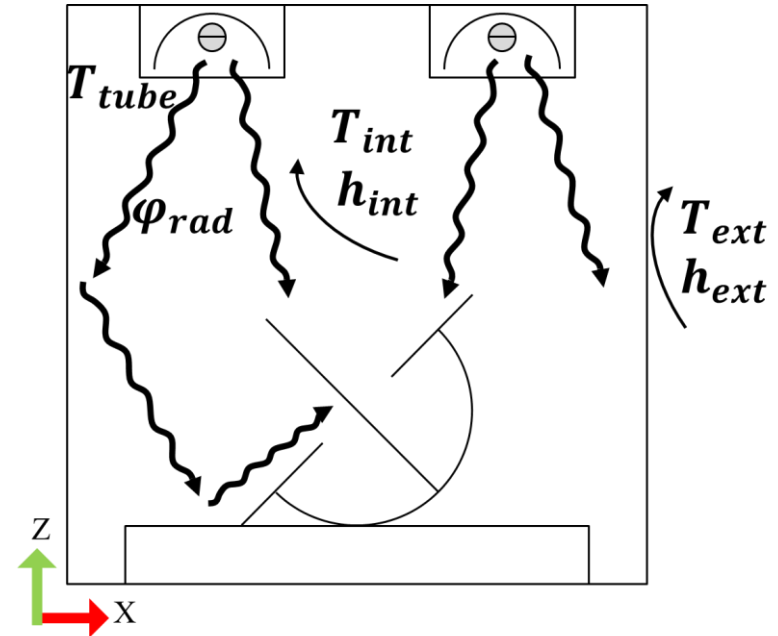

## Objectifs :

1. Identification des sources radiatives (températures)
2. Reconstruction du champ thermique au niveau de l'objet





## Problème physique:




## Formulation discrète

$$C\bar{T} = [K + H]T + U_0 + U_{cpl}T_{int}(T) + \bar{R}_{rad}\bar{T}^4 + T_{gaz}(t)U_{tube}$$

Avec les équations couplées :

- Pour la convection :  $T_{int}(T) = DT$
- Pour le rayonnement :  $\bar{T} = U_R^t T$

## Problème physique : Processus complexe et long



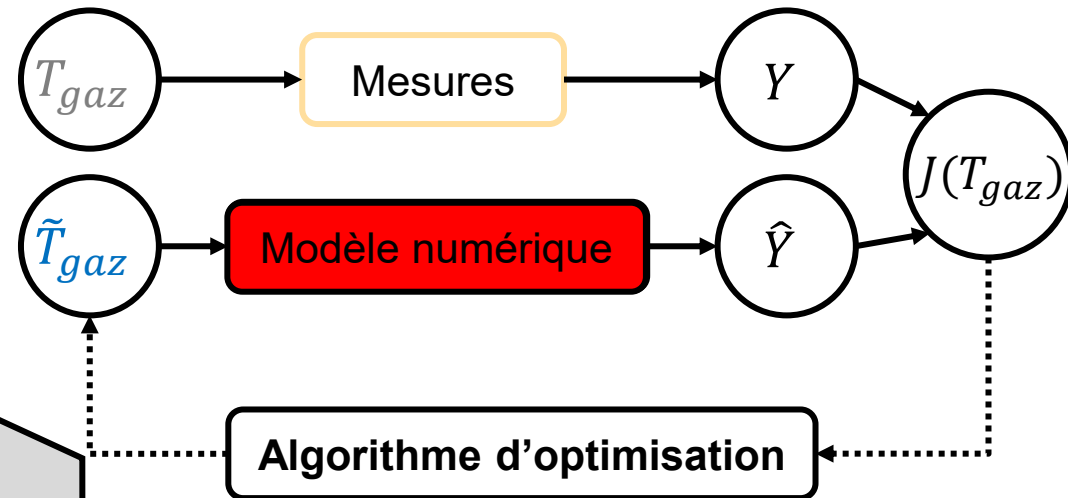

## Spécificités du problème

- Rayonnement : [44 838 DDL]
- Média non participatif
- Corps gris diffus isotropes
- Modèle coque : [12 167 DDL]
- Couplage convectif

# PROBLÈME INVERSE


## Difficultés :

1. Processus complexe et  $t_{CPU}$
2. Identification par technique itérative




$$J(T_{gas}) = \sum_{N_{pts}} \sum_{N_t} (Y(t) - \hat{Y}(T_{gas}, t))^2$$

☐ Méthode classique : éléments finis




$$= \sum^N$$



$$\textcircled{C} \dot{T} = AT + U(t)$$

Rayonnement :  $D\bar{\varphi} = R\bar{T}^4$



**DDL importants  
 et matrices  
 moins creuses**

Méthode classique : éléments finis

### Solutions envisagées :

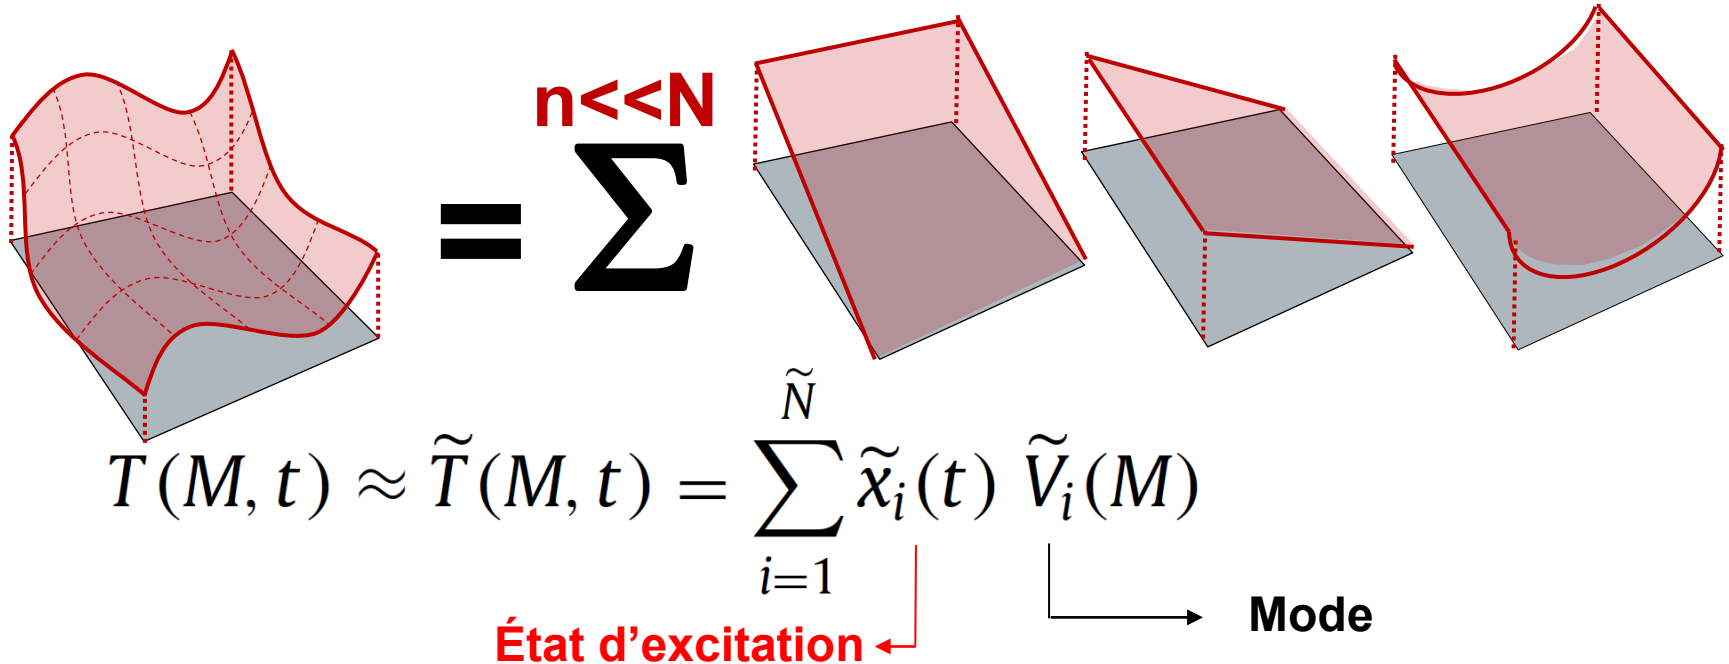
- Travailler par portion → Fenêtre glissante
- Dégrader le modèle : maillage EF grossier et regroupement de Patch pour les radiosités,...
- Utiliser un modèle réduit

A stylized line drawing of a person's face wearing glasses. The drawing is composed of simple black lines on a white background. The person has a neutral expression and is looking forward. The glasses have a simple rectangular frame. The drawing is positioned in the center of the slide, above the main title.

# RÉDUCTION DE MODÈLE



Alternative : la formulation modale



on remplace N inconnues de Températures T en  $n$  états d'excitation x  
**En respectant la géométrie du problème, avec  $n \ll N$ , on obtient une approximation satisfaisante avec un gain important en temps calcul !**

**permet de diminuer le DDL par rapport à la géométrie**

# Principe de la réduction modale

$$C\dot{T} = AT + U(T)$$

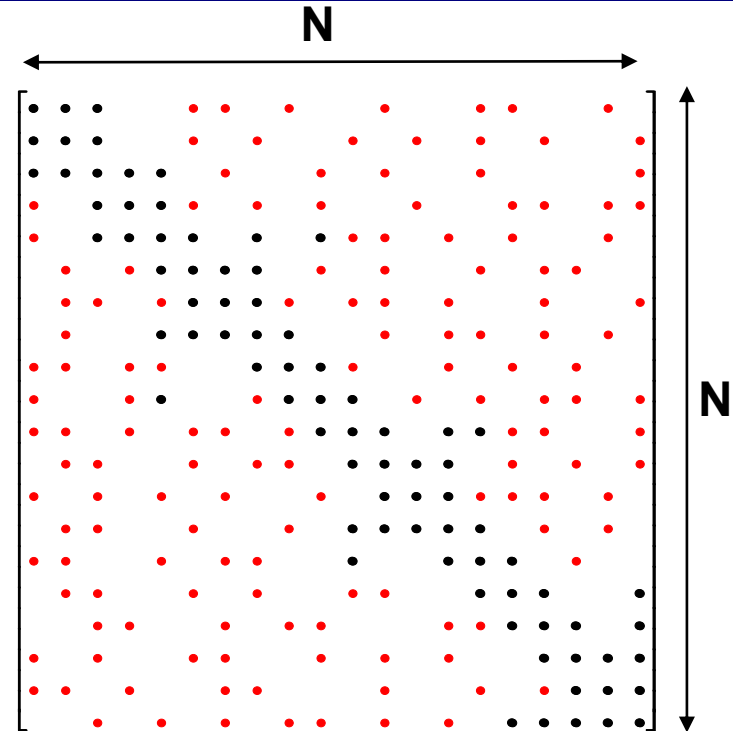



$$V^t C V \dot{X} = (V^t A V) X + V^t U(T)$$



$$L \tilde{X} = M \tilde{X} + N(T)$$

$$\tilde{T} = \tilde{V} \tilde{X}$$



**En respectant la géométrie du problème, avec  $n \ll N$ , on obtient une approximation satisfaisante avec un gain important en temps calcul !**

MIM

POD, PGD

AROMM

V

Calcul de la base complète

$$T(M, t) = \sum_{i=1}^n V_i(M) x_i(t)$$

Réduction  
de la base

$\tilde{V}$

Obtention de  
l'équation  
d'états

$$\mathbf{L} \frac{d\tilde{\mathbf{X}}}{dt} = \mathbf{M} \tilde{\mathbf{X}} + \mathbf{N}$$

## Principe de la méthode de la réduction

Le principe la méthode AROMM (Amalgam Reduced Order Modal Model) repose sur deux étapes :

1. Calcul d'une base complète  $\mathbf{V}$ , sur laquelle il est possible d'effectuer une décomposition rigoureuse du champ de température

$$T(M, t) = \sum_{i=1}^{\infty} V_i(M) x_i(t)$$


2. L' obtention d'une base réduite  $\tilde{\mathbf{V}}$ , afin de diminuer fortement l'ordre du modèle tout en permettant un calcul satisfaisant du champ de température

$$\mathbf{T}(t) \approx \sum_{i=1}^{\tilde{n}} \tilde{\mathbf{V}}_i \mathbf{x}_i(t)$$

**Simulation de  
référence**

**DATA**

## Réduction de la base modale : **Calcul de la base initiale:**



Base complète

Base issue du problème physique :


$$-\int_{\Omega} e k \vec{\nabla} V_i \cdot \vec{\nabla} f d\Omega = z_i \int_{\Omega} e c V_i f d\Omega$$

Pour l'amalgame, la base doit toujours respecter les conditions d'orthogonalités :


$$\forall i, j \in [1, N], \quad \int_{\Omega} e c V_i V_j d\Omega = \delta_{ij},$$

$$\forall i, j \in [1, N], \quad \int_{\Omega} e k \vec{\nabla} V_i \cdot \vec{\nabla} V_j d\Omega = z_i \delta_{ij}.$$

# Réduction de la base modale : **Méthode d'amalgame** :




Base complète




Minimisation selon un critère énergétique:

$$J = \int_{t=0}^{\infty} \int_{\Omega} [T(M, t) - \tilde{T}(M, t)] c_0(M) [T(M, t) - \tilde{T}(M, t)] dv dt$$



En utilisant les propriétés d'orthogonalités:


$$J = \sum_{P=1}^{\tilde{N}_1} \sum_{k=1}^{n_P} \varepsilon_{P,k} \quad \text{avec} \quad \varepsilon_{P,k} = \int_0^{\infty} (x_{P,k} - \alpha_{P,k} x_{P,1})^2 dt$$



Le coefficient d'amalgame s'exprime comme :

$$\alpha_{P,k} = \frac{\int_0^{\infty} x_{P,k} x_{P,1} dt}{\int_0^{\infty} x_{P,1}^2 dt}$$

# Réduction de la base modale : **Méthode d'amalgame** :




Base complète

**Processus  
d'amalgame**



# Réduction de la base modale : **Méthode d'amalgame** :




Base complète

**Processus d'amalgame**

**DATA !!**



- Tous les modes sont utilisés une seule fois
- Processus rapide
- Minimisation sur un critère énergétique des états
- Nécessite la connaissance des états de référence
- La simulation de référence peut être enrichi

Base réduite




# Application de la réduction:


• Méthode **AROMM** :  $T(M, t) = \sum_{i=1}^N V_i(M) x_i(t)$




Mode propre 5




Mode propre 16



Mode propre 40



Mode propre 599






## Simulation de référence

- Toutes les surfaces = corps-noirs
- Durée de simulation courte
- Température de tube fixe


Application de la réduction:  $\tilde{n} \ll N$

• Méthode **AROMM** :  $\tilde{T}(M, t) = \sum_{i=1}^{\tilde{n}} \tilde{V}_i(M) \tilde{x}_i(t)$

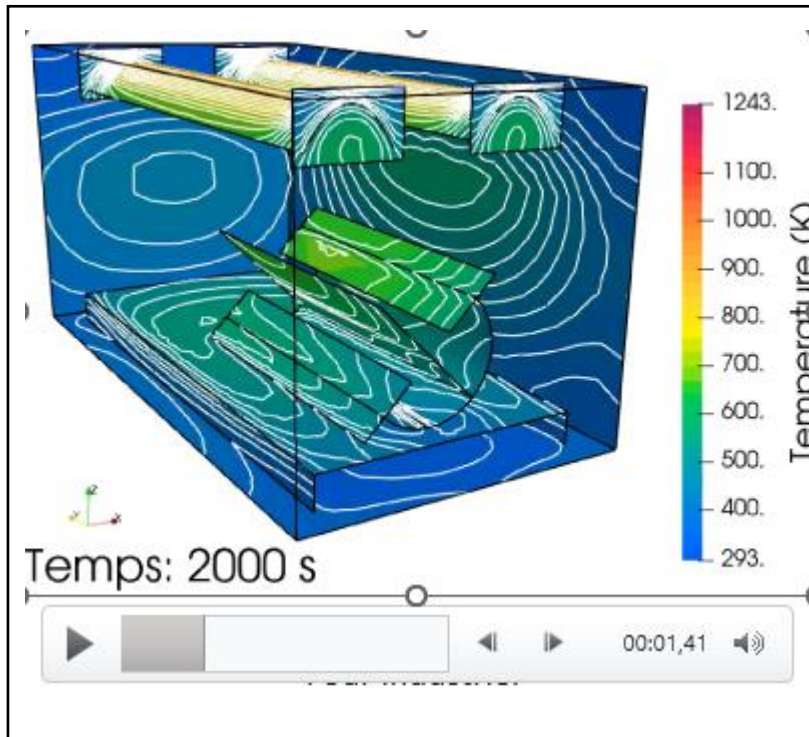


## Simulation de référence

- Toutes les surfaces = corps-noirs
- Durée de simulation courte
- Température de tube fixe



# Validation du modèle réduit



Four industriel

MR d'ordre 200 :


Gain de temps calcul  $\times 100$

Précision :  $\varepsilon_{max} \approx 3\%$  ( $< 26^\circ\text{C}$ )

$\langle \varepsilon \rangle \approx 0.1\%$  ( $< 1^\circ\text{C}$ )

*B. Gaume, F. Joly and O. Quémener, Modal reduction for a problem of heat transfer with radiation in an enclosure, Int. J. Heat Mass Transfer, 141 (2019) 779-788*

# APPLICATION








# Processus d'identification

## 1. Mesures :

- Données générées par simulation EF
- 2 points de mesure A et B
- Bruit blanc  $\sigma_b = 2K$  et  $5K$

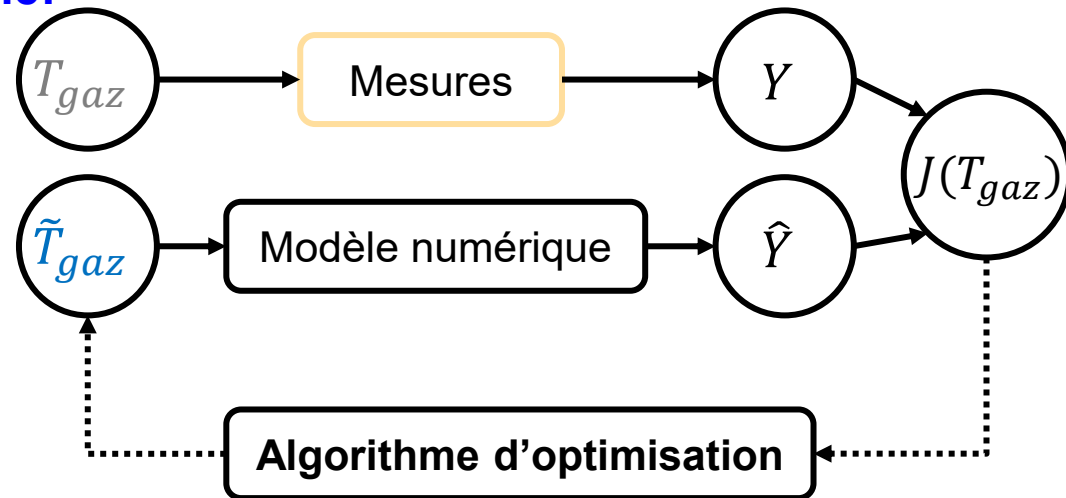


Evolution de la température du tube à identifier et du point de mesure A

# Processus d'identification

## 2 Identification avec ordre très faible:

- **Modèle réduit  $\tilde{N}_{id} = 20/50$  modes**
- **Algorithme de région de confiance**
- **Utilisation d'une fenêtre glissante**



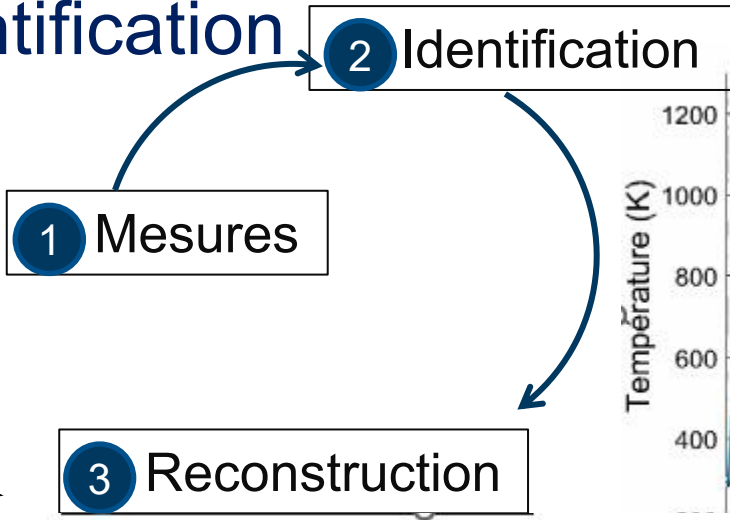



## 3 Reconstruction avec ordre faible :

- **Modèle réduit  $\tilde{N}_{rec} = 20$  à 300 modes**
- **Reconstruction en temps réel possible**




# Processus d'identification



*B. Gaume, Y. Rouizi, F. Joly, O. Quéméner, Identification of variable radiant source in an enclosure by reduced model, Int. J. Heat Mass Transfer (2021)*

# Processus d'identification





1 Mesures

2 Identification

**Erreurs sur l'objet :**

3  $\sigma_{max} = 38K$   
 $\bar{\sigma} = 1,92K$

*Temps du process < 5000 s*



B. Gaume, Y. Rouizi, F. Joly, O. Quéméner, Identification of variable radiant source in an enclosure by reduced model, Int. J. Heat Mass Transfer (2021)

# Conclusions

- **Intérêt des modèles réduits dans un processus d'identification**
  - ✓ Utilisable pour tous types de problèmes
  - ✓ Facilement adaptable
  - ✓ Permet le calcul en temps réel
  - ✓ Accès à l'ensemble du champ de température
- **Limites :**
  - ✓ Géométrie fixe
  - ✓ Non linéarités (passage dans l'espace des températures récurrent)
- **Perspectives :**
  - ✓ Contrôle en temps réel
  - ✓ Identification multi-sources
  - ✓ Améliorer la procédure d'amalgame en intégrant la phase de réduction dans la procédure inverse.
  - ✓ Intégrer d'autres méthodes de réduction pour la phase d'identification

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

**Merci de votre  
attention**





## Journée SFT

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

O. Farges<sup>‡</sup>, A. Royer<sup>††</sup>, P. Boulet<sup>‡</sup>, D. Burot<sup>†</sup>

<sup>‡</sup>Lemta, Université de Lorraine - <sup>†</sup>Safran Aircraft Engine

olivier.farges@univ-lorraine.fr

Jeudi 8 Juin 2023

**1** Contexte

**2** Un couplage MC-ANN

**3** Mise en œuvre et résultats

**4** Conclusion

**1** Contexte

**2** Un couplage MC-ANN

**3** Mise en œuvre et résultats

**4** Conclusion





- Constat :

- Constat :
  - ✓ Place du transfert radiatif vs CFD pour chambre de combustion aéronautique

- Constat :
  - ✓ Place du transfert radiatif vs CFD pour chambre de combustion aéronautique
  - ✓ Rendement : Gaz plus chaud, rendement cycle plus élevé

- Constat :
  - ✓ Place du transfert radiatif vs CFD pour chambre de combustion aéronautique
  - ✓ Rendement : Gaz plus chaud, rendement cycle plus élevé
  - ✓ Tendances : Augmentation de la température de combustion

- Constat :
  - ✓ Place du transfert radiatif vs CFD pour chambre de combustion aéronautique
  - ✓ Rendement : Gaz plus chaud, rendement cycle plus élevé
  - ✓ Tendence : Augmentation de la température de combustion
  - ✓ Besoin : Modélisation fine du rayonnement

- Constat :
  - ✓ Place du transfert radiatif vs CFD pour chambre de combustion aéronautique
  - ✓ Rendement : Gaz plus chaud, rendement cycle plus élevé
  - ✓ Tendances : Augmentation de la température de combustion
  - ✓ Besoin : Modélisation fine du rayonnement
- Enjeux :



- Constat :
  - ✓ Place du transfert radiatif vs CFD pour chambre de combustion aéronautique
  - ✓ Rendement : Gaz plus chaud, rendement cycle plus élevé
  - ✓ Tendances : Augmentation de la température de combustion
  - ✓ Besoin : Modélisation fine du rayonnement
- Enjeux :
  - ✓ Augmenter la précision sans augmenter les besoins informatiques

- Constat :
  - ✓ Place du transfert radiatif vs CFD pour chambre de combustion aéronautique
  - ✓ Rendement : Gaz plus chaud, rendement cycle plus élevé
  - ✓ Tendances : Augmentation de la température de combustion
  - ✓ Besoin : Modélisation fine du rayonnement
- Enjeux :
  - ✓ Augmenter la précision sans augmenter les besoins informatiques
  - ✓ Évaluer  $T_{paroi}$  le plus finement possible

- Constat :
  - ✓ Place du transfert radiatif vs CFD pour chambre de combustion aéronautique
  - ✓ Rendement : Gaz plus chaud, rendement cycle plus élevé
  - ✓ Tendances : Augmentation de la température de combustion
  - ✓ Besoin : Modélisation fine du rayonnement
- Enjeux :
  - ✓ Augmenter la précision sans augmenter les besoins informatiques
  - ✓ Évaluer  $T_{paroi}$  le plus finement possible
  - ✓ Estimer la durée de vie, la production de polluants,...

## Modélisation du transfert radiatif

## Modélisation du transfert radiatif

- Modélisation du rayonnement : l'ETR
  - ✓ Méthode aux Ordonnées Discrètes
  - ✓ Méthode de Monte Carlo
  - ✓ Méthode Volumes Finis,
  - ✓ Méthode Éléments Finis, ...

## Modélisation du transfert radiatif

- Modélisation du rayonnement : l'ETR
  - ✓ Méthode aux Ordonnées Discrètes
  - ✓ Méthode de Monte Carlo
  - ✓ Méthode Volumes Finis,
  - ✓ Méthode Éléments Finis, ...
- Modélisation de gaz
  - ✓ Modèle Raie par Raie,
  - ✓ Modèles à bandes
  - ✓ Modèles globaux (WSGG, SLW,...)

- Limitations fortes sur la puissance de calcul



- Limitations fortes sur la puissance de calcul
  - ✓ Contexte industriel : maillages extrêmement lourds, simulations couplées, ressources dédiées limitées

- Limitations fortes sur la puissance de calcul
  - ✓ Contexte industriel : maillages extrêmement lourds, simulations couplées, ressources dédiées limitées
  - ✓ Solution retenue aujourd'hui au vu des contraintes : WSGG  
=> erreurs importantes

- Limitations fortes sur la puissance de calcul
  - ✓ Contexte industriel : maillages extrêmement lourds, simulations couplées, ressources dédiées limitées
  - ✓ Solution retenue aujourd'hui au vu des contraintes : WSGG => erreurs importantes
  - ✓ Des besoins en constante augmentation => respect des normes, environnements de plus en plus chauds, etc

- Limitations fortes sur la puissance de calcul
  - ✓ Contexte industriel : maillages extrêmement lourds, simulations couplées, ressources dédiées limitées
  - ✓ Solution retenue aujourd'hui au vu des contraintes : WSGG => erreurs importantes
  - ✓ Des besoins en constante augmentation => respect des normes, environnements de plus en plus chauds, etc

**Problématique : Comment atteindre la précision des méthodes statistiques (MC) et des modèles spectraux avec un temps de calcul acceptable? => Méthode de rupture**



1 Contexte

**2** Un couplage MC-ANN

3 Mise en œuvre et résultats

4 Conclusion

## Alliance de deux méthodes

## Alliance de deux méthodes

- Les méthodes statistiques pour la précision en calcul sonde (Monte Carlo)

## Alliance de deux méthodes

- Les méthodes statistiques pour la précision en calcul sonde (Monte Carlo)
- Les réseaux de neurones pour l'interpolation et le calcul en champs



## Alliance de deux méthodes

- Les méthodes statistiques pour la précision en calcul sonde (Monte Carlo)
- Les réseaux de neurones pour l'interpolation et le calcul en champs
- Objectif :

## Alliance de deux méthodes

- Les méthodes statistiques pour la précision en calcul sonde (Monte Carlo)
- Les réseaux de neurones pour l'interpolation et le calcul en champs
- Objectif :
  - ✓ Proposer une nouvelle méthodologie de calcul de champs utilisable à l'échelle industrielle

## Alliance de deux méthodes

- Les méthodes statistiques pour la précision en calcul sonde (Monte Carlo)
- Les réseaux de neurones pour l'interpolation et le calcul en champs
- Objectif :
  - ✓ Proposer une nouvelle méthodologie de calcul de champs utilisable à l'échelle industrielle
  - ✓ Atteindre une précision spectrale

## Alliance de deux méthodes

- Les méthodes statistiques pour la précision en calcul sonde (Monte Carlo)
- Les réseaux de neurones pour l'interpolation et le calcul en champs
- Objectif :
  - ✓ Proposer une nouvelle méthodologie de calcul de champs utilisable à l'échelle industrielle
  - ✓ Atteindre une précision spectrale
  - ✓ Diminuer drastiquement l'utilisation des ressources de calcul (temps + RAM) / aux méthodes existantes



# L'intelligence artificielle comme « produit dopant »



## Alliance de deux méthodes

## Alliance de deux méthodes

- Construction d'une base de données d'entraînement

## Alliance de deux méthodes

- Construction d'une base de données d'entraînement
  - ✓ Méthode et modèle : Monte Carlo + modèle de gaz SNB-CK  
=> calcul point sonde

## Alliance de deux méthodes

- Construction d'une base de données d'entraînement
  - ✓ Méthode et modèle : Monte Carlo + modèle de gaz SNB-CK  
=> calcul point sonde
  - ✓ Tirage de N points dans le domaine d'étude : calcul de la divergence du flux en ces points



## Alliance de deux méthodes

- Construction d'une base de données d'entraînement
  - ✓ Méthode et modèle : Monte Carlo + modèle de gaz SNB-CK  
=> calcul point sonde
  - ✓ Tirage de N points dans le domaine d'étude : calcul de la divergence du flux en ces points
  - ✓ Entraînement du réseau de neurones sur la base de données :  
valeur de  $\nabla \cdot q$  pour un ensemble de paramètres  
( $x_i, y_i, T_i, [\text{H}_2\text{O}]_i, [\text{CO}_2]_i$ )

## Alliance de deux méthodes

- Construction d'une base de données d'entraînement
  - ✓ Méthode et modèle : Monte Carlo + modèle de gaz SNB-CK  
=> calcul point sonde
  - ✓ Tirage de N points dans le domaine d'étude : calcul de la divergence du flux en ces points
  - ✓ Entraînement du réseau de neurones sur la base de données :  
valeur de  $\nabla \cdot q$  pour un ensemble de paramètres  
( $x_i, y_i, T_i, [\text{H}_2\text{O}]_i, [\text{CO}_2]_i$ )
  - ✓ Reconstruction du champ de divergence de flux par interpolation

## Construction, entraînement et utilisation des réseaux de neurones en modélisation

## Construction, entraînement et utilisation des réseaux de neurones en modélisation

- Idées reçues

## Construction, entraînement et utilisation des réseaux de neurones en modélisation

- Idées reçues
  - ✓ «boite noire»

## Construction, entraînement et utilisation des réseaux de neurones en modélisation

- Idées reçues
  - ✓ «boite noire»
  - ✓ outil magique
  - ✓ ...

## Construction, entraînement et utilisation des réseaux de neurones en modélisation

- Idées reçues
  - ✓ «boite noire»
  - ✓ outil magique
  - ✓ ...
- Les ANN sont des outils statistiques avancés

## Construction, entraînement et utilisation des réseaux de neurones en modélisation

- Idées reçues
  - ✓ «boite noire»
  - ✓ outil magique
  - ✓ ...
- Les ANN sont des outils statistiques avancés
  - ✓ Tout dépend de la base de données, de la méthode d'entraînement, des choix paramétriques utilisés, ...



## Construction, entraînement et utilisation des réseaux de neurones en modélisation

- Idées reçues
  - ✓ «boite noire»
  - ✓ outil magique
  - ✓ ...
- Les ANN sont des outils statistiques avancés
  - ✓ Tout dépend de la base de données, de la méthode d'entraînement, des choix paramétriques utilisés, ...
  - ✓ Autrement dit, tout dépend du travail «humain» de conception

## Construction, entraînement et utilisation des réseaux de neurones en modélisation

## Construction, entraînement et utilisation des réseaux de neurones en modélisation

- Algorithme de Levenberg- Marquardt : phase d'apprentissage => minimisation écarts entre résultats du réseau et données d'entrée

## Construction, entraînement et utilisation des réseaux de neurones en modélisation

- Algorithme de Levenberg- Marquardt : phase d'apprentissage => minimisation écarts entre résultats du réseau et données d'entrée
- Régularisation Bayésienne => Aucun hyperparamètre à fixer « en dur »

## Construction, entraînement et utilisation des réseaux de neurones en modélisation

- Algorithme de Levenberg- Marquardt : phase d'apprentissage => minimisation écarts entre résultats du réseau et données d'entrée
- Régularisation Bayésienne => Aucun hyperparamètre à fixer « en dur »
  - ✓ Adaptation de la topologie

## Construction, entraînement et utilisation des réseaux de neurones en modélisation

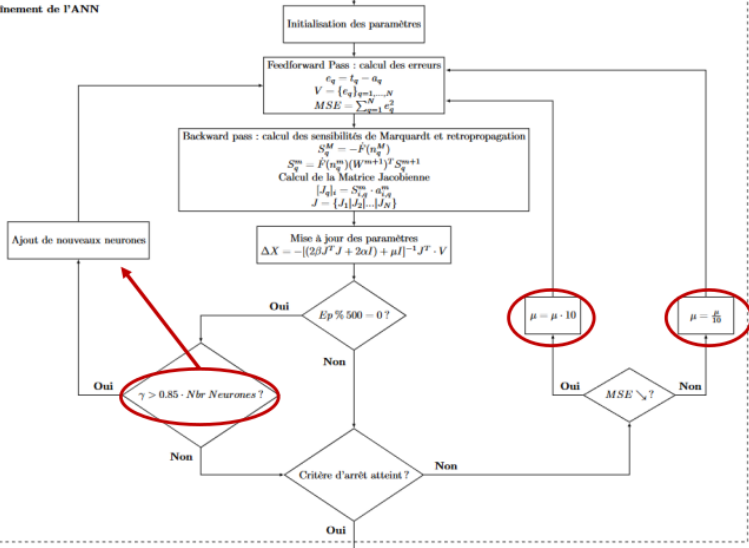
- Algorithme de Levenberg- Marquardt : phase d'apprentissage => minimisation écarts entre résultats du réseau et données d'entrée
- Régularisation Bayésienne => Aucun hyperparamètre à fixer « en dur »
  - ✓ Adaptation de la topologie
  - ✓ Loi d'évolution de  $\mu$  intégrée

## Construction, entraînement et utilisation des réseaux de neurones en modélisation

- Algorithme de Levenberg- Marquardt : phase d'apprentissage => minimisation écarts entre résultats du réseau et données d'entrée
- Régularisation Bayésienne => Aucun hyperparamètre à fixer « en dur »
  - ✓ Adaptation de la topologie
  - ✓ Loi d'évolution de  $\mu$  intégrée
  - ✓ Intrinsèquement peu sensible à l'overfitting

# L'intelligence artificielle comme « produit dopant »

Entraînement de l'ANN






1 Contexte

2 Un couplage MC-ANN

**3** Mise en œuvre et résultats

4 Conclusion


- Cas académique de type « flamme de diffusion »
  - ✓ Champs de température et d'espèces paramétriques
  - ✓ Pas de variation brutale des grandeurs thermo-physiques




$$T(l, r) = 800 + 1200 \left(1 - \frac{r}{R}\right) \left(\frac{l}{L}\right)$$


$$x_{H_2O}(l, r) = 0.05 \left[1 - 2 \left(\frac{l}{L} - 0.5\right)^2\right] \left(2 - \frac{r}{R}\right)$$


$$x_{CO_2}(l, r) = 0.04 \left[1 - 3 \left(\frac{l}{L} - 0.5\right)^2\right] \left(2.5 - \frac{r}{R}\right)$$



# Validation sur un cas benchmark












## Validation sur un cas benchmark




## Validation sur un cas benchmark





Méthode	RMSE ( $kW.m^{-3}$ )
ANN	1.0453
Splines cubiques	15.79
Proche voisin	15.21
Bi-linéaire	14.06

Tab. : Comparaison de la valeur de la RMSE calculée pour les différentes méthodes d'interpolation



## Alliance de deux méthodes

- Construction d'une base de données d'entraînement
  - ✓ Méthode et modèle : Monte Carlo + modèle de gaz SNB-CK  
=> calcul point sonde
  - ✓ Tirage de N points dans le domaine d'étude : calcul de la divergence du flux en ces points
  - ✓ **Entraînement du réseau de neurones sur la base de données : valeur de  $\nabla \cdot q$  pour un ensemble de paramètres  $(x_i, y_i, T_i, [H_2O]_i, [CO_2]_i)$**
  - ✓ Reconstruction du champ de divergence de flux par interpolation



## Ajout d'un point chaud très ponctuel

- Même champs que précédemment + point chaud paramétrique très intense



- Même champs que précédemment + point chaud paramétrique très intense
  - ✓ Numériquement très complexe à modéliser, même avec des méthodes déterministes


- Même champs que précédemment + point chaud paramétrique très intense
  - ✓ Numériquement très complexe à modéliser, même avec des méthodes déterministes
  - ✓ Typique d'un phénomène de cliquetis dans l'industrie automobile par exemple

- Même champs que précédemment + point chaud paramétrique très intense
  - ✓ Numériquement très complexe à modéliser, même avec des méthodes déterministes
  - ✓ Typique d'un phénomène de cliquetis dans l'industrie automobile par exemple
- La question : comment un ANN peut-il prendre en compte ce type de phénomène ? Peut-il seulement le détecter ?


- Même champs que précédemment + point chaud paramétrique très intense
  - ✓ Numériquement très complexe à modéliser, même avec des méthodes déterministes
  - ✓ Typique d'un phénomène de cliquetis dans l'industrie automobile par exemple
- La question : comment un ANN peut-il prendre en compte ce type de phénomène ? Peut-il seulement le détecter ?

**Importance de la construction de la base de données**


## Ajout d'un point chaud très ponctuel




# Ajout d'un point chaud très ponctuel



## Ajout d'un point chaud très ponctuel



# Ajout d'un point chaud très ponctuel





Paramètre	Valeur
Base de données	500 points
Méthode de tirage	Halton
Temps moyen de calcul d'un point de référence	21.3 s
Nombre de neurones	4
Nombre de paramètres	29
Valeur de $\gamma$	25
Nombre d'époques	10000
Temps d'entraînement	49.03 s
RMSE	5.740 kW.m <sup>-3</sup>

TAB. : Caractéristiques du réseau de neurones et de l'entraînement - Cas "Point chaud"

1 Contexte

3 Mise en œuvre et résultats

2 Un couplage MC-ANN

4 Conclusion

- La méthode proposée est capable de :
  - ✓ Tracer des champs d'une grandeur radiative en mobilisant peu de ressources de calcul
  - ✓ Atteindre la précision des meilleures méthodes stochastiques
  - ✓ Prendre en considération des événements très ponctuels
  - ✓ S'adapter à la difficulté du problème traité grâce au paradigme bayésien
  - ✓ S'affranchir de certaines limites relatives à ce type d'outil : définition de beaucoup d'hyperparamètres, forte tendance au sur-apprentissage...
  - ✓ Étude d'autres cas académiques avec d'autres type de singularité (bruit numérique, discontinuités)

- Prochaines étapes :
  - ✓ Couplage avec des logiciels commerciaux type Fluent
  - ✓ Étude d'un cas « métier » : test de la méthode sur une chambre de combustion réelle
  - ✓ **Soutenance de thèse d'Alex Royer le 23 juin prochain**



5èmes Journées Annuelles du GDR TAMARYS  
26-28 juin 2023 à Nancy



## 5 conférences invitées

- ❖ Claire Prada, Institut Langevin (Paris) « Résonances locales et dispersion négative dans les guides d'ondes élastiques observées par ultrasons laser – applications »
- ❖ Denis Rochais, CEA Le Ripault (Monts) « Ingénierie numérique des matériaux : une nouvelle stratégie pour concevoir et élaborer des matériaux optimisés »
- ❖ Yann Favennec, LTEN (Nantes) « Un cadre éléments finis pour la résolution de problèmes radiatifs et conducto-radiatifs »
- ❖ Eric Louradour, 3D CERAM-SINTO (Bonnac-La-Côte) « Réalisation de pièces architecturées par impression 3D céramique »
- ❖ Célien Zacharie, Fives Cryo (Golbey) « Modèle réduit pour le pilotage procédé HT Fives Cryo »

Et de nombreuses communications orales et par affiches!

**Vous avez encore quelques jours pour vous inscrire aux 5<sup>èmes</sup> Journées Annuelles (JA) du GDR TAMARYS qui auront lieu sur le campus ARTEM de Nancy ! (26-28 juin 2023)**

Ces Journées démarreront le **lundi 26 à 14h00** pour finir le **mercredi 28 à 12h00**.

La manifestation est organisée par le **LEMTA** et l'**UIL** de Nancy et bénéficie du partenariat de la **Société Française de Thermique** et du parrainage du **France Interepo Chapter**. Ces Journées sont également soutenues par les pôles scientifiques, Matière, Matériau, Métallurgie, Mécanique (**M4**) et Energie, Mécanique, Procédés, Produits (**EMPP**) de l'Université de Lorraine.

Les inscriptions sont gratuites pour les doctorants, post-doctorants et ATER. Elles sont portées à 75€ HT pour les permanents du GDR (académiques et industriels) et fixées à 400€ HT pour les industriels non membres du GDR.

⇒ Pour vous inscrire (jusqu'au 14 juin!)

<https://www.azur-colloque.fr/DR06/inscription/inscription/71/fr>

⇒ Informations pratiques : <https://gdr-tamarys.cnrs.fr/5emes-journees-annuelles-du-gdr-tamarys-26-28-juin-2023/>

## 3 ateliers thématiques

- ❖ Mise en place de l'exercice d'analyse comparée des méthodes de modélisation du couplage conduction-rayonnement dans des matériaux hétérogènes (coordinateur **Franck Enguehard**, Institut P', Poitiers).
- ❖ Problèmes de thermique dans les plasmas (coordinateur **Yann Cressault**, LAPLACE, Toulouse)
- ❖ Nouveaux matériaux et nouveaux concepts pour la récupération, la conversion et le stockage de la chaleur à haute température (coordinateurs **Olivier Farges**, LEMTA, Nancy & **Gérard Vignoles**, LCTS, Pessac)

## 2 présentations institutionnelles

- **Fabrice Lemoine**, Co-directeur du PEPR SPLEEN (Soutenir l'innovation pour développer de nouveaux procédés industriels largement décarbonés) « Présentation du PEPR SPLEEN »
- **Christophe Coutanceau**, Délégué Scientifique Cellule Energie CNRS, « Présentation du plan Europe au CNRS »

# Réseaux de neurones informés par la physique pour la reconstruction de courants de gravité

Yoann Cheny, Mickaël Delcey, Adrien Ganz & Sébastien K. de Richter  
Université de Lorraine, France  
[yoann.cheny@univ-lorraine.fr](mailto:yoann.cheny@univ-lorraine.fr)

Situation typique : étude d'écoulements 3D à partir d'observations expé. 0D, 2D

**Écoulements de Poudres et Suspensions**, courants de gravité écoulements induits par  $\Delta\rho$



Lock-exchange configuration  
*Western Washington University*


Méetrologie des courants de gravité :

- $(u, v)$  : Particle Image Velocimetry (PIV *2D-2C*)
- $\rho$  : Planar Laser Induced Fluorescence (PLIF)
- $\bar{\rho} = \int \rho(z) dz$  Light Attenuation Technique (LAT)

Mesures volumétriques onéreuses : RMN, Tomo-PIV, 3D-LIF, 3DBoS...

Situation typique : étude d'écoulements 3D à partir d'observations expé. 0D, 2D

**Écoulements de Poudres et Suspensions**, courants de gravité écoulements induits par  $\Delta\rho$



Métrologie des courants de gravité :

- $(u, v)$  : Particle Image Velocimetry (PIV *2D-2C*)
- $\rho$  : Planar Laser Induced Fluorescence (PLIF)
- $\bar{\rho} = \int \rho(z) dz$  Light Attenuation Technique (LAT)

Mesures volumétriques onéreuses : RMN, Tomo-PIV, 3D-LIF, 3DBoS...

Peut-on reconstruire l'écoulement 3D  $(\rho, u, v, w, p)$  à partir de données lacunaires ? [Delcey et al. 2023]



Deux classes de méthodes pour la reconstruction d'écoulement :

- **Méthodes orientées données** (POD, PCA, Machine Learning)

- ⊗ Requiert une connaissance *a priori* de l'écoulement

- **Assimilation de données :**

Idée directrice : associer les données observées à un modèle physique (CFD)

- ⊗ Procédure itérative très gourmande en ressources CPU
  - ⊗ Pas adapté à l'assimilation des grandeurs intégrées


**Point de départ : Physics-Informed Neural Networks (PINNs) [Raissi et al. 2020]**

**Enrichissement** du Deep Learning par la physique sous-jacente (EDP)

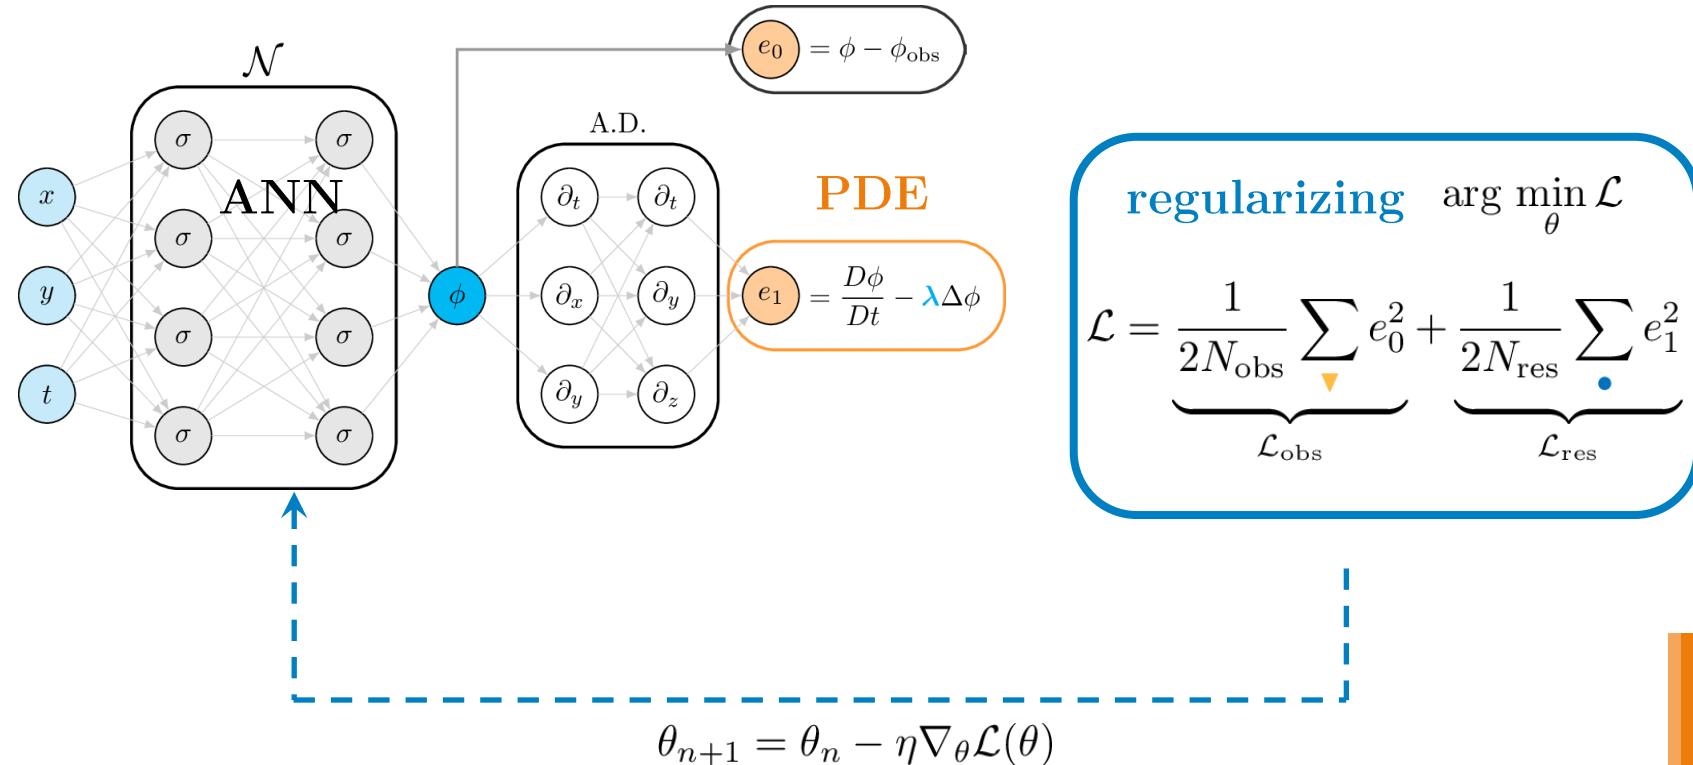
# Principe des PINNs

**Exemple simple : advection-diffusion**  $\frac{\partial \phi}{\partial t} + (\mathbf{v} \cdot \nabla)\phi - \lambda \Delta \phi = 0$  avec  $\mathbf{v} = (1, 1)^T$

- ▼  $N_{\text{obs}}$  points d'observation  $\phi_{\text{obs}}$
- $N_{\text{res}}$  points de collocation




PINNs correspondent au pipeline “ANN-PDE-regularizing” [Kim et al. 21]



In fine :  $\phi \simeq \mathcal{N}(x, y, t)$

Reconstruction des courants de gravité

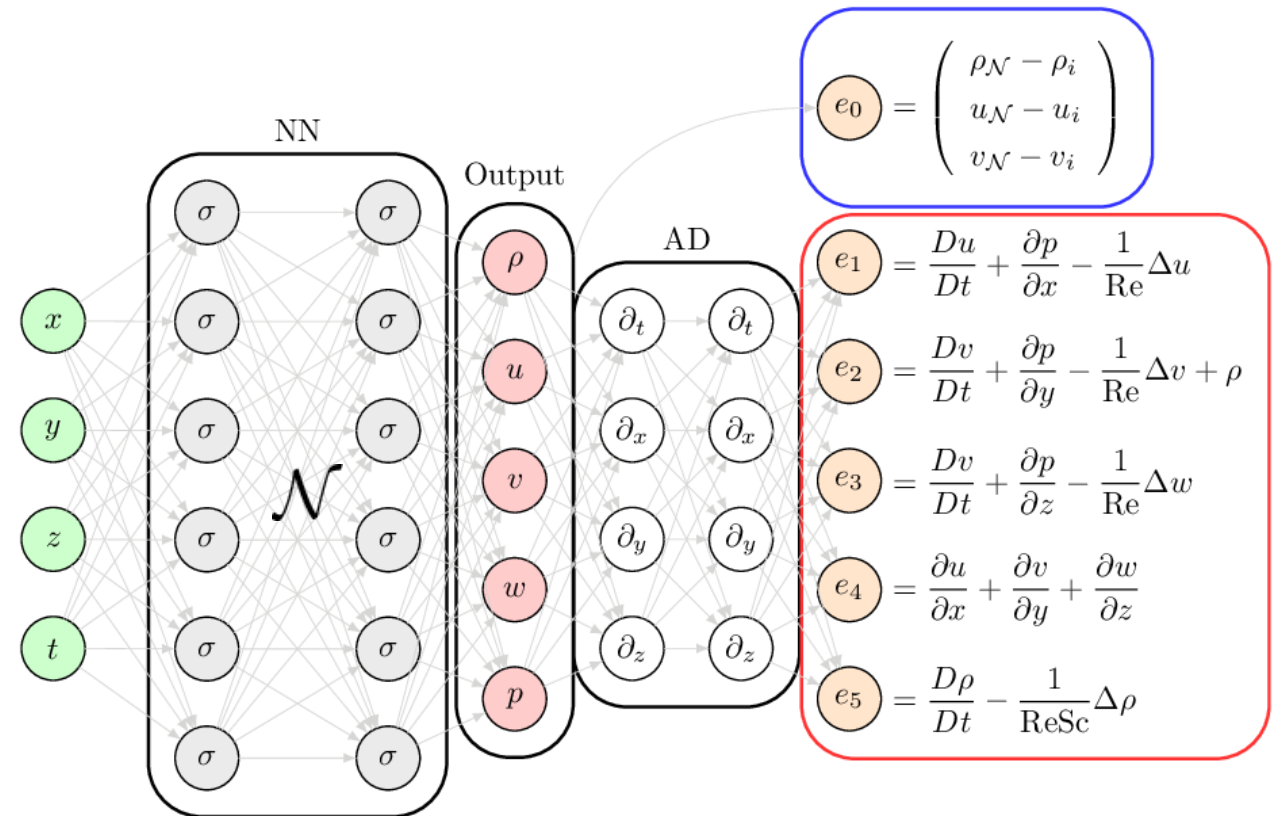
$$(\rho, u, v, w, p) \simeq \mathcal{N}(x, y, z, t)$$



Représentation des données (cas PLIF-PIV)

■ points d'observation

● points de collocation



$$\mathcal{L} = \underbrace{\frac{1}{2N_{\text{obs}}} \sum_{\blacksquare} e_0^2}_{\mathcal{L}_{\text{obs}}} + \underbrace{\frac{1}{2N_{\text{res}}} \sum_{\bullet} \sum_{k=1}^5 e_k^2}_{\mathcal{L}_{\text{res}}}$$

- Pour les problèmes « directs » :

$$\text{EDP+C.L.+C.I. connues} \rightarrow (\rho, u, v, w, p)$$

$$\mathcal{L} = \mathcal{L}_{\text{res}} + \mathcal{L}_{\text{C.L.}} + \mathcal{L}_{\text{C.I.}}$$

- Et les problèmes « indirects » :

- Reconstruction d'écoulement :

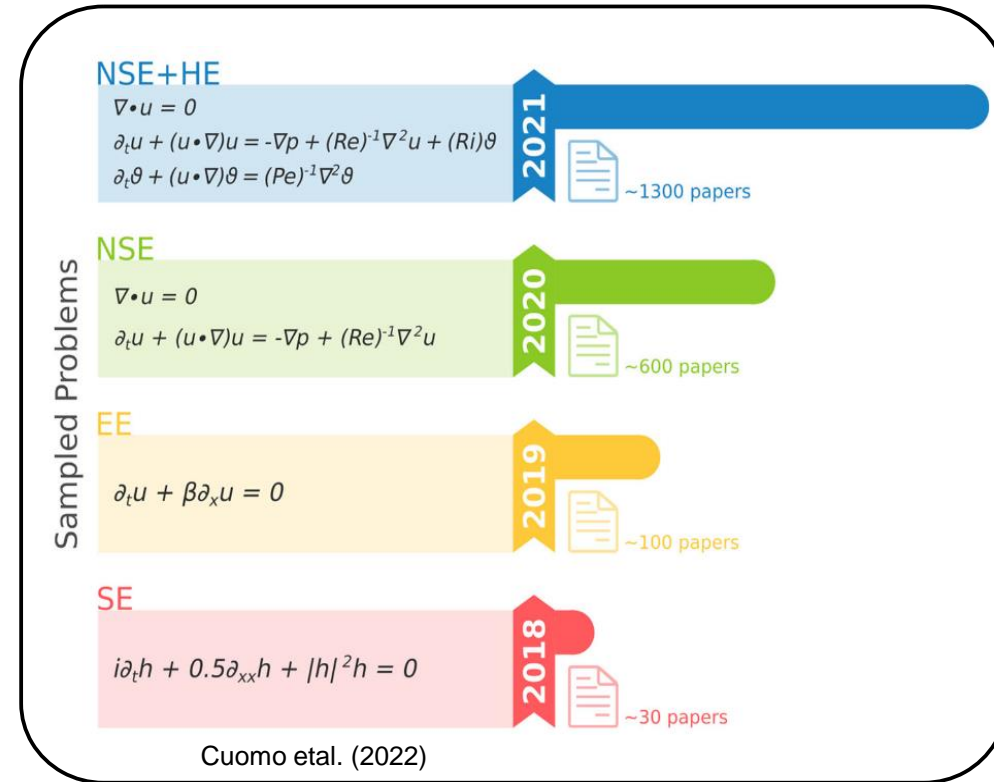
$$\text{EDP} + (\rho, u, v)_{\text{obs}} \rightarrow (\rho, u, v, w, p)$$

$$\mathcal{L} = \mathcal{L}_{\text{res}} + \mathcal{L}_{\text{obs}}$$

- « Découverte » de modèles :

$$\left\{ \begin{array}{l} (u, v, p)_{\text{obs}} + \frac{D\mathbf{v}}{Dt} = \nabla \cdot \boldsymbol{\sigma} \\ \text{avec } \boldsymbol{\sigma} = \alpha p \mathbf{I} + \beta (\nabla \mathbf{v} + \nabla^{\dagger} \mathbf{v}) + \gamma \frac{1}{p} \nabla (p \mathbf{v}) \end{array} \right.$$

$$\alpha = -1, \beta = \frac{1}{Re}, \gamma = 0$$




Énorme potentiel pour trouver des modèles de fermeture !

Physique connue

Qté de données

Base de données  
&  
Cas tests étudiés

Cas test : Lock-Exchange  $Re = 5500$  et  $Sc = 1$  avec hypothèse de Boussinesq



$$\frac{\partial \mathbf{v}}{\partial t} + (\mathbf{v} \cdot \nabla) \mathbf{v} + \nabla p - \frac{1}{Re} \nabla^2 \mathbf{v} + \rho \mathbf{e}_y = 0$$

$$\frac{\partial \rho}{\partial t} + (\mathbf{v} \cdot \nabla) \rho - \frac{1}{Re Sc} \nabla^2 \rho = 0$$

$$\nabla \cdot \mathbf{v} = 0$$


Résolu par code spectral Nek5000

Données de référence  $\mathcal{D}^{\text{ref}} = \left\{ \rho_{\mathbf{x}}, u_{\mathbf{x}}, v_{\mathbf{x}}, w_{\mathbf{x}}, p_{\mathbf{x}} \right\}$  acquises dans  $\Omega_{\text{obs}}$  pour  $t \in [8, 10]$

domaine spatio-temporel discrétisé unif.  $50 \times 76 \times 51 \times 18$

$$|\mathcal{D}^{\text{ref}}| = 14M$$

- Construction de dispositifs exp. synthétiques
- Pour mesurer l'erreur de l'inférence







Isovaleurs de  $\rho$  à  $z = \frac{l_z}{2}$

- **3D-LIF** : mes. volumétriques de  $\rho$  dans  $\Omega_{obs}$   
experimental cost : ★★★★★

- **PLIF-PIV** :  $(\rho, u, v)$  at  $z = \frac{l_z}{2}$   
experimental cost : ★★★

- **LAT** :  $\bar{\rho} = \frac{2}{l_z} \int_0^{\frac{l_z}{2}} \rho(\cdot, z) dz$   
 $\bar{\rho}_N \simeq Quad_z(\rho_N)$  (trapèzes)  
$$\mathcal{L}_{data} = \frac{1}{N_{data}} \sum_{i=1}^{N_{data}} \|Quad_z(\rho_N) - \bar{\rho}_i\|^2$$
experimental cost : ★

- **LAT-2PIV** : **LAT** +  $(u, v)$  en  $z = \frac{l_z}{2}$  et  $z = \frac{l_z}{4}$   
experimental cost : ★★★





# Résultats numériques

Calcul de la norme L2 de l'erreur dans l'ensemble du domaine spatio-temporel  $\epsilon_\rho = \frac{100}{\sup_{\Omega} |\rho_{\mathbf{x}}|} \sqrt{\frac{\sum_{\mathbf{x} \in \Omega} |\rho_{\mathcal{N}}(\mathbf{x}) - \rho^{\text{ref}}(\mathbf{x})|^2}{|\Omega|}}$

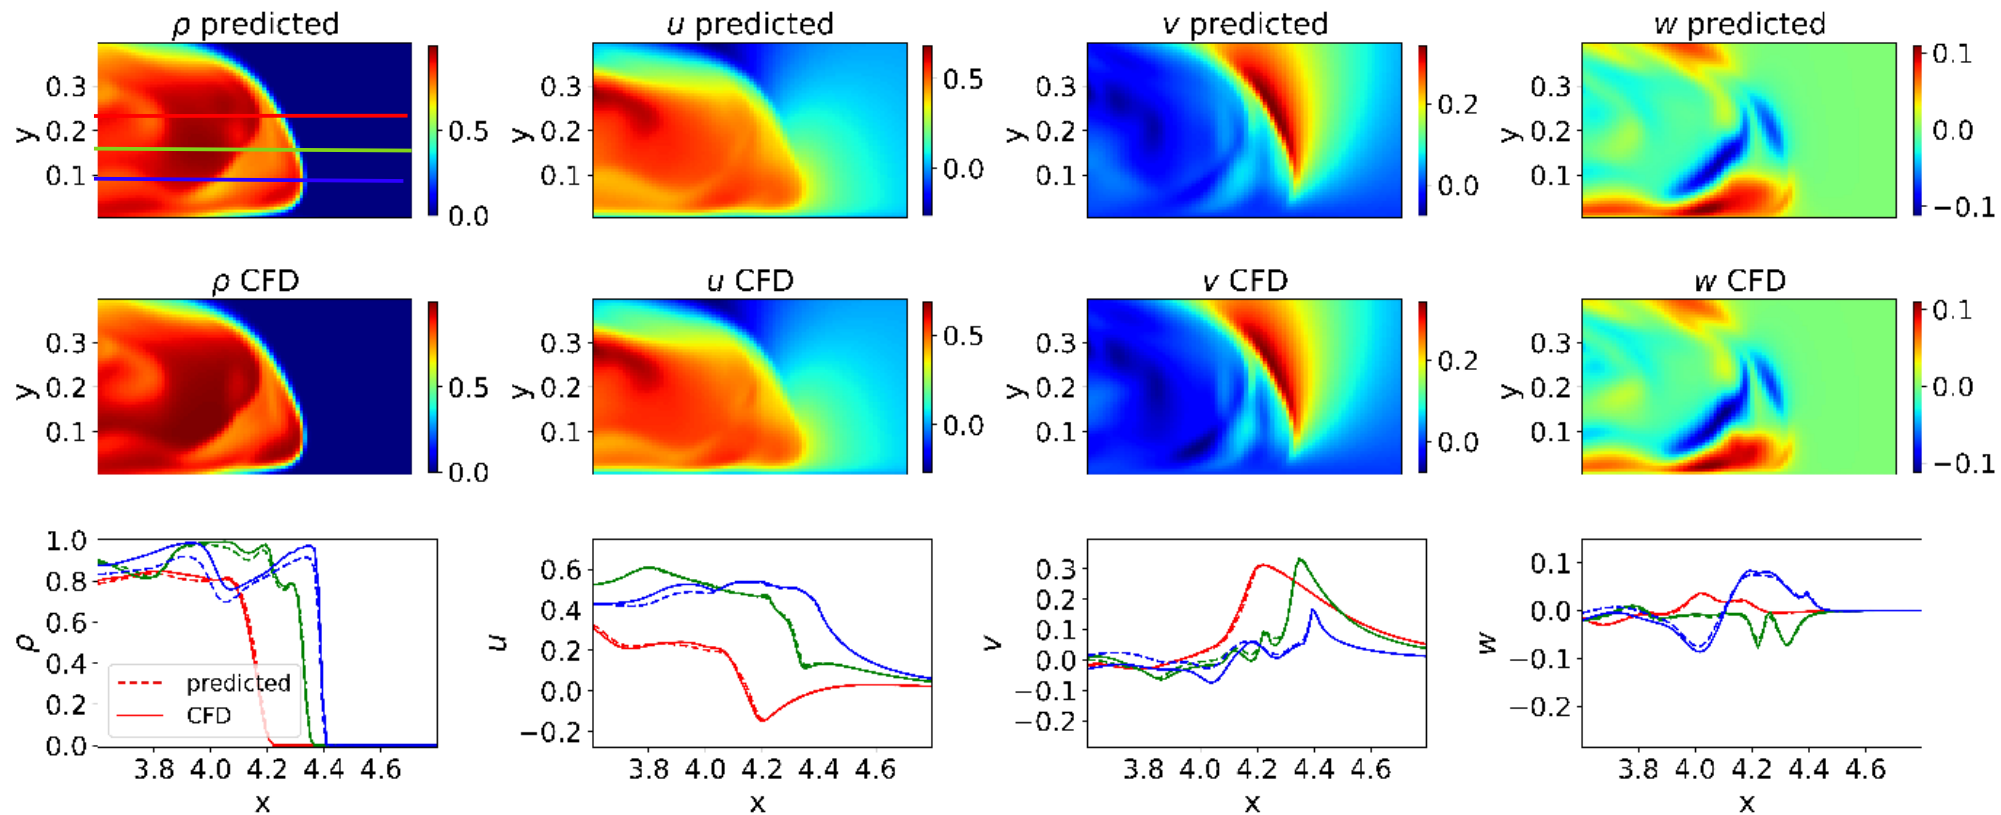
Réseaux de 10 couches cachées de 200 neurones, arrêt entraînement à 300 epochs, temps GPU ~ 24 h

Cas	$\epsilon_\rho$	$\epsilon_u$	$\epsilon_v$	$\epsilon_w$	$\epsilon_p$	$\bar{\epsilon}$	Coût	Data
3D-LIF	0.53%	5.99%	5.00%	4.08%	3.91%	3.90%	*****	2800000
LAT	9.98%	14.49%	26.20%	11.24%	8.47%	14.07%	*	252000
PLIF-PIV	19.99%	18.20%	18.83%	8.87%	5.12%	14.20%	** **	756000
LAT-2PIV	5.34%	3.31%	6.36%	3.43%	1.23%	3.93%	** *	1260000

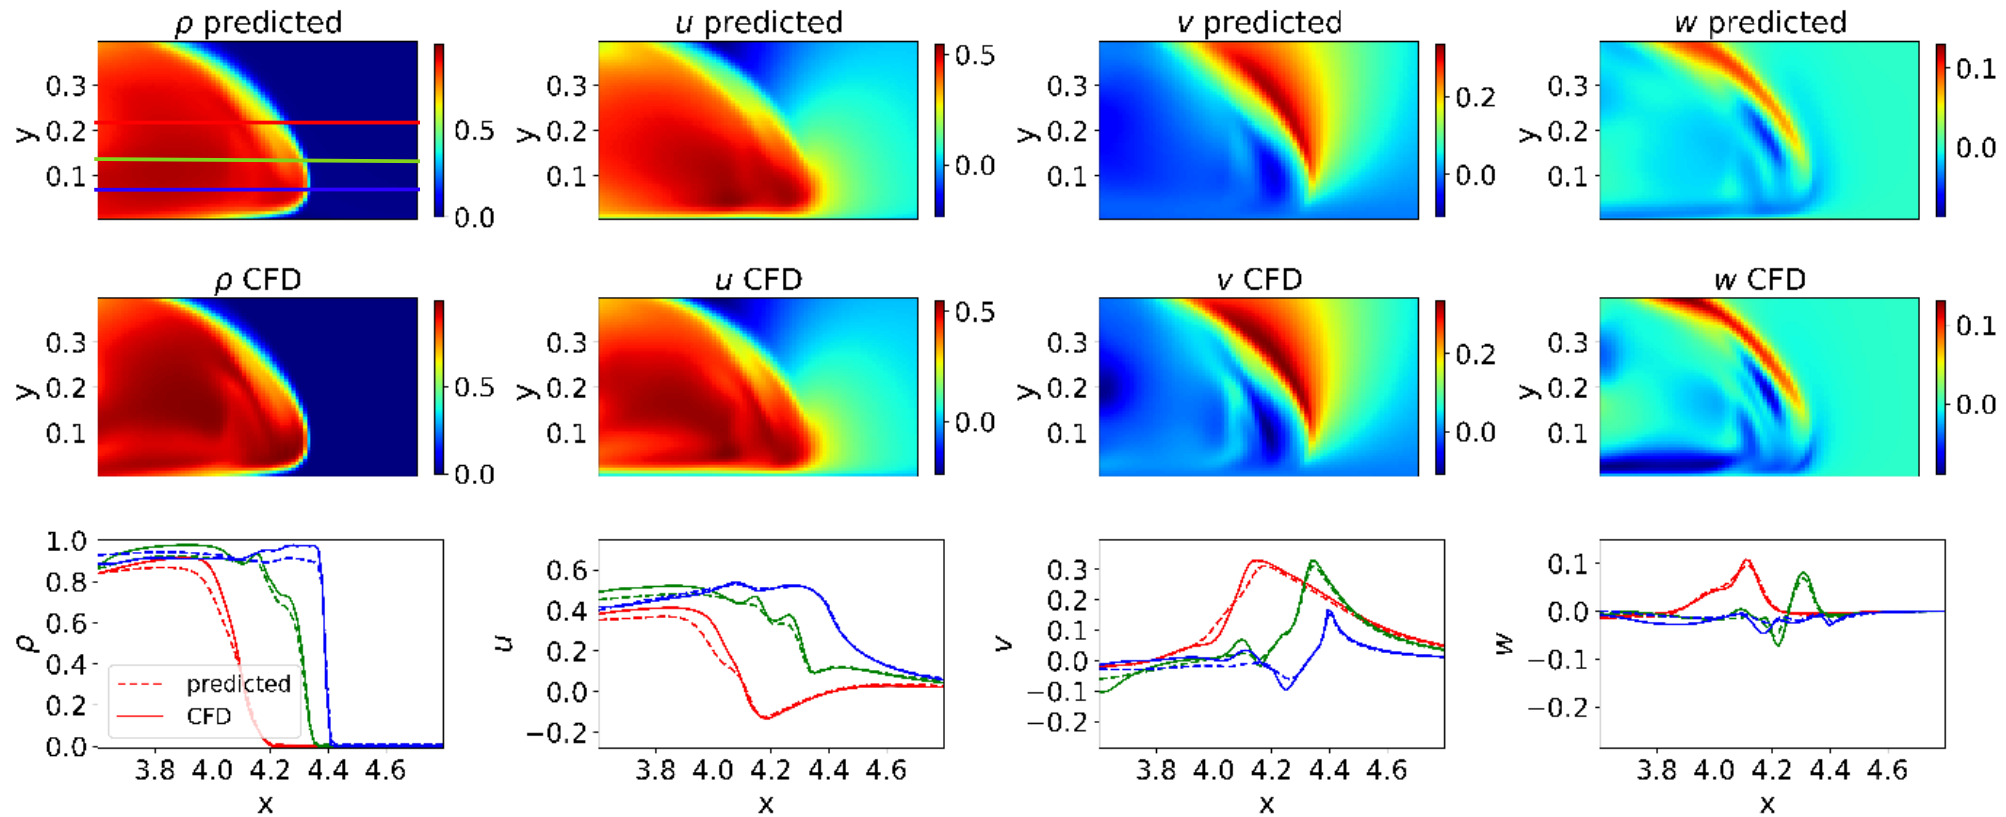
Conclusions partielles :

- **3D-LIF** erreur < 6 % pour chaque cas
- **LAT** aussi précise que **PLIF-PIV** pour une fraction du coût expé (et 3 fois moins de données)
- **LAT-2PIV** permet une inférence aussi précise que **3D-LIF** (tests à venir dans l'OS)

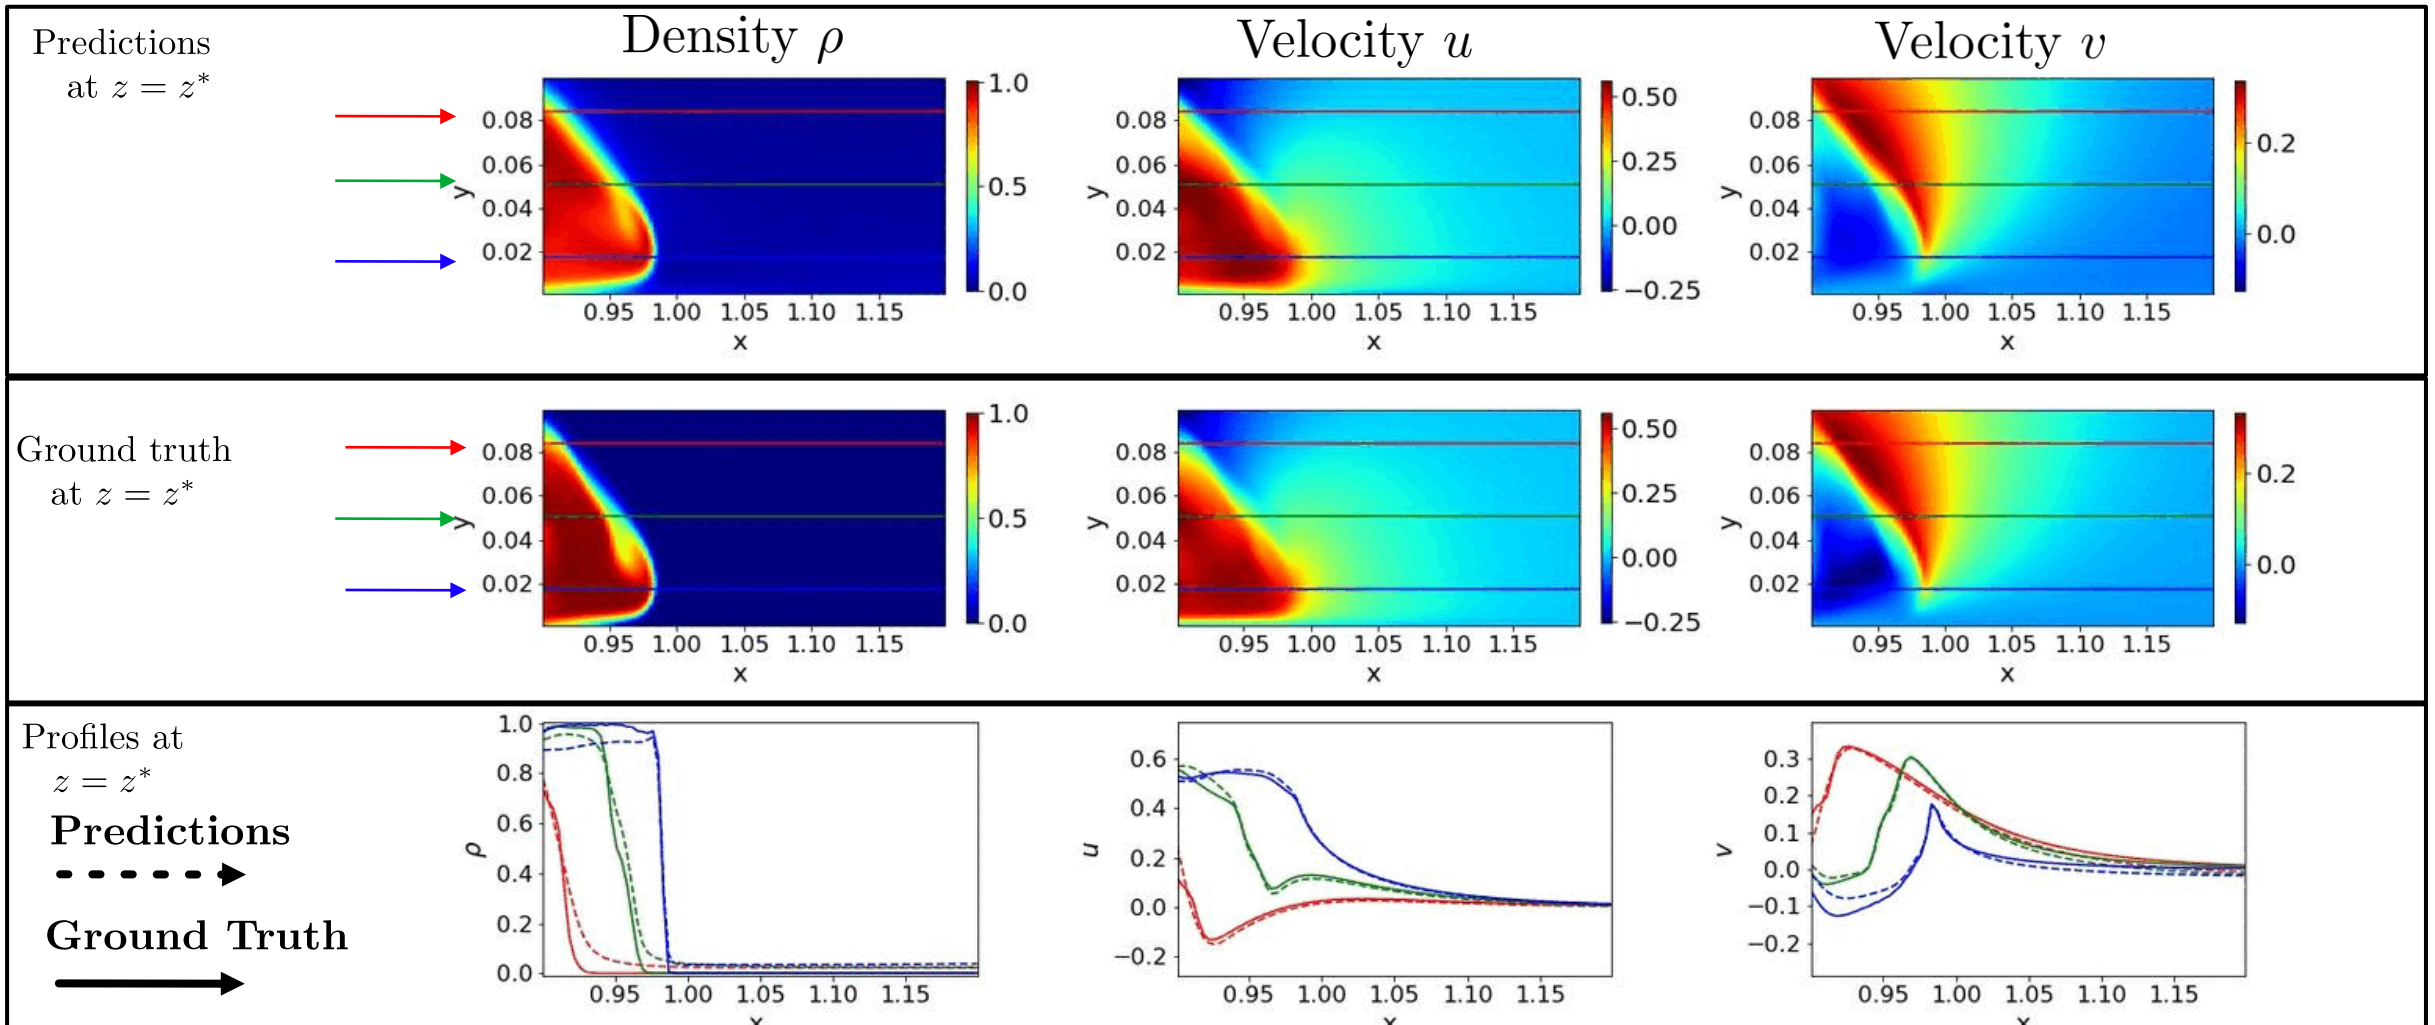
Profils des champs prédits en  $z=0.16$  i.e. proche plan de symétrie




Profils des champs prédits en  $z=0.05$  i.e. proche paroi




# Profils horizontaux au cours du temps



Predictions  
at  $z = z^*$




Ground truth  
at  $z = z^*$



Profiles at  
 $z = z^*$

Predictions  
- - - - ->  
Ground Truth  
—————>



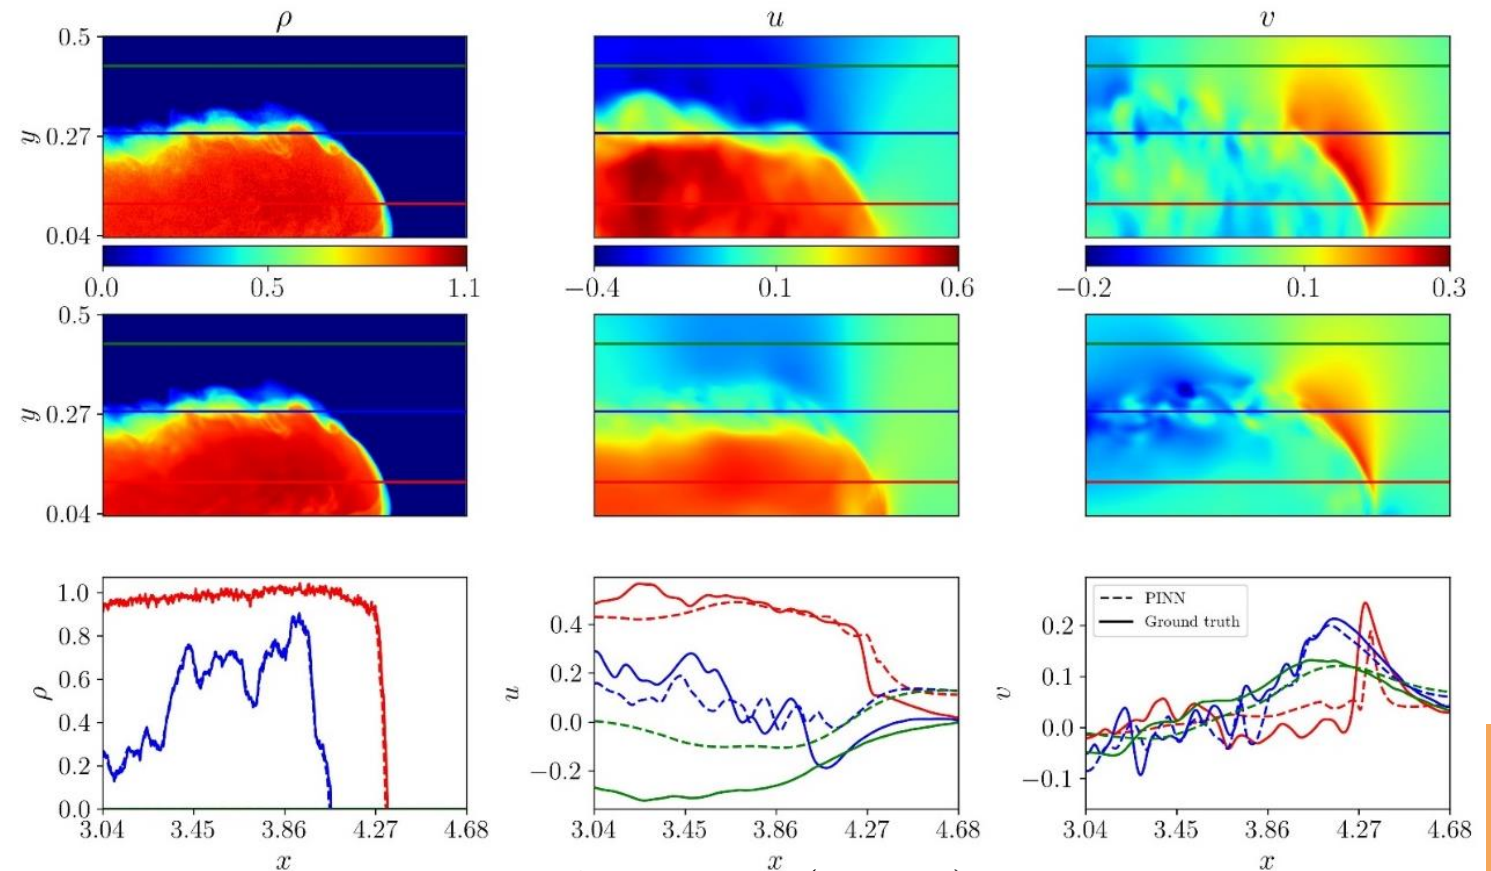


Une preuve de concept donnée sur des données synthétiques [Delcey et al. PoF 2023] :

- capacité de reconstruction jusqu'aux parois
- faible sensibilité au bruit (non-présenté)
- LAT-2PIV un dispositif prometteur pour l'étude exp. des courants de gravité

Application aux données expérimentales (soumis à Ocean Modelling) :

- validation partielle (équations 2D)
- donne accès à la pression



LAT-PIV :  $(\bar{\rho}, u, v)$



Journée SFT du 8 Juin 2023



UNIVERSITÉ  
DE LORRAINE

*Groupe "Mesures thermiques et techniques inverses" « (METTI)*

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

*Denis Maillet, Benjamin Rémy, Adrien Barthélemy*  
LEMTA (Université de Lorraine & CNRS , Nancy)

[denis.maillet@univ-lorraine.fr](mailto:denis.maillet@univ-lorraine.fr)






## Plan de l'exposé

- 1. **Modèle convolutif** transitoire générique en diffusion/advection thermique : conditions d'application, propriétés et expressions
- 2. Un modèle paramétrique: le **modèle ARX** (AutoRégressif à variable(s) Exogène(s))
- 3. liens entre modèles **ARX** et **convolutif**: choix du nombre de paramètres et reconstruction de la réponse impulsionnelle
- 4. Conclusions/perspectives

## 1.1 Rappel: Transformée de Laplace transform et Equation différentielle ordinaire Linéaire à coefficients Indépendants du Temps (LTI)

$$\begin{cases} \frac{dy}{dt} + a y = b u ; a \text{ et } b : \text{ constantes} \\ y(t=0) = y_0 \end{cases}$$

TRANSFORMATION DE LAPLACE :  $\bar{y}(p) = \mathcal{L}[y(t)] = \int_0^{\infty} \exp(-p t) y(t) dt$



  
variable de Laplace

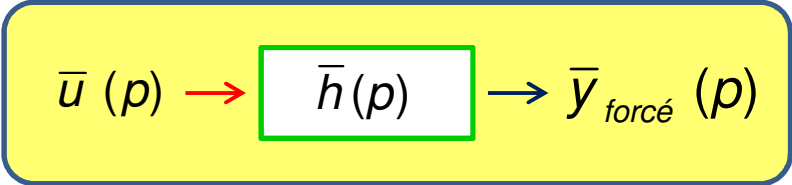
**Propriété 1 :**

$$\mathcal{L}\left[\frac{dy}{dt}\right] = p \bar{y} - y_0$$

$$\bar{y}(p) = \frac{b}{p+a} \bar{u}(p) + \frac{1}{p+a} y_0 = \bar{y}_{forcé}(p) + \bar{y}_{relax}(p)$$

$$\bar{y}_{forcé}(p) = \bar{h}(p) \bar{u}(p)$$



  
fonction de transfert



$$\bar{u}(p) \rightarrow \bar{h}(p) \rightarrow \bar{y}_{forcé}(p)$$

$$\bar{y}_{forced}(p) = \bar{h}(p) \bar{u}(p)$$

$\downarrow$   
 fonction de transfert



**Propriété 2 :**  $\mathcal{L}^{-1} [\bar{h}(p) \bar{u}(p)] = (h * u)(t) \equiv \int_0^t h(t-t') u(t') dt' = \int_0^t h(t') u(t-t') dt'$

**produit de convolution**

$$y_{forced}(t) = (h * u)(t) = \int_0^t h(t-t') u(t') dt'$$

$\downarrow$  **Sortie Réponse (conséquence)**     
  $\downarrow$  **Réponse impulsionnelle**     
  $\downarrow$  **Entrée Excitation (cause)**


Ici, **problème mathématique**:

Expression analytique de la réponse impulsionnelle of impulse response:  $h(t) = b \exp(-at)$

Expression analytique du terme de relaxation:  $y_{relax}(t) = y_0 \exp(-at)$

## 1.2 Transformée de Laplace et transfert 3 D

Système physique **multicomposant** =  $K$  domaines **solides** ou **fluides**




Hypothèses: **propriétés thermophysiques** et **champ des vitesses** invariants en temps

- hypothèses :**
- régime initial permanent + (éventuellement) multiplicité sources permanentes (puissances thermiques et/ou températures imposées) dont 1 excitation volumique d'intensité uniforme  $Q_v^{ss}$  sur une une portion du domaine
  - à l'instant  $t = 0^+$ , on change  $Q_v^{ss}$  en  $Q_v^{ss} + Q_v(t)$  (perturbation)
  - pas de changement des autres sources, ni de  $T_\infty$ , ni des coeffs. échange externes, ni de(s) température(s) d'entrée des fluide(s) interne(s)

Variation température en tout point P ( $t > 0$ ):

$$\theta(P, t) = T(P, t) - T_{init}(P)$$

no change of inlet fluid temperature B. C. : no change of  $T$ , or  $\phi$ , or  $T_\infty$ )



Soustraction: E. chaleur ( $t > 0$ ) – E chaleur ( $t \leq 0$ )

$$\boxed{\rho c(P) \frac{\partial \theta}{\partial t}(P, t)} + \boxed{\rho c(P) \vec{u}(P) \cdot \vec{\nabla} \theta(P, t)} = \boxed{\vec{\nabla} \cdot (\lambda(P) \vec{\nabla} \theta(P, t))} + \boxed{\frac{f(P)}{V_{source}} Q_v(t)}$$

Transient                      Advection                      Conduction                      Internal source

EDP + conditions limites: *Linéaires à coefficients Invariants en Temps (LTI) + source séparable + régime initial permanent*

Consequences : *Equation de la chaleur dans le domaine de Laplace\** (disparition dérivée temporelle)

$$\boxed{\rho c(P) p \bar{\theta}(P, p)} + \boxed{\rho c(P) \bar{u}(P) \cdot \vec{\nabla} \bar{\theta}(P, p)} = \boxed{\vec{\nabla} \cdot (\lambda(P) \vec{\nabla} \bar{\theta}(P, p))} + \boxed{\frac{f(P)}{V_{\text{source}}} \bar{Q}_v(p)}$$

Transient
Advection
Conduction
Internal source

entrée :  $\bar{u}(p) \equiv \bar{Q}_v(p) \Rightarrow$  solution = sortie  $\bar{y}(P, t)$  en température ou en densité de flux en tout point P

$$\bar{y}(P, p) = \bar{h}(P, p) \bar{u}(p)$$

proportionalité

ou produit convolution (en temps)

excitation

$$\text{Réponse forcée} \leftarrow y(P, t) = h(P, t) * u(t) = \int_0^t h(P, t-t') u(t') dt'$$

**Transient variation of excitation :**

$$u(t) = Q_v(t) - Q_v^{init} \text{ or } Q_s(t) - Q_s^{init}$$

$$\text{or } T_s(t) - T_s^{init} \text{ or } T_\infty(t) - T_\infty^{init}$$

$$\text{or } T_b^{in}(t) - T_b^{in,init}$$

**Impulse response**

$$h(P, t)$$

« init » = initial steady state

**Transient variation of temperature at point P**


$$y(t) = T(P, t) - T_{init}(P)$$

or variation of local heat flux  $\phi_x(P, t)$   
in any direction x

\* 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 115 (2017) 304–313.

Excitation $u$	Response $y$	Transfer function $H$
Power source $Q$ (watts)	Temperature difference $\theta$ (kelvins)	Impedance $Z$ ( $K.J^{-1}$ )
Temperature difference $\theta$ (kelvins)	Temperature difference $\theta$ (kelvins)	Transmittance $W$ ( $s^{-1}$ )
Power source $Q$ (watts)	Rate of heat flow $\Phi$ (watts)	Transmittance $W$ ( $s^{-1}$ )
Temperature difference $\theta$ (kelvins)	Rate of heat flow $\Phi$ (watts)	Admittance $Y$ ( $W.K^{-1}.s^{-1}$ )

### 1.3 Ecriture d'un produit de convolution discret (cas d'une transmittance paramétrisée)



$q(t)$  : vraie source  
 $u(t) = \theta_1(t)$  : pseudo-source = entrée  
 $y(t) = \theta_2(t)$  : sortie



response    transmittance    unique pseudo source  
 ↓                    ↓                    ↓

$$\begin{aligned}
 y(t) &= (w * u)(t) \\
 &= \int_0^t u(t-t') w(t') dt'
 \end{aligned}$$

$$y(t_i) \approx \Delta t \sum_{j=1}^m \tilde{u}_{i-j+1} \tilde{w}_j$$

sampled

Parameterization:  
averaged over 1 time interval



## Forme vectorielle/matricielle d'un produit de convolution discret

Introduction of a square matrix, function  $\mathbf{N}$  (.) that depends on a column-vector  $\mathbf{x}$ :

$\mathbf{N}(\mathbf{x})$  is a **Lower Triangular Toeplitz matrix (LTTM)**  
 (nice mathematical properties: set of LTTM = commutative ring\*)

$$\mathbf{N}(\mathbf{x}) \equiv \begin{bmatrix} x_1 & & & & \\ x_2 & x_1 & & & 0 \\ x_3 & x_2 & x_1 & & \\ \vdots & \vdots & \vdots & \ddots & \\ x_k & x_{k-1} & x_{k-2} & \cdots & x_1 \end{bmatrix}$$

Continuous time domain:

$$y(t) = (h * u)(t)$$

Laplace domain :

$$\bar{y}(p) = \bar{h}(p) \bar{u}(p)$$

Discrete vector form (numerical quadrature for each line) :

$$y = \mathbf{N}(\hat{h}) \tilde{u} = \mathbf{N}(\tilde{u}) \hat{h}$$

$y$  : vector of **instant values** of output

$\tilde{u}$  : vector of **averaged values** of  $u(t)$

$\hat{h}$  : vector of **doses** of  $h(t)$



Matrices de **convolution**  $\mathbf{M}(\cdot)$   $\longrightarrow$

vecteur des moyennes par intervalle :  $\tilde{\mathbf{x}} = \mathbf{N}(\mathbf{x})$

vecteur des doses :  $\hat{\mathbf{x}} = \Delta t \tilde{\mathbf{x}}$

$$\mathbf{M}(\mathbf{x}) \equiv \mathbf{N}^2(\mathbf{f}) \mathbf{N}(\mathbf{x})$$

avec  $\mathbf{f} = \frac{1}{2} [1 \ 1 \ 0 \ \dots \ 0]^T$

NB1:  $\mathbf{M}(\mathbf{x}) = \Delta t \mathbf{N}(\tilde{\mathbf{x}})$   
 avec  $\tilde{x}_i = \frac{1}{4} (x(t_{i-2}) + 2x(t_{i-1}) + x(t_i))$

NB2:  $(\mathbf{N}(\mathbf{f}))^{-1} = \mathbf{N}(\mathbf{f}^+)$   
 avec  $\mathbf{f}^+ = 2 [1 \ -1 \ 1 \ -1 \ \dots \ (-1)^{m-1}]^T$

$$\mathbf{y} = \mathbf{M}(\mathbf{u}) \quad \mathbf{h} = \mathbf{M}(\mathbf{h}) \mathbf{u}$$

modèle pour  
identifier  $\mathbf{h}$



modèle pour  
estimer  $\mathbf{u}$

$\mathbf{y}$  : vector of **instant values** of output  $y(t)$

$\mathbf{u}$  : vector of **instant values** of input  $u(t)$

$\mathbf{h}$  : vector of **instant values** of impulse response  $h(t)$

## 1.4 Identification d'une transmittance en 1D : plaque isolant léger & fortes pertes face arrière




$q(t)$  : vraie source

$u(t) = \theta_1(t)$  : pseudo-source = entrée

$y(t) = \theta_2(t)$  : sortie

Calcul direct en Laplace: quadripôles\* (analytique)  
+ inversion numérique de Laplace (1000 temps)

$$\text{cond}(\mathbf{M}(u)) = 1.02 \cdot 10^{23}$$



Ajout de bruit:


$$\mathbf{y} = \mathbf{y}^{exact} + \boldsymbol{\varepsilon}_y$$

$$\mathbf{u} = \mathbf{u}^{exact} + \boldsymbol{\varepsilon}_u$$

Régularisation par TSVD :

53 ou 55 valeurs singulières conservées

Résidus  $\approx$  bruit sur sortie (Morozov)



\* D. Maillet, S. André, J.C. Batsale, A. Degiovanni, C. Moyne, Thermal Quadrupoles – Solving the heat equation through integral transforms, Wiley, 2000

## 2. Modèles ARX

$$y_k = - \sum_{\substack{i=1 \\ i < k}}^{n_a} a_i y_{k-i} + \sum_{\substack{j=1 \\ j \leq k}}^{n_b} b_j u_{k-j+1-n_r}$$

partie  
AutoRégressive
partie  
eXogène

Modèle scalaire obtenu par pondération entre termes de relaxation et termes de forçage, en faisant glisser le temps initial\*

4 étapes:

- Choix de l'ordre du modèle:  $n_a$ ,  $n_b$ ,  $n_r$  (retard)
- Calibrage = estimation des  $a_i$  et des  $b_j$  : moindres carrés ordinaires
- Calcul des résidus
- Validation en direct du jeu de coefficients sur une autre expérience

Sur **données exactes** (températures faces AV/AR de la plaque), sélection du meilleur jeu de  **$n_a, n_b, n_r$**  pour un jeu de paramètres entiers variant entre limites extrêmes, en minimisant le critère de Akaike:

$$AIC_c = m \ln \left( \frac{1}{m} \sum_{k=1}^m (y_{mesure}[k] - y_{ARX}[k])^2 \right) + 2n + m[\ln(2\pi) + 1] + \frac{2n(n+1)}{m-n-1}$$

Avec :


- $m$  le nombre de mesures
  - $y_{mesure}$  la sortie « mesurée »
  - $y_{ARX}$  la sortie calculée par le modèle ARX (en mode « simulation »)
  - $n$  le nombre de paramètres ( $n = n_a + n_b + 1$ )
- Cas n°1 -  $1 \leq n_a \leq 5, 1 \leq n_b \leq 5$  et  $n_r = 0$  (25 modèles ARX en compétition pour l'AICc)
  - Cas n°2 -  $1 \leq n_a \leq 5, 1 \leq n_b \leq 5$  et  $0 \leq n_r \leq 5$  (150 modèles ARX en compétition)
  - Cas n°3 -  $1 \leq n_a \leq 10, 1 \leq n_b \leq 10$  et  $n_r = 0$  (100 modèles ARX en compétition)
  - Cas n°4 -  $1 \leq n_a \leq 10, 1 \leq n_b \leq 10$  et  $0 \leq n_r \leq 10$  (1100 modèles ARX en compétition)

### Résultats :

Cas	$n_a$	$n_b$	$n_r$	fit (%)
1	5	5	0	99.89886
2	5	5	4	99.99695
3	9	10	0	99.99954
4	7	6	3	99.99997


$$fit = \left( 1 - \frac{\| \mathbf{y} - \mathbf{y}_{ARX}(\mathbf{a}, \mathbf{b}) \|}{\| \mathbf{y} - \mathbf{y}_{average} \|} \right)$$

## Sur données exactes ( $\sigma_u = 0$ K, $\sigma_y = 0$ K)



Cas	$n_a$	$n_b$	$n_r$	fit (%)
1	5	5	0	99.89886
2	5	5	4	99.99695
3	9	10	0	99.99954
4	7	6	3	99.99997

## Sur données bruitées ( $\sigma_u = 0.2$ K, $\sigma_y = 0.05$ K)



Cas	$n_a$	$n_b$	$n_r$	fit (%) par rapport à $y_{noise}$	fit (%) par rapport à $y_{exact}$
1	4	5	0	94.32609	97.13266
2	4	5	5	94.39405	97.32243
3	4	10	0	94.57951	97.82692
4	7	7	7	94.86628	98.82261

### 3. Du modèles ARX au modèle convolutif

$$\sum_{\substack{i=0 \\ i < k}}^{n_a} a_i y_{k-i} = \sum_{\substack{j=1 \\ j \leq k}}^{n_b} b_j u_{k-j+1-n_r} \quad \text{où } a_0 = 1$$

→ ressemble à un double produit de convolution discret

On complète les coefficients  $a$  et  $b$  par des zéros → vecteurs  $\mathbf{a}_{\text{large}}$  et  $\mathbf{b}_{\text{large}}$  ( $m \times 1$ )

$$\mathbf{N}(\mathbf{a}_{\text{large}}) \mathbf{y}_{ARX} = \mathbf{N}(\mathbf{b}_{\text{large}}) \mathbf{u}$$


$$\Rightarrow \mathbf{y}_{ARX} = (\mathbf{N}(\mathbf{a}_{\text{large}}))^{-1} \mathbf{N}(\mathbf{b}_{\text{large}}) \mathbf{u} = \mathbf{C} \mathbf{u}$$

Rappel:  $\mathbf{y}_{conv} = \Delta t \mathbf{N}^2(\mathbf{f}) \mathbf{N}(\mathbf{w}) \mathbf{u} = \mathbf{M}(\mathbf{w}) \mathbf{u}$


Identification:  $\mathbf{y}_{conv} = \mathbf{y}_{ARX} \Rightarrow \mathbf{N}(\mathbf{w}) = \frac{1}{\Delta t} \mathbf{N}^2(\mathbf{f}^+) \mathbf{C}$

⇒  $\mathbf{w}$  (valeurs échantillonnées de transmittance  $w(t)$ ) = première colonne de  $\frac{1}{\Delta t} \mathbf{N}^2(\mathbf{f}^+) \mathbf{N}^{-1}(\mathbf{a}_{\text{large}}) \mathbf{N}(\mathbf{b}_{\text{large}})$


et  $\tilde{\mathbf{w}} = \mathbf{N}(\mathbf{f}) \mathbf{w}$  (valeurs moyennes par intervalle de  $w(t)$ ) est égal à la première colonne de  $\frac{1}{\Delta t} \mathbf{N}(\mathbf{f}^+) \mathbf{N}^{-1}(\mathbf{a}_{\text{large}}) \mathbf{N}(\mathbf{b}_{\text{large}})$



ZOOM



$$\tilde{w} = N(f) w$$




NB: La reconstruction de la transmittance ne fonctionne pas si les données  $u$  et  $y$  sont bruitées

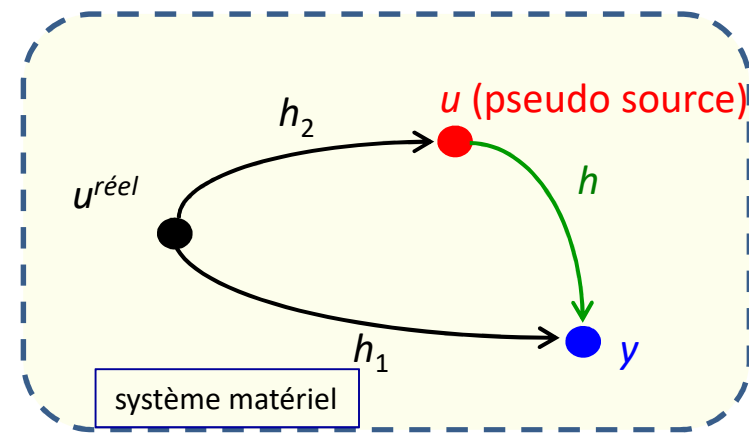
## Interprétation physique

$$y = \mathbf{M}(z_1) \mathbf{q}; \quad u = \mathbf{M}(z_2) \mathbf{q} \Rightarrow \mathbf{M}(z_2) y = \mathbf{M}(z_1) u \Leftrightarrow z_2^* y = z_1^* u$$

$$\mathbf{N}(a_{\text{large}}) y_{ARX} = \mathbf{N}(b_{\text{large}}) u$$



- $q(t)$  : source réelle
- $\theta_1(t)$ : pseudo source
- $\theta_2(t)$ : conséquence





## 4. Conclusions/perspectives

- Modèle convolutif générique universel en calcul direct (thermique instationnaire)  
**si** régime permanent initial, système LTI et excitation unique séparable  
**mais** identification de réponse impulsionnelle souvent difficile en inverse  
(algorithmes de régularisation: TSVD, Tikhonov, paramétrisation non isochrone\*...)
  
- Résidus de calibration ARX faibles (cas avec ou sans bruit)
- Modèles ARX robustes en validation et utilisables en estimation de sources
- **mais** volatilité des paramètres  $a$  et  $b$  estimés
- lien modèle ARX/convolutif établi
  
- Perspectives : évaluer les écarts types des  $a$  et  $b$  estimés lors de calibration

**Groupe « METTI (Mesures Thermiques et Techniques Inverses) »**

**« Inversion de données faisant appel à un modèle en thermique, quels apports de l'intelligence artificielle ? »**

Journée thématique SFT - Jeudi 8 juin 2023

organisée par : Fabrice Rigollet (IUSTI), Jean-Luc Battaglia (I2M), Denis Maillet (LEMTA)

La journée thématique « Inversion de données faisant appel à un modèle en thermique, quels apports de l'intelligence artificielle ? » s'est tenue le 08 Juin 2023 au FIAP, 30 rue Cabanis, Paris 14<sup>ème</sup> arrondissement.

La journée a réuni 32 personnes dont 7 doctorants, 2 jeunes chercheurs, 2 ingénieurs et 21 chercheurs et enseignants chercheurs. Un des présentateurs était en connexion à distance depuis le Brésil. Outre la présentation d'introduction, 9 présentations ont eu lieu en 2 sessions séparées par un repas pris sur place.

L'objectif de cette journée était de partager les différentes pratiques, existant dans la communauté de la SFT, concernant le traitement de données expérimentales (les *mesures*, les *datas*) et la construction d'un modèle du système qui a généré ces *datas*. Les activités identifiées dans ce cadre, et régulièrement mises en œuvre dans le groupe METTI, peuvent se ranger en 3 catégories : a) identification expérimentale du modèle direct qui prédit les *datas* de sorties pour des entrées données, b) construction d'un modèle direct rapide à partir d'un modèle détaillé plus lourd et c) utilisation d'un modèle pour la résolution de problème inverse de mesures.

Ces 3 catégories ont été abordées dans la journée. Les outils d'apprentissage statistique (faisant partie du grand domaine de l'IA, Intelligence Artificielle) étant de plus en plus utilisés pour modéliser le lien entre des données d'entrées et des données de sorties, deux tiers des présentations ont illustré leur utilisation en transferts radiatifs en milieu participant (#3, #7) ou entre surfaces opaques (#4), en mécanique des fluides (#5, #8) et en contrôle non destructif par voie thermique (#1). De plus, hors outils de l'IA, deux présentations ont montré l'intérêt d'utiliser en transferts thermiques instationnaires des modèles dont la structure s'appuie soit sur des dérivées d'ordre non-entier des entrées et des sorties (#2) ou bien sur le principe de convolution temporelle (#9) dont la version ARX est plus parcimonieuse en paramètres. Enfin, la méthode de réduction de modèle par amalgame modal (AROMM) a été présentée sur un problème de rayonnement instationnaire entre surfaces, couplé à la convection (#6).

Cette journée a permis de faire des parallèles intéressants entre différentes pratiques, utilisant ou pas des outils de l'IA. Il était intéressant notamment de noter que l'hybridation des 2 types de pratiques peut être envisagée : par exemple les outils de l'IA pour la détection de défaut, et les outils 'physiques' pour la caractérisation de ces défauts (#1). Ou bien, dans des problèmes couplés, des outils 'physiques' pour résoudre une partie des transferts et les outils de l'IA pour d'autres (divergence du flux radiatif #7), avec souvent un gain de temps à l'appui, une fois la phase d'apprentissage réalisée. Les auteurs (#7) comparent d'ailleurs les outils de l'IA à un 'super-interpolateur' dans leur démarche. Cette approche hybride trouve son point culminant dans l'utilisation de *réseaux de neurones informés par la physique* (PINN, #8). Un point de vigilance soulevé en #1 concerne l'aspect pénalisant des outils de l'IA en termes de consommation énergétique et de ressources matérielles.

Ce premier rendez-vous en appelle certainement d'autres avec, parmi les questions à aborder, quelques propositions comme : quand faut-il privilégier l'IA ? En cas de « grand » nombre d'entrées et « grand » nombre de sorties (à définir) ? Peut-on imaginer un ou deux cas de comparaison de performances des différentes approches ? En identification de modèle ? En inversion de mesures ? Enfin, un autre aspect de l'utilisation de ces outils n'a pas été évoqué à cette première journée : Le « design numérique » de matériaux à propriétés (radiatives, conductives par exemple) souhaitées.

Un programme avec résumés a été rédigé et mis en ligne, avec les présentations. De plus, le premier exemplaire de *Cahier de la Thermique* a été rédigé sur la base de cette journée.

- #1 - 10:15 - 10:40 Emmanuelle Abisset-Chavanne, Malo Lecorgne, Morgane Suhas, Marie Marthe Groz, Thomas Lafargue, Christophe Pradère (I2M, Bordeaux) - Quel apport de l'IA dans l'obtention et le traitement des données expérimentales ?**
- #2 - 10:40 - 11:05 Jean-Luc Battaglia (I2M, Bordeaux) - Identification de systèmes thermiques linéaires et non linéaires par des structures mathématiques d'intégration d'ordre non entier.**
- #3 - 11:35 – 12 :15 Frédéric André (Partie 1) et Cindy Delage (partie 2) (CETHIL, Lyon) – Combinaison de modèles physiques et d'outils d'apprentissage statistique pour l'approximation des propriétés radiatives d'atmosphères non-uniformes**
- #4 - 12:15 – 12 :40 Marie-Hélène Aumeunier, Alexis Juven (CEA, Cadarache) – Réseaux neuronaux convolutifs pour la thermographie quantitative en environnement complexe.**
- #5 - 14:20 – 14 :45 Helcio Orlando (COPPE, Rio de Janeiro) et al. – Metamodel based on evolutionary neural networks for the solution of inverse problems within the Bayesian framework of statistics.**
- #6 - 14:45 – 15 :10 Benjamin Gaume, Yassine Rouizi, Frédéric Joly, Olivier Quéméner (LMEE, Evry Val d'Essone) - Apport des modèles réduits pour la mesure thermique indirecte en temps réel dans un four rayonnant**
- #7 - 15:10 – 15 :35 Olivier Farges, Alex Royer, Pascal Boulet (LEMTA, Nancy), Daria Burot (Safran Aircraft Engine) – Modélisation du transfert radiatif dans des milieux participants, par réseaux de neurones bayésiens et méthode de Monte Carlo.**
- #8 - 15:35 – 16 :00 Yoann Cheny, Mickaël Delcey, Adrien Ganz, Sébastien K. de Richter (LEMTA, Nancy) – Réseaux de neurones informés par la physique (PINNs) pour la reconstruction de courants de gravité.**
- #9 - 16:00 – 16 :25 Denis Maillet, Benjamin Rémy, Adrien Barthélemy (LEMTA, Nancy) – Construction de modèles convolutifs transitoires ou paramétriques (ARX) pour une utilisation ultérieure directe ou inverse en thermique**