

# Estimation du flux de chaleur sur les composants face au plasma du Tokamak WEST par réseau de neurones.

Yann ANQUETIN<sup>1\*</sup>, Jonathan GASPAR<sup>1</sup>, Fabrice RIGOLLET<sup>1</sup>, Yann CORRE<sup>2</sup>,  
Quentin TICHIT<sup>2</sup>, Jean-Laurent GARDAREIN<sup>1</sup>

<sup>1</sup>Aix Marseille Univ, CNRS, IUSTI, Marseille, France,

<sup>2</sup>CEA, Institute for Research on Fusion by Magnetic confinement, 13108 St-Paul-Lez-Durance, France

\* (auteur correspondant : yann.anquetin@univ-amu.fr)

**Résumé** - Cet article présente le développement d'un réseau de neurones pour la résolution d'un problème inverse d'estimation de flux. La forme et l'intensité d'un flux de chaleur surfacique sont estimées à partir de mesures de températures enfouies. Le développement de cet outil se fait en deux étapes avec une première partie centrée sur l'analyse de sensibilité du problème inverse et une seconde partie centrée sur le développement du réseau de neurones utilisé pour la résolution. Les performances du réseau de neurones sont validées sur des données numériques puis expérimentales.

## Nomenclature

$x_0$	position du maximum de flux	$\phi$	flux de chaleur
$S$	facteur d'étalement	$\phi_m$	flux de chaleur maximum
$Z^*$	sensibilité réduite	$\lambda_q^t$	longueur de décroissance du flux
		$\phi_{BG}$	flux environnement

## 1. Introduction

Des recherches sur la fusion par confinement magnétique sont menées dans des machines appelées tokamak. Afin d'assurer l'intégrité de la machine il est nécessaire de contrôler les échauffements des composants face au plasma (CFP) soumis à des flux de chaleur jusqu'à 10 MW/m<sup>2</sup> en régime permanent. Dans le tokamak WEST [1] des fibres à Réseaux De Bragg (RDBs) sont enfouies 5 mm sous la surface des CFP pour les protéger des flux de chaleur en surface. Ces fibres permettent de mesurer 11 points de températures le long du CFP, celui-ci étant constitué de 35 blocs (MB) de tungstène de 12 mm de large chacun (1 point de mesure par MB pour 11 des 35 MB). Il est possible, par méthode inverse, de caractériser le flux de chaleur en surface à partir des mesures d'échauffements enfouies dans la matière. On distingue les problèmes inverses, des problèmes directs, par le fait de remonter des conséquences (ici l'échauffement) vers les causes (ici le flux de chaleur). La résolution de tels problèmes peut être coûteuse en temps de calcul dans le cas de systèmes complexes ou quand le nombre de paramètres à estimer est grand. De précédents travaux [2] ont montré la fiabilité des estimations obtenues en couplant un modèle 3D non-linéaire et instationnaire du composant et un algorithme de minimisation itérative par gradient conjugués. Cependant, cette méthode nécessite des temps de calculs importants (plusieurs jours) pour quelques dizaines de secondes d'expérience et quelques heures si on considère un problème stationnaire. Lors des sessions expérimentales sur WEST il est important d'avoir une première estimation du flux entre deux décharges du plasma, soit dans un intervalle d'environ 10 minutes. On présente dans cet article le développement d'un nouvel outil basé sur l'intelligence artificielle (IA) permettant l'estimation quasi-instantanée du flux de chaleur dans le cas stationnaire.

Le problème inverse est présenté dans la section 2, la distribution spatiale du flux de chaleur caractérisée par 5 paramètres ainsi que les sensibilités des températures à chacun de ces paramètres sont présentées. Le développement du réseau de neurones, sa validation numérique et son utilisation sur des données expérimentales sont présentés dans la section 3.

## 2. Le problème inverse d'estimation de flux

### 2.1. Distribution spatiale du flux surfacique

On dispose avec notre fibre à réseaux de Bragg enfouie de 11 mesures de températures avec une résolution spatiale de 12,5 mm. Afin d'estimer une répartition continue du flux de chaleur en surface un a priori sur sa forme est nécessaire. Les travaux de Eich et al. [3] ont permis de définir la forme du flux de chaleur déposé sur les CFP en fonction de plusieurs paramètres comme présenté dans (1).

$$\phi(x) = \frac{\phi_m}{2} * \exp\left(\left(\frac{S}{2\lambda_q^t}\right)^2 - \frac{x - x_0}{\lambda_q^t}\right) * \operatorname{erfc}\left(\frac{S}{2\lambda_q^t} - \frac{x - x_0}{S}\right) + \phi_{BG} \quad (1)$$

On cherche pour caractériser le flux de chaleur à estimer les paramètres en gras :

- $\phi(x)$  : Le flux de chaleur déposé dans la direction poloïdale et fonction du temps (W/m<sup>2</sup>)
- $\phi_m$  : Le flux de chaleur maximum (W/m<sup>2</sup>)
- $\phi_{BG}$  : Le flux de chaleur résultant du rayonnement du plasma dans la machine (W/m<sup>2</sup>)
- $\lambda_q^t$  : La longueur caractéristique de décroissance du flux sur les composants (m)
- $S$  : Le facteur d'étalement dans la région privée (m)
- $x_0$  : La position de la dernière surface magnétique fermée (m)

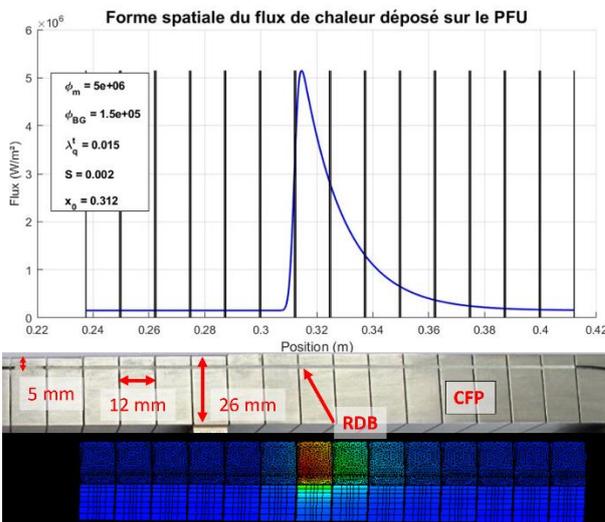


Figure 1 : Forme du flux déposé sur la surface d'un CFP, vue d'un CFP équipé d'un RDB et son modèle 3D

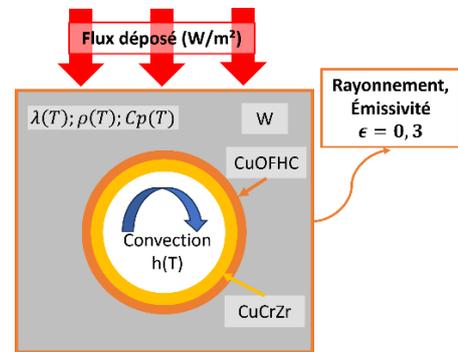


Figure 2 : Schéma du modèle thermique du CFP

Cette forme de flux a été identifiée à partir de mesures par thermographie infrarouge sur plusieurs machines avec des matériaux en carbone (forte émissivité) et fait office de référence dans le domaine de la fusion et représente fidèlement les observations faites dans WEST [4].

## 2.2. Analyse de sensibilité

Afin de quantifier la capacité théorique à estimer correctement les paramètres du flux de chaleur à partir de nos mesures de température, on étudie la sensibilité des températures à chacun de ces paramètres. Le modèle thermique utilisé pour calculer les températures est un modèle 3D non-linéaire (propriété thermique fonction de la température), avec de la convection fonction de la température dans le tube de refroidissement intérieur et du rayonnement sur les surface externe et stationnaire (valide pour des décharges plasmas stable supérieur à 5s, Figure 2). Afin de pouvoir comparer entre eux les résultats obtenus pour chaque paramètre entre eux on s'intéressera aux sensibilités réduites (équation 2) afin de comparer des grandeurs similaires (°C).

$$Z_{X_i}^* = \frac{T_{X_i+\delta X_i} - T_{cas\ ref}}{\delta X_i} * X_i \quad (2)$$

$Z_{X_i}^*$  est la sensibilité réduite des températures au paramètre  $X_i$ ,  $i=1$  à 4 ou 5, les températures à la position des capteurs pour chaque cas sont notées  $T_{cas\ ref}$ , les températures après variation d'un paramètre de 1% sont notées  $T_{X_i+\delta X_i}$  et  $\delta X_i$  est la variation du paramètre  $X_i$ . La sensibilité des températures aux différents paramètres est fonction de la valeur de ces derniers rendant le problème inverse non-linéaire. On définit donc une centaine (104) de cas représentatif des flux de chaleurs attendus dans WEST (Tableau 1).

$\phi_m$	$\phi_{BG}$	$\lambda_q^t$	$S$	$x_0$
MW/m <sup>2</sup>	kW.m <sup>2</sup>	mm	mm	mm
5	150	5 ; 10 ; 15 ; 20	2 ; 5	306 – 318 (tous les mm)

Tableau 1 : Valeurs des différents paramètres de forme du flux de chaleur

La Figure 3 présente les sensibilités réduites calculées pour chaque capteur et pour un jeu de paramètres du flux (indiqués sur la figure) avec en abscisses le numéro du réseau de Bragg.

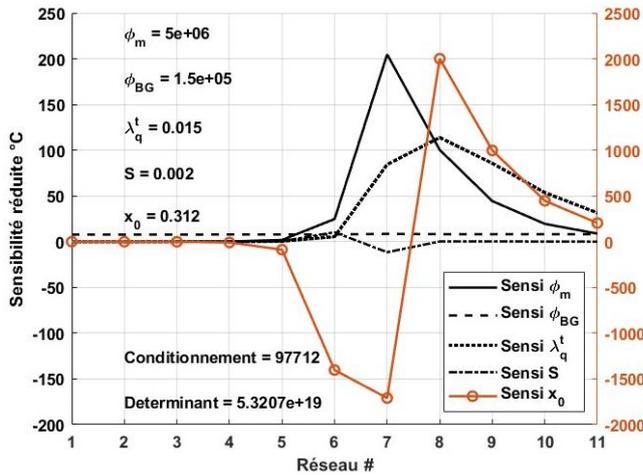


Figure 3 : Sensibilité réduite pour chaque paramètre (échelle à gauche) (-) :  $Z_{\phi_m}^*$ , (- -) :  $Z_{\phi_{BG}}^*$ , (...) :  $Z_{\lambda_q^t}^*$ , (-.-) :  $Z_S^*$ , (échelle à droite) (-o-) :  $Z_{x_0}^*$

En bas à gauche de la figure est indiquée la valeur du conditionnement et du déterminant qui seront discutés dans la partie 2.3. On note que la sensibilité réduite du paramètre  $x_0$  est d'un ordre de grandeur supérieur par rapport aux autres paramètres. La Figure 3 montre ainsi que la variation de 1% de chaque paramètre produit bien un effet mesurable sur les échauffements. Il n'y a pas de corrélation flagrante (2 à 2) entre les sensibilités aux différents paramètres. De plus le déterminant de  $Z^{*t}Z^*$  est grand ce qui nous indique que la matrice est bien non-singulière. Plusieurs autres indicateurs quantitatifs sont présentés à la section suivante.

Dans la suite deux cas sont considérés, le premier où 5 paramètres ( $\phi_m$ ,  $\phi_{BG}$ ,  $\lambda_q^t$ ,  $S$  et  $x_0$ ) sont estimés et le second où  $S$  est supposé connu et  $\phi_m$ ,  $\phi_{BG}$ ,  $\lambda_q^t$  et  $x_0$  sont les paramètres estimés. Ce choix est motivé par la possibilité d'estimer autrement ce paramètre (par mesure infrarouge) et de simplifier l'estimation des autres paramètres.

### 2.3. Optimisation du problème inverse à résoudre

On a confirmé dans la partie 2.2 la faisabilité de l'inversion en s'assurant que la matrice de sensibilité était non singulière. On souhaite désormais quantifier la confiance relative que l'on peut attendre de nos estimations. Pour cela il existe dans la littérature plusieurs indicateurs permettant de quantifier cette information [5]. Ces indicateurs sont basés sur la matrice « d'amplification des erreurs »  $P^*$  calculée à partir des sensibilités réduites et que l'on multiplie par la variance du bruit de mesure supposé gaussien  $\sigma_\epsilon^2$  (ici 0,1 °C bruit de mesure de la chaîne d'acquisition des données dans WEST) pour obtenir la matrice de covariance relative  $C^*$  dont les éléments diagonaux contiennent les carrés des écart types relatives associées à chacun des paramètres estimés.

$$C^* = \sigma_\epsilon^2 * P^* \text{ avec } P^* = [Z^{*t} Z^*]^{-1} \quad (3)$$

Pour un bruit  $\sigma_\epsilon^2$  et un niveau de confiance  $1 - \alpha = 95,4\%$  ( $\alpha$  : niveau de signification statistique) fixé, la taille caractéristique  $r_{caract}$  de la région de confiance (hyper-ellipsoïde de dimension  $n=4$  ou  $n=5$ ) est donnée par l'équation (4) [5] avec  $\sqrt{\chi_{1-\alpha}^2(4)} = 3,113$  et  $\sqrt{\chi_{1-\alpha}^2(5)} = 3,359$  (donné par exemple par `chi2inv(1-alpha, n)` dans Matlab®). Il s'agira de minimiser cet indicateur :

$$r_{caract} = \frac{\sqrt{\chi_{1-\alpha}^2(n)} * \sigma_\epsilon}{[\det(Z^{*t} Z^*)]^{\frac{1}{2n}}} \quad (4)$$

Le conditionnement de  $[Z^{*t} Z^*]$  (équation 5), avec  $\lambda_{max}$  et  $\lambda_{min}$  respectivement la plus grande et la plus petite valeur propre de  $[Z^{*t} Z^*]$ , représente l'étirement de l'ellipsoïde formé par la région de confiance (carré du ratio grand axe/petit axe).

$$cond(Z^{*t} Z^*) = \frac{\lambda_{max}(Z^{*t} Z^*)}{\lambda_{min}(Z^{*t} Z^*)} \quad (5)$$

Il traduit le déséquilibre de la qualité d'estimation des différents paramètres, dû à des déséquilibres d'amplitude de leur sensibilité réduite. Dans le cas idéal cet indicateur devrait tendre vers 1 (région de confiance sphérique), on cherche à minimiser sa valeur. Finalement l'indicateur de A-optimalité est la moyenne des écarts type en % que l'on peut espérer lors de l'estimation de chaque paramètre, cet indicateur est calculé à l'aide de la diagonale de  $C^*$ . On cherche à minimiser cet indicateur. Ces trois indicateurs (taille caractéristique de la région de confiance, conditionnement et A-optimalité) vont nous permettre de quantifier la qualité d'estimation attendue pour les 104 jeux de paramètres.

Les Figure 4 et Figure 5 résument les résultats de l'étude pour les deux cas (avec et sans estimation de  $S$  respectivement en bleu et orange) et tous les jeux de paramètres. La Figure 4 présente en échelle logarithmique la taille caractéristique de l'hyper-ellipsoïde  $r_{caract}$  (en ordonnée) en fonction du conditionnement  $cond(Z^{*t} Z^*)$  (en abscisses) pour chaque jeu de paramètres. La population « Sans estimation S » (**x oranges**) a des valeurs de  $r_{caract}$  légèrement inférieures à la population « Avec estimation du S » (**+ bleus**). Pour le conditionnement les valeurs de la population « Avec » vont de  $\sim 10^5$  à  $\sim 10^{10}$ , tandis que la valeur maximale du conditionnement pour la population « Sans » est de  $\sim 10^6$ . La Figure 4 montre donc l'intérêt de ne pas estimer le paramètre  $S$  s'il est possible de le déterminer autrement. La Figure 5 confirme également cette observation en illustrant que le critère d'A-optimalité est bien inférieur lorsque l'on n'estime pas le paramètre  $S$  et ce de plusieurs ordres de grandeurs suivant les cas. On rappelle que le critère A-optimalité représente la moyenne des écart type en % que l'on peut attendre lors de l'estimation de chaque paramètre. On observe notamment que, sans

estimer  $S$ , cet écart type moyen dépasse rarement 1% et est souvent proche de 0.2%. Les résultats de cette étude démontrent l'intérêt de n'estimer que 4 paramètres et de fixer le paramètre  $S$ . Pour la suite nous fixons la valeur du paramètre  $S$  à 2 mm qui est une valeur provenant d'analyse infrarouge réalisée sur WEST [6].

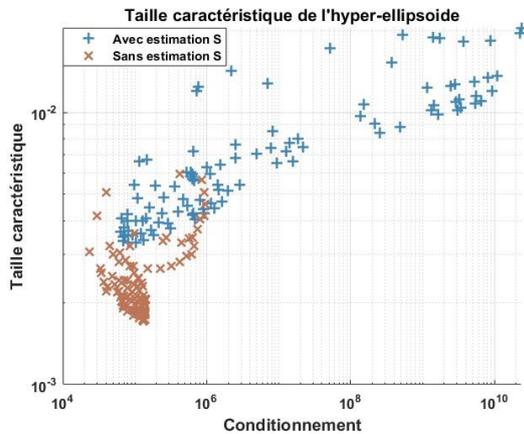


Figure 4 : Taille caractéristique de la région de confiance en fonction du conditionnement pour les deux cas (avec estimation  $S$  : « + » bleus, sans estimation du  $S$  : « x » oranges) et chaque jeu de paramètres

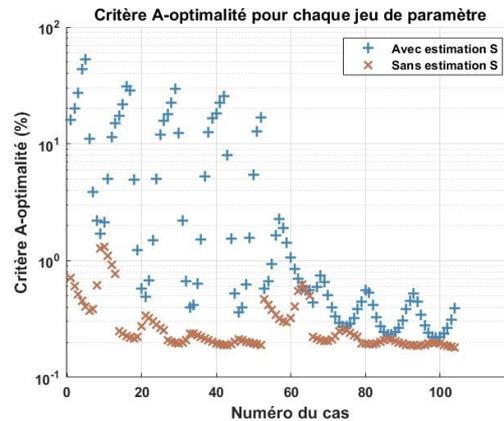


Figure 5 : Comparaison du critère A-optimalité pour les deux cas (avec estimation  $S$  : « + » bleus, sans estimation du  $S$  : « x » oranges) et chaque jeu de paramètres

### 3. Utilisation de l'IA pour la résolution de problèmes inverse

#### 3.1. Développement du réseau de neurones

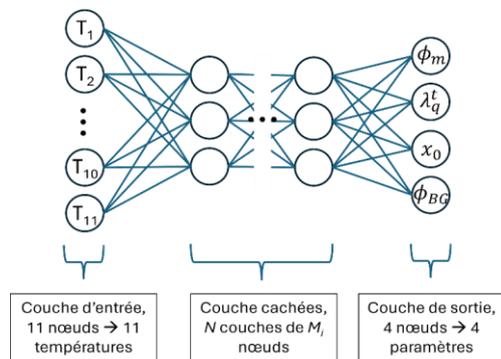


Figure 6 : Schéma d'un perceptron multicouche complètement connecté

On a vu dans la partie 2.3 l'intérêt de fixer la valeur du paramètre  $S$  et de concentrer l'estimation sur les 4 paramètres restants, caractérisant la distribution spatiale du flux de chaleur. L'estimation devant avoir lieu entre décharges plasma lors de sessions expérimentales l'estimation doit être rapide (temps inférieur à 10 min) tout en tenant compte des différentes non-linéarités de nos problèmes direct et inverse. Pour cela nous avons fait le choix de développer un réseau de neurones afin de créer un « modèle inverse » ayant pour entrées les 11 valeurs de températures et pour sortie la valeur des 4 paramètres définissant le flux de chaleur.

Ce genre de problèmes est appelé problème de régression et est généralement résolu en utilisant un réseau de neurones de type « perceptron multicouches » [7] dont le schéma de fonctionnement est illustré par la Figure 6. Le réseau possède donc 11 nœuds en entrée pour les 11 mesures de température, 4 nœuds en sortie pour les 4 paramètres, le nombre de couches cachées et de nœuds sont ajustés afin d'obtenir les meilleures performances lors de l'estimation. Le réseau présentant les meilleures performances comporte  $N=8$  couches cachées et un nombre  $M_i$  de nœuds pour chacune allant de  $M_i=1024$  à  $M_i=128$  (première couche,  $M_1=1024$ , couches 2 à 6  $M_{2-6}=512$ ,  $M_7=256$  et  $M_8=128$ ). Les données utilisées pour l'entraînement du réseau sont générées à partir du modèle 3D non-linéaire et stationnaire du composant [2]. Un ensemble de

flux de chaleur représentatifs de WEST est défini puis les températures à la position des capteurs sont calculées en régime permanent. Les valeurs des paramètres sont résumées dans le Tableau 2.

	$\phi_m$ (MW/m <sup>2</sup> )	$\phi_{BG}$ (MW/m <sup>2</sup> )	$\lambda_q^t$ (mm)	$S$ (mm)	$x_0$ (mm)
Valeurs des paramètres	0,1 puis 0.5 → 10 tous les 0,5	0 → 0,125 tous les 0,25	5 → 50 tous les 2,5 mm	2	275 → 362 tous les ~4 mm

Tableau 2 : Valeurs des paramètres du flux pour la base de données d'entraînement de l'IA

La base de données complète comporte plus de 55 000 cas qui sont répartis aléatoirement dans les données d'entraînement, de validation et de test [7] avec 70% des cas pour l'entraînement (39 100 cas), 15% pour la validation (9 879 cas) et 15% pour les tests (9 879 cas). Le développement et l'entraînement du réseau a lieu avec l'architecture Keras/TensorFlow [8]. Une fois l'entraînement réalisé (plusieurs jours de calculs) on peut prédire la valeur des paramètres en fonction des mesures de températures en l'espace de quelques ms. Afin de valider les performances de l'IA les valeurs des paramètres prédites par l'IA sont utilisées pour recalculer la température à la position des capteurs. Les températures recalculées en 1 à 2 minutes par le modèle thermique sont comparées aux températures de référence et l'écart quadratique moyen normalisé par la température maximale est calculé comme indicateur de performances pour chaque cas.

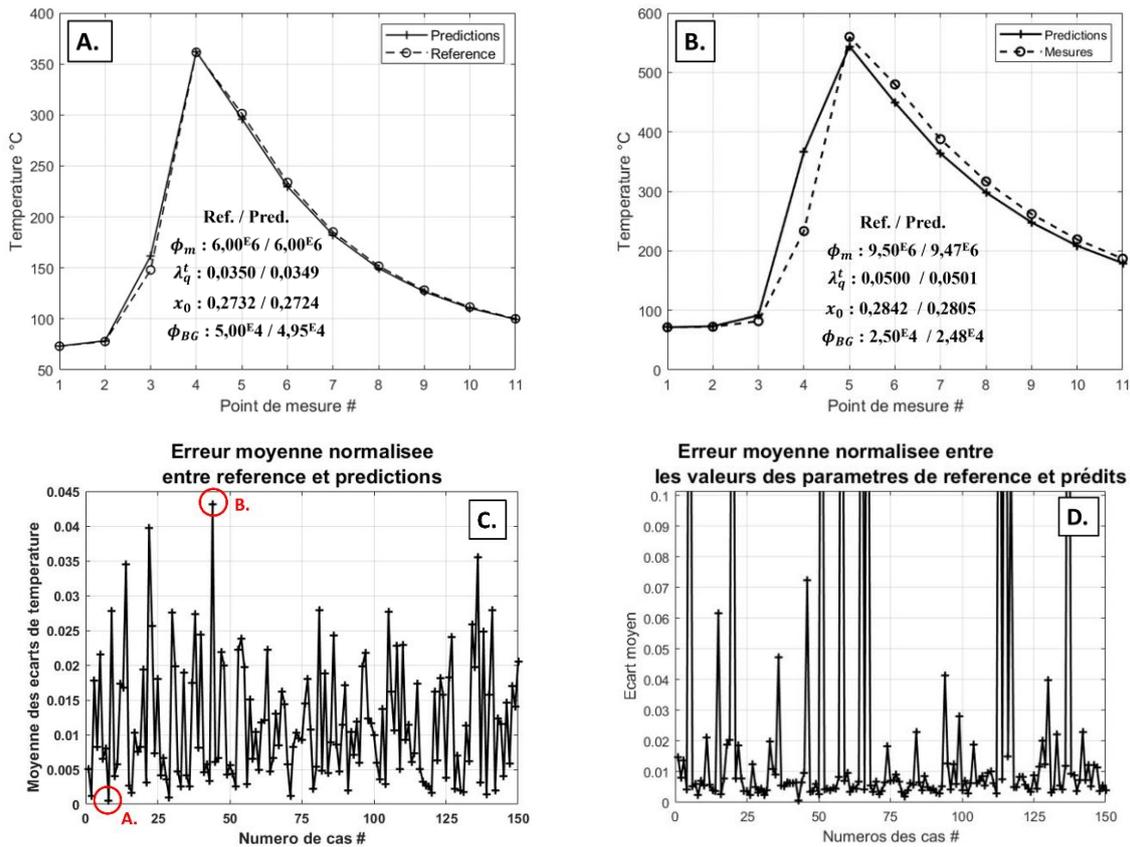


Figure 7 : Validation numérique des performances de l'IA, **A.** : comparaison entre estimation et référence pour le meilleur résultat de l'estimation, **B.** comparaison entre estimation et référence pour le pire résultat de l'estimation, **C.** écart moyen entre référence et estimation normalisé par la température maximum, **D.** moyenne des écarts moyens entre les paramètres prédits et de référence

Les résultats de la validation numérique sont présentés dans les Figure 7 **A.**, **B.**, **C.** et **D.**. La Figure 7 **A.** présente la comparaison entre températures recalculées et températures de références pour un cas correctement estimé. On voit que la forme de l'échauffement est bien retrouvée par le réseau de neurones (1% d'erreur au maximum pour le  $\phi_{BG}$ ). La Figure 7 **B.** présente le pire résultat obtenu pour la prédiction. L'écart de valeur entre les paramètres reste faible cependant l'impact sur les températures mesurées est plus clairement visible. La Figure 7 **C.** présente pour 150 cas recalculés de la population de test, l'erreur moyenne entre estimation et référence normalisées par la température max afin de s'affranchir des écarts de puissance entre les différents cas et avoir ainsi un indicateur de comparaison. Les cas **A.** et **B.** discuté précédemment sont entourés en rouge. On voit que l'erreur moyenne sur les estimations est inférieure à 5% de l'échauffement max et avec l'essentiel des cas pour lesquels l'écart est inférieur à 2% (moyenne 1.25%) validant l'entraînement du réseau. On remarque également sur la figure **D.** des écarts plus importants (jusqu'à 25%) dans la valeur des paramètres prédit par le réseau. Ces écarts sont dû à l'estimation du flux ambiant dont la sensibilité et l'intensité est moindre mais qui affecte peu les températures calculées.

### 3.2. Résultats du réseau de neurones sur des cas expérimentaux

On dispose des mesures de températures pour une 40<sup>aine</sup> de décharges réalisées lors de la campagne expérimentale de janvier à avril 2023. Le réseau développé dans la partie 3.1 est utilisé pour prédire en une centaine de ms la valeur des 4 paramètres  $\phi_m$ ,  $\phi_{BG}$ ,  $\lambda_q^t$  et  $x_0$  à partir de ces mesures. Pour évaluer la pertinence des prédictions, on calcule à l'aide du modèle thermique (1 à 2 minutes de calculs) les températures obtenues avec les paramètres prédits par notre réseau de neurones, les résultats sont présentés dans les Figure 8 **A.**, **B.** et **C.**. Avec cette méthode on estime donc le flux de chaleur en 1 à 2 minutes ce qui rend son utilisation compatible avec le délai entre deux plasmas (10<sup>aine</sup> de minute).

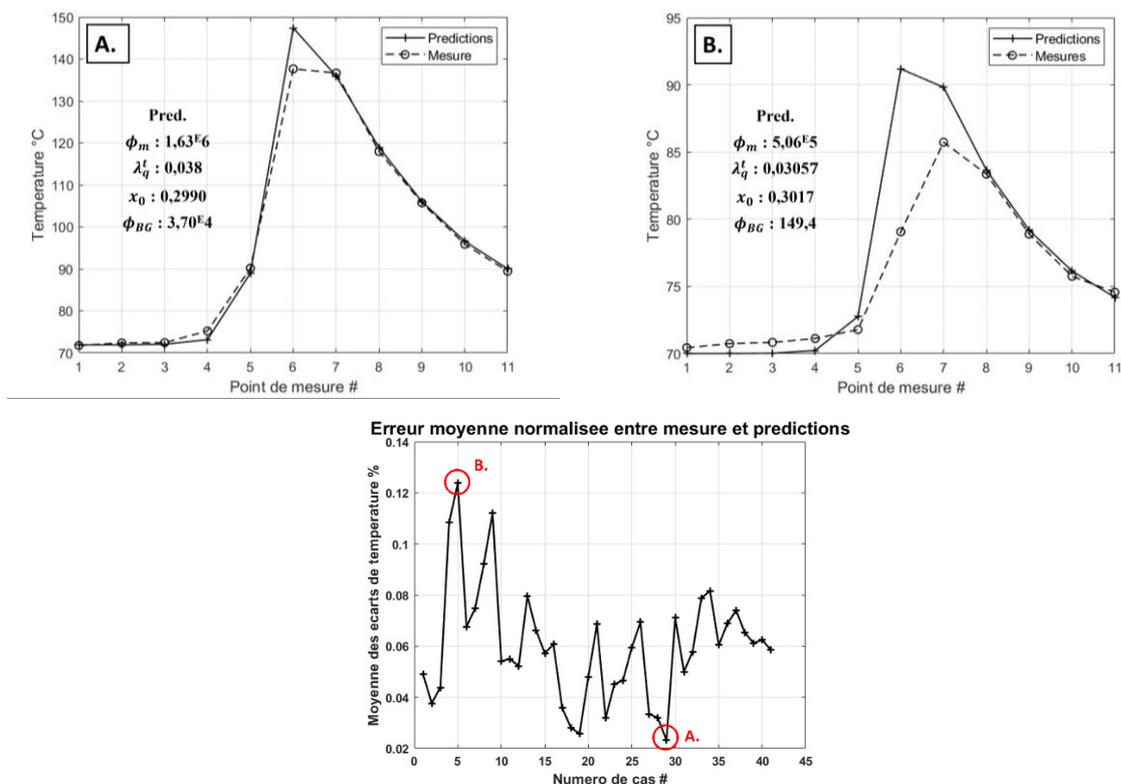


Figure 8 : Evaluation des performances de l'IA sur des données expérimentales : comparaison entre prédictions et mesures **A.** pour le meilleur résultat, **B.** pour le pire résultat, **C.** écart moyen entre mesures et prédictions normalisé par la température maximum

Comme pour les figures de la partie 3.1, les Figure 8 **A.** et **B.** présentent respectivement, la meilleure et moins bonne prédiction. Contrairement à la validation numérique, on remarque ici qu'on ne parvient jamais à retrouver parfaitement la bonne forme de flux, comme le montre les écarts de températures issus de ce dernier sur la Figure 8 **A.**. Ce résultat n'a rien de surprenant compte tenu des hypothèses simplificatrices, notamment sur l'état stationnaire (petits mouvements du plasma ou variation d'intensité dans le cas expérimental) mais également sur la distribution du flux surfacique qui reste une forme empirique. Néanmoins la Figure 8 **C.** présente des écarts moyens normalisés entre mesures et prédictions légèrement supérieurs aux écarts obtenus sur les cas numériques. On a pour les 40 cas étudiés une erreur quadratique moyenne proche de 10 % de la température maximale pour des décharges provoquant des échauffements de 15 °C à presque 200 °C ce qui montre la robustesse de cette méthode d'estimation sur une grande variété de plasma. Ces résultats encourageants permettent l'utilisation de ce réseau de neurones lors de la prochaine campagne expérimentale de WEST.

## 4. Conclusion

Dans cet article le développement et l'utilisation de l'IA pour la résolution de problème inverse en thermique sont présentés après avoir validé la faisabilité de cette estimation avec une analyse de sensibilité. Cette dernière a permis de démontrer la faisabilité de l'inversion et l'intérêt de n'estimer que 4 des 5 paramètres du problème afin de maximiser la confiance dans les résultats. Un réseau de neurone de type perceptron multicouche a ensuite été développé pour répondre à notre problématique et estimer la valeur de 4 paramètres nécessaires à définir la forme d'un flux de chaleur en surface à partir de mesures de températures enfouies dans les composants face au plasma du tokamak WEST. Cette IA permet de retrouver les températures mesurées par les RDBs lors de sessions expérimentales avec une précision moyenne inférieure à 10 % et avec un faible temps de calcul. Ce résultat démontre l'intérêt de l'IA dans la résolution de problèmes inverse en thermique. Cependant l'usage de ces nouveaux outils impose une certaine vigilance à avoir vis-à-vis des résultats. Tout d'abord le fonctionnement en « boîte noire » des réseaux de neurones demande de développer une méthode de validation des estimations. Dans cet article un calcul direct utilisant les valeurs estimées des 4 paramètres est réalisé puis en regardant les écarts entre température mesurées et calculées sont étudiés pour valider l'estimation. Il est aussi important de souligner que l'IA est complètement dépendante des données utilisées pour son entraînement et que l'on introduit donc un biais avec celles-ci. Il est donc nécessaire de s'assurer que ces données sont cohérentes et représentatives du problème à résoudre puisque l'IA ne fera ensuite qu'interpoler entre celles-ci.

## Références

1. [Bucalossi, J. et al \(2014\). \*Fusion Engineering and Design\*, 89\(7–8\), 907–912.](#)
2. [Anquetin, Y. et al \(2023\). \*Fusion Engineering and Design\*, 190, 113480.](#)
3. [Eich, T. et al \(2011\). \*Physical Review Letters\*, 107\(21\), 215001.](#)
4. [Gaspar, J. et al \(2021\). \*Nuclear Fusion\*, 61\(9\), 096027.](#)
5. Beck, J. V., & Arnold, K. J. (1977). *Parameter estimation in engineering and science*. New York: Wiley.
6. [Tichit, Q. et al \(2023\). \*Nuclear Materials and Energy\*, 37, 101537.](#)
7. Chollet, F. (2018). *Deep learning with Python*. Shelter Island, New York: Manning Publications Co.
8. TensorFlow, Keras. (n.d.). *TensorFlow*. from <https://www.tensorflow.org/guide/keras?hl=fr>