

Simulation des auto-échauffements par des réseaux neuronaux informés par la physique : détermination des limites de fatigue des composites stratifiés

Deep learning simulations of self-heating using physics-informed neural networks: determination of fatigue limits for laminated composites

Laurent GORNET

1 : GeM, UMR CNRS 6183
Ecole Centrale de Nantes
1 Rue de la Noë, 44321 Nantes
e-mail : laurent.gornet@ec-nantes.fr

Résumé

L'objectif de cette étude est de déterminer les propriétés de fatigue d'une nappe unidirectionnelle carbone/époxy haute résistance. Elle porte sur la reconstruction des caractéristiques de fatigue du pli élémentaire carbone/époxy à l'aide d'un réseau de neurones. Les réseaux de neurones, représentant les données expérimentales, sont mis en œuvre tout en satisfaisant les modèles thermiques décrivant l'auto-échauffement des composites stratifiés. Ces réseaux de neurones peuvent être qualifiés de modélisations PINN (« Physics-Informed Neural Networks »). Les essais de fatigue ont été réalisés à température ambiante sous un chargement cyclique en traction-traction à différentes stratifications. Des essais d'auto-échauffement ont également été menés sur ces matériaux composites stratifiés dans le but de déterminer leurs limites de fatigue. Les essais classiques de fatigue ont permis d'obtenir les courbes de Wöhler de ces matériaux composites stratifiés sous différents chargements. Les limites de fatigue obtenues par les deux méthodes ont été comparées avec succès.

Abstract

The objective of this study is to determine the fatigue properties of a high-strength unidirectional carbon/epoxy laminate. The study focuses on reconstructing the fatigue characteristics of the carbon/epoxy elementary ply using a neural network. The neural networks, which represent the experimental data, are implemented while satisfying thermal models that describe the self-heating of laminated composites. These neural networks can be described as PINN ("Physics-Informed Neural Networks") models. Fatigue tests were conducted at room temperature under cyclic tension-tension loading with different layups. Self-heating tests were also performed on these laminated composite materials to determine their fatigue limits. Traditional fatigue tests allowed for the generation of Wöhler curves for these laminated composites under different loading conditions. The fatigue limits obtained through both methods were successfully compared.

Mots Clés : fatigue, laminate, Réseaux de neurones physiquement informés

Keywords : fatigue, laminate, Physics-Informed Neural Networks

1. Caractérisation d'un matériau composite carbone époxy UD

L'objectif principal de cette étude est de simuler les propriétés de fatigue d'une nappe unidirectionnelle carbone/époxy haute résistance, matériau largement utilisé dans les applications aéronautiques, automobiles et autres secteurs exigeant une combinaison optimale de légèreté et de robustesse. L'accent est mis sur la reconstruction des caractéristiques de fatigue d'un pli élémentaire carbone/époxy à l'aide d'approches avancées basées sur les réseaux de neurones. Dans ce cadre, des réseaux de neurones artificiels ont été développés pour représenter les données expérimentales obtenues, tout en intégrant des modèles thermiques décrivant le phénomène d'auto-échauffement des composites stratifiés sous chargement cyclique. Ces réseaux de neurones, appelés modélisations PINN (Physics-Informed Neural Networks), se distinguent par leur capacité à intégrer des lois physiques dans le processus d'apprentissage, garantissant ainsi une meilleure précision et une robustesse accrue des prédictions. Des essais de fatigue ont été réalisés dans des

conditions contrôlées, à température ambiante, sous un chargement cyclique en traction-traction à une fréquence de 5 Hz. Différentes stratifications ont été testées afin de mieux comprendre l'influence de l'architecture du composite sur son comportement en fatigue. En complément, des essais spécifiques d'auto-échauffement ont été menés sur ces matériaux stratifiés pour déterminer les limites de fatigue. Ces essais consistent à mesurer la température générée dans le matériau en raison des cycles de chargement, dans le but de déterminer les limites de fatigue en corrélant le niveau d'échauffement avec la dégradation progressive du matériau [1-7]. Les essais classiques de fatigue ont permis de construire les courbes de Wöhler, qui représentent la relation entre le nombre de cycles à rupture et l'amplitude de chargement appliqué. Ces courbes offrent une vision complète des performances des matériaux composites stratifiés sous différents régimes de chargement. En parallèle, les limites de fatigue déterminées à partir des essais d'auto-échauffement ont été comparées avec celles obtenues par les essais classiques. Les résultats montrent une forte concordance entre les deux méthodes, ce qui valide l'approche basée sur l'auto-échauffement comme une alternative rapide et efficace pour évaluer la durabilité des composites [6].

2. Limite de fatigue par méthodes d'auto échauffement

Le matériau étudié est une nappe unidirectionnelle de carbone haute résistance et résine époxy. L'ensemble des essais de fatigue et auto-échauffement sont menés sur des stratifiés symétriques carbone/époxy de dimensions 250*20*2,5 millimètres (ASTM D3039, ISO 527). Les plaques créées sont polymérisées en bûche à vide dans un four, dans des conditions identiques à celles du cycle de fabrication industriel. Les propriétés mécaniques quasi-statiques et de fatigue du matériau ont été déterminées à partir d'une base canonique d'identification. Pour caractériser notre matériau élémentaire, les essais de traction quasi-statique jusqu'à rupture ont été menés sur les empilements $[0]_8$, $[+45/-45]_{4S}$, $[+67.5/-67.5]_{4S}$. L'identification complète des propriétés mécaniques du pli élémentaire est réalisée à partir de ces trois essais. Les conditions de chargement moyen en fatigue étudiées pour chaque stratification sont listées dans le Tableau 1. Ce tableau présente la contrainte moyenne appliquée à l'échelle du stratifié dans le sens de sollicitation en traction ($\overline{\sigma_{xx}}$) et la contrainte moyenne à l'échelle des plis constitutifs de chaque stratification dans le sens de la sollicitation en traction $\overline{\sigma_{12}}$ pour les plis à 45° et $\overline{\sigma_{22}}$ pour les plis à 90° du sens de la sollicitation). La stratification quasi-isotrope $[+45/-45/90/0]_S$ a été testé à un niveau d'effort qui mène à un niveau de contrainte dans les plis à 45° et 90° qui correspond à celui testé respectivement dans les stratifications $[+45/-45/+45/-45]_S$ et $[0/90/0/90]_S$. La courbe d'auto échauffement et la limite de fatigue sont présentées sur la (Figure 1). La contrainte moyenne apparente est donnée dans le tableau 1. Les ratios $R = \overline{\sigma_{xx}Min}/\overline{\sigma_{xx}Max}$ sont théoriquement de 0. Dans le cas de la stratification quasi isotrope, la limite d'endurance définie à 5 millions de cycles est de 400 MPa pour une contrainte apparente axiale de 250 MPa.

Stratifications	Echelle de la structure	Echelle du pli
$[+45/-45/+45/-45]_S$	$\overline{\sigma_{xx}} = 50 \text{ MPa}$	Pli à 45°: $\overline{\sigma_{12}} = 25 \text{ MPa}$
$[0/90/0/90]_S$	$\overline{\sigma_{xx}} = 335 \text{ MPa}$	Pli à 90°: $\overline{\sigma_{22}} = 41 \text{ MPa}$
$[+45/-45/90/0]_S$	$\overline{\sigma_{xx}} = 250 \text{ MPa}$	Pli à 45°: $\overline{\sigma_{12}} = 25 \text{ MPa}$ Pli à 90°: $\overline{\sigma_{22}} = 42 \text{ MPa}$

Tab1. Conditions de chargement étudiées en fonction des stratifications

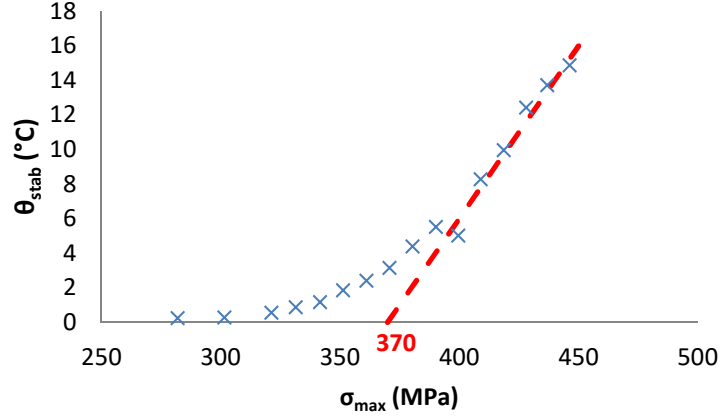


Fig 1 : Courbes d'auto-échauffement du $[+45/-45/90/0]_S$ sous une contrainte moyenne $\bar{\sigma}_{xx} = 250$ MPa. La limite de fatigue par auto échauffement est de 370 MPa

3. Modélisation par des réseaux de neurones

On cherche à identifier un réseau de neurones représentant des données expérimentales de fatigue tout en satisfaisant un modèle physique. On parle de modélisation par réseau de neurones de type PINN « Physics-Informed Neural Networks ». Identifier les caractéristiques les paramètres d'un réseau de neurones PINN c'est entraîner le réseau de neurones sur un jeu de données afin de représenter toutes les données expérimentales du domaine d'identification [8]. Dans le cas des PINN associés à des données expérimentales, on réalise une analyse inverse pour déterminer le réseau de neurones et les paramètres correspondant à la solution de l'équation différentielle ou de l'équation aux dérivées partielles issue de la physique. Dans notre cas c'est l'équation de la chaleur et donc les propriétés de conduction de l'éprouvette stratifiée. Après optimisation des paramètres du modèle et de ceux du réseau de neurones, le réseau reproduira les données expérimentales et permettra d'obtenir une approximation en dehors des points identifiés. Les exemples PINN proposés sont uniquement basés sur une équation différentielle du deuxième ordre associée à des conditions initiales et limites en température et à des données issues des essais d'auto échauffement (les sources thermiques et des températures en certains points de l'éprouvette). L'utilisation d'une approche PINN a été proposée pour la première fois par IE Lagaris [9]. Contrairement aux méthodes numériques classiques comme celle des éléments finis, le domaine n'est pas maillé.

Pour chaque bloc de chargement d'un essai d'auto échauffement, considérons l'équation aux dérivées partielles de la chaleur qui devra satisfaire des données expérimentales les sources de chaleurs r_i générées par les dissipations de l'éprouvette lors de l'essai d'auto échauffement et la convection supposée constante. Les paramètres du réseau de neurones NN (ou poids du réseau) sont identifiés par minimisation de la fonction coût L afin que le réseau optimisé représente au mieux les données expérimentales (Eq 1). Dans le cas d'une éprouvette homogénéisé :

$$L = \frac{1}{m} \sum_{i=1}^m \left(-\lambda_{xx} \frac{d^2 NN_i}{dx^2} + r_i + \varphi - \rho c \frac{dNN_i}{dt} \right)^2 + \frac{1}{p} \sum_{i=1}^p (NN - \theta_{mesure})^2 + \frac{1}{m} \sum_{i=1}^m (\varphi - h(NN - T_\infty))^2 \quad \text{Eq 1.}$$

Dans le cas d'une approche PINN, la condition limite et les data r_i sont intégrées dans le réseau de neurone et dans la fonction coût. Des poids peuvent être pris en compte entre les différentes parties de la fonction coût. En l'absence de données expérimentales l'approche est dite non supervisée cela correspond à la recherche d'un réseau de neurones solution de l'équation différentielle. Dans le cas

ou des données expérimentales sont dans la fonction coût en plus de l'équation différentielle et de la condition limite cela correspond à une analyse inverse et c'est une approche dite supervisée. Les programmes sont développés en Langage Python en utilisant la librairie TensorFlow qui est un outil d'apprentissage automatique développé par Google. L'interface Keras est utilisée pour simplifier l'écriture du réseau de Neurones. La version actuelle utilise le Langage Python (3.9.19), l'interface Keras (2.9.0) (<https://keras.io>) et la librairie TensorFlow (2.9.1) (<https://www.tensorflow.org>). A titre d'exemple le tableau 2 représente la déclaration d'un réseau de neurone avec Keras, TensorFlow constitué d'une entrée (**1** neurone), la source interne de chaleur et de deux sorties (**2** neurones) et de couches cachées. L'exemple présenté présente une couche de 16 neurones connectés à une couche de 8 neurones cachés. On peut ajouter des autres couches ou changer le nombre de neurones par couche cachée. Le nombre de paramètres du réseau dépend du nombre de neurones et de couches de neurones. L'entrée du réseau de neurones NN(t) représente la source de chaleur de l'éprouvette et la sortie représente la température T(t) représentée par le réseau de neurones et la conductivité. L'optimisation est réalisée par l'optimisateur **Adam**

```

NN =
tf.keras.models.Sequential([tf.keras.layers.Input((1,)),tf.keras.layers.Dense(units = 16,
activation = 'sigmoid'), tf.keras.layers.Dense(units = 8, activation = 'sigmoid'),
tf.keras.layers.Dense(units = 2) ])

optm = tf.keras.optimizers.Adam(learning_rate = 0.001)

```

Tab2. Exemples d'un réseau de neurones TensorFlow, Keras

4. Solution stationnaire de l'essai d'auto-échauffement

Lors de l'essai d'auto-échauffement, l'éprouvette est soumise à des températures imposées à ses extrémités, ainsi qu'à une source de chaleur générée par les mécanismes de dissipation internes. Ces extrémités correspondent aux températures des mors supérieur et inférieur de la machine de fatigue hydraulique [6]. L'équation thermique unidimensionnelle peut être utilisée pour vérifier la cohérence entre la source de dissipation et les températures mesurées (Eq. 2). La température moyenne de l'éprouvette, déterminée expérimentalement à l'aide de thermocouples placés sur celle-ci, dépend du rapport entre la source de chaleur et la conductivité thermique axiale r/λ_{xx} . Ce rapport gouverne la température stationnaire moyenne atteinte après 3000 cycles de fatigue, pour une contrainte maximale donnée. La source de dissipation peut être déterminée à partir des constantes extraites de la fonction de perte (Eq. 3). Une approche plus rigoureuse, bien que plus coûteuse, consiste à intégrer directement l'équation différentielle de la chaleur ainsi que les conditions aux limites dans la fonction de perte (Eq. 3).

$$\lambda_{xx} \frac{d^2 T(x)}{dx^2} - r = 0 \quad \text{solution} \quad T(x) = -\frac{r}{\lambda_{xx}} \frac{x^2}{2} + \left(\frac{T_h - T_b}{L} + \frac{r}{\lambda_{xx}} \frac{L}{2} \right) x + T_b \quad \text{Eq 2.}$$

$$T(x) = -\frac{r}{\lambda_{xx}} \frac{x^2}{2} + C_1 x + C_2 \quad L = \frac{1}{m} \sum_{i=1}^m (NN_{moyen}(\sigma_{max_i}) - \theta_{mesure_i})^2 \quad \text{Eq 3.}$$

$$L = \frac{1}{m} \sum_{i=1}^m \left(-\lambda_{xx} \frac{d^2 NN_i}{dx^2} + r_i \right)^2 + (NN_{moyen} - \theta_{mesure})^2 + (NN_i(0) - T_b)^2 + (NN_i(L) - T_h)^2 \quad \text{Eq 4.}$$

A titre d'illustration, la courbe d'auto échauffement représentant la variation de température moyenne d'une éprouvettes $[0,90]_s$ issue de la résolution par le réseau de neurone a permit de montrer (Figure 1a) que après 500 MPa il y a une incohérence de la source de dissipation expérimentale car la variation de température baisse contrairement à la température mesurée. La source a ensuite été corrigée pour retrouver les données expérimentales (Figure 1b). Notre hypothèse est que le mécanisme de micro délaminages des fissures dans les couches à 90° n'a pas été correctement évalué.

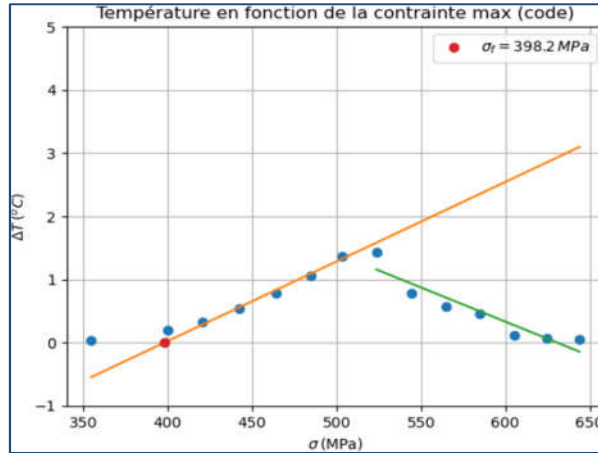


Figure 1. Essai d'autoéchauffement simulée par les réseau de neurone à partir de la donnée de la source expérimentale.




Figure 2. Simulation avec recallage de la source expérimentale.




Figure 3. Evolution de la correction de la source de chaleur pour l'essai d'auto-échauffement d'une éprouvette [0,90]_s

5. Conclusion

En conclusion, la méthode d'auto-échauffement est un outil précieux pour les ingénieurs et chercheurs cherchant à évaluer rapidement les performances en fatigue des matériaux tout en économisant du temps et des ressources. De plus, l'utilisation de réseaux de neurones informés par les lois physiques constitue une avancée significative dans le domaine de la modélisation et de la prédiction des comportements en fatigue, permettant de réduire le nombre d'essais expérimentaux nécessaires et d'accélérer les processus de conception et de validation des structures composites. L'utilisation des réseaux de neurones pour résoudre une équation différentielle ou aux dérivées partielles est une alternative aux méthodes éléments finis ou différences finis qui oblige à une discrétisation du domaine géométrique. Il est important de souligner que, lors de la résolution d'une équation différentielle et a fortiori d'une équation aux dérivées partielles à l'aide d'un réseau de neurones, la prise en compte des conditions aux limites dans la fonction de perte constitue un enjeu essentiel pour la qualité des simulations.

Références

- [1] F. Cura, G. Curti, R. Sesana, « A new iteration method of the thermographic determination of fatigue limit in steels ». *International Journal of Fatigue*, Vol. 27, pp. 453-459, 2005.
- [2] G. La Rosa, A. Risitano, « Thermographic methodology for rapid determination of the fatigue limit of materials and mechanical components ». *International Journal of Fatigue*, Vol. 22, pp. 65-73, 2000.
- [3] G. Fargione, A. Geraci, G. La Rosa, A. Risitano, « Rapid determination of fatigue curve by the thermographic method ». *International Journal of Fatigue*, Vol. 24, pp. 11-19, 2002.
- [4] M. Poncelet, C. Doudard, S. Calloch, F. Hild, B. Weber, A. Galtier, « Prediction of self-heating measurements under proportional and non-proportional multiaxial cyclic loadings ». *Comptes Rendus Mécanique*, Vol. 335, pp. 81-86, 2007.
- [5] V. Le Saux, Y. Marco, S. Calloch, C. Doudard, P. Charrier, « Fast evaluation of the fatigue lifetime of rubber-like materials based on a heat build-up protocol and micro-tomography measurements ». *International Journal of Fatigue*, Vol. 32, pp. 1582-1590, 2010.
- [6] O. Westphal, thèse Centrale Nantes, « Analyse thermomécanique de l'endommagement en fatigue de stratifiés carbone/époxy : détermination de la limite d'endurance à partir d'essais d'auto-échauffement », 2014.
- [7] L. Gornet, O. Westphal, C. Burtin, J.L. Bailleul, P. Rozycki, L. Stainier, « Rapid determination of the high cycle fatigue limit curve of carbon fiber epoxy matrix composite laminates by thermography methodology: tests and finite element simulations », *Procedia Engineering*; 66, 697-704; 2013.
- [8] A. Benady, L. Chamoin, E. Baranger, Réseaux de neurones informés par la physique pour l'apprentissage de lois de comportement, Congrès Français de Mécanique, 2022
- [9] A. Likas, D. Fotiadis, Artificial neural networks for solving ordinary and partial differential equations, IEEE 1998