



HAL
open science

Identification des propriétés des matériaux à partir de champs cinématiques via le deep learning

Nikzad Motamedi, Vincent Magnier, Hazem Wannous

► **To cite this version:**

Nikzad Motamedi, Vincent Magnier, Hazem Wannous. Identification des propriétés des matériaux à partir de champs cinématiques via le deep learning. 15ème colloque national en calcul des structures, Université Polytechnique Hauts-de-France [UPHF], May 2022, 83400 Hyères-les-Palmiers, France. hal-03718087

HAL Id: hal-03718087

<https://hal.science/hal-03718087>

Submitted on 8 Jul 2022

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Identification des propriétés des matériaux à partir de champs cinématiques via le deep learning

N. Motamedi¹, V. Magnier¹, H. Wannous²

¹ Univ. Lille, CNRS, Centrale Lille, UMR 9013 - LaMcube - Laboratoire de Mécanique, Multiphysique, Multiéchelle, F-59000 Lille, France, {nikzad.motamedi,vincent.magnier}@univ-lille.fr

² IMT Nord Europe, Univ. Lille, CNRS UMR 9189 - CRISTAL, F-59000 Lille, France, hazem.wannous@univ-lille.fr

Résumé — Le dimensionnement de système nécessite de maîtriser le comportement des matériaux utilisés. C'est-à-dire de connaître la loi de comportement et ses paramètres associés. De nombreuses recherches ont été proposées pour répondre à cette question primordiale mais se limitent toujours à des cas simplifiés, ce qui reste inapproprié. Dans ce papier, nous tenterons de relever le défi en utilisant l'intelligence artificielle pour identifier les paramètres d'une loi de comportement isotrope transverse. Le "Convolutional Neural Network" sera utilisé à partir d'une base de données générées par FEM.

Mots clefs — Propriétés mécaniques, Deep learning, Loi de comportement.

1. Introduction

Déterminer le lien entre la déformation et la contrainte est un défi en particulier lorsque le matériau présente un comportement complexe (anisotropie, hétérogénéité, endommagement, asymétrie du comportement en traction/compression, etc.). La connaissance de cette relation est la clé pour dimensionner au mieux les problèmes de structure. Cette question est d'autant plus essentielle sur les nouveaux matériaux utilisés (composites, impression 3D, etc.) qui permettent d'obtenir un allègement de matière, une meilleure rigidité etc.

D'un point de vue bibliographique, l'approche actuelle pour caractériser des propriétés mécaniques des matériaux consiste principalement à reprendre les essais normalisés qui ont fait leurs preuves sur des matériaux classiques [1]. En parallèle, des méthodes inverses ont été proposées conduisant à déterminer les propriétés mécaniques à partir de mesures de champs cinématiques [2][3][4][5][6]. Cette méthodologie permet d'estimer une loi de comportement et ses paramètres associés. Dans cette approche, l'effort est principalement porté sur la préparation de l'essai afin de n'appliquer qu'un seul mode de chargement en particulier (traction, compression, cisaillement, etc.). Lorsque le test est fortement instrumenté, notamment au moyen de caméras, des études plus poussées ont permis de développer des stratégies basées sur un dialogue expérimental-numérique [7][8] comme les méthodes FEMU [9] et ses variantes [10]. Néanmoins, l'utilisation de ces méthodes numériques d'identification inverse ne donne pas entière satisfaction lorsque le nombre de paramètres à déterminer devient important. La difficulté réside dans la minimisation d'une seule fonction de coût qui peut aussi générer plusieurs couples de solutions "admissibles".

Récemment, de nouvelles méthodes ont été développées comme "Data Driven Computational Mechanics" (DDCM) [12] et dans la continuité "Data Driven Identification" (DDI). Ces méthodes sont basées sur la construction d'un champ statiquement admissible à partir de mesures de champs. De là, ces méthodes permettent l'identification de certains paramètres [11] [13] [14].

Dans cette recherche, nous proposons une méthode basée uniquement sur la mesure de champ cinématiques à partir d'un essai de caractérisation. La méthodologie utilisée consistera à exploiter l'intelligence artificielle sur un jeu de données généré par des calculs FEM. Une stratégie multi-échelle

est déployée basée sur le "Deep-learning" et plus précisément sur le réseau de neurones "2D-Convolutional Neural Network" (2D-CNN).

Même si ce cadre est utilisable pour l'ensemble des modèles de comportement, un algorithme d'apprentissage supervisé a été utilisé ici dans le cadre d'un matériau isotrope transverse. Ainsi les objectifs seront de déterminer le module de Young dans les directions longitudinale et transversale à l'axe d'isotropie, le coefficient de Poisson, le module de cisaillement ainsi que l'angle d'orientation de l'isotropie.

2. GÉNÉRATION DE LA BASE DE DONNÉES

Pour construire la base de données par programmation dans le logiciel Abaqus, 17680 modèles ont été lancés avec différentes propriétés mécaniques. Étant donné que dans le modèle les matériaux élastiques isotrope transverse sont utilisés et dans ce type de matériaux, les propriétés mécaniques qui jouent un rôle plus important, incluent le coefficient de Poisson, le module de Young dans les directions longitudinale et transversale, le module de cisaillement et l'angle d'orientation de la propriété mécaniques. Les bornes utilisées afin de construire la base de données pour le coefficient de Poisson compris entre 0.06 et 0.4, le module de Young dans les directions longitudinale et transversale varie entre 50 et 500 MPa, le module de cisaillement varie entre 50 et 200 MPa, et enfin l'angle d'orientation varie entre 0 et 90 degrés. La géométrie utilisée dans la modélisation est inspirée d'une géométrie utilisée pour les essais expérimentaux de traction. Celle-ci est illustrée sur la Figure 1 où l'on retrouve une réduction de section au centre de l'éprouvette. Un encastrement est imposé sur le bord à gauche de l'éprouvette (noté B sur la Figure 1) et un déplacement de 5 mm a été appliqué sur le bord droit par l'intermédiaire d'un point distant (noté A). Ensuite, les déplacements et déformations ont été enregistrés sur l'ensemble des points se trouvant sur la partie centrale de l'éprouvette (2544 points en rouge sur la Figure 2).

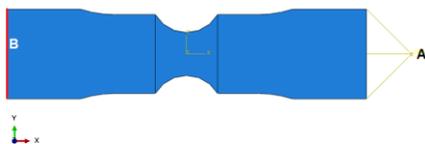


Figure 1 – Géométrie du modèle utilisée

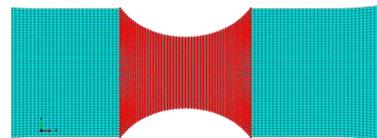


Figure 2 – Les informations de points rouge ont été extraites du modèle

3. PRESENTATION DU SCHEMA IA

3.1. Premier Schéma IA : Du champ de déplacement aux propriétés à identifier

L'objectif est de déterminer les propriétés indiquées ci-dessus à partir du champ de déplacement que l'on pourrait avoir à partir de la corrélation d'images par exemple. Un premier schéma a été proposé et l'objectif est de pouvoir prédire les propriétés mécaniques en utilisant les déplacements et la force de réaction au point A. Le schéma du modèle est illustré sur la Figure 3 et la structure du modèle se compose de six couches convolutives et divers filtres qui ont été appliqués pour rendre les données d'entrée claires pour le modèle. Puisque le but est la prédiction, la fonction d'activation "linear" a été utilisée dans les deux premières couches et la fonction d'activation "relu" a été utilisée dans les autres

couches. Ensuite, sept couches de "densification" avec fonction d'activation "relu" ont été utilisées. L'optimiseur utilisé est "adam" et la fonction du coût utilisé est "mean_squared_error". Afin de clarifier le comportement du modèle l'un des paramètres qui montre la performance du modèle est l'évolution de courbe de fonction de coût pendant la phase d'apprentissage. Sur la Figure 4, les courbes sont affichées pour chacune des sorties. Les résultats montrent que toutes les courbes sont divergentes et le modèle ne peut pas trouver une corrélation entre les entrées et les sorties. Cela signifie que le modèle ne dispose pas de suffisamment d'informations pour trouver les propriétés mécaniques. Un travail a été effectué sur le schéma AI en augmentant me nombre de couches notamment, ce qui n'a pas permis de résoudre le problème.

Figure 3 – Schéma du modèle utilisé pour déterminer les propriétés mécaniques

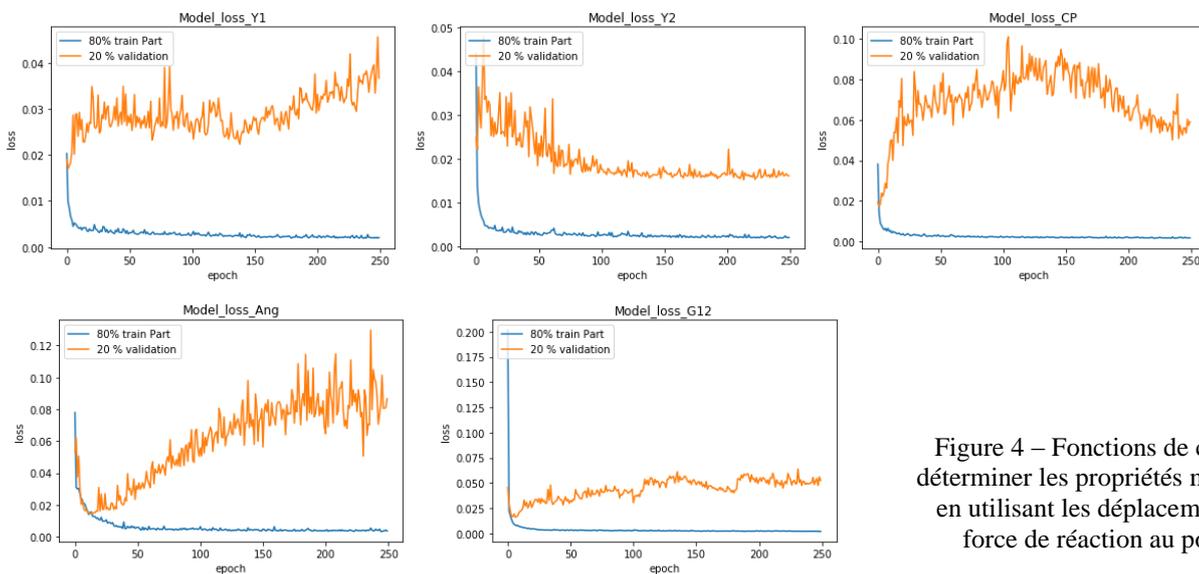
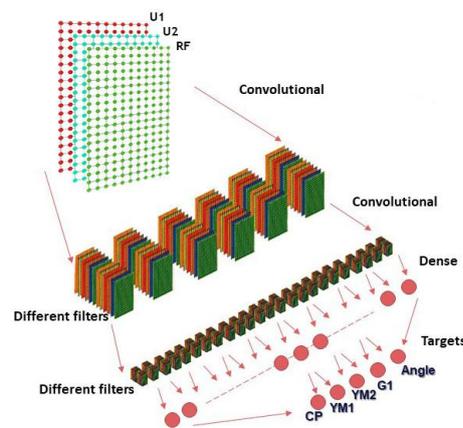


Figure 4 – Fonctions de coût pour déterminer les propriétés mécaniques en utilisant les déplacements et la force de réaction au point A.

3.2. Second Schéma IA : Des champs de déplacement et de déformation aux propriétés à identifier

Les résultats n'étant pas complètement concluants, il était alors indispensable d'enrichir physiquement le modèle initial en s'inspirant d'un modèle "Physics Informed Neural Networks" (PINNs) [15] [16] où les champs de déformations seraient introduits en tant que données d'entrée au même titre que le

champ de déplacements. Ce champ de déformation est déduit à partir d'un autre schéma IA dont les données d'entrée sont le champ de déplacement. Ce dernier est aussi issu d'un schéma de type 2D-CNN (Figure 5). Le but de cette section est d'améliorer la performance du modèle en utilisant un modèle "Application Programming Interface" (API) et en divisant le processus d'apprentissage en deux parties. Dans la première partie, le modèle prédit les déformations en analysant les déplacements dans les directions longitudinale et transversale. Ensuite les sorties de cette étape entrent dans la deuxième partie avec les entrées de la première étape pour prédire les propriétés mécaniques. La structure de modèle en première étape se compose de cinq couches convolutives. La fonction d'activation utilisée dans la première couche est "linear" et dans les autres couches, la fonction d'activation "relu" est utilisée. Après les couches convolutives, quatre couches de "dense" sont appliquées, afin d'améliorer le comportement du modèle. La fonction d'activation dans ces couches est "relu" et la fonction d'optimisation utilisée est "adam" et la fonction de coût utilisée est "mean_squared_error" qui avaient une performance acceptable. Dans la deuxième étape du modèle, le même modèle de la section (3.1) a été utilisé, à la différence qu'au lieu d'utiliser sept couches de dense, six couches ont été utilisées. Puisque le type de matériaux modélisés dans la base de données sont élastique isotrope transverse, l'objectif principal est de déterminer les propriétés mécaniques telles que le module de Young dans les deux directions longitudinale et transversale, le coefficient de Poisson, le module de cisaillement et l'angle d'orientation des matériaux.

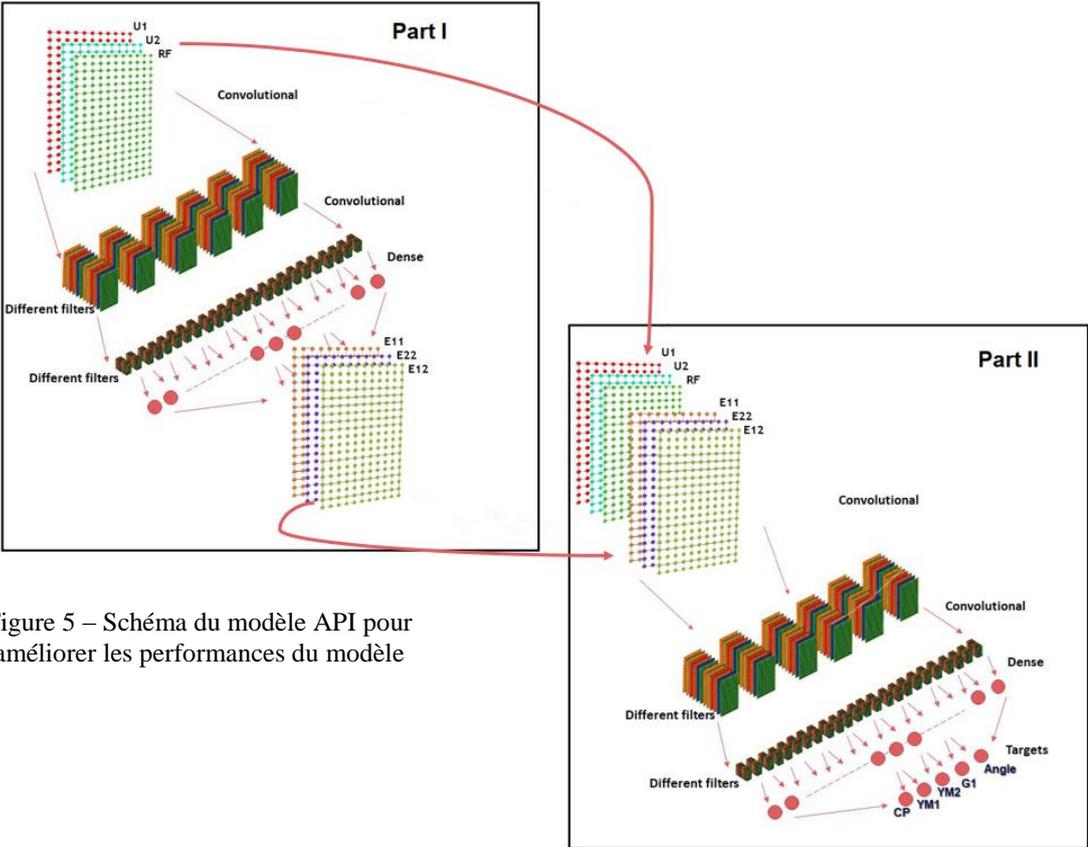


Figure 5 – Schéma du modèle API pour améliorer les performances du modèle

3.2.1 Analyser les résultats obtenus à partir du modèle

Dans ce qui suit, le comportement du modèle est vérifié en deux parties, d'abord avec l'analyse de la fonction de coût et ensuite avec les données de test. La figure 7 compare des résultats à travers 10 tests sélectionnés au hasard à partir des données test. Les étoiles bleues représentent les valeurs réelles et les étoiles rouges représentent les valeurs prédites par l'IA. Le premier paramètre à analyser est le coefficient de Poisson, dont la courbe de fonction de coût est illustrée sur la Figure 6. Comme montré, la courbe tend bien vers zéro et indique un bon apprentissage du modèle. Après avoir terminé l'apprentissage du modèle, l'efficacité du modèle a été vérifiée avec des données en dehors de la base de données initiale. De cette façon, les déformations ont d'abord été prédites, puis les propriétés mécaniques ont été prédites à l'aide de ces informations. La Figure 7 montre les résultats obtenus à partir du modèle et indique que le modèle fonctionne bien et le taux d'erreur du modèle dans la phase de prédiction du coefficient de Poisson est de 5,37 %.

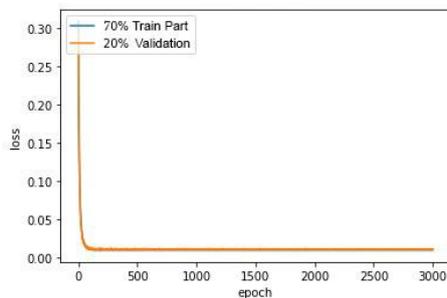


Figure 6 – Courbe de fonction de coût pour prédire le coefficient de Poisson

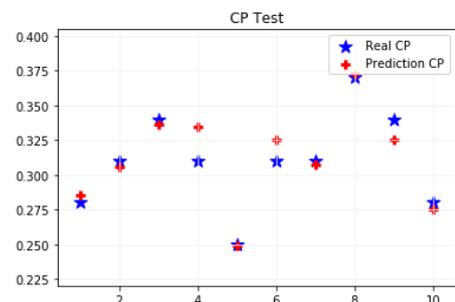


Figure 7 – Résultats du test du modèle pour déterminer le coefficient de Poisson

La deuxième variable à analyser était le module de Young dans la direction longitudinale, dont la courbe de la fonction de coût est représentée sur la Figure 8, qui montre une bonne performance du modèle en phase d'apprentissage. De plus, l'erreur du modèle dans la phase de test est de 2,67% et des résultats sont acceptables. La Figure 9 montre les résultats.

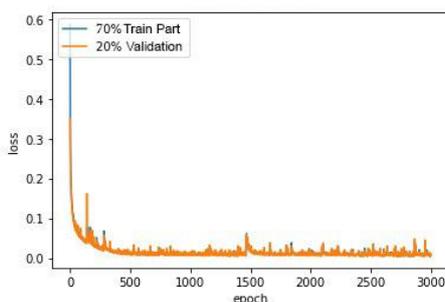


Figure 8 – Courbe de fonction de coût pour prédire le module d'Young (la direction longitudinale)

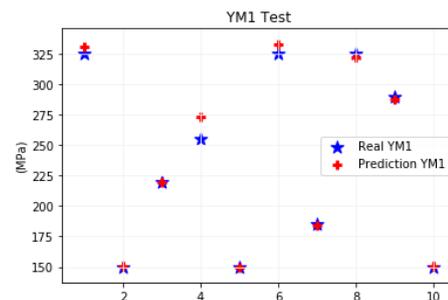


Figure 9 – Résultats du test du modèle pour déterminer le module d'Young (la direction longitudinale)

Le module de Young dans la direction transversale a ensuite été prédit, dont la courbe de fonction de coût avait une bonne performance dans les phases d'apprentissage et de validation et tendait vers zéro (Figure 10). Aussi le test du modèle a eu de bonnes réponses avec un taux d'erreur de 3,47%. La Figure 11 montre les résultats.

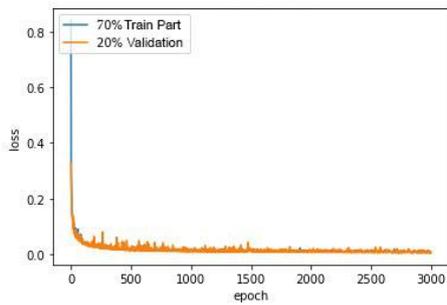


Figure 10 – Courbe de fonction de coût pour prédire le module d'Young la direction transversale

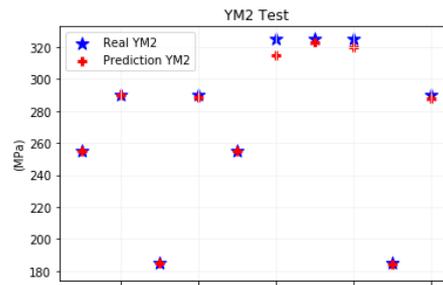


Figure 11 – Résultats du test du modèle pour déterminer le module d'Young la direction transversale

Le processus d'apprentissage du modèle et la fonction de coût pour la prédiction du module de cisaillement sont illustrés sur la Figure 12 et les résultats de test du modèle sont illustrés sur la Figure 13. Le taux d'erreur est 1,98% qui est une bonne indication de l'efficacité du modèle.

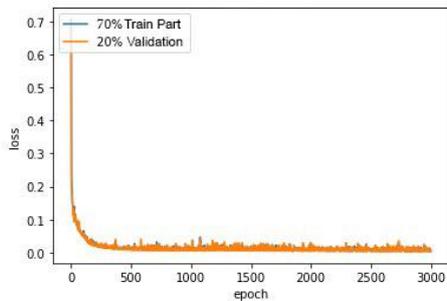


Figure 12 – Courbe de fonction de coût pour prédire le module de cisaillement

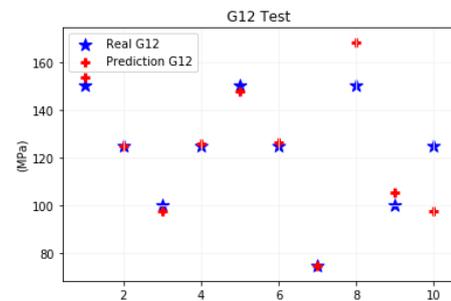


Figure 13 – Résultats du test du modèle pour déterminer le module de cisaillement

Le dernier paramètre à analyser était l'angle d'orientation des propriétés mécaniques. La courbe de la fonction de coût est montrée sur la Figure 14, qui tend vers zéro, indiquant une bonne performance de la phase d'apprentissage. Puis dans la phase de test, le taux d'erreur du modèle était de 1,35 %, ce qui indique la puissance du modèle à prédire ce paramètre. (Figure 15).

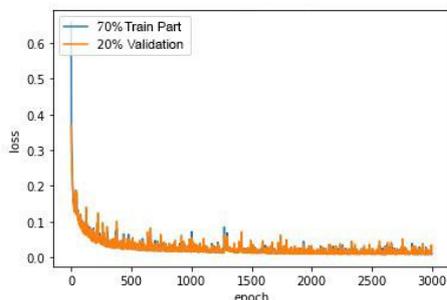


Figure 14 – Courbe de fonction de coût pour prédire l'angle d'orientation

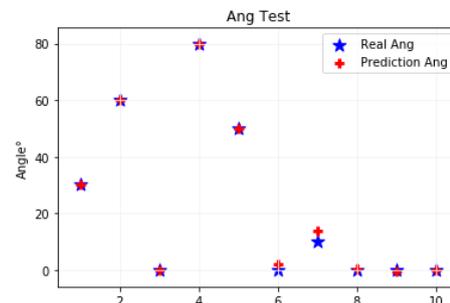


Figure 15 – Résultats du test du modèle pour déterminer l'angle d'orientation

5. Conclusion

Une nouvelle méthode d'identification de loi de comportement a été proposée dans cette communication se basant uniquement sur les champs de déplacements. Cette méthode est basée sur le deep learning comprenant plusieurs étapes. Dans un premier, il a été nécessaire de déterminer le

champ de déformation puis dans un second temps, l'ensemble des résultats obtenus ont permis d'aller jusque l'identification de propriétés matériaux. Les résultats sont probants dans un temps de réponse quasi-instantané. Même si la démarche a été proposée uniquement aux cas d'un matériau élastique isotrope transverse dans ce papier, une extension à d'autres modèles comme sur des modèles hyperélastique, ou avec plasticité ont été effectués avec succès. Il a également été montré que le modèle utilisé considère l'effet multi-échelle à travers des schémas imbriqués. En perspective, les données peuvent être combinées avec des données expérimentales afin que le modèle puisse montrer ses capacités dans la partie expérimentale.

Références

- [1] M. Bonnet and A. Constantinescu, "Inverse problems in elasticity," *Inverse Probl.*, vol. 21, no. 2, 2005, doi: 10.1088/0266-5611/21/2/R01.
- [2] A. Constantinescu and N. Tardieu, "On the identification of elastoviscoplastic constitutive laws from indentation tests," *Inverse Probl. Eng.*, vol. 9, no. 1, pp. 19–44, 2001, doi: 10.1080/174159701088027751.
- [3] R. Forestier, Y. Chastel, and E. Massoni, "3D inverse analysis model using semi-analytical differentiation for mechanical parameter estimation," *Inverse Probl. Eng.*, vol. 11, no. 3, pp. 255–271, 2003, doi: 10.1080/1068276031000135908.
- [4] A. Gavras, E. Massoni, and J. L. Chenot, "An inverse analysis using a finite element model for identification of rheological parameters," *J. Mater. Process. Technol.*, vol. 60, no. 1–4, pp. 447–454, 1996, doi: 10.1016/0924-0136(96)02369-2.
- [5] R. Mahnken and E. Stein, "Parameter identification for viscoplastic models based on analytical derivatives of a least-squares functional and stability investigations," *Int. J. Plast.*, vol. 12, no. 4, pp. 451–479, 1996, doi: 10.1016/S0749-6419(95)00016-X.
- [6] N. Tardieu and A. Constantinescu, "On the determination of elastic coefficients from indentation experiments," *Inverse Probl.*, vol. 16, no. 3, pp. 577–588, 2000, doi: 10.1088/0266-5611/16/3/303.
- [7] BERGER A., WITZ J.F., EL BARTALI A., LIMODIN N., DUBAR M., "Pixel-wise full-field strain measurements for analysis of strain heterogeneities with regards to the material microstructure," *Photomech. IDICS*, 2020.
- [8] S. M. A., *Image correlation for shape motion and deformation measurements : basic concepts, theory and applications / Michael A. Sutton, Jean-José Orteu, Hubert Schreier*. Boston: Springer, 2009.
- [9] A. Guery, F. Hild, F. Latourte, and S. Roux, "Identification of crystal plasticity parameters using DIC measurements and weighted FEMU," *Mech. Mater.*, vol. 100, pp. 55–71, 2016, doi: 10.1016/j.mechmat.2016.06.007.
- [10] K. T. Kavanagh and R. W. Clough, "Finite element applications in the characterization of elastic solids," *Int. J. Solids Struct.*, vol. 7, no. 1, pp. 11–23, 1971.
- [11] M. Dalémat, "Une expérimentation réussie pour l'identification de la réponse mécanique sans loi de comportement : Approche data-driven appliquée aux membranes élastomères," p. 212, 2019, [Online]. Available: <https://tel.archives-ouvertes.fr/tel-02506891>.
- [12] T. Kirchdoerfer and M. Ortiz, "Data-driven computational mechanics," *Comput. Methods Appl. Mech. Eng.*, vol. 304, pp. 81–101, 2016, doi: 10.1016/j.cma.2016.02.001.
- [13] A. Leygue, M. Coret, J. Réthoré, L. Stainier, and E. Verron, "Data-based derivation of material response," *Comput. Methods Appl. Mech. Eng.*, vol. 331, pp. 184–196, 2018, doi: 10.1016/j.cma.2017.11.013.
- [14] H. Yang, X. Guo, S. Tang, and W. K. Liu, "Derivation of heterogeneous material laws via data-driven principal component expansions," *Comput. Mech.*, vol. 64, no. 2, pp. 365–379, 2019, doi: 10.1007/s00466-019-01728-w.
- [15] Raissi, Maziar & Perdikaris, Paris & Karniadakis, George. (2017). *Physics Informed Deep Learning (Part I): Data-driven Discovery of Nonlinear Partial Differential Equations*.
- [16] Raissi, Maziar & Perdikaris, Paris & Karniadakis, George. (2017). *Physics Informed Deep Learning (Part II): Data-driven Solutions of Nonlinear Partial Differential Equations*.