

Optimisation du thermo estampage composite assisté par IA

AI powered Composite thermoforming optimisation

Juan Pedro Berro Ramirez¹, Sergio Octavio Esparza¹

¹ : Altair
28 RUE DU CHÂTEAU DES RENTIERS, 75013, PARIS
e-mail : jbramirez@altair.com; sesparza@altair.com

Résumé

Ce papier porte sur une suite des travaux de simulations de thermo estampage des structures composites à matrice thermodurcissable 3R avec un modèle de comportement hypoélastique thermodependant. Ce travail explore l'utilisation des techniques de réduction de modèle par apprentissage profond pour accélérer les processus d'optimisation de ce type procédés visant à réduire la probabilité de défauts et optimiser la consommation d'énergie.

Abstract

This paper is a continuation of the work on simulations of the thermoforming of 3R thermoset matrix composite structures with a thermodependent hypoelastic behaviour model. This work explores the use of deep learning model reduction techniques to accelerate optimisation processes of this type, aimed at reducing the probability of defects and optimising energy consumption.

Mots Clés : Thermo estampage, Intelligence artificiel, Comportement matériaux

Keywords : Thermoforming, AI, Material Behavior

1. Introduction

Une tendance actuelle dans le secteur industriel, particulièrement en Europe, est de minimiser le temps de développement des produits afin d'accroître la compétitivité des entreprises. Parallèlement, les simulations deviennent de plus en plus complexes en raison de la finesse des maillages, de la sophistication des modèles de comportement et des couplages multiphysiques. Le thermoformage des matériaux composites en est un exemple typique, nécessitant des simulations à la fois complexes et coûteuses en temps de calcul, ce qui laisse peu de marges pour optimiser le processus de fabrication tout en maintenant un temps de développement acceptable.

Ce contexte a stimulé la recherche de méthodes visant à réduire les temps de calcul, notamment par la réduction de modèle, que ce soit par des techniques telles que la POD [1], la PGD [2], ou plus récemment par des approches basées sur l'apprentissage profond, utilisant des auto-encodeurs [3] ou des réseaux de type graphe (apprentissage profond géométrique) [4].

Cet article présente une approche de réduction de modèle par intelligence artificielle visant à accélérer le processus de thermoformage d'une structure en demi-cylindre avec une résine vitrimère de type 3R, développée dans le cadre du projet européen AIRPOXY [5].

2. Modèle de comportement

En général, les lois hypoélastiques sont largement utilisées dans les codes d'éléments finis pour modéliser le comportement du composite à grande déformation [6-10]. Le comportement hypoélastique ne relie pas la contrainte à la déformation comme le constituant élastique, mais il

relie la dérivée objective du tenseur de contrainte de Cauchy $\underline{\underline{\sigma}}^\nabla$ au taux de déformation $\underline{\underline{D}}$ par un tenseur constitutif $\underline{\underline{C}}$. Alors, les lois hypoélastiques ont la forme suivante :

$$\underline{\underline{\sigma}}^\nabla = \underline{\underline{C}} : \underline{\underline{D}} \quad (1)$$

Le comportement des fibres est considéré linéaire mais avec des raideurs différentes en traction et compression pour prendre en compte la perte de résistance due aux ondulations du tissu composites.

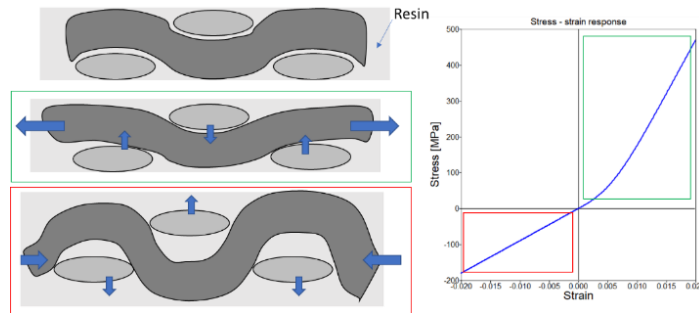


Fig. 1. Comportement du renfort

Les polymères thermoplastiques et thermodurcissables présentent un comportement viscoélastique, plus marqué à haute température. Pour cette raison, un comportement viscoélastique isotrope pour la résine pourrait être un bon candidat pour reproduire les effets visqueux associés à ces matériaux. Un modèle général d'éléments de Maxwell est mis en œuvre, conformément à [11], avec 4 contributions visqueuses (linéaires).

$$\bar{\sigma}(t) = \int_0^t \bar{\Gamma}(t-s) \frac{\partial \bar{\epsilon}(s)}{\partial s} ds \quad \text{where} \quad \bar{\Gamma}(t-s) = \gamma_0 + \sum_{j=1}^N \gamma_j \exp\left(-\frac{t-s}{\tau_j}\right) \quad (2)$$

Les détails sur l'identification et validation de ces modèles sont décrits dans [5].

3. Réduction de modèle

Les méthodes de réduction de modèle se composent de deux éléments principaux : d'abord, elles cherchent à déterminer la 'vraie' dimensionnalité du problème, ce qui est réalisé par des techniques de réduction de dimensionnalité, puis elles effectuent une projection du problème dans cet espace réduit. Cette projection peut entraîner une diminution significative de la taille du problème, conduisant à des gains de temps de calcul considérables.

Deux grandes familles de méthodes peuvent être distinguées en fonction de la manière dont cette étape de projection est réalisée : les méthodes intrusives et non intrusives. Les méthodes intrusives consistent en une projection du système d'équations dans l'espace vectoriel engendré par les bases réduites (projection de type Galerkin). Un inconvénient majeur de ces méthodes est la nécessité d'écrire un code spécifique pour la projection de Galerkin et d'accéder aux codes sources. Cela implique une complexité d'implémentation et de maintenance très élevée.

D'autre part, les méthodes de réduction de modèle non intrusives (également appelées Data-Driven) n'ont pas besoin d'accéder aux codes sources, permettant ainsi l'utilisation de codes commerciaux et offrant une plus grande flexibilité d'implémentation, de développement et de maintenance. Cependant, elles ne s'appuient pas sur le système d'équations physiques, à l'exception des méthodes

de type PINNs [12]. Cette famille des méthodes non intrusives se compose d'une grande variété des méthodes, parmi lesquelles on peut citer :

- POD
- Processus Gaussiens
- DMD
- Apprentissage profond

Les méthodes de type POD [1] ont démontré leur puissance et leur versatilité dans de nombreux types de problèmes physiques. Elles reposent sur une opération de codage et de décodage entre l'espace haute-fidélité et l'espace réduit. Ensuite, un système dynamique d'ordre inférieur agissant sur les coefficients POD peut être identifié, par exemple au moyen d'une méthode de décomposition (DMD) [13]. La même logique est suivie pour introduire une dépendance paramétrique au lieu de temporelle. Dans ce cas, les coefficients de la base POD sont interpolés à l'aide d'une régression (linéaire ou non linéaire).

Les développements récents en intelligence artificielle (IA), notamment dans les réseaux de neurones artificiels (ANN) et les réseaux de neurones profonds (DNN), ont ouvert la voie à l'identification de systèmes physiques complexes à grande échelle, y compris les systèmes dynamiques paramétrés. Des approches très similaires à celles présentées précédemment peuvent être implémentées par des réseaux de neurones, en utilisant des auto-encodeurs pour la réduction de dimensionnalité et des réseaux de type LSTM (Long Short Term Memory) pour la dynamique des variables réduites. Un exemple de cette implémentation est décrit dans [14].

L'une des méthodes les plus récentes à émerger dans le domaine de la simulation est la méthode des réseaux de type graphe [4], appartenant à la discipline de l'apprentissage profond géométrique. Les réseaux de graphes permettent de traiter des données non structurées, telles qu'un maillage qui change pour chaque spécimen. Ces réseaux apprennent le lien entre le graphe (le maillage/la géométrie) et la prédiction demandée. Cette capacité a permis à ce type de méthodes de s'imposer dans le domaine industriel.




Fig. 2. Principe de fonctionnement d'un réseau de neurones type graphe

Le modèle réduit, issu de l'apprentissage et du développement de ce type de modèles, est utilisé dans des démarches de planification d'expériences et d'optimisation, permettant de localiser rapidement les ensembles de paramètres optimaux.

4. Simulation

L'exemple d'application présenté ici est la simulation du thermoformage d'une structure sphéro-cylindrique avec un composite 3R issu du projet AIRPOXY. Les dimensions initiales de l'outillage sont les suivantes :




Fig. 3. Dimensions du Sphero-cylindre.

Des variables de forme ont été définies sur la plaque initiale à l'aide des techniques de morphing. La figure ci-dessous représente la forme imposée pour une valeur unité. Ces variables de forme peuvent prendre des valeurs dans l'intervalle $[-1, 1]$




Fig. 4. Formes définies sur la plaque composite.

Pour alimenter et valider le modèle, 14 calculs ont été lancés suivant un plan d'expérience du type XX. L'entraînement du modèle a été fait avec 11 calculs, en gardant 3 pour la phase de validation du modèle. Le processus d'entraînement a pris 0h06min01.33s (avec GPU) pour 1000 epochs. Les hyperparamètres utilisés lors de ce processus se trouvent dans le tableau suivant :

Width	Depth	Batch size	Learning rate	Parameters
30	3	1	0.0007	26651

Tab. 1. Hyperparamètres du réseau.

L'entraînement se déroule correctement comme le montre la fonction perte dans la figure suivante :

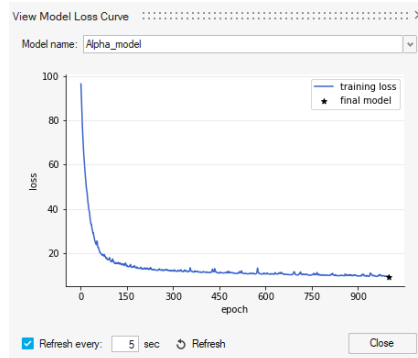


Fig. 5. Fonction perte

Une fois le modèle entraîné, il a été utilisé pour prédire des nouveaux résultats sur des formes autres que celles utilisés lors de l'entraînement et la phase de tests.

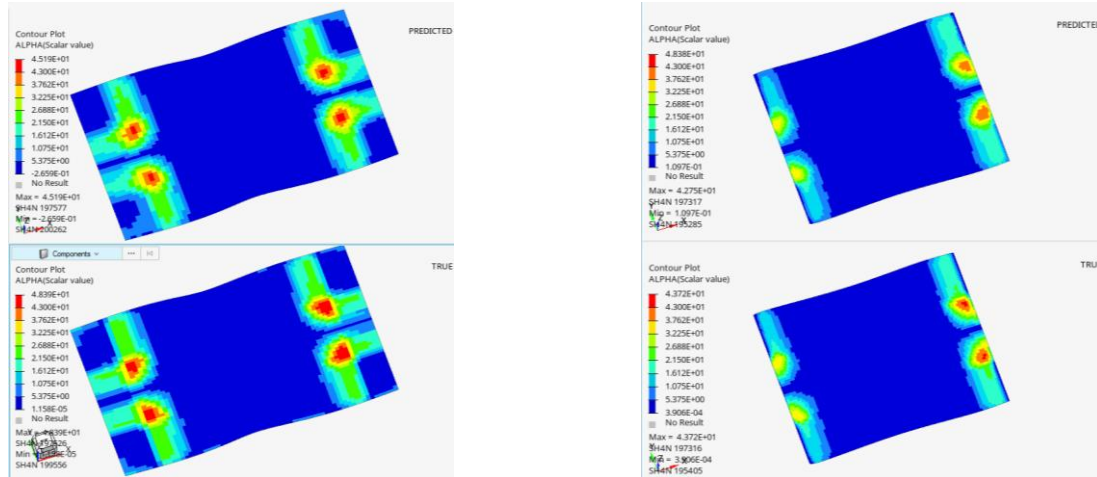


Fig. 6. Prédications du modèle sur nouvelles formes

On peut observer que les contours d'angle de cisaillement prédits par le modèle réduit présentent une forme très similaire à ceux calculés avec le modèle haute-fidélité. Les modèles à gauche montrent un résultat presque symétrique avec des angles de cisaillement élevés dans les sommets des L. Bien que la localisation soit bien capturée par le modèle réduit, la forme de cette concentration présente certaines différences, étant moins nette dans la prédiction par rapport à la simulation. Nous observons une différence d'environ 3 degrés, soit une erreur relative de 6,125%. Le deuxième cas (image à droite) montre une dissymétrie de la distribution d'angle de cisaillement, bien capturée par le modèle réduit. Pour ce cas, c'est le modèle réduit qui surestime la valeur maximale d'angle de cisaillement (+10,66%), bien que le contour reste très proche de la simulation.

Le modèle réduit démontre une bonne capacité à prédire qualitativement les distributions d'angle de cisaillement en fonction de la forme de la plaque composite, malgré le nombre réduit de calculs utilisés pour la base d'entraînement. Il sera utilisé dans une démarche d'optimisation pour trouver une forme qui minimise l'angle de cisaillement tout en maintenant une symétrie dans sa distribution.

Remerciements

Ce travail a été réalisé avec les données issus du projet AIRPOXY. Ce projet a été financé par le programme de recherche et d'innovation Horizon 2020 de l'Union européenne dans le cadre de la convention de subvention n° 769274.

Références

- [1] M. Bergman, CH Bruneau, A. Iollo. «Improvement of Reduced Order Modeling based on Proper Orthogonal Decomposition » in: Research Report RR-6561, INRIA, 2008
- [2] F. Chinesta, P. Ladeveze, E. Cueto. « A Short Review on Model Order Reduction Based on Proper Generalized Decomposition » in: Archives of Computational Methods in Engineering, Volume 18, pages 395–404, 2011
- [3] O. Azencot, N.B. Lin, M. Mahoney, « Forecasting sequential data using consistent koopman autoencoders », in: International conference on machine learning, PMLR, 475-485, 2020
- [4] J. Xu, A. Pradhan, and K. Duraisamy, « Conditionally parameterized, discretization-aware neural networks for mesh-based modeling of physical systems, » in: Adv. Neural Inf. Process. Syst. 34, 1634-1645, 2021.
- [5] JP Berro Ramirez, S. Weidman, C. Kelly, N. Markaide, « Numerical Assessment of smart Epoxy resin Thermoformed parts for aerospace industry » in: Congrès Français de Mécanique, 2022.

- [6] Zouari, B., Daniel, J. L., & Boisse, P. «A woven reinforcement forming simulation method. Influence of the shear stiffness» in: *Computers and Structures*, 84(5–6), 351–363, 2006
- [7] RADIOSS Users Manual, Version 2024
- [8] T.JR Hughes and J. Winget. « Finite rotation effects in numerical integration of rate constitutive equations arising in large-deformation analysis » in: *International journal for numerical methods in engineering*, 15(12):1862– 1867, 1980.
- [9] T. Belytschko, W.K. Liu, Brian Moran, and K. Elkhodary. « Nonlinear finite elements for continua and structures» in: *John wiley & sons*, 2013.
- [10] XQ Peng and J Cao. « A continuum mechanics-based non-orthogonal constitutive model for woven composite fabrics » in: *Composites Part A: Applied Science and Manufacturing*, 36(6):859–874, 2005.
- [11] Berro JP, Palaniswamy H, Roy S. Numerical modelling of thermoplastic resin behaviour for thermoforming of laminates composed of non-crimp fabrics» in: *Journal of Physics: Conference Series*, Volume 1063, NUMISHEET 2018: 11th International Conference and Workshop on Numerical Simulation of 3D Sheet Metal Forming Processes 30 July to 3 August 2018, Tokyo, Japan
- [12] M. Raissi, P. Perdikaris, G.E. Karniadakis, « Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations » in: *Journal of Computational Physics*, Volume 378, Pages 686-707, 2019
- [13] J.H. Tu, C.W. Rowley, D.M. Luchtenburg, S.L. « Brunton and J.N. Kutz, On dynamic mode decomposition: theory and applications » in: *J. Comp. Dynamics* 1(2), 391–421, 2014
- [14] A. Pulikkathodi, E. Longette-Lacazedieu, L. Chamoin, J P Berro Ramirez, L. Rota, « A neural network-based data-driven local modeling of spotwelded plates under impact » in: *Mechanics & Industry*, 24, pp24, 2023