

Identification inverse des propriétés mécaniques à partir d'un spectre de fréquences

N. Motamedi¹, O. Mortadi¹, V. Magnier², S. Chaki¹

¹ IMT Nord Europe, Institut Mines-Télécom, Univ. Lille, Centre for Materials and Processes, Lille, France, nikzad.motamedi@imt-nord-europe.fr

¹ IMT Nord Europe, Institut Mines-Télécom, Univ. Lille, Centre for Materials and Processes, Lille, France, ossama.mortadi.etu@imt-nord-europe.fr

¹ IMT Nord Europe, Institut Mines-Télécom, Univ. Lille, Centre for Materials and Processes, Lille, France, salim.chaki@imt-nord-europe.fr

² Univ. Lille, CNRS, Centrale Lille, UMR 9013 - LaMcube - Laboratoire de Mécanique, Multiphysique, Multiéchelle, Lille, France, vincent.magnier@polytech-lille.fr

Résumé — Ce travail propose une méthode d'identification inverse des propriétés de matériaux transversalement isotropes à partir de leurs fréquences propres. Une base de données générée par éléments finis est utilisée pour entraîner les modèles d'intelligence artificielle. Les résultats montrent une prédiction précise, avec une erreur d'environ 5 % pour les cinq paramètres mécaniques du matériau. Cette approche, non destructive et économique, offre une alternative aux méthodes classiques pour l'identification de matériaux et ouvre des perspectives en contrôle qualité et optimisation des procédés.

Mots clefs — Identification inverse, Éléments finis, Intelligence artificielle, Analyse modale, Matériaux anisotropes.

1. Introduction

Les avancées récentes dans les technologies de fabrication, notamment la fabrication additive et l'utilisation de matériaux innovants comme les composites, ont profondément modifié la conception et la production des matériaux structuraux [1]. Ces procédés génèrent des microstructures complexes et anisotropes, ouvrant de nouvelles perspectives mais rendant leur caractérisation mécanique plus difficile [2]. La connaissance précise de leurs propriétés reste pourtant indispensable pour prédire leur comportement, optimiser les structures et répondre aux exigences de secteurs tels que l'aéronautique, le ferroviaire ou l'automobile.

Pour relever ces défis, plusieurs méthodes ont été développées. La corrélation d'images (DIC) [3] fournit des champs de déplacement et de déformation de haute résolution, Le FEMU [4] permet d'identifier les paramètres constitutifs en ajustant un modèle numérique, et les approches de Data-Driven Identification (DDI) [5] exploitent directement les données expérimentales sans imposer de loi de comportement.

Ces techniques présentent toutefois des limitations, la DIC requiert un matériel optique précis, le FEMU est souvent coûteux en calcul et sensible aux problèmes d'ill-posedness, tandis que le DDI dépend fortement de la qualité et de la quantité des données disponibles. Malgré cela, elles restent essentielles pour l'étude des matériaux hétérogènes et anisotropes.

L'émergence récente de méthodes fondées sur l'intelligence artificielle [6] ouvre désormais de nouvelles voies pour l'identification des propriétés mécaniques, en permettant une exploitation plus flexible des données et en réduisant la dépendance aux approches expérimentales lourdes et aux modèles constitutifs traditionnels.

Dans ce travail, une stratégie combinant modélisation numérique et apprentissage profond est

proposée pour identifier les propriétés mécaniques d'un matériau transversalement isotrope. La méthode repose sur la génération d'une base de données par éléments finis et sur l'entraînement d'un réseau neuronal chargé de résoudre le problème inverse à partir de réponses du système également accessibles expérimentalement, notamment les fréquences propres. La suite du document présente ce scénario méthodologique.

1.1. Scénario global

La méthodologie adoptée s'articule autour de quatre étapes principales :

- Étape 1 : Génération des données par éléments finis
- Étape 2 : Préparation, nettoyage et normalisation des données
- Étape 3 : Apprentissage supervisé de modèles MLP pour l'identification des paramètres
- Étape 4 : Validation de la méthode sur des cas tests indépendants.

Une représentation schématique est fournie en Figure 1.




Figure 1 – Scénario global d'analyse et de traitement des données. (a) Génération de données. (b) Préparation de la base de données. (c) Choix de l'algorithme. (d) Interprétation.

2. Génération de la base de données par éléments finis

La base de données utilisée pour l'entraînement des modèles d'intelligence artificielle a été générée à partir d'une vaste campagne de simulations par éléments finis, afin d'établir un lien direct entre différentes combinaisons de paramètres mécaniques et le spectre modal associé. Pour rendre cette démarche expérimentalement réaliste, un essai simplifié et facilement reproductible a été considéré. Une plaque de dimensions $200 \times 20 \times 1$ mm a été modélisée, et ses propriétés matérielles modules élastiques $E1$ et $E2$, module de cisaillement $G12$, angle de transversalité et coefficient de Poisson, ont été systématiquement modifiées selon un ensemble de configurations représentatives. Pour chaque combinaison de paramètres, les dix premières fréquences propres ont été extraites, permettant de constituer un ensemble de données complet regroupant environ 65 000 configurations uniques. Cette base de données constitue le support principal permettant d'entraîner et d'évaluer les performances du modèle d'apprentissage profond dédié à l'identification des propriétés mécaniques.

3. Préparation des données pour l'intelligence artificielle

Avant l'entraînement des modèles, les données obtenues par simulation ont été nettoyées et organisées afin d'assurer un apprentissage fiable. La première étape a consisté à extraire les fréquences propres de chaque simulation, puis à supprimer les cas inutilisables. Certaines configurations extrêmes ne permettaient pas d'obtenir toutes les fréquences demandées, et quelques jeux de paramètres ne

respectaient pas les conditions de base du matériau. Ces cas ont donc été retirés pour ne garder que des données correctes et cohérentes.

Ensuite, une normalisation a été appliquée aux données. En effet, les paramètres mécaniques, les fréquences propres et les valeurs sans unité n'ont pas la même échelle. Pour éviter que certaines grandeurs n'influencent trop l'apprentissage, chaque donnée a été divisée par sa valeur maximale. Cette opération place l'ensemble des valeurs sur une échelle comparable et améliore la stabilité de l'entraînement. Après normalisation, les données ont été réorganisées : les dix premières fréquences propres constituent l'entrée du modèle, tandis que la sortie correspond à un seul paramètre mécanique ($E1$, $E2$, $G12$, $\nu12$ ou θ). Cette structure permet d'entraîner un réseau spécialisé pour chaque propriété. Enfin, la base de données a été séparée en trois ensembles : 80 % pour l'apprentissage, 15 % pour la validation et 5 % pour le test, ce qui permet d'évaluer correctement la performance du modèle et de limiter le surapprentissage.

4. Architecture Conception de l'Architecture d'Apprentissage Automatique

Comme les entrées du modèle sont uniquement constituées d'un vecteur de fréquences propres, l'utilisation d'un réseau de type Multi-Layer Perceptron (MLP) s'est imposée comme la solution la plus adaptée. Ce type d'architecture permet de modéliser efficacement la relation non linéaire entre les fréquences modales et les paramètres mécaniques, tout en restant plus léger, plus simple à entraîner et moins sensible au sur-ajustement que des architectures plus complexes telles que les réseaux convolutionnels.

Pour chaque paramètre mécanique, plusieurs essais ont été réalisés afin de déterminer la configuration de MLP la plus appropriée, en faisant varier la profondeur du réseau, le nombre de neurones, les fonctions d'activation ou encore le rythme d'apprentissage. Le but était de trouver un compromis satisfaisant entre précision, stabilité et temps d'apprentissage. Les courbes d'apprentissage et de validation obtenues pour les cinq paramètres sont présentées dans la Figure 2(a-e) :

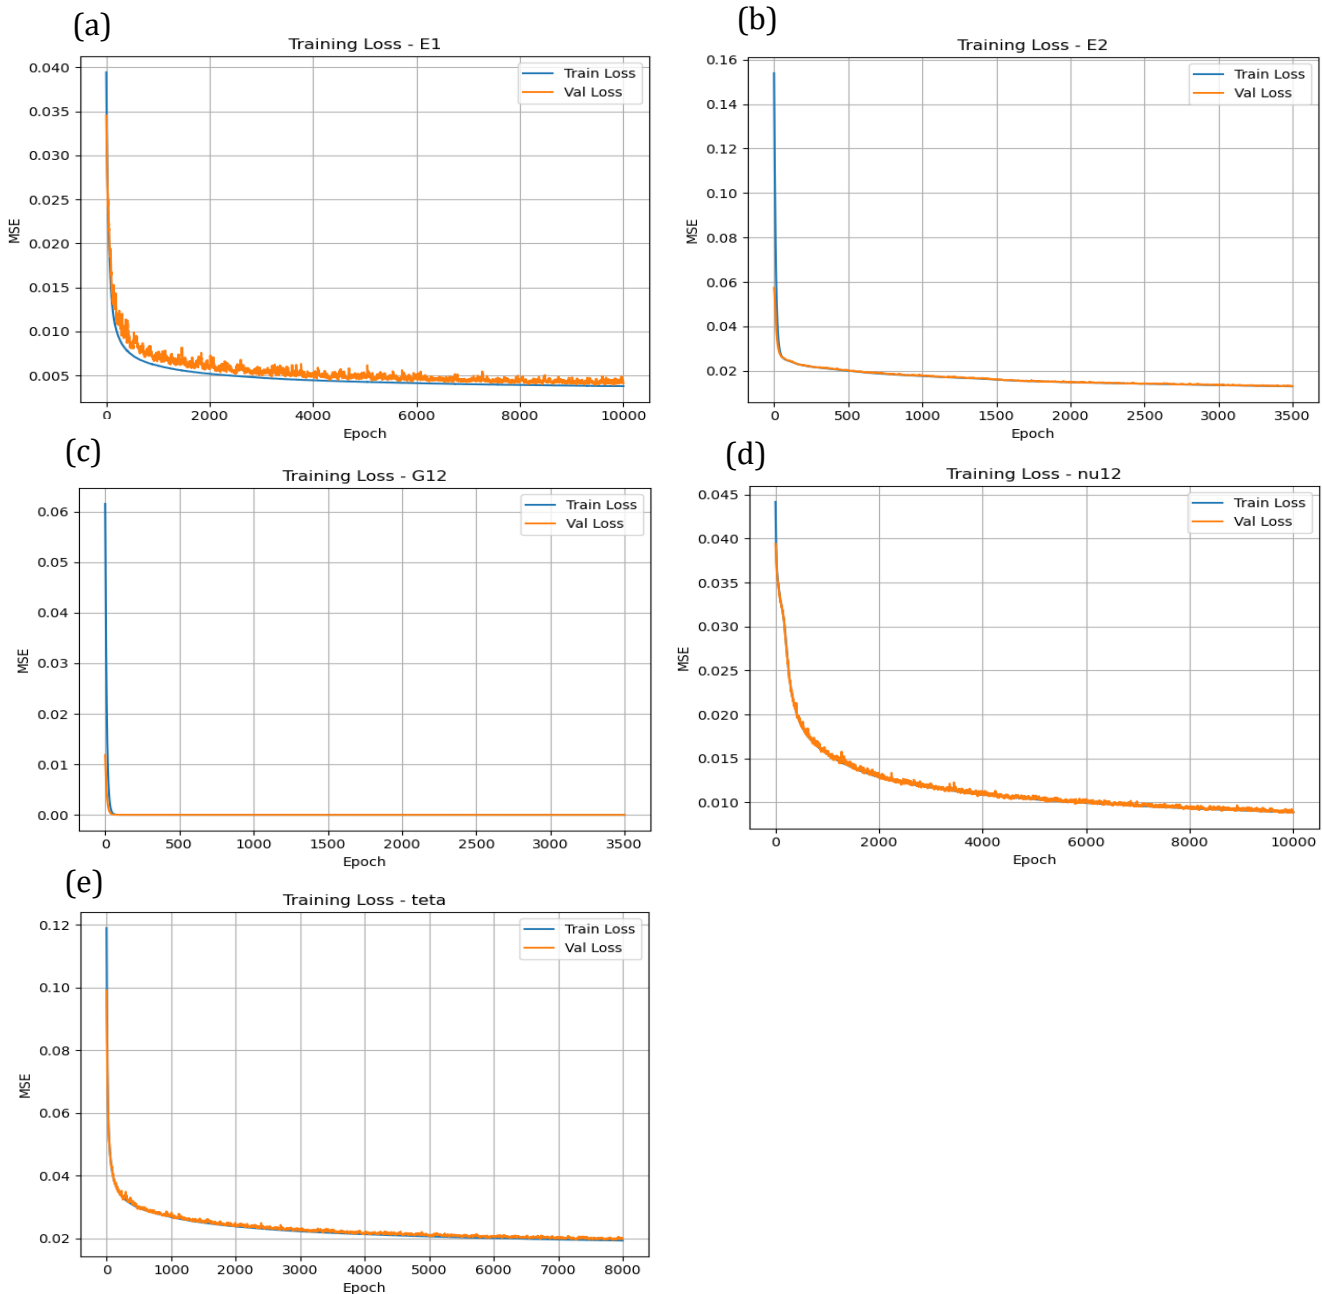


Figure 2(a-e) – Les courbes d’apprentissage et de validation obtenues pour les cinq paramètres. (a) apprentissage du paramètre E1. (b) apprentissage du paramètre E2. (c) apprentissage du paramètre $G12$. (d) apprentissage du coefficient de Poisson $\nu/2$. (e) apprentissage de l’angle de transversalité θ .

Les courbes d’apprentissage présentées dans la Figure 2(a–e) montrent l’évolution de l’erreur quadratique moyenne (MSE) pour les jeux d’entraînement et de validation lors de l’identification des cinq paramètres mécaniques. Dans tous les cas, la perte diminue rapidement au début de l’apprentissage, ce qui indique que le modèle parvient dès les premières époques à capturer la relation entre les fréquences propres et le paramètre visé. La décroissance progressive et régulière de la perte de validation confirme également une bonne capacité de généralisation.

Pour chaque paramètre, les courbes d’entraînement et de validation restent proches l’une de l’autre, ce qui suggère une absence de sur-apprentissage significatif. Les plateaux atteints en fin d’apprentissage témoignent d’une stabilisation du modèle et de la convergence vers une solution fiable. Les différences de vitesse de convergence observées entre les paramètres s’expliquent par leur influence respective sur les fréquences modales : certains paramètres, comme $G12$ ou $E2$, modifient fortement les

modes, facilitant l'apprentissage, tandis que d'autres, comme v12, produisent des effets plus faibles et nécessitent davantage d'époques pour stabiliser la perte.

De manière générale, ces résultats montrent que l'architecture MLP retenue est capable d'apprendre efficacement le lien entre le spectre modal et chacun des paramètres, et qu'une configuration spécifique pour chaque modèle permet d'obtenir une convergence stable et précise.

5. Performance du Modèle Éléments Finis pour l'Identification Inverse

Avant d'aborder l'analyse détaillée des performances prédictives, il convient de rappeler que l'identification des propriétés mécaniques à partir des seules fréquences propres constitue un problème inverse fortement non linéaire, sensible au bruit, aux corrélations entre paramètres et aux phénomènes d'ill-posedness. Dans un tel contexte, la capacité d'un modèle d'apprentissage automatique à reconstruire fidèlement les paramètres constitutifs dépend à la fois de la richesse de la base de données, de la représentativité des configurations simulées et de l'aptitude du réseau à extraire les relations sous-jacentes entre les observations modales et les propriétés recherchées.

Les résultats présentés ci-après permettent d'évaluer, de manière quantitative et qualitative, dans quelle mesure l'architecture retenue (MLP) parvient à capturer ces relations complexes. Les graphiques comparant valeurs réelles et valeurs prédites fournissent une première indication sur la fidélité de la reconstruction, tandis que les indicateurs statistiques extraits des distributions d'erreur permettent d'apprécier la dispersion des prédictions et la robustesse globale du modèle. Afin d'évaluer la précision du modèle, les valeurs prédites ont été comparées directement aux valeurs réelles issues des simulations éléments finis. La visualisation True vs Predicted présentée en Figure 3, proposée ici à titre d'exemple pour illustrer la qualité des prédictions, montre le cas de l'identification du module de Young longitudinal (E1). Il est important de préciser que ces résultats correspondent aux données du jeu de test, c'est-à-dire à des configurations qui n'ont pas été utilisées lors de l'apprentissage du modèle, et constituent ainsi un indicateur pertinent de sa capacité de généralisation.

Dans cette figure, chaque point bleu représente une valeur réelle tandis que chaque point rouge correspond à la valeur prédite par le réseau neuronal. La superposition ou la proximité de ces deux ensembles de points témoigne de la capacité du modèle à reproduire fidèlement la tendance générale et l'amplitude de la propriété mécanique considérée, constituant ainsi un indicateur visuel fort de la qualité de la prédiction.




Figure 3 – isualisation True vs Predicted pour le module de Young longitudinal (E1) sur le jeu de test, illustrant la précision du modèle MLP.

En complément de cet examen qualitatif, la précision du modèle a été quantifiée à l'aide du MAPE (Mean Absolute Percentage Error), qui fournit une mesure relative de l'erreur, indépendante des unités ou des ordres de grandeur des paramètres. Les valeurs obtenues, comprises entre environ 4 % et 5.25 % selon les propriétés considérées, témoignent d'une bonne cohérence entre valeurs prédites et valeurs réelles. Le module longitudinal E1, dont la variabilité est importante, présente un MAPE d'environ 4.65%, ce qui indique que le modèle restitue correctement l'amplitude malgré la sensibilité modérée des fréquences à ce paramètre. Le module transversal E2 est prédit avec une précision particulièrement élevée (MAPE $\approx 4,7$ %), ce qui confirme la capacité du modèle à capturer son influence sur la dynamique de la plaque. Le module de cisaillement G12, fortement corrélé aux modes de flexion et de torsion, est également bien identifié (MAPE $\approx 5,24$ %), ce qui montre que l'information contenue dans les fréquences modales permet de reconstruire efficacement ce paramètre clé du comportement mécanique. Le coefficient de Poisson ν_{12} , malgré sa faible amplitude numérique et son influence plus limitée sur le spectre modal, est prédit avec une erreur relative d'environ 4,77 %, traduisant une excellente stabilité de l'estimation. Enfin, l'angle d'orientation θ présente le MAPE le plus faible ($\approx 4,93$ %), ce qui confirme que le modèle parvient à capturer la symétrie directionnelle du matériau et à distinguer correctement les variations d'orientation, même lorsque leur influence sur certains modes peut être atténuée.

Dans l'ensemble, les valeurs numériques de l'erreur montrent que le modèle parvient à prédire correctement les propriétés mécaniques à partir des fréquences propres. Les valeurs prédites restent proches des valeurs réelles, la dispersion des erreurs demeure faible, et les quartiles issus des distributions d'erreur indiquent une bonne stabilité sur l'ensemble du domaine étudié. Ces résultats montrent que l'architecture MLP retenue parvient à capturer la relation complexe entre spectre modal et propriétés constitutives avec un niveau de précision satisfaisant. Ainsi, même sans recourir systématiquement aux histogrammes d'erreur, l'analyse conjointe des mesures quantitatives et des comparaisons graphiques confirme la fiabilité de la prédiction et la pertinence de l'approche adoptée pour résoudre ce problème inverse.

6. Conclusion

Ce travail a présenté une démarche d'identification inverse des propriétés mécaniques d'un matériau transversalement isotrope à partir de ses fréquences propres, en s'appuyant sur une base de données générée par éléments finis et sur des modèles d'apprentissage profond de type MLP. La méthodologie proposée, fondée sur un essai simplifié et aisément reproductible, permet d'établir un lien direct entre le spectre modal et les paramètres mécaniques sans recourir à des mesures complexes ni à des modèles constitutifs détaillés.

Les résultats obtenus montrent que le réseau neuronal parvient à reconstruire avec une bonne précision les cinq paramètres étudiés. Les indicateurs d'erreur confirment la stabilité globale de la prédiction : les valeurs prédites suivent correctement les valeurs réelles, les erreurs moyennes restent modérées et les quartiles témoignent d'une bonne robustesse du modèle. Malgré les limites intrinsèques du problème inverse considéré, l'approche démontre une capacité réelle à capturer la relation non linéaire entre fréquences modales et propriétés mécaniques.

Cette étude met ainsi en évidence le potentiel des méthodes hybrides EF-IA pour l'identification de matériaux anisotropes, en particulier dans un cadre non destructif et à faible coût. Les perspectives incluent l'extension de la démarche à des géométries plus complexes, l'intégration de données expérimentales réelles.

Références

- [1] O. Zinovieva, V. Romanova, E. Dymnich, A. Zinoviev, and R. Balokhonov, “A review of computational approaches to the microstructure-informed mechanical modelling of metals produced by powder bed fusion additive manufacturing,” *Materials*, vol. 16, no. 19, p. 6459, 2023.
- [2] T. Sheikh and K. Behdinan, “Insight of discrete scale and multiscale methods for characterization of composite and nanocomposite materials,” *Archives of Computational Methods in Engineering*, vol. 30, no. 2, pp. 1231–1265, 2023.
- [3] M. S. Dizaji, “Deep learning-based Visual Measurement Extraction within an Adaptive Digital Twin Framework from Limited Data Using Transfer Learning,” *arXiv preprint arXiv:2410.05403*, 2024.
- [4] B. Chen, B. Starman, M. Halilovič, L. A. Berglund, and S. Coppieters, “Finite element model updating for material model calibration: A review and guide to practice,” *Archives of Computational Methods in Engineering*, vol. 32, no. 4, pp. 2035–2112, 2025.
- [5] A. Sharma, J. Chen, E. Diewald, A. Imanian, J. Beuth, and Y. Liu, “Data-driven sensitivity analysis for static mechanical properties of additively manufactured Ti-6Al-4V,” *ASCE-ASME Journal of Risk and Uncertainty in Engineering Systems, Part b: Mechanical Engineering*, vol. 8, no. 1, p. 11108, 2022.
- [6] N. Motamedi, H. Wannous, and V. Magnier, “Deep learning identifies transversely isotropic material properties using kinematics fields,” *Int J Mech Sci*, vol. 283, p. 109672, 2024.