



HAL
open science

Optimisation par apprentissage automatique du procédé de fabrication additive métallique par diffusion atomique

Elisabeth Lacazedieu

► To cite this version:

Elisabeth Lacazedieu. Optimisation par apprentissage automatique du procédé de fabrication additive métallique par diffusion atomique. 16ème Colloque National en Calcul de Structures (CSMA 2024), CNRS; CSMA; ENS Paris-Saclay; CentraleSupélec, May 2024, Hyères, France. hal-04611012

HAL Id: hal-04611012

<https://hal.science/hal-04611012v1>

Submitted on 3 Dec 2024

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.

Optimisation par apprentissage automatique du procédé de fabrication additive métallique par diffusion atomique

S. Nehme¹, J. Marae Djouda^{1,2}, E. Lacazedieu³

¹ LMPS UMR CNRS 9026 Laboratoire de Mécanique Paris Saclay,

² EPF School of Engineering, Cachan, France

³ LAMIH UMR CNRS 8201 Laboratoire d'Automatique, de Mécanique et d'Informatique Industrielles et Humaines, elisabeth.lacazedieu@uphf.fr

Résumé — Le présent article a pour objet d'optimiser les paramètres intervenant dans la fabrication additive métallique par le procédé de diffusion atomique grâce à un usage optimal des données expérimentales disponibles issues d'essais de caractérisation des propriétés mécaniques de matériaux obtenus par ce biais. L'objectif est d'utiliser de grands volumes de données hybrides issues de mesures physiques et de modèles numériques, recueillies pour décrire des phénomènes à des échelles nano- à effets induits sur des échelles micro- et macro-scopiques, pour contribuer in fine au déploiement d'une conception itérative soutenable de matériaux métalliques constitutifs de composants mécaniques. Les données sont traitées pour construire des réseaux de neurones artificiels permettant de relier les paramètres de fabrication aux propriétés des matériaux ainsi conçus. Ces réseaux de neurones sont ensuite utilisés pour ajuster ou modifier par approche inverse les paramètres de fabrication et réduire ou éliminer les défauts de conception qui se présentent sous la forme de porosités incluses à l'échelle des microstructures du matériau. La combinaison de réseaux de neurones convolutifs et récurrents permet d'aborder aussi bien les problématiques de maîtrise des distributions spatiales des porosités que la question de l'auto-réparation et correction en temps réel des défauts avec le suivi en dynamique du comportement du matériau. L'enjeu est la réduction des coûts de production par la maîtrise et la suppression ou la remédiation en temps réel des défauts induits par le procédé de fabrication.

Mots clés — Intelligence artificielle, optimisation, résistance des matériaux.

1 Introduction

La fabrication additive (FA) permet la création de pièces basées sur des modèles de Conception Assistée par Ordinateur (CAO) et réalisées par dépôt de matériau couche par couche. Elle présente de nombreux avantages, notamment une flexibilité de conception, une réduction du gaspillage de matériaux et des délais de production efficaces. Initialement utilisée dans le contexte du prototypage rapide, elle a considérablement évolué et trouve des applications dans divers systèmes tels l'énergie, le transport, le domaine médical pour la fabrication de pièces spécifiques. En fonction des caractéristiques du matériau visé, plusieurs techniques de FA ont été développées ; parmi elles, le Dépôt de Fil Fondu (FFF) est la plus répandue. Initialement conçue pour les matériaux thermoplastiques, elle consiste à déposer des pièces en polymère aux géométries complexes à travers des buses chauffées. Le coût global de production des composants résultants reste relativement économique. Dans le contexte de la production de pièces métalliques, les techniques exploitant des sources de haute énergie telles que les lasers sont devenues d'usage courant, comme par exemple la Fusion Sélective par Laser (SLM) et le Dépôt à Energie Dirigée (DED) [6] et elles produisent des pièces aux propriétés mécaniques intéressantes. Cependant, ces processus induisent des mesures de sécurité contraignantes lors de la manipulation de la poudre et l'utilisation du laser, conduisant à des dépenses de fabrication élevées avec des limitations en termes d'applications.

Pour réduire les dépenses associées aux pièces métalliques issues de la FA, une méthode de fabrication additive par extrusion de métal a été développée. Elle exploite sa capacité de conception géométrique complexe en utilisant la FFF tout en minimisant les coûts et dans le même temps en évitant l'utilisation de lasers et de poudres. Des filaments composés de poudre liée par un polymère sont chauffés puis déposés à travers une buse. Les pièces subissent ensuite des étapes de lavage et de frittage pour éliminer

le polymère et les consolider. Néanmoins, les pièces obtenues présentent des imperfections intrinsèques au processus de fabrication. Surmonter ces défauts pour obtenir des pièces présentant des propriétés mécaniques satisfaisantes constitue un défi majeur aujourd'hui dans le domaine de la FA.

Une stratégie basée sur l'Intelligence Artificielle (IA) est proposée ici. A partir d'échantillons de fabrication recueillis en laboratoire et d'essais puis de simulations numériques de caractérisation des propriétés mécaniques des matériaux, l'objectif visé est de construire des réseaux de neurones à même de relier les paramètres de fabrication aux caractéristiques des matériaux et ainsi disposer d'une méthode numérique assistée par des données pour connaître les caractéristiques des porosités présentes au niveau des échantillons réels. Les paramètres de FA pourront ensuite être ajustés pour contrôler les microstructures responsables des défauts des matériaux et améliorer les propriétés mécaniques des structures pour les usages visés.

2 Objectifs

2.1 Contexte de la Fabrication Additive

Selon la norme ISO, la FA est définie comme le processus de création d'un objet physique couche par couche grâce à l'ajout de matériau, sur la base d'un modèle numérique. Elle se distingue des méthodes soustractives conventionnelles qui consistent à retirer de la matière pour fabriquer des pièces. Le processus commence par la création d'un modèle géométrique à l'aide d'un logiciel de CAO ou de techniques de retro-ingénierie ou par numérisation 3D. Le modèle est ensuite converti pour définir les surfaces externes servant de base aux calculs couche par couche. Il est ensuite découpé couche par couche pour générer un fichier de code machine qui permet de procéder à l'opération de fabrication. La FA s'appuie sur les principes suivants : une représentation numérique de l'objet à réaliser ; l'usage de matériaux consolidés sous leur forme la plus petite possible, comme des gouttelettes de liquide, du fil ou de la poudre ; le recours à un outil chargé de déposer et de superposer les matériaux ; enfin l'utilisation d'un système de contrôle numérique qui guide l'outil dans le dépôt des matériaux couche par couche, construisant à la forme souhaitée de l'objet. Les principaux avantages de cette technologie sont : la consolidation de pièces grâce au remplacement de plusieurs composants par un seul avec une réduction du nombre de pièces à assembler ; la diminution des coûts d'outillage grâce à la fabrication directe des pièces sans outillage ; enfin, l'accès à des géométries complexes puisque la FA offre la possibilité de fabriquer des géométries complexes.

La FA offre ainsi une grande flexibilité de conception par rapport aux méthodes soustractives classiques. Elle permet l'intégration de stratégies de conception innovantes et permet aux concepteurs d'explorer de nouvelles possibilités sans les contraintes imposées par les techniques de fabrication traditionnelles. En outre, elle permet la production de pièces topologiquement optimisées, résultant en des structures légères. Ainsi il est possible de placer stratégiquement le matériau uniquement là où il est nécessaire tout en préservant les propriétés recherchées.

Compte tenu de l'émergence récente de nombreuses technologies, une classification basée sur la norme ISO définit des familles de procédés additifs incluant l'extrusion de matériau, la stéréolithographie, le jet, le dépôt sélectif, le jet de liant ou encore la fusion sur lit de poudre, le dépôt d'énergie dirigée ou le laminage. En ce qui concerne la FA par extrusion de métaux, les premiers procédés de FA métallique bien connus sont dits directs. Ils consistent à déposer directement du métal chauffé, soit sous forme de filament, soit par chauffage couche par couche de poudre métallique, pour créer la forme souhaitée de la pièce.

2.2 Cas de la Fabrication Additive par Diffusion Atomique

Le procédé le plus récent, qui est l'extrusion de poudre liée, est appelé procédé indirect car il implique des étapes de post-traitement pour obtenir le produit final. Dans le présent article, on s'intéresse à l'extrusion de métal via la technologie mise en place par Markforged, Atomic Diffusion Additive Manufacturing (ADAM) à l'aide de machine Metal X. Le principe est le suivant : de la poudre métallique est agglomérée par un liant polymère pour former un filament. Le processus de fabrication implique un dépôt couche par couche de ce filament, à l'instar de la technique FFF [12]. Cependant, le procédé ADAM nécessite des étapes supplémentaires de lavage et de déliantage pour éliminer le liant polymère.

Le processus de déliantage a lieu dans un four à basse température avant l'étape de frittage traditionnelle. Le frittage, qui se déroule à une température légèrement inférieure au point de fusion, est nécessaire au compactage de la pièce. L'inclusion de cette étape de frittage ajoute une étape supplémentaire au processus de FA, le classant comme un processus de FA métallique indirect. Ainsi, en raison de ces étapes et du processus d'impression avec les paramètres d'impression initiaux adoptés, des défauts à l'intérieur de l'objet imprimé apparaissent et les plus persistants se présentent sous la forme de pores. Comprendre la distribution et les dimensions de porosité et essayer de réduire son effet sur les propriétés mécaniques est une problématique à enjeu majeur. Cette porosité limite les propriétés mécaniques des pièces obtenues et ainsi leurs spectres d'application (Figure 1).




FIGURE 1 – Principales étapes de la Fabrication Additive par Diffusion Atomique (ADAM).

L'objectif est de réduire la population et maîtriser la répartition de ces défauts. Il s'agit de recourir à l'apprentissage automatique (ou Machine Learning ML) pour détecter des modèles cachés complexes dans des ensembles de données de grande dimension, de manière à améliorer les processus de FA depuis les étapes initiales en passant par la surveillance, jusqu'aux étapes finales en incluant l'auto-réparation in situ en temps réel avec l'objectif d'améliorer les propriétés mécaniques des pièces mécaniques fabriquées en fonction de leurs usages. De nombreuses recherches ont été menées à l'aide de l'apprentissage automatique pour améliorer certaines phases des processus de FA tels que SLM et DED. Cependant, peu de travaux ont été réalisés sur le procédé d'extrusion de métal. Il est l'objet du présent projet. Pour prédire le comportement mécanique des pièces imprimées en 3D, trois problématiques combinées sont abordées en parallèle : (1) l'effet des paramètres de procédé ou d'impression, (2) l'effet des porosités en fonction de leurs distributions et de leurs géométries, (3) l'effet des défauts des matériaux constituant les pièces obtenues en fonction des propriétés mécaniques requises pour les usages visés.

3 Principales étapes

3.1 Méthode d'analyse

La recherche d'une combinaison optimale de paramètres est le principal enjeu de l'impression 3D pour obtenir une pièce de bonne qualité. Plusieurs recherches ont été menées pour étudier ces paramètres ; ainsi [8] étudie le comportement à la rupture de différents matériaux obtenus par des procédés de FA pour collecter des informations sur l'influence du processus d'impression et des paramètres sur le comportement à la rupture des pièces imprimées. Cela requiert du temps et de nombreuses expériences coûteuses. Le Machine Learning (ML) est une alternative qui a fait ses preuves pour optimiser les paramètres du processus de FA. Dans [10], l'effet des paramètres d'impression tels que l'épaisseur de la couche, l'orientation de la construction et l'angle de trame via la modélisation par dépôt fondu sur l'usure

par glissement de la pièce imprimée est étudié et des Réseaux de Neurones Artificiels (ANN) sont utilisés pour confirmer les résultats.

Un algorithme de rétro-propagation est adapté pour modéliser les paramètres d'impression. Les entrées sont les paramètres d'impression et les sorties correspondent à une valeur caractéristique de l'usure du matériau. Des comparaisons avec des valeurs expérimentales sont proposées. [11] traite des mêmes paramètres d'impression du FDM mais avec une relation en termes de résistance à la compression. Le même type d'ANN est proposé avec les paramètres d'impression comme entrées et la résistance à la compression comme sortie et les résultats donnent satisfaction. L'un des aspects les plus importants de la FA est d'obtenir une pièce possédant de bonnes propriétés mécaniques, ce qui suppose a minima une pièce imprimée entièrement dense. [3] décrit comment les pores présentes à la surface et à l'intérieur du matériau affectent la résistance, la rigidité et d'autres propriétés mécaniques des objets imprimés. De nombreuses recherches se concentrent sur la porosité détectée dans les pièces imprimées et les prédisent en fonction du processus d'impression tout en essayant d'atteindre la combinaison optimale. [1] prédit la porosité à l'aide d'ANN Récurrents et Convolutifs (RNN, CNN) dans les pièces obtenues par SLM, les données utilisées provenant de travaux reliant le nombre de pores et leurs diamètres à la vitesse de balayage et la puissance du laser. Ainsi, deux équations de régression sont établies et permettent de prévoir le nombre de pores et la taille correspondante

Les progrès dans le secteur de la FA n'ont pas permis d'éliminer complètement la plupart des défauts. Certains peuvent prendre la forme de fissures, de délaminage et de rugosité de surface. Plusieurs travaux traitent du regroupement de ces effets ou leur suivi lors de la phase d'impression. Une méthode d'identification des défauts pour la FA est ainsi proposée [4]. Elle utilise des signaux d'Emission Acoustique (AE) et des algorithmes de ML pour différencier les événements AE liés à la formation de fissures et le bruit de fond. Un haut niveau de précision atteignant jusqu'à 99 % est obtenu lorsque les événements sont représentés dans l'espace décomposé suivant les composantes principales. Il s'agit d'utiliser des techniques telles que le traitement d'images basé sur le ML, la surveillance de la porosité en cours de processus de fabrication, la détection des défauts en temps réel dans l'impression 3D et l'analyse de la qualité du matériau métallique obtenu avec la détection de fissures in situ. On propose ici d'aborder la détection de la porosité pour des matériaux obtenus par extrusion de poudre liée avec ADAM.

3.2 Cas d'étude

Il est proposé d'évaluer la faisabilité de la démarche avec un métal Inconel 625 qui est imprimé à l'aide d'une imprimante 3D Metal X. Il s'agit d'un superalliage à base de nickel à haute résistance et résistance à la température. L'intérêt porte plus particulièrement sur la porosité de surface après le processus de frittage et dans le volume observée par acquisition au tomographe. Des images de dimension 2 de grandes dimensions (de l'ordre du mm^2) sont utilisées pour extraire et suivre les défauts. Des volumes reconstruits à l'aide de relevés tomographiques sont également reproduits et analysés. Une première étape consiste à caractériser la porosité.

De nombreuses méthodes sont possibles pour mesurer la teneur en vides et en pores. Par traitement d'images, il est possible d'identifier le contenu des vides, la localisation et la taille moyenne des pores. La segmentation d'image par seuillage est utilisée ici et ce processus aboutit à une image segmentée binaire. Un histogramme est utilisé pour décrire l'intensité disponible dans la micrographie et le niveau seuil. Le seuillage aboutit à une teneur en porosité utilisée pour créer une microstructure représentative à utiliser pour construire un modèle numérique synthétique de matériau. Des ANN sont déduits à l'aide de bases d'apprentissage qui sont déduites des simulations numériques réalisées sur les échantillons virtuels obtenus. Il est alors possible d'identifier une répartition de la porosité et de détecter la distribution que suivent les pores selon leur emplacement à l'intérieur de la micrographie traitée.

Il s'agit ensuite d'évaluer les performances de l'ANN sur des échantillons réels et fictifs. Le but est par exemple est de créer un ANN capable de prédire un niveau de contrainte de Von Mises dans n'importe quel échantillon avec microstructures poreuses sans recours à la simulation numérique ni à l'expérimentation. L'objectif est d'obtenir une architecture de démonstrateur en fin de projet. En ce qui concerne la génération des bases de données d'apprentissage, il est nécessaire d'optimiser le caractère prédictif des ANN. En établissant et en exploitant la relation entre les paramètres d'impression 3D et les caractéristiques des porosités à l'aide de l'apprentissage automatique, le but est d'optimiser le processus

de fabrication additive en trouvant les meilleures combinaisons de paramètres d'impression possibles conduisant au nombre de porosités minimal et à la distribution optimale pour le matériau et la forme considérés tout en contribuant à une réduction de la quantité de matière utilisée.

4 Premiers résultats

4.1 Traitement des images

L'ANN se compose d'un agencement séquentiel de couches, en commençant par une couche d'entrée qui provient d'images d'une dimension dépendant des données disponibles (300 x 300 pixels pour 90 000 neurones d'entrée). Des couches convolutives suivent, extrayant progressivement les caractéristiques à l'aide de filtres. Chaque couche convolutive est couplée à une fonction d'activation (par exemple une fonction d'activation d'unité linéaire rectifiée ReLU), améliorant la non-linéarité du réseau. Des couches intermédiaires sont introduites pour améliorer le caractère prédictif de l'ANN. La couche de sortie, dotée d'un seul neurone, prédit la fraction de vides.

La Figure 2 représente une image avant et après application d'un seuil ainsi qu'une image synthétique déduites des caractéristiques de l'image initiale, à savoir le taux de vide surfacique moyen et le rayon moyen des pores mesurés. Plusieurs distributions de porosités disponibles suivant une direction x sont représentées sur la Figure 3. La distribution obtenue est comparée à des distributions de lois possibles : les lois normales, exponentielles et log-normales. Il s'avère qu'aucune loi standard ne correspond de sorte que dans toute la suite, une distribution aléatoire est retenue dans toute la suite.



FIGURE 2 – Exemple de micrographie binaire correspondant à une porosité de surface (à gauche); micrographie après seuillage (au milieu); modèle synthétique après calcul de la fraction surfacique de vide : 1,5% et du rayon de pore moyen : 0.01mm (à droite).

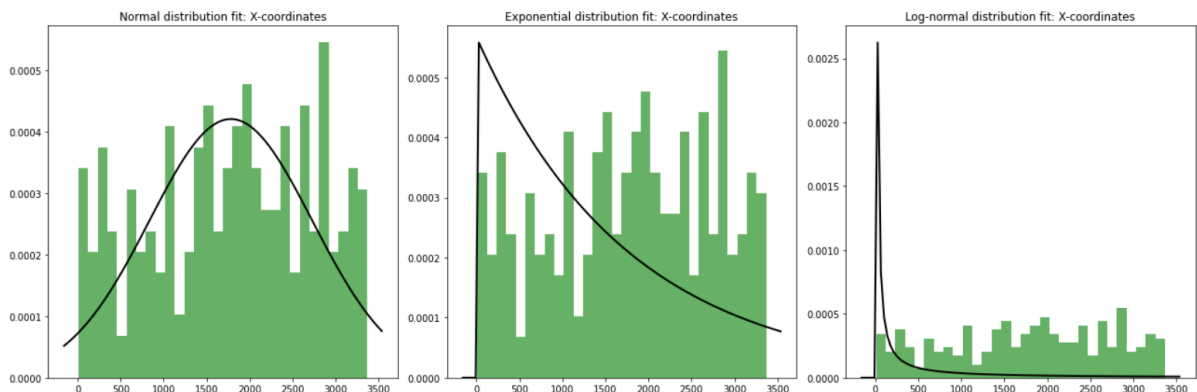


FIGURE 3 – Comparaison de la distribution de pores obtenue à des lois de distributions bien connues : normale (à gauche), exponentielle (au milieu) et log-normale (à droite).

4.2 Génération de microstructure

Une section de 0,8 x 0,8 mm avec des pores circulaires de rayon compris entre 0,003 et 0,01 mm avec une fraction de vide (porosité) de 2% a été adoptée. Ceci a été écrit sur Python pour pouvoir gérer ultérieurement la génération d'ensembles de données de simulation et d'apprentissage automatique.

Sur la figure 4 , nous pouvons voir la microstructure qui sera utilisée plus tard à des fins de simulation.




FIGURE 4 – Exemple de Microstructure de porosité à l'intérieur d'une micrographie générée.

4.3 Simulations numériques

Pour mieux comprendre l'effet des pores dans la microstructure générée, ABAQUS a été utilisé pour tracer la contrainte de Von Mises le long de la microstructure 2D. L'interphase Python Abaqus a été utilisée pour utiliser la microstructure générée et la carte de contraintes obtenue afin de générer ultérieurement un ensemble de données d'image et la carte de contraintes correspondante à utiliser dans la partie réseau neuronal. La matrice était représentée par Inconel 625 et les vides étaient traités comme des inclusions et dotés d'une propriété matérielle triviale de 10% de celle de la matrice. La condition aux limites considérée ici est une tension pure, comme le montre la figure 5, l'extrémité gauche de la microstructure est fixe et une déformation est appliquée à l'extrémité droite. La déformation est maintenue à 0,1% pour rester dans la zone élastique de la courbe.




FIGURE 5 – Condition aux limites utilisée.

Nous pouvons maintenant traiter du modèle selon lequel nous allons générer un ensemble de données à utiliser dans la partie réseau neuronal. Nous avons utilisé un plan 2D statique explicite avec contrainte plane comme base du modèle. La figure 6 montre un exemple de carte de contraintes obtenue.

4.4 Génération des bases d'apprentissage

L'ANN est entraîné pour détecter les pores dans toute image fournie. Dans ce cas, 900 images sont utilisées avec différents contenus de vides et tailles de pores. La fraction de vide représente le rapport entre la zone contenant des pores (pixels non nuls) et la surface totale de l'image. La Figure 7 montre un exemple de simulation numérique réalisée avec un modèle synthétique.

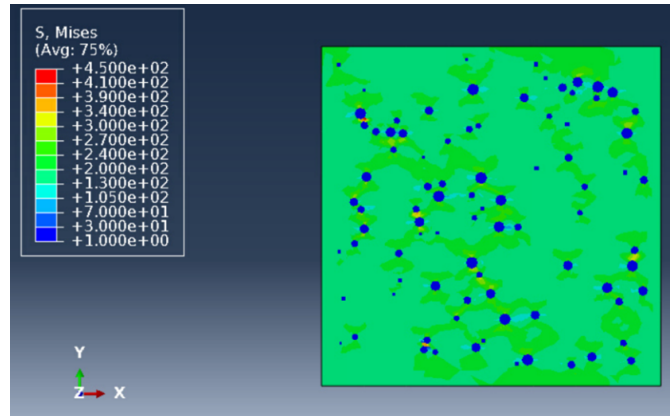


FIGURE 6 – Figure montrant la carte des contraintes de von mises.




FIGURE 7 – Exemple de maillage pour les simulations numériques d’essais de traction (à gauche); porosité de surface utilisée dans le modèle numérique (au milieu); calcul de la distribution de contrainte selon le critère de Von Mises (à droite).

4.5 Evaluation de performances

4.5.1 ANN pour la détection des pores

L’architecture ANN est représentée sur cette figure 8. Une série de couches convolutives avec une mise en commun maximale suivie d’une série de couches entièrement connectées pour atteindre une sortie avec un seul neurone représentant le contenu vide dans l’image fournie.




FIGURE 8 – Structure du ANN.

Le réseau de neurones artificiels (ANN) formé démontre des performances impressionnantes dans la prédiction de la fraction de vide dans les images figure 9. Le processus de formation a nécessité 15 époques au cours desquelles la perte du réseau a été constamment réduite. Au fil de chaque époque, l’ANN a progressivement affiné sa précision de prédiction, comme en témoigne la diminution des pertes de formation et de validation.

4.5.2 ANN pour la prévision du stress

ANN est conçu pour effectuer une tâche de traduction d’image à image, générant spécifiquement des cartes de distribution de contraintes de von Mises à partir d’images de microstructure en niveaux de gris.

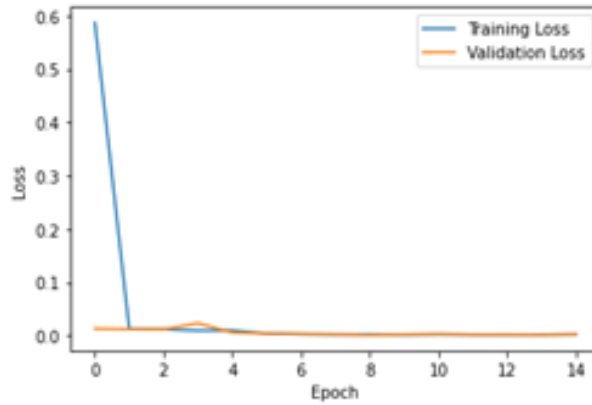


FIGURE 9 – Pertes de validation et de formation.

L'architecture ANN ressemble à une structure U-Net composée d'une série de couches convolutives, comme le montre la figure 10.

Nous pouvons voir l'entrée une image en échelle de gris et la sortie est l'image de prédiction de la carte des contraintes.




FIGURE 10 – Structure du ANN.

15 cycles sont requis au cours desquels la fonction coût est constamment réduite. Au fil de chaque cycle, l'ANN améliore sa précision de prédiction, comme en témoigne la Figure 11. Ce résultat met en évidence le potentiel de l'ANN à prédire de manière robuste la fraction de vide dans les images. La figure 12 montre un exemple de reconstruction de solution par l'ANN avec un bon accord avec les valeurs attendues déduites de simulations numériques menées sur une configuration connue de manière déterministe.




FIGURE 11 – Evolution de la performance du réseau de neurones en fonction du nombre de cycles, pour l'apprentissage et pour la reconnaissance.




FIGURE 12 – Utilisation du réseau de neurones pour la prévision du critère de Von Mises : distribution des microstructures du modèle synthétique (à gauche); calcul de la distribution du contraintes et du critère de Von Mises par simulation numérique (au milieu à gauche); prévision de la distribution du critère de Von Mises par le réseau de neurones (au milieu à droite); représentation de l'erreur sous forme binaire (à droite).

5 Conclusion et perspectives

Ce travail porte sur l'identification de la porosité des matériaux métalliques obtenus par extrusion de poudre liée, technique d'impression 3D réalisée à l'aide de l'imprimante Metal X de Markforged. En utilisant une combinaison de paramètres d'impression, des échantillons sont imprimés; une analyse micrographique permet de caractériser la porosité en fonction de la taille et de la distribution des pores. Les représentations microstructurales sont traduites sous la forme d'un modèle mécanique bidimensionnel. Des conditions aux limites spécifiques sont introduites pour évaluer les propriétés mécaniques résultantes, en se concentrant principalement sur la contrainte de von Mises, un ensemble de données synthétiques de microstructures et leurs distributions de contraintes associées étant généré automatiquement sur la base des analyses des micrographies et des entrées microstructurales. Cet ensemble de données est utilisé pour entraîner l'ANN afin de prédire la contrainte de von Mises. Il est ainsi possible d'établir une corrélation entre les paramètres d'impression, la porosité et les propriétés mécaniques, offrant ainsi un potentiel d'optimisation future de l'impression 3D avec la perspective d'une prévision accessible des défauts induits par le procédé sous la forme de porosités.

Références

- [1] Alamri, N.M., Packianather, M., Bigot, S., 2022. *Predicting the Porosity in Selective Laser Melting Parts Using Hybrid Regression Convolutional Neural Network*. Applied Sciences 12 : 12571.
- [2] Ali Bouaziz, M., Marae Djouda, J., Hild, F., 2021. *On Mesoscale strain fluctuations in tensile tests on additively manufactured 17-4PH stainless steel*. The Journal of Strain Analysis for Engineering Design, 57(8).
- [3] Al-Maharma, A., Y., Patil, S.P., Markert., B., 2020. *Effects of Porosity on the Mechanical Properties of Additively Manufactured Components : A Critical Review*. Materials Research Express 7(12) : 122001.
- [4] Khan, F., 2021. *Real-Time Defect Detection in 3D Printing Using Machine Learning*. Materials Today : Proceedings 42 : 521 ?28.
- [5] Ferraro, A., Marae Djouda, J., Lio, G., Leveque, G., Adam, P.M., Umeton, T., Caputo, R., 2022. *Investigation of Lattice Plasmon modes in 2D arrays of Au Nanoantennas*. Crystals, 12(3), 336.
- [6] Haghdam, N., Laleh, M., Moyle, M., Primig, 2021. *Additive manufacturing of steels : a review of achievements and challenges*. Journal of Materials Sciences, 56(1), 64-107.
- [7] Kasmir, A., Marae Djouda, J., Hild, F., 2022. *On elastic anisotropy of 3D printed acrylonitrile butadiene styrene structures*. Polymer, 254, 125032.
- [8] Khosravani, Reza, M., Berto, F., Ayatollahi, M.R., Reinicke, T. 2020. *Fracture Behavior of Additively Manufactured Components : A Review*. Theoretical and Applied Fracture Mechanics 109 : 102763.
- [9] Pulikkathodi, A., Lacazedieu, E., Chamoin, L., Berro Ramirez, J.P. , Rota, L., Zarroug, M., 2023. *A neural network-based data-driven local modeling of spotwelded plates under impact*. Mechanics & Industry 24, 34.
- [10] Sood, A.K., 2011. *An Investigation on Sliding Wear of FDM Built Parts*. Journal of Manufacturing Science and Technology.
- [11] Sood, A.K. , Ohdar, R.K., Mahapatra, S., 2012. *Experimental Investigation and Empirical Modelling of FDM Process for Compressive Strength Improvement*. Journal of Advanced Research, 3(1), 81-90.

- [12] Valizadeh, M., Wolff, S.J., 2022. *Convolutional Neural Network Applications in Additive Manufacturing : A Review*. *Advances in Industrial and Manufacturing Engineering*, 4, 100072.