

CIGI QUALITA MOSIM 2023

Paramètres de fabrication additive métallique arc-fil : vers un modèle d'aide à la décision

LAURENT TERRENOIR^{1,2}, LAURA LAGUNA SALVADO¹, CHRISTOPHE MERLO¹, JULIE LARTIGAU¹, ARUN ARJUNAN²

¹ Univ. Bordeaux, ESTIA Institute of Technology,
Technopole Izarbel 64210 Bidart, France

l.terrenoir@estia.fr, l.lagunasalvado@estia.fr, c.merlo@estia.fr, j.lartigau@estia.fr

² Additive Manufacturing of Functional Materials research group
University of Wolverhampton
TN9 2FT Telford, UK
a.arjunan@wlv.ac.uk

Résumé – Pour contribuer à l'intégration industrielle des procédés de fabrication additive métallique, la maîtrise des performances relatives à la qualité des pièces produites et relatives au procédé de fabrication est impérative. Cet article propose un cadre méthodologique outillé pour faciliter la mise en œuvre de ces technologies via le choix de paramètres de fabrication pertinents. Il combine un algorithme génétique, adapté à l'optimisation de paramètres de fabrication, le *Nondominated Sorting Genetic Algorithm II* (NSGA II) à un algorithme de classement multicritères permettant ainsi une interaction avec le décideur, une puissance de calcul élevée et une simplicité d'utilisation pour le décideur. Le modèle proposé a été développé pour l'optimisation des paramètres de fabrication du procédé additif arc-fil (*Wire Arc Additive Manufacturing* - WAAM) en fonction de critères mécaniques (force maximale admissible et précision dimensionnelle) et industriels (coût et impact environnemental). Ce modèle vise à participer à l'industrialisation des procédés dits de dépôt de matière sous flux d'énergie dirigé (*Directed Energy Deposition* – DED). Ainsi, il a été conçu pour être applicable à des cas d'études variés intégrant diverses géométries, matériaux et procédés DED.

Abstract – Directed Energy Deposition (DED) processes are not widely used in industry. To contribute to their integration, it appears essential to handle both the quality of the produced parts and the sustainability of the manufacturing process. This paper presents a methodological framework to support the implementation of these technologies through the choice of relevant manufacturing parameters according to the targeted performances. It combines a genetic algorithm, suited to the optimisation of manufacturing parameters, the Nondominated Sorting Genetic Algorithm II (NSGA II) with a multi-criteria ranking algorithm. Thus, it brings the necessary interaction with the decision-maker, a high computational power and a simplicity of use for the decision maker. The proposed model has been developed for the optimisation of manufacturing parameters of the Wire Arc Additive Manufacturing (WAAM) process according to both mechanical characteristics (load bearing capacity and dimensional accuracy) and industrial criteria (cost and environmental impact). As this model aims to participate to the industrialisation of DED processes, it has therefore been designed to be transferable to a broad range of cases integrating various geometries, materials and DED processes.

Mots clés – Aide à la décision, fabrication additive métallique, optimisation multicritères, industrialisation, paramètres de fabrication.

Keywords – Decision support system, metal additive manufacturing, multicriteria optimisation, industrialisation, process parameter.

1 INTRODUCTION

La Fabrication Additive Métallique (FAM) fait référence à différentes solutions technologiques, inégalement intégrées dans l'industrie [Ahn, 2021]. Alors que les technologies dites de lit de poudre sont déjà implantées, les technologies de dépôt de matière sous flux d'énergie dirigé (*Directed Energy Deposition* - DED) peinent à passer la porte des centres de recherche pour être utilisées à échelle industrielle.

Les procédés DED peuvent être classés selon la forme du matériau d'apport et la source d'énergie de fusion. Ces différences technologiques donnent lieu à des performances variées et donc à des usages privilégiés en fonction de la technologie utilisée. Pour pouvoir intégrer ces technologies dans leurs lignes de production, les industriels ont besoin d'en

maîtriser les performances. Elles regroupent à la fois les performances mécaniques, relatives à la qualité des pièces fabriquées, mais aussi les performances industrielles durables du procédé de fabrication.

La durabilité des procédés de fabrication est aujourd'hui un élément clé pour les industriels. Afin de la prendre en considération dans le cadre de l'implémentation de la FAM, ses impacts économiques, environnementaux et sociaux doivent être adressés [Peng et al., 2018]. La maîtrise et l'optimisation de l'ensemble de ces performances, parfois conflictuelles, passent notamment par la sélection des paramètres de fabrication les plus adaptés. Or, si certaines études, comme l'ont rapporté [Ahn et al., 2021], ont contribué à développer les connaissances relatives aux procédés, celles-ci sont souvent compartimentées

selon les domaines d'études (mécanique, physique, économique, environnemental) et difficilement exploitables pour les industriels.

Ainsi, il apparaît que le développement d'un modèle d'aide à la décision, permettant aux industriels de choisir les paramètres de fabrication adaptés aux performances mécaniques des pièces fabriquées ainsi qu'aux performances industrielles durables du processus de fabrication, contribue à l'industrialisation des procédés DED (Peng et al., 2018). À cette fin, une définition précise du problème d'aide à la décision considéré et la démarche mise en œuvre pour le résoudre sont proposées dans cet article.

Cette démarche s'inscrit dans le développement d'une méthodologie pluridisciplinaire qui combine génie industriel et mécanique. Dans un premier temps, un procédé DED a été sélectionné. Il s'agit du procédé *Wire Arc Additive Manufacturing* (WAAM). Un modèle de connaissances liant les performances aux paramètres de fabrication a été développé. Dans cet article, un modèle d'aide à la décision est présenté pour contribuer au transfert de ces connaissances aux industriels et pour répondre à la question de recherche suivante : « Comment aider au choix des paramètres de fabrication du procédé WAAM en fonction de critères mécaniques et industriels durables ? ».

Dans la partie 2, le problème de décision considéré sera exposé en détail. Puis, dans la partie 3, un état de l'art des recherches effectuées sur le choix des paramètres de fabrication ainsi que sur les outils d'aide à la décision applicables à notre problème sera présenté. Enfin la démarche considérée pour résoudre le problème de décision sera explicitée en partie 4. La partie 5 présentera une conclusion.

2 DEFINITION DU PROBLEME

2.1 Positionnement

Le cycle de vie des pièces fabriquées par FAM, tel que décrit dans la littérature, s'étend de la phase de conception à la phase de gestion de fin de vie comme illustré en Figure 1. Pour contribuer à l'intégration de la FAM dans l'industrie, il a été souligné le besoin d'en maîtriser l'ensemble des phases. Cela passe par le développement de solutions permettant d'assurer la gestion des données tout au long de celui-ci [Jarrar et al., 2021] et la détermination de l'impact économique, environnemental et social de la FAM sur l'ensemble du cycle de vie considéré et donc sur chacune de ses phases [Peng et al., 2018].




Figure 1: Cycle de vie de pièces fabriquées par FAM

Pour contribuer à la maîtrise du cycle de vie de la FAM, les travaux présentés dans cet article se concentrent sur la phase de fabrication, avec la perspective d'étendre l'approche aux autres phases dans un second temps. Dans le cycle de vie considéré, cette phase intervient après la conception de la pièce et comprend le pré-traitement, le procédé de FAM, et le post-traitement.

Lors de la fabrication, l'ingénieur procédé doit paramétrer la machine. Aujourd'hui, ces paramètres sont choisis en se basant sur l'expertise métier de l'ingénieur et sur les recommandations du fournisseur de la technologie par rapport à la géométrie et au matériau de la pièce fabriquée. Aussi, l'ensemble des performances relatives à la pièce et au procédé de fabrication ne

sont pas pris en compte dans ce choix.

Les performances mécaniques, permettent d'assurer que la pièce répond aux spécifications définies dans l'étude de conception. La résistance mécanique de la pièce à différentes sollicitations, la précision dimensionnelle, et son état de surface doivent être conformes. Les performances industrielles durables, évaluent l'impact économique, environnemental et social de la phase de fabrication. Ces critères doivent être cohérents avec la stratégie, le modèle économique et les orientations de l'entreprise.

La sélection de paramètres optimaux pour favoriser l'ensemble des performances n'est pas toujours possible, ni aisée, voire conflictuelle. Ces travaux ont donc pour objectif d'aider les ingénieurs procédé à choisir les paramètres de fabrication, pour maîtriser les performances mécaniques et industrielles durables.

2.2 Application au WAAM

Le procédé WAAM consiste à déposer goutte à goutte un fil métallique fondu au moyen d'un arc électrique, et à répéter l'opération couche après couche. Ce procédé permet la fabrication de pièce de grandes dimensions, mais avec un état de surface nécessitant une reprise par usinage, au moins pour les surfaces fonctionnelles. Le WAAM atteint des vitesses de fabrication parmi les plus élevées pour la FAM [Ahn, 2021]. Il est particulièrement adapté pour les matériaux à haute valeur ajoutée et les pièces épaisses.

Dans notre cas d'étude, il a été choisi de considérer le procédé WAAM appliqué à la fabrication d'une pièce comportant des parallélépipèdes rectangles épais ($e = 2.5 \text{ cm}$) en acier inoxydable (316L).

Pour une géométrie et un matériau donné, les paramètres de fabrication les plus impactants du procédé sont la vitesse d'avance de fil (le débit de sortie du fil), la vitesse d'avance de torche (soit la vitesse de déplacement du robot), le débit de gaz de protection, l'angle de mouillage, le diamètre du fil et le temps inter-couche [Ahn, 2021; Rouchon et al., 2021]. Pour construire un modèle de connaissances, un plan d'expérience factoriel complet (Tableau 1) a été élaboré à partir de deux paramètres : les vitesses d'avance de fil (notées *WFS* pour *Wire Feed Speed*) et vitesses d'avance de torche (notées *TS* pour *Torch Speed*). Ce plan d'expérience permet ainsi de caractériser les relations entre les paramètres retenus et les critères à partir d'un minimum de pièces fabriquées. En effet, les temps et coûts de fabrication ne sont pas négligeables. Ce modèle de connaissances permettra de prouver la faisabilité de la méthodologie proposée. Dans le futur un plan d'expérience prenant en compte davantage de paramètres permettra d'élaborer un modèle de connaissances plus complet.

Les critères retenus parmi les performances mécaniques sont la force maximale admissible (notée $F_{max adm}$) et la précision dimensionnelle de la pièce. $F_{max adm}$ correspond au chargement mécanique que peut supporter une pièce donnée (géométrie et matériau fixés). Le niveau maximal atteignable est défini par la limite élastique du matériau divisée par un coefficient de sécurité. L'état de surface n'a pas été retenu car le WAAM ne permet pas d'obtenir un état de surface correct et les surfaces fonctionnelles devront être réusinées dans tous les cas.

Les critères caractérisant les performances industrielles durables sont le coût et l'impact environnemental sous forme d'éco-score (méthodologie ReciPE [Kellens et al., 2014]).

Les deux variables continues, *WFS* et *TS*, sont reliées aux critères par des équations polynomiales de degré deux. Elles ont été établies grâce à l'analyse en surface de réponse des données expérimentales, fruits du plan d'expériences.

Les critères considérés ont été répartis en objectifs et en

contraintes. L'optimisation de la force admissible relève de la phase de conception de la pièce. Lors de la phase de fabrication, on veut s'assurer que les paramètres choisis garantissent la résistance mécanique précédemment déterminée. C'est pourquoi la force maximale admissible n'est pas un objectif de l'optimisation mais une contrainte.

Tableau 1. Plan d'expériences

N° Essai	Facteurs	
	WFS (m/min)	TS (m/min)
1	1	0
2	0	0
3	-1	0
4	-1	-1
5	0	-1
6	1	-1
7	1	1
8	0	1
9	-1	1

Niveau -1	5.0	0.60
Niveau 0	7.5	0.75
Niveau 1	10	0.90

Dans notre cas d'étude, les fonctions objectifs résultantes des critères observés sont les suivantes :

$$f_1(WFS, TS) = \min(\text{coût de fabrication}) \quad \text{Eq.1}$$

$$f_2(WFS, TS) = \min(\text{éco-score}) \quad \text{Eq.2}$$

$$f_3(WFS, TS) = \max(\text{précision dimensionnelle}) \quad \text{Eq.3}$$

Les contraintes considérées sont les suivantes :

$$g_1(WFS, TS_s) = F_{\text{appliquée}} \leq F_{\text{max adm}} \quad \text{Eq.4}$$

$$WFS \in [5 ; 10] \text{ m/min} \quad \text{Eq.5}$$

$$TS \in [0,6 ; 0,9] \text{ m/min} \quad \text{Eq.6}$$

Le problème consiste donc à choisir le couple de paramètres WFS et TS optimal du WAAM qui minimise les coûts et l'impact environnemental de la fabrication tout en garantissant la tenue mécanique et en maximisant la précision dimensionnelle de la pièce fabriquée.

2.3 Défis et enjeux

Pour aider l'ingénieur à choisir les paramètres de fabrication adaptés, un modèle d'aide à la décision intégrant l'optimisation de ces paramètres est proposé dans cet article. Le problème de décision présenté est un problème multicritères et multivariables. Comme discuté ci-dessus, le modèle sera validé dans un premier temps pour le cas d'étude présenté comportant quatre critères et deux variables. Cependant, le modèle doit permettre de considérer l'optimisation sur l'ensemble des paramètres de fabrication (variables > 6).

Pour être approprié à un usage industriel, le modèle devra permettre une utilisation intuitive et non chronophage. L'optimisation devra être efficace, c'est-à-dire converger vers les solutions optimales rapidement, et s'assurer de trouver les meilleures solutions parmi l'ensemble des solutions existantes. Le modèle doit aider l'ingénieur à hiérarchiser ses critères et ainsi à choisir les paramètres les plus adaptés.

Pour résoudre le problème présenté, le modèle d'aide à la décision doit :

- permettre la résolution d'optimisation multicritères et multivariables ;

- pouvoir intégrer les équations polynomiales continues de degré deux du modèle de connaissances ;
- permettre un temps de calcul faible et une grande précision des solutions en considérant un nombre élevé de variables de décisions (ce qui implique une grande population de solutions candidates) ;
- être interactif et synthétique. Simple d'utilisation mais complet, il n'exigera pas un expert spécialement formé pour le faire fonctionner ;
- être extensible pour s'adapter à l'évolution du modèle de connaissances en intégrant davantage de paramètres de fabrication et des étapes de post-traitement ;
- être transposable à d'autres procédés DED.

3 AIDE A LA DECISION MULTICRITERES POUR LA FAM

3.1 Optimisation de paramètres de fabrication

Comme [Ahn et al., 2021] l'ont souligné dans leur état de l'art sur les technologies DED, de nombreux travaux mesurent et modélisent numériquement l'impact des paramètres de fabrication du WAAM sur les caractéristiques mécaniques du matériau fabriqué. Cependant, ces travaux ne s'étendent pas à l'optimisation des paramètres étudiés. De plus, ils sont souvent concentrés sur l'étude de cordons unitaires et non sur des géométries représentatives de pièces industrielles réelles. Certains travaux récents se sont penchés sur l'optimisation des paramètres de fabrication au regard des performances mécaniques du cordon seul [Rouchon et al., 2021]. Ainsi, il apparaît que l'optimisation de paramètres de fabrication du WAAM pour des pièces épaisses est encore peu étudiée.

D'autre part, des travaux portant sur l'optimisation des paramètres de fabrication au regard des performances mécaniques et industrielles durables de la pièce produite ont été menés pour la FA polymère. Un modèle permettant d'optimiser les paramètres d'impression d'un procédé de FA polymère a été développé pour aider les fabricants dans la sélection des paramètres en fonction des critères de temps de production, de matériel consommé, d'état de surface et de la performance mécanique [Asadollahi-Yazdi et al., 2018]. Les quatre variables de décision choisies par les auteurs sont les trois angles de positionnement de la pièce et la hauteur de couche. Ce problème d'optimisation multi-objectifs a été résolu à l'aide d'un algorithme génétique : *Nondominated Sorting Genetic Algorithm II* (NSGA II).

Une autre étude récente utilise le même outil afin d'optimiser les paramètres d'usinage d'un matériau renforcé en fibre de carbone [Ge et al., 2023]. Le problème considéré vise l'optimisation de trois critères de performance, deux liés à la pièce et un lié au processus. Les deux variables de décision sont les paramètres d'usinage suivants : la vitesse d'avance et la vitesse de rotation. En appliquant l'algorithme NSGA II, des solutions Pareto-optimales sont trouvées. Puis ces solutions sont classées avec la méthode *Techniques for Order of Preference by Similarity to Ideal Solution* (TOPSIS). En effet le NSGA II a permis d'obtenir neuf solutions optimales, ce qui est un nombre trop élevé de solutions pour permettre le choix des paramètres de fabrication. En utilisant TOPSIS, la solution la plus proche de la solution idéale envisagée par le décideur a été trouvée. Cependant, cette dernière méthode demande au décideur d'avoir une idée précise de la pondération qu'il souhaite appliquer aux critères.

[Shin et al., 2017] ont relevé une dizaine d'études portant sur l'optimisation des performances durables de divers processus de fabrication via le choix des paramètres de fabrication. Cependant, si ces efforts ont permis l'utilisation fructueuse de

modèles d'optimisation, il apparaît que l'application des techniques d'optimisation peut être problématique pour les industriels. Cela est dû à la complexité de formalisation du problème et de mise en œuvre de l'optimisation [Shin et al., 2017].

3.2 Modèles d'aide à la décision multicritères

Parmi les modèles d'aide à la décision multicritères ou *Multi-Criteria Decision Making* (MCDM), de nombreux outils ont été développés pour résoudre quantité de problèmes variés. Une approche MCDM permet de formuler et de résoudre un problème d'optimisation [Shin et al., 2017].

Les méthodes d'optimisation multi-objectifs sont classées en deux catégories : les méthodes classiques et les méthodes métaheuristiques. Parmi les méthodes classiques, on retrouve notamment les *weighted sum methods* (méthodes des sommes pondérées) et le *goal programming* [Liu et al., 2020].

Les algorithmes métaheuristiques sont particulièrement adaptés pour l'optimisation de paramètres de fabrication au regard de performances mécaniques et durables car ces critères sont souvent en conflit. De plus, les méthodes métaheuristiques sont efficaces : les solutions optimales sont trouvées en un temps de calcul acceptable [Liu et al., 2020].

3.2.1 Modèles d'optimisation métaheuristiques

Les approches métaheuristiques sont inspirées de processus biologiques, physiques ou comportementaux connus. Dans leur état de l'art sur les algorithmes génétiques [Katoch et al., 2021] affirment que ces approches sont particulièrement adaptées pour traiter des problèmes de la vie réelle. On distingue les algorithmes basés sur une solution unique (tels que *simulated annealing*, ou *guided local search*) ou basés sur une population (tels que *genetic algorithm* ou *particle swarm optimisation*). Se baser sur une solution unique signifie qu'une solution candidate est améliorée jusqu'à atteindre la solution optimale. Cependant la solution trouvée peut n'être qu'un extremum local. Se baser sur une population signifie, à l'inverse, que la solution optimale est recherchée parmi un ensemble de solutions candidates.

Les algorithmes génétiques (notés GA) sont des algorithmes métaheuristiques fréquemment utilisés, s'inspirant de la théorie de l'évolution, pour lesquels les alternatives sont représentées par des individus [Michalewicz & Schoenauer, 1996]. Chaque individu est caractérisé par ses gènes représentant les variables de décision. Chaque combinaison de variables donc de gènes est unique. L'ensemble des individus représente l'ensemble des alternatives. Parmi ces individus, une population aléatoire de n individus est prélevée. Chaque individu est évalué par rapport à chaque critère puis les individus sont comparés entre eux. Les meilleurs sont sélectionnés (par exemple, selon le principe de dominance au sens de Pareto). À partir des individus sélectionnés, une nouvelle population est créée via des opérations de croisement et de mutation. Les gènes qui favorisent les solutions optimales sont donc sélectionnés. La nouvelle population ainsi créée est la nouvelle génération. Elle est à son tour évaluée, sélectionnée, puis mutée et recombinée. Cette boucle est répétée jusqu'à atteindre un nombre de générations prédéfini. Selon les données du problème et les techniques utilisées, la convergence des solutions est atteinte plus ou moins rapidement. Finalement, les solutions optimales qui satisfont le mieux les critères sont obtenues.

Les GA sont de puissants algorithmes et un nombre élevé d'itérations permet de s'assurer de trouver les extremums globaux [Deb et al., 2002]. Différents modèles de GA ont été développés selon le codage des gènes et des individus, le choix des opérateurs de combinaisons et de mutation, la fonction d'évaluation et le mode de sélection. Ces différents modèles

présentent diverses forces et faiblesses et ne sont donc pas adaptés aux mêmes problèmes d'optimisation [Slowik & Kwasnicka, 2020].

Les GA multi-objectifs présentent deux principales catégories selon le principe de sélection : basée sur la dominance (au sens de Pareto) ou basée sur la décomposition. Le principe de décomposition consiste à décomposer le problème multi-objectifs en sous problèmes uni-objectif. Les GA basés sur la dominance au sens de Pareto consistent à évaluer la dominance d'une solution par rapport à une autre pour chacun des critères considérés. Ils permettent d'explorer des variables continues avec une bonne performance.

En 2002, le modèle *Nondominated Sorting Genetic Algorithm II* (NSGA II) a été proposé [Deb et al., 2002]. Cet algorithme de la famille des GA, basé sur la dominance au sens de Pareto, est aujourd'hui un des plus utilisés dans la littérature. Le fonctionnement de cet algorithme est basé sur l'introduction d'un opérateur spécifique permettant de trier les individus au sein d'un même front de Pareto. Il s'agit du *crowding distance operator*. À chaque génération, les individus sont classés en fonction de leur rang de nondomination dans différents fronts de Pareto. Le front le moins élevé contient les meilleures solutions. Les solutions les plus optimales sont déterminées en fonction de leur rang et du *crowding distance operator* qui garantit l'élitisme de l'algorithme. Puis la nouvelle population est créée en mutant et en recombinant les individus sélectionnés [Deb et al., 2002].

Les performances de l'algorithme tel que paramétré originellement sont satisfaisantes. NSGA II offre en effet une complexité de calcul réduite, une convergence et une diversité satisfaisantes des solutions sur le front de Pareto [Nebro et al., 2022]. De plus, il est applicable à des problèmes avec une grande population de solutions candidates. La principale limitation du NSGA II réside dans sa difficulté à adresser des problèmes avec plus de dix objectifs [Li et al., 2015]. Cependant, si les performances du NSGA II original souffrent d'un trop grand nombre d'objectifs lors de l'optimisation, des améliorations ont été apportées par la suite [Nebro et al., 2022]. Si des travaux ont cherché à améliorer et définir la paramétrie optimale de cet algorithme, les paramètres définis par Deb et al. sont utilisés dans la majorité des cas d'application [Nebro et al., 2022]. De futures recherches sont nécessaires pour explorer une plus grande gamme de paramétrage de l'optimisation et permettre une sélection automatique des paramètres selon le cas d'application [Katoch et al., 2021]. Ses applications pour l'optimisation de paramètres de fabrication montrent des performances de calcul et des solutions satisfaisantes [Asadollahi-Yazdi et al., 2018; Ge et al., 2023; Nebro et al., 2022].

3.2.2 Tri des solutions optimales

Les algorithmes d'optimisation présentés, et particulièrement NSGA II, donne au décideur une liste d'alternatives optimales par rapport à l'ensemble des critères. Cette liste peut être conséquente et les différences entre les alternatives ne sont pas toujours faciles à appréhender, surtout lorsqu'un grand nombre de critères est considéré.

Le choix de paramètres de fabrication parmi cette sélection de solutions optimales relève du décideur. Il est important que ce processus de décision soit interactif car c'est au décideur de déterminer l'importance de chacun des critères sélectionnés et de choisir in fine l'alternative qui correspond le mieux à ses besoins [Laguna Salvadó et al., 2022]. Ces mêmes auteurs soulignent également la nécessité d'adresser dans le processus

de décision l'incertitude du décideur quant à la pondération des critères.

Dans la revue des modèles d'aide à la décision multicritères appliqués au domaine de la fabrication du point de vue du développement durable, [Jamwal et al., 2021], catégorisent les méthodes MCDM en modèles de classement, modèles de mesure de la valeur et modèles d'objectifs. Il discute notamment des méthodes suivantes : AHP, TOPSIS et PROMETHEE.

La méthode *Analytical Hierarchy Process* (AHP) fait partie des modèles de mesure de la valeur. C'est une méthode de type comparaison deux à deux. Les objectifs sont hiérarchisés, puis les poids de chaque critère sont calculés. Enfin le score de chaque alternative est calculé à partir du score pour chacun des critères. Si cette méthode est simple et flexible elle peut être délicate à résoudre quand le nombre de critères augmente ainsi que pour les équations linéaires. Du fait de son adaptabilité et de sa facilité d'utilisation, elle est très répandue surtout dans le domaine de la logistique et des transports [Jamwal et al., 2021]. La méthode TOPSIS (*Techniques for Order of Preference by Similarity to Ideal Solution*), particulièrement utilisée dans l'optimisation de la fabrication, est une méthode de compromis de classement. La première étape est la construction de la matrice de décision. Puis après avoir normalisé la matrice de décision pour pouvoir comparer les solutions entre elles, les poids définis par le décideur sont attribués aux différents critères. Les matrices idéales positives et négatives sont calculées à partir des solutions. Enfin, le calcul de l'écart de chaque solution à la solution idéale positive et la solution idéale négative permet de classer les solutions. La méthode TOPSIS a déjà été utilisée dans des problèmes similaires à celui présenté ici et couplée avec le NSGA II [Ge et al., 2023; Jamwal et al., 2021]. Cependant, cette méthode ne favorise pas l'interaction entre le décideur et le modèle d'aide à la décision. De plus, il n'est pas toujours aisé pour le décideur d'attribuer lui-même un poids aux différents critères.

La méthode PROMETHEE (*Preference Ranking Organization METHod*) est une méthode de comparaison deux à deux. Souvent utilisée dans les domaines de la fabrication et du génie industriel, elle permet au décideur d'assigner les poids. Cependant si elle admet l'intégration de données floues et incertaines aussi bien quantitatives que qualitatives, les objectifs ne sont pas structurés proprement et son usage requiert un expert [Jamwal et al., 2021].

Une nouvelle méthode de classement, adaptée à l'optimisation multicritères, a été développée par [Laguna Salvadó et al., 2022]. Le *Ranking Decision Support System algorithm* (auquel on referra par la suite par RDSS2022) permet un classement des alternatives de manière interactive avec le décideur. Celui-ci peut choisir et pondérer les critères qualitativement les uns par rapport aux autres et ajouter des incertitudes propres aux valeurs de chaque critère. L'outil combine une interface utilisateur dynamique couplée à un algorithme de classement. Une fois les alternatives identifiées et les critères évalués, ceux-ci sont normalisés. Puis le décideur sélectionne les critères, définit leur granularité et leur importance relative via l'interface. La granularité caractérise le niveau d'incertitude sur un critère pour ne pas discriminer des alternatives qui sont proches. Ensuite l'algorithme calcule les intervalles de granularité de chaque critère, les dominances locales et globales puis affiche le classement final. Si le décideur est satisfait, il choisit l'alternative qui lui convient. Sinon, il modifie via l'interface la sélection de critère, leur granularité et leur importance.

Ce modèle récent a été développé et testé sur un cas d'étude provenant de la littérature, pour la sélection de technologies

d'isolations de bâtiments par rapport à six critères. Ainsi, il sera intéressant de l'appliquer à un autre cas d'étude avec des données réelles et d'évaluer les résultats par rapport à un autre algorithme MCDM.

3.3 Synthèse

Parmi les modèles d'aide à la décision multicritères, les algorithmes génétiques sont un outil adapté à l'optimisation multi-objectifs des paramètres de fabrication. Ces algorithmes permettent en effet de trouver les solutions Pareto-optimales parmi un grand nombre d'alternatives, avec de faibles temps de calcul. De plus, ces algorithmes sont adaptés aux problèmes d'optimisation basés sur des modèles d'équations continues et polynomiales.

NSGA II est un GA particulièrement puissant qui permet de trouver les solutions optimales sans avoir besoin d'un expert pour le manipuler, et qui garantit la diversité des solutions Pareto-optimales. NSGA II a été appliqué à des problèmes de décisions présentant des similarités avec le problème considéré dans la présente étude. Cet algorithme peut s'adapter à différents problèmes intégrant diverses technologies.

Cependant, l'obtention grâce au NSGA II d'une liste de solutions Pareto-optimales au regard de l'ensemble des critères n'est pas suffisante pour guider le choix d'une solution par le décideur.

Parmi les démarches permettant le classement de solutions et la pondération des critères, le modèle TOPSIS a fait ses preuves dans des environnements similaires. Cependant, comme il est important de pouvoir adresser les incertitudes du décideur pour la pondération des critères et d'intégrer les incertitudes des données grâce à la gestion de la granularité, le modèle RDSS2022 semble plus adapté.

Ainsi, pour notre modèle d'aide à la décision pour le choix des paramètres de fabrication du procédé WAAM, en prenant en compte à la fois les performances mécaniques et les performances industrielles durables, l'algorithme NSGA II est choisi pour obtenir les solutions optimales du problème. Puis l'algorithme RDSS2022 sera appliqué pour permettre au décideur de choisir parmi ces solutions optimales. Ses performances seront comparées à celle de TOPSIS afin de s'assurer de son efficacité. Le modèle proposé est détaillé dans la partie suivante.

4 MODELE D'AIDE A LA DECISION PROPOSE

4.1 Processus de décision

Afin de répondre au problème d'aide à la décision présenté, l'état de l'art a mis en lumière les outils d'optimisation multi-objectifs et de hiérarchisation des critères les plus adaptés. Nous proposons donc un modèle d'aide à la décision dans lequel s'intègrent les outils sélectionnés. La figure 2 présente le modèle proposé. Cette représentation, inspirée du *service experience blueprinting* [Patrício et al., 2011] illustre le fonctionnement du modèle d'aide à la décision (noté DSS) et met en évidence les interactions entre le décideur (noté DM) et le système. Le modèle d'aide à la décision considéré s'articule autour d'un modèle de connaissances, qui l'alimente, et de l'interface qui fait le lien avec le décideur. Le cas d'étude considéré est la fabrication d'une pièce en acier inoxydable avec le procédé WAAM.

Les étapes A1 à A3 décrivent la construction du modèle de connaissances qui alimente le modèle d'aide à la décision. Tout d'abord, un cas d'étude et son périmètre sont définis (A1).

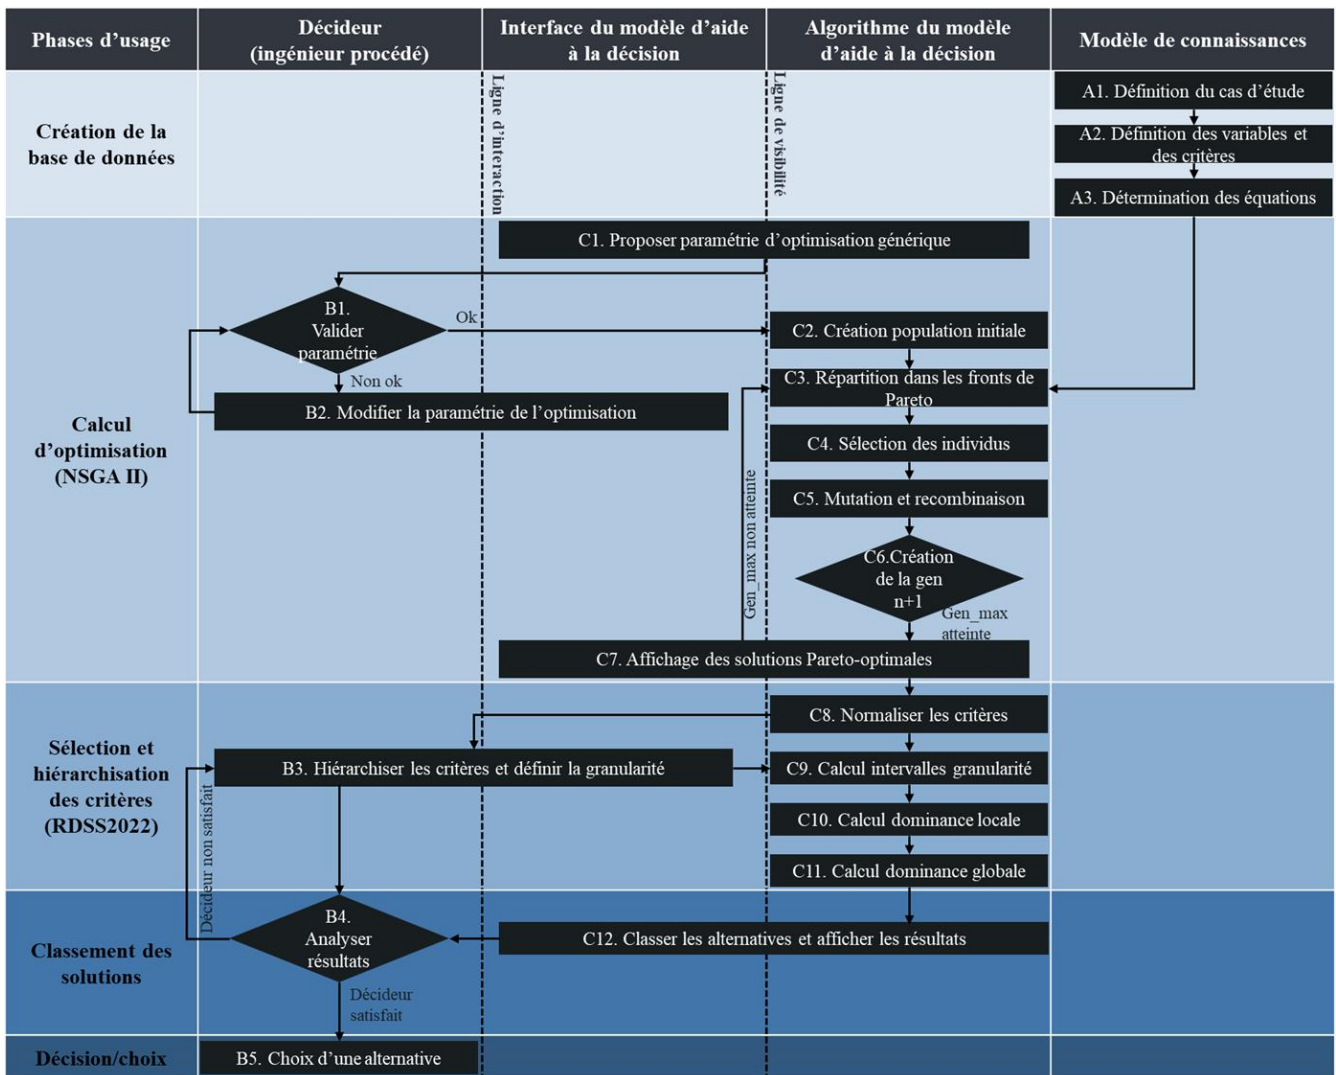


Figure 2 : Modèle d'aide à la décision proposé, sous la forme du *service experience blueprinting* [Patrício et al., 2011]

Puis, un plan d'expériences, décrit en section 2.2, définit les variables de décision et les critères observés. Des équations régissant les critères en fonction des variables sont ainsi développées. Ces critères sont traduits en fonctions objectifs et contraintes du système d'aide à la décision. Les étapes B1 à B5 décrivent l'interaction entre le modèle et le décideur. La première mission du décideur est de valider les paramètres proposés pour l'optimisation (taille de la population, nombre de génération, type et indicateurs des opérateurs de mutations et recombinaison) (B1). Si le décideur est satisfait de cette paramétrie ou ne souhaite pas approfondir ce sujet, les paramètres proposés par le modèle sont validés. Si le décideur le souhaite, il peut modifier les paramètres d'optimisation (B2). Après la génération des solutions Pareto-optimales, le décideur définit l'importance des critères et leur granularité (B3). Selon le résultat donné par le modèle en fonction de B3, le décideur itère avec l'algorithme pour affiner son choix (B4). Quand il est satisfait, il choisit la solution proposée (B5) et l'algorithme d'aide à la décision prend fin.

Les étapes C1 à C12 détaillent le fonctionnement de l'algorithme. Les étapes C1 à C7 représentent l'algorithme NSGA II. En C3, les données du modèle de connaissances permettent d'évaluer les critères pour les solutions considérées. Ainsi la dominance au sens de Pareto est évaluée et les solutions sont triées dans les fronts de Pareto correspondants. Puis ces étapes sont répétées jusqu'à atteindre le nombre de générations maximal, validé en B1. En C7, les solutions Pareto-optimales

obtenues par NSGA II sont affichées ainsi que les valeurs de performances correspondantes pour chacun des critères. Les étapes C8 à C12 schématisent l'algorithme RDSS2022. L'étape C8 consiste à normaliser les critères afin de pouvoir les comparer entre elles. En C9, les choix du décideur sont transmis à l'algorithme. Les intervalles de granularité sont calculés. L'intervalle de granularité est proportionnel à la valeur donnée par le décideur et centré sur la valeur de chaque solution. Pour chaque critère, chaque alternative est comparée aux autres alternatives. Le nombre d'alternatives dominées pour chacune d'elles est compté. Il est dit que le critère a domine le critère b si la valeur de l'intervalle inférieur de a est supérieure à l'intervalle supérieur de b . Dans cette même étape, les dominances locales sont normalisées en fonction de la granularité de chaque critère afin que le résultat final ne soit pas influencé par la granularité définie (C10). En C11, les dominances globales sont calculées : la moyenne des dominances locales normalisées, pondérées par l'importance de chaque critère est calculée. Après le calcul, l'algorithme affiche sur l'interface les solutions Pareto-optimales, soit les couples de variables WFS et TS obtenus par le NSGA II, et leurs performances pour chacun des critères, classées selon la dominance globale de la plus faible à la plus élevée (C12).

4.2 Validation des performances de l'algorithme

Le modèle proposé a été construit afin de pouvoir s'adapter à des modèles de connaissances contenant davantage de variables de décisions et de plus grandes plages de données que dans le

cas d'étude proposé. Cela induirait un plus grand nombre de solutions candidates. Dans le cas d'étude présenté, deux variables de décisions, la vitesse d'avance de fil WFS , et la vitesse d'avance du robot TS , sont considérées. Donc les individus de l'algorithme NSGA II auront deux gènes. Dans les intervalles fixés (Eq. 5 et Eq. 6), WFS et TS varient respectivement de 0.1 m/min et 0.06 m/min pour la machine utilisée. Ainsi WFS peut prendre cinquante valeurs et TS cinq. Deux cent cinquante combinaisons sont donc possibles. Ce nombre est faible à l'échelle des algorithmes génétiques. Les performances de l'ensemble des solutions pourraient donc être évaluées et comparées dans un temps raisonnable, sans devoir utiliser une population aléatoire et le processus de mutation et recombinaison pour créer de nouvelles générations jusqu'à l'identification des solutions les plus proches du front de Pareto. Les performances de la totalité des solutions de l'espace de solutions seront calculées en utilisant les mêmes fonctions d'évaluations que dans le modèle proposé mais sans utiliser NSGA II. Les solutions Pareto-optimales ainsi identifiées, calculées à partir de l'espace complet des solutions, seront comparées aux solutions obtenues avec NSGA II. Ainsi l'efficacité et la rapidité du calcul de l'algorithme pour un cas d'étude simple seront évaluées.

Pour valider le couplage du modèle RDSS2022 au NSGA II le classement des solutions Pareto-optimales via RDSS2022 sera comparé au classement obtenu avec le modèle TOPSIS. Pour cela les pondérations obtenues grâce au RDSS2022 seront utilisées avec la méthode TOPSIS. La comparaison du classement final de chacun des modèles permettra d'identifier des différences entre les deux approches et d'éventuelles limites.

Après ces deux étapes de validation, une nouvelle version du modèle sera développée. L'étape de validation suivante sera l'application du modèle à des cas d'études comportant plus de données. Ainsi les limites de calcul du modèle au regard des performances algorithmiques seront déterminées.

5 CONCLUSION ET PERSPECTIVES

Cet article présente un modèle d'aide à la décision pour le choix des paramètres de fabrication du procédé arc-fil, usuellement désigné par WAAM. En effet, il est important pour les industriels de maîtriser les paramètres de fabrication du procédé qui influencent à la fois les performances mécaniques de la pièce produite mais aussi les performances industrielles durables du processus de fabrication.

Le modèle d'aide à la décision proposé, est basé sur l'articulation d'un algorithme d'optimisation multicritères parmi les plus utilisés, le NSGA II, avec un récent algorithme de classement basé sur la dominance, le RDSS2022.

Ce modèle permet d'adresser le cas d'étude présenté, multicritères et multi-variables. Il a été conçu extensible pour intégrer davantage de variables de décision et pour être transposable à des cas plus complexes requérant une plus grande puissance algorithmique.

Ce modèle est interactif et prend en compte l'incertitude du décideur pour la pondération des critères. De plus, il est simple d'utilisation et ne nécessite pas d'être piloté par un expert. Les algorithmes qui le composent sont très performants et garantissent l'obtention et le classement des solutions Pareto-optimales en un temps de calcul raisonnable.

Le processus de validation du modèle présenté permettra de valider ces performances. De futurs travaux porteront sur le développement mathématique et informatique de l'algorithme, ainsi que son application au cas d'étude. Le modèle proposé pourra contribuer à l'industrialisation des procédés DED en

étant appliqué à d'autres géométries, d'autres matériaux et d'autres technologies.

6 REMERCIEMENTS

Ces travaux de recherche ont été soutenus financièrement par la Communauté d'Agglomération Pays-Basque. Ils ont été réalisés au sein de l'ESTIA (Fr) et de l'Université de Wolverhampton (UK) avec le soutien technique de la plateforme ADDIMADOUR (Fr).

7 REFERENCES

- Ahn, D. G. (2021). Directed Energy Deposition (DED) Process: State of the Art. In *International Journal of Precision Engineering and Manufacturing - Green Technology* (Vol. 8, Issue 2). Korean Society for Precision Engineering. <https://doi.org/10.1007/s40684-020-00302-7>
- Asadollahi-Yazdi, E., Gardan, J., & Lafon, P. (2018). Multi-Objective Optimization of Additive Manufacturing Process. *IFAC-PapersOnLine*, 51(11), 152–157. <https://doi.org/10.1016/j.ifacol.2018.08.250>
- Deb, K., Pratap, A., Agarwal, S., & Meyarivan, T. (2002). A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, 6(2), 182–197. <https://doi.org/10.1109/4235.996017>
- Ge, J., Zhang, W., Luo, M., Catalanotti, G., Falzon, B. G., Higgins, C., Zhang, D., Jin, Y., & Sun, D. (2023). Multi-objective optimization of thermoplastic CF/PEKK drilling through a hybrid method: An approach towards sustainable manufacturing. *Composites Part A: Applied Science and Manufacturing*, 167, 107418. <https://doi.org/10.1016/j.compositesa.2022.107418>
- Jamwal, A., Agrawal, R., Sharma, M., & Kumar, V. (2021). Review on multi-criteria decision analysis in sustainable manufacturing decision making. In *International Journal of Sustainable Engineering* (Vol. 14, Issue 3, pp. 202–225). Taylor & Francis. <https://doi.org/10.1080/19397038.2020.1866708>
- Jarrar, Q., Belkadi, F., & Bernard, A. (2021). A Knowledge-Based Approach for Decision Support System in Additive Manufacturing. *IFIP Advances in Information and Communication Technology*, 634 IFIP, 319–327. https://doi.org/10.1007/978-3-030-85914-5_34
- Katoch, S., Chauhan, S. S., & Kumar, V. (2021). A review on genetic algorithm: past, present, and future. In *Multimedia Tools and Applications* (Vol. 80, Issue 5). Multimedia Tools and Applications. <https://doi.org/10.1007/s11042-020-10139-6>
- Kellens, K., Renaldi, R., Dewulf, W., Kruth, J. P., & Duflou, J. R. (2014). Environmental impact modeling of selective laser sintering processes. *Rapid Prototyping Journal*, 20(6), 459–470. <https://doi.org/10.1108/RPJ-02-2013-0018>
- Laguna Salvadó, L., Villeneuve, E., Masson, D., Abi Akle, A., & Bur, N. (2022). Decision Support System for technology selection based on multi-criteria ranking: Application to NZEB refurbishment. *Building and Environment*, 212, 108786. <https://doi.org/10.1016/J.BUILDENV.2022.108786>
- Li, B., Li, J., Tang, K., & Yao, X. (2015). Many-Objective Evolutionary Algorithms. *ACM Computing Surveys (CSUR)*, 48(1). <https://doi.org/10.1145/2792984>
- Liu, Q., Li, X., Liu, H., & Guo, Z. (2020). Multi-objective metaheuristics for discrete optimization problems: A

- review of the state-of-the-art. *Applied Soft Computing Journal*, 93, 106382.
<https://doi.org/10.1016/j.asoc.2020.106382>
- Michalewicz, Z., & Schoenauer, M. (1996). Evolutionary Algorithms for Constrained Parameter Optimization Problems. *Evolutionary Computation*, 4(1), 1–32.
<https://doi.org/10.1162/EVCO.1996.4.1.1>
- Nebro, A. J., Galeano-Brajones, J., Luna, F., & Coello, C. A. C. (2022). Is NSGA-II Ready for Large-Scale Multi-Objective Optimization? *Mathematical and Computational Applications 2022, Vol. 27, Page 103*, 27(6), 103. <https://doi.org/10.3390/MCA27060103>
- Patrício, L., Fisk, R. P., e Cunha, J. F., & Constantine, L. (2011). Multilevel service design: From customer value constellation to service experience blueprinting. *Journal of Service Research*, 14(2), 180–200.
https://doi.org/10.1177/1094670511401901/SUPPL_FILE/MULTILEVEL_SERVICE_DESIGN_PATRICIO_FISK_CUNHA_CONSTANTINE.PDF
- Peng, T., Kellens, K., Tang, R., Chen, C., & Chen, G. (2018). Sustainability of additive manufacturing: An overview on its energy demand and environmental impact. *Additive Manufacturing*, 21(June 2017), 694–704.
<https://doi.org/10.1016/j.addma.2018.04.022>
- Rouchon, F., Lavernhe, S., Christophe, T., Lorang, X., & Tournier, C. (2021). Modélisation des dimensions géométriques de cordon aux points de changement de direction en WAAM. *Conference Manufacturing'21*.
<https://hal.archives-ouvertes.fr/hal-03268258>
- Shin, S. J., Kim, D. B., Shao, G., Brodsky, A., & Lechevalier, D. (2017). Developing a decision support system for improving sustainability performance of manufacturing processes. *Journal of Intelligent Manufacturing*, 28(6), 1421–1440. <https://doi.org/10.1007/s10845-015-1059-z>
- Slowik, A., & Kwasnicka, H. (2020). Evolutionary algorithms and their applications to engineering problems. In *Neural Computing and Applications* (Vol. 32, Issue 16, pp. 12363–12379). Springer. <https://doi.org/10.1007/s00521-020-04832-8>