



**HAL**  
open science

## Classification des paramètres procédé de soudage par analyse expérimentale et apprentissage automatique.

Theo Boutin, Issam Bendaoud, Josselin Delmas, Damien Borel, Cyril Bordreuil

### ► To cite this version:

Theo Boutin, Issam Bendaoud, Josselin Delmas, Damien Borel, Cyril Bordreuil. Classification des paramètres procédé de soudage par analyse expérimentale et apprentissage automatique.. 25e Congrès Français de Mécanique, Aug 2022, Nantes, France. hal-04280079

**HAL Id: hal-04280079**

**<https://hal.science/hal-04280079>**

Submitted on 10 Nov 2023

**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.

# Classification des paramètres procédé de soudage par apprentissage automatique.

T.BOUTIN<sup>a</sup>, I.BENDAOUD<sup>b</sup>, J.DELMAS<sup>c</sup>, D.BOREL<sup>d</sup>, C.BORDREUIL<sup>e</sup>,

a. EDF R&D - LMGC Université Montpellier : theo.boutin@edf.fr

b. LMGC Université Montpellier : issam.bendaoud@umontpellier.fr

c. EDF R&D : josselin.delmas@edf.fr

d. EDF R&D : damien.borel@edf.fr

e. LMGC Université Montpellier : cyril.bordreuil@umontpellier.fr

## Résumé :

*Cette étude présente un algorithme de Machine Learning (ML) robuste pour la détection et la classification des modes opératoires de soudage. Le modèle ML développé est alimenté par des données expérimentales issues de plusieurs instruments, d'une part, des capteurs (tension, intensité, vitesse fil, vitesse de soudage...) permettant le suivi des paramètres de procédés et par conséquent le suivi d'énergie transmise au cours du soudage, et d'autre part, des caméras couplées à un algorithme de traitement d'images permettant l'acquisition in-situ des dimensions géométriques du bain de fusion. Toutes ces informations sont stockées, étiquetées, ordonnées dans une base de données pour un traitement simple et rapide. Par ailleurs, la mise en place de la base de données est nécessaire pour les étapes d'apprentissage, de validation et de prédiction du modèle ML. Plusieurs méthodes de Machine Learning sont comparées et analysées en se basant sur des critères de performances (précisions, temps de traitement...). Pour conclure, on montre que les modèles de ML permettent de détecter un écart du mode opératoire lors d'une modification de diffusion de la chaleur induisant une modification de la géométrie du bain.*

**Mots clefs : Soudage TIG, Machine Learning, traitement d'images, physique du bain.**

## 1 Introduction

Le besoin industriel pour EDF est de mieux maîtriser les opérations de soudage pour un gain en qualité lors de l'assemblage des gros composants. Aujourd'hui, toutes ces pièces sont contrôlées après fabrication et tout défaut doit être réparé. Depuis de nombreuses années, le contrôle in-situ des soudures en cours de réalisation s'avère donc être un point crucial dans les secteurs d'activité qui ont de fortes exigences sur la qualité des pièces soudées. Ce contrôle passe essentiellement par le suivi des paramètres procédés. Un mauvais réglage de ces paramètres ou une fluctuation en cours de fabrication influe directement sur la distribution de l'énergie transmise à la pièce qui pilotera la taille et la forme du bain de fusion. Par exemple, dans un chanfrein étroit, une modification de l'énergie transférée influe sur le comportement du bain liquide à l'interface métal de base-zone fondue et par conséquent peut provoquer des

défauts de type porosité, fissure ou manque de pénétration. L'utilisation d'un système de surveillance de soudage en ligne capable de détecter les dérives permettrait un gain de temps en identifiant en cours de fabrication une fluctuation au niveau de la géométrie du cordon qui pourrait nuire à l'intégrité de l'assemblage. Pour réaliser un système de surveillance, un dispositif de capteurs sans contact permettant de scruter le procédé et un traitement des données issues de ces capteurs doivent être mis en place.

La littérature sur l'utilisation de différents capteurs en cours de soudage est abondante. Un certain nombre de travaux ont développé des capteurs plus élaborés : l'analyse spectroscopique de l'émission de l'arc électrique comme dans le cas de Mirapeix et al. [1, 2, 3], l'analyse acoustique permettant de mesurer les variations de pression dues à l'arc [4, 5] et la mesure de la géométrie du bain de fusion [6, 7, 8] pour détecter un éventuel défaut. A partir de ces mesures, ces chercheurs ont développé des algorithmes basés sur l'apprentissage automatique pour classer les cordons de soudure avec et sans défauts. Par exemple, Mirapeix et al [1, 2, 3], ont proposé une méthode de détection et de classification automatique des défauts de soudure basée sur l'utilisation combinée de plusieurs algorithmes d'apprentissage automatique liant physique de l'arc et comportement du bain en temps réel. Par ailleurs, Sumesh et al [4, 5] ont utilisé de l'apprentissage automatique avec différents algorithmes de décisions pour assurer la qualité d'une opération de soudage à l'électrode enrobée et classifier les différents états de pénétration. Ces algorithmes de traitement s'appuient sur une base de données issue des mesures en cours de procédé qui servira à l'apprentissage des modèles. Les avantages de ces algorithmes sont qu'ils sont capables de s'enrichir en cours de fabrication et sont bien adaptés lorsque la physique est complexe. Les algorithmes de classification sont particulièrement intéressants puisqu'ils permettent de vérifier que le procédé se déroule dans les bonnes conditions.

Dans ce contexte, l'article présente une étude basée sur le couplage des données expérimentales et l'apprentissage automatique pour classifier plusieurs modes opératoires. Le cas d'une configuration de soudage à plat d'une pièce en acier inoxydable 316L effectué avec le procédé GTAW avec apport de métal a été choisi. Une instrumentation est développée autour du procédé contenant plusieurs capteurs (tension, intensité, vitesse de soudage...) pour le suivi et l'analyse de l'influence des paramètres de soudage et en parallèle, deux caméras sont mises en place donnant accès à plusieurs informations sur la taille du bain liquide, l'arrivée du fil dans le bain de fusion et son influence sur la forme finale du cordon. Pour mesurer la géométrie du bain, un algorithme de traitement d'images est utilisé permettant la détection du contour du bain en temps réel. Une base de données est créée d'une part pour le stockage et l'étiquetage et d'autre part pour alimenter l'algorithme de Machine Learning dans ses étapes d'apprentissage, de validation et de prédiction. Le but principal de cette étude est de classifier les différents paramètres procédé en comparant les performances de plusieurs algorithmes de décision tels que le KNN (k-nearest neighbor), DT (Decision Tree), RF (Random Forest) et d'étudier leurs robustesses. Pour tester la capacité du modèle ML à prédire une dérive du mode opératoire lors de présence d'une modification du procédé, des dérives sont artificiellement introduites au cours soudage. Premièrement, une variation de géométrie de la pièce avec une présence de rainures, et une deuxième modification des paramètres de soudage en cours de l'opération. Avec ces modifications, l'algorithme ne classe plus les conditions opératoires dans les conditions désirées pour la bonne réalisation du cordon ce qui laisse envisager une dérive.

## 2 Dispositif expérimental

Dans cette partie, la plateforme expérimentale pour une campagne d'essais est présentée. Pour permettre un suivi de la dynamique du bain au cours de l'opération, plusieurs moyens de mesure ont été identifiés, choisis en fonction des contraintes et de l'objectif pour répondre aux exigences. D'une part, les procédés à l'arc sont gouvernés par le courant électrique ( $I$ ), la tension de soudage ( $U$ ), la vitesse de soudage ( $V_s$ ), vitesse de dévidage ( $V_f$ ), gaz de protection, assurant la qualité de l'opération et influant directement sur l'état résiduel du bain de soudage. Par conséquent, le contrôle de ces paramètres au cours de l'opération est primordiale (cf. figure 1). Pour maîtriser la puissance lors de l'opération de soudage dans la tôle générée par l'arc électrique, l'acquisition en continu des paramètres procédés (tension, intensité) est réalisée. De plus, la mise en place d'un capteur pour mesurer la protection gazeuse et la vitesse de dévidage du fil est effectuée. D'autre part, pour permettre de suivre l'évolution de la géométrie du bain de soudage, le recours à des données visuelles tels que des caméras est nécessaire. Pour ce faire, deux caméras ont été implémentées pour agrandir le champ de vision permettant d'augmenter les informations visuelles sur l'aspect du bain de fusion, et de garantir un meilleur contrôle de la qualité au cours d'une opération (cf. figure 1). D'une part, une caméra est installée pour l'observation de la face supérieure (oscillation du bain, largeur du bain) et d'autre part, l'observation de la face de côté (hauteur du bain, mouillage, arrivée du métal d'apport dans le bain liquide). Enfin, la synchronisation de la chaîne d'acquisition des différents capteurs doit être garantie pour permettre le couplage entre les différents moyens de mesure et le stockage des données permettant la traçabilité de chaque opérations.

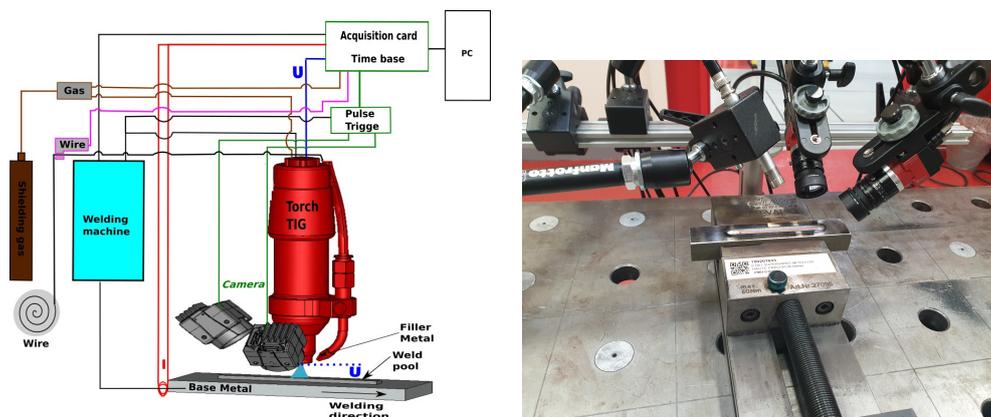


FIGURE 1 – Schéma global de câblage du montage expérimental.

### 2.1 Paramètres procédé

Dans cette section, les modes opératoires de soudage sont présentés (paramètres procédé, géométrie des coupons) pour la création de la base de données d'apprentissage, de test et de classification. Une campagne d'essais a été réalisée sur tôles en acier inoxydable austénitique 316L avec des dimensions de 150 mm de longueur, 50 mm de largeur et 10 mm d'épaisseur. De plus, les échantillons ont été soudés avec le procédé GTAW avec apport de métal. Les paramètres utilisés lors de ces essais sont rappelés en tableau 1. Ces trois essais permettent le développement d'une base de données multi-physiques (multi-capteurs comme présentés dans la section 2) alimentant la phase d'apprentissage et de test des algorithmes d'apprentissage automatique.

Enfin, le rajout de trois expérimentations a été réalisé pour alimenter en plus la base de données et per-

Expérimentation	Intensité (A)	Tension (V)	Vitesse d'avance (m/min)	Énergie linéique $E$ (J/mm)	Vitesse de dévidage (m/min)	Débit gaz de protection (L/min)
FLT1-130	130	11,8	0,13	708	2,6	13,0
FLT1-150	150	11,8	0,15	708	3,0	13,0
FLT1-170	170	11,8	0,17	708	3,4	13,0

TABLE 1 – Paramètres de soudage TIG utilisés ; FLT1 : Fusion Line TIG campagne numéro 1.

mettre leur classification / prédiction. En figure 2 est illustrée la géométrie des trois nouveaux cordons. D'une part, pour la validation des algorithmes de ML, une première expérimentation a été faite avec un changement de paramètres au cours de l'opération de soudage. D'autre part, en raison d'un flux de chaleur localisé générant de fort gradient thermique dans le métal de base, deux expériences ont été faites avec un changement d'épaisseur du substrat (rainure en face de dessus et dessous) toutes les deux affectant la diffusion thermique et pouvant jouer sur une potentielle variation de la mouillabilité (interaction liquide / matière) et de la géométrie du bain de soudage (modification de la répartition de la chaleur). C'est pourquoi la compréhension des mécanismes physiques du comportement du bain liquide et des différentes interfaces constitue donc un enjeu important pour la maîtrise de la qualité des assemblages soudés.

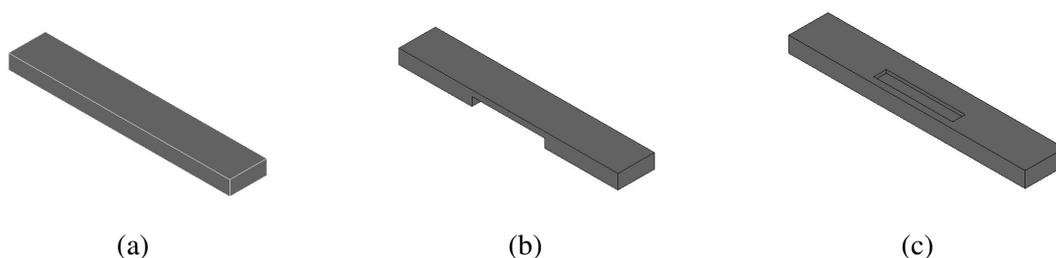


FIGURE 2 – Symétrie de la géométrie du métal de base pour les trois expérimentations, (a) géométrie expérimentation avec changement de paramètres, (b) géométrie avec présence d'une rainure en face envers, (c) géométrie avec présence de rainure en face endroit.

## 2.2 Théorie et méthodologie

### 2.2.1 Extraction des caractéristiques géométriques du bain de soudage

Dans cette section, la méthode de traitement des images est présentée (cf. figure 3) permettant l'extraction des caractéristiques géométriques du bain de fusion. La première étape étant, le redressement de l'image afin d'obtenir les grandeurs de la géométrie réelles lors du traitement d'images. Une région d'intérêt est alors choisie en fonction de la position du bain liquide sur l'ensemble de l'image acquise par les caméras. Ensuite, une méthode de lissage gaussien est ensuite utilisée pour réduire le bruit dans l'image. Après cela, étant donné que le niveau de gris du bain de soudure est différent du métal de base, un seuillage adaptatif est alors réalisé sur la zone d'intérêt permettant le seuil de manière dynamique sur l'image. Aussi, un algorithme est utilisé pour détecter les bords permettant d'extraire les points en segments à l'aide d'un objet  $\alpha$ -shape. Pour finir, la théorie des graphes est utilisée pour extraire le contour

présent sur l'image.

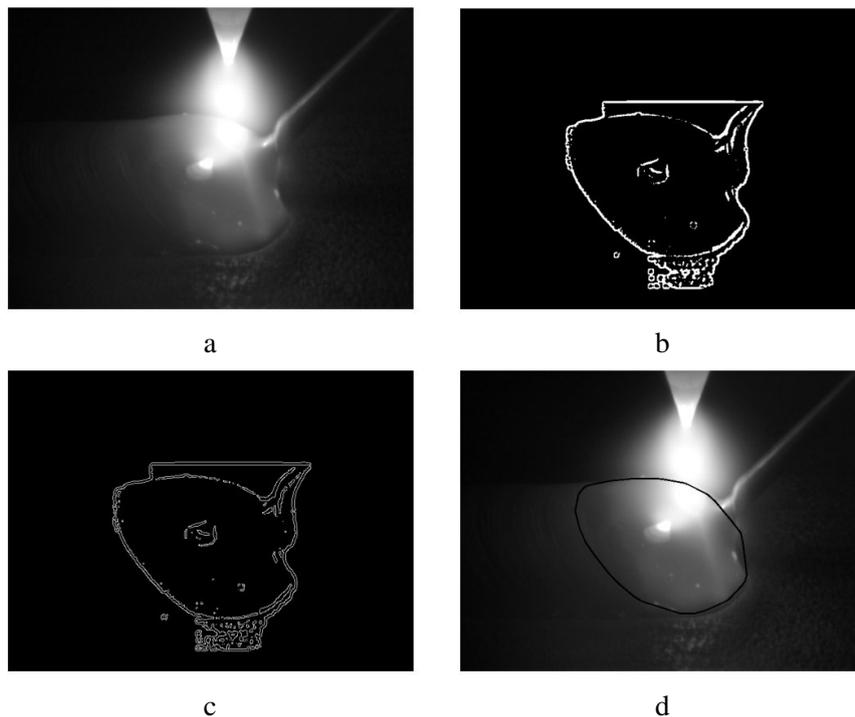


FIGURE 3 – (a) Redressement de l'image via une mire de calibration, (b) utilisation d'un filtre adaptative threshold, (c) utilisation d'un filtre Canny, (d) utilisation d'un filtre de dilatation, (e) détection de contours par l'utilisation de la méthode  $\alpha$ -shape couplée à un algorithme de graphe.

### 2.2.2 Base de données

Dans cet article, différentes caractéristiques géométriques ont été extraites par des algorithmes de traitement d'images telles que la boîte englobante (largeur, longueur), la surface et d'autres caractéristiques comme présentées en figure 4. L'accès à ces grandeurs permet en d'autre part de déduire des informations sur la stabilité du bain de fusion au cours du temps et sa répétabilité. Par ailleurs, l'extraction des contours permet un traitement physique des images (variation de la géométrie fonction de l'apport d'énergie ou d'une modification de la diffusion de la chaleur). Enfin, pour répondre à la dernière partie du travail qui consiste à tester des algorithmes de ML sur des données expérimentales permettant de prédire/classifier les modes opératoires. Pour ce faire, la mise en place d'une nouvelle base données à partir des caractéristiques géométriques du bain liquide est réalisée. Ceci permet la réduction de cette présente base de données et un gain de temps lors de l'apprentissage des différents algorithmes de ML testés. Enfin, la mise en place de méta-données permet de structurer la base de données. Dans ce fichier, les informations liées aux paramètres opératoires régis par la norme de qualification de l'opération de soudage sont retrouvés.

### 2.2.3 Apprentissage automatique (supervisé)

Dans cette section, la structure d'apprentissage pour les algorithmes d'apprentissage supervisés est présentée, de plus, un exemple de résultats de précision est illustré. L'apprentissage supervisé [9, 10]

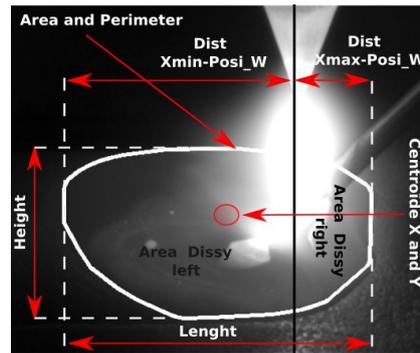


FIGURE 4 – Exemple de caractéristiques géométriques du bain de soudage.

consiste à apprendre le lien entre deux ensembles de données. D'une part, les données observées X (ici les caractéristiques géométriques) comme illustrées en figure 4 et d'autre part une variable de sortie (Y) que l'on essaie de prédire comme présenté en tableau 2.

Données observées	Variables de sortie
Distance Xmin - Position tungstène	Tension, Intensité, Apport de chaleur, Rapport Vitesse fil / Vitesse de soudage
Distance Xmax - Position tungstène	
Longueur du bain de soudage	
Largeur du bain de soudage	
Aire dissymétrique gauche	
Aire dissymétrique droite	
Centroïde X	
Centroïde Y	
Périmètre	
Aire	

TABLE 2 – Caractéristiques géométriques pour l'apprentissage des algorithmes de ML et variables à prédire .

Dans la méthode proposée, la prédiction des paramètres procédés tels que l'intensité, l'apport de chaleur, la tension etc.. est divisée en trois phases. Dans la figure 5 (a) sont illustrées les différentes étapes d'apprentissage. Premièrement, le traitement et le stockage des données de formation provenant des caractéristiques géométriques du bain de soudage. Deuxièmement, la division de l'ensemble de données en sous-ensembles aléatoires de formation et de test. Enfin, un dernier sous-ensemble permettant la validation de l'algorithme utilisé. D'une part, l'ensemble d'entraînement est utilisé pour entraîner, ajuster les paramètres du modèle utilisé. D'autre part, l'ensemble de test est nécessaire pour vérifier la performance du résultat. Pour finir, l'ensemble de validation utilisé à la fin du processus permet de mesurer l'erreur de prédiction pour choisir entre plusieurs modèles. Ceci garantit la robustesse de l'algorithme utilisé. Par ailleurs, pour augmenter la performance du modèle choisi, la validation croisée est utilisée comme illustrée en figure 5 (b). Le principe de cette méthode est de partitionner aléatoirement les données d'entraînement et de test en n sous-ensembles. Ce processus est répété n fois, de sorte que chaque sous-ensemble soit utilisé pour la phase d'entraînement et de test. L'erreur de validation croisée moyenne est utilisée comme indicateur de performance.

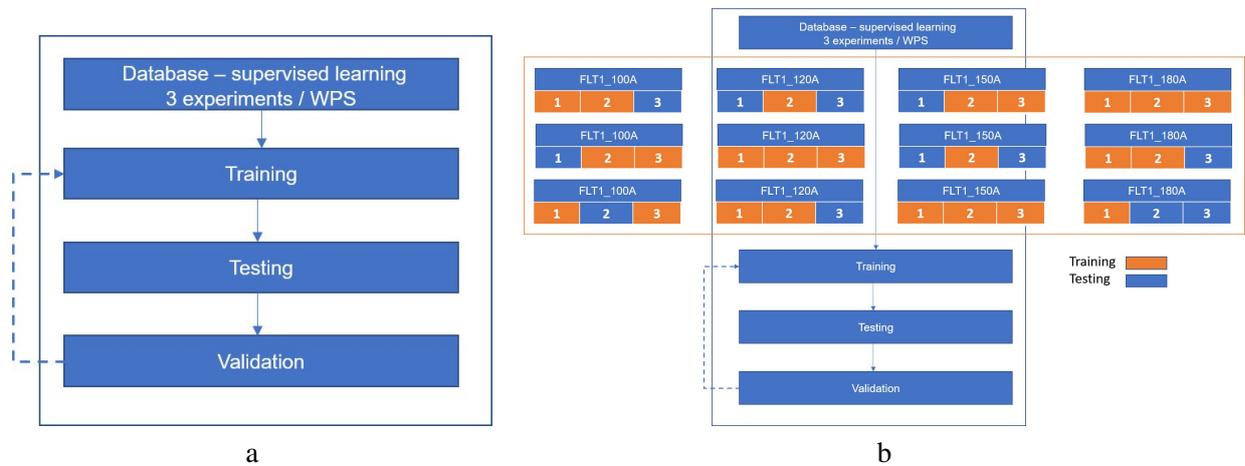


FIGURE 5 – (a) Structure d'apprentissage du ML; (b) Exemple de la validation croisée.

Divers algorithmes de classification ont été utilisés dans cette étude de classification des paramètres procédé. Ils comprennent la méthode d'arbre de décision, la forêt aléatoire, et les méthodes des k plus proches voisins.

## 2.2.4 Critère d'évaluation

La quantification de la performance des modèles s'appuie sur diverses métriques. En classification, il existe, Classification report, validation curve, et bien d'autres.

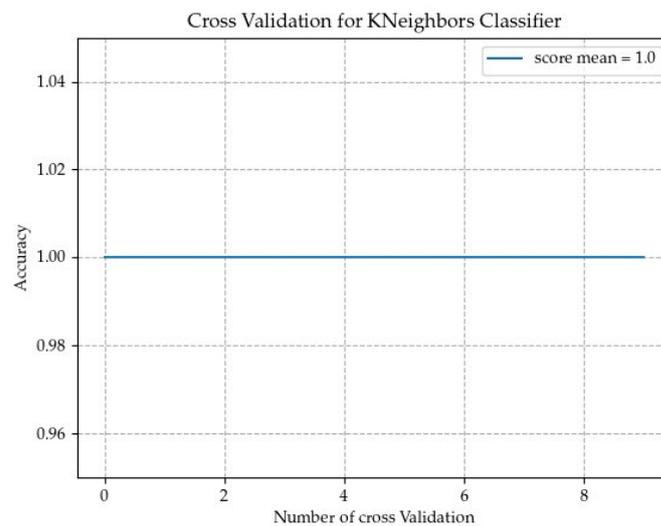


FIGURE 6 – Exemple de résultat de la validation croisée pour l'algorithme KNN.

La figure 6 illustre les résultats de la validation croisée pour l'algorithme KNN. Quelle que soit la base de test et d'entraînement, l'algorithme arrive à un score de précision d'environ 100%. Le modèle est suffisamment robuste pour être sauvegardé et validé. De plus, la précision pour les deux autres algorithmes

d'apprentissage automatique (DT, RF) présentent les mêmes caractéristiques.

### 3 Discussion et résultats

#### 3.1 Extraction des caractéristiques géométriques et prédiction d'un contour

Une fois la quantification des performances du modèle retenu, validé à partir des différents résultats métriques. L'objectif est maintenant d'estimer les performances du modèle d'apprentissage sur de nouvelles données qui n'ont pas été utilisées pour former le modèle.

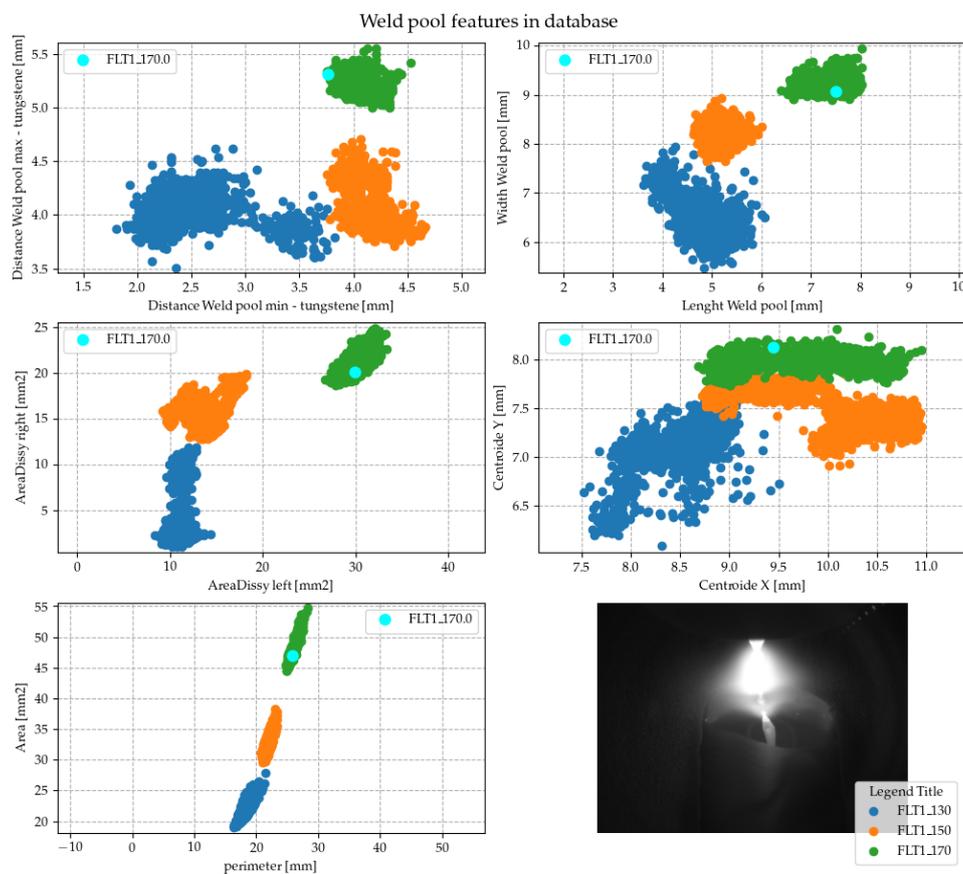


FIGURE 7 – Exemple de résultat de prédiction d'un contour géométrique pour l'algorithme KNN.

Dans la figure 7 est présenté un exemple de résultat de point de prédiction pour une expérience réalisée avec une intensité de 170A. De plus, l'image présentée est celle de la caméra en face supérieure. Dans un premier temps, les différentes caractéristiques sont représentées pour l'ensemble des données présentes dans la BDD d'apprentissage, telles que l'aire, les centres de gravité, la boîte englobante, etc. D'autre part, les différentes entités sont représentées pour toutes les données présentes dans la BDD d'apprentissage. Chaque nuage de points de même couleur fait partie d'une même classe. Un point en bleu turquoise est représenté sur cette figure 7 qui correspond au point de prédiction du contour injecté dans le modèle de ML. En observant les différentes caractéristiques, le point est placé dans le bon nuage de points (FLT\_170), qui correspond aux paramètres programmés. L'algorithme de classification a prédit la bonne classe.

## 3.2 Analyse des prédictions des algorithmes utilisés sur les opérations

Cette partie se concentre sur l'étude des résultats de prédiction des trois algorithmes choisis (KNN, DT, RF). D'une part, pour étudier les influences des paramètres de soudage sur les dimensions du bain de soudure, les valeurs ont été soigneusement mesurées dans un état quasi-stationnaire. D'autre part, seule une caractéristique géométrique a été représentée au cours du temps (ici l'aire du bain de fusion) pour l'analyse des résultats. Cependant, les autres caractéristiques géométriques auraient pu être illustrées. Enfin, l'évolution des surfaces sur les trois configurations de soudage (cf. figure 2) et la prédiction des algorithmes ne sont pas calculées entre la phase d'initiation jusqu'à atteindre une taille constante du bain de soudure (il peut y avoir une certaine fluctuation dans cette zone). De plus, la phase d'extinction de l'arc n'est pas représentée. Par ailleurs, la représentation de l'évolution de l'aire au cours du temps peut être pour chaque configuration, scindée en trois parties. Dans un premier temps, la géométrie du coupon est similaire aux expérimentations permettant la phase d'apprentissage des modèles de ML (expérimentation 2, cf. tableau 1). Dans un second temps, une deuxième zone qui correspond à une variation de paramètres de soudage (cf. section 2.1) ou une modification de la géométrie de l'épaisseur du métal de base. Enfin, une troisième zone qui correspond au retour de l'état "initial" des paramètres ou de l'épaisseur de l'échantillon.

### 3.2.1 Modification des paramètres de soudage

La figure 8 représente la géométrie du métal de base et l'évolution de l'aire du contour du bain de soudage pour l'expérience analysée. La deuxième zone (en rose sur la figure 8 (b)), correspond à l'instant où une modification de paramètres de soudage en cours d'opération affectant l'énergie transmise à la pièce et la répartition de la chaleur pouvant créer une variation de la géométrie du bain de fusion (classe numéro 3 cf. tableau 1). L'essence de cette expérimentation permet sur une même opération de couvrir deux classes présentes dans la BDD d'apprentissage au vu de valider les différents modèles d'apprentissage automatique choisis.

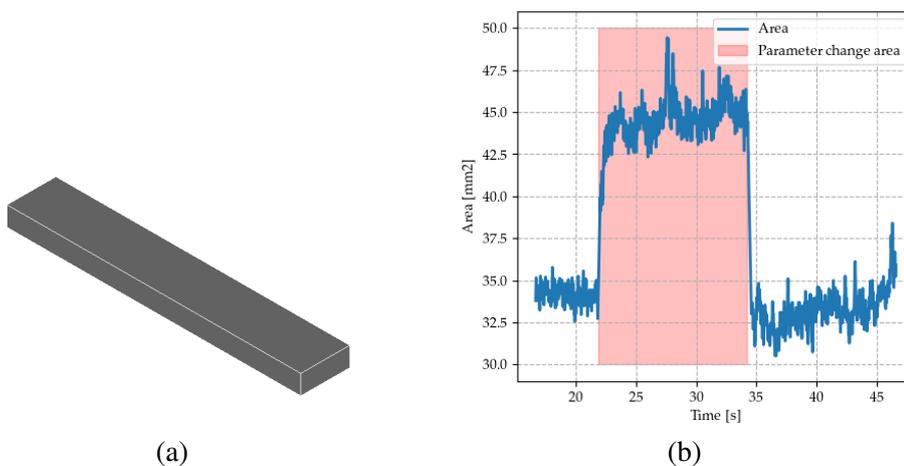


FIGURE 8 – (a) Géométrie du métal de base pour la première expérience, (b) évolution de l'aire du bain de fusion au cours du temps.

La figure 9 illustre la prédiction de chaque algorithme (KNN, DT, RF). D'une part, l'observation de ces

résultats permet de valider la robustesse des méthodes d'apprentissage utilisées. Chaque algorithme a réussi à classer cette modification avec la bonne étiquette. Cependant, pour les algos DT et RF, en fin de troisième zone, ces modèles prédisent quelques contours en un contour ayant des paramètres similaires à la zone deux. Ceci peut être expliqué au vu de l'augmentation de l'air en fin de cordon en raison de l'accumulation de la chaleur dans le métal de base (bain plus mouillant). Par conséquent, l'algorithme KNN étant un algorithme cherchant la distance des points les plus proches, celui-ci n'arrive pas à détecter une variation de l'état stationnaire du bain.

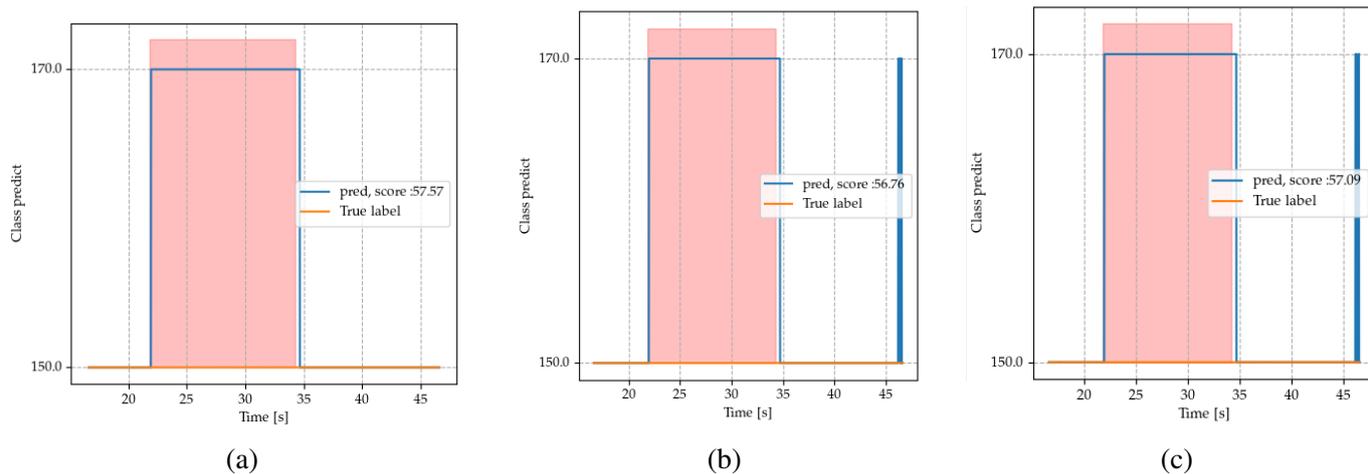


FIGURE 9 – Résultats de prédiction des différents modèles de ML lors d'un changement de paramètres, (a) Classification pour l'algorithme KNN, (b) Classification pour l'algorithme DT, (c) Classification pour l'algorithme RF.

### 3.2.2 Modification de l'épaisseur du métal de base : rainure en face envers

En figure 10 sont représentées la géométrie du métal de base avec la rainure en face envers et l'évolution de l'aire du contour du bain de soudage pour l'expérience analysée. La zone deux, correspond à une modification de l'épaisseur du métal de base pouvant affecter directement la diffusion thermique (conduction) au sein même de la pièce et l'interaction entre le métal liquide et solide.

Comme le montre la figure 10 (b), le bain n'a pas le temps de se stabiliser avant son passage au niveau de la rainure en face envers. Ceci est expliqué par la conduction de la chaleur dans la pièce (pompage thermique intervient fortement). De plus, la géométrie n'augmente pas soudainement. L'évolution de l'aire du bain, tout comme ses autres caractéristiques ont un aspect croissant (pouvant être approché par l'équation d'une droite par exemple) jusqu'à atteindre son maximum local. Par ailleurs, lorsque le bain est localisé sur la rainure, celui-ci ne se stabilise pas, en raison de la dynamique du bain, d'un flux de chaleur très concentré et d'une modification forte de la répartition de la chaleur dans le volume du substrat. Enfin, lors de l'arrivée du bain en fin de la rainure, une diminution croissante de la largeur du bain apparaît du fait de la modification de l'épaisseur du métal de base et donc du pompage thermique associé. Cependant, l'effet de la rainure affecte toujours la stabilité du bain de soudage. Celui-ci n'arrive pas à se stabiliser même si, l'épaisseur du métal de base est "revenue" à la normale. Pour conclure, une modification de la géométrie du métal de base (ici une modification de l'épaisseur métal de base) influe directement sur la diffusion de la thermique dans le volume de la pièce et donc influe aussi directement sur la stabilité et la géométrie du bain.

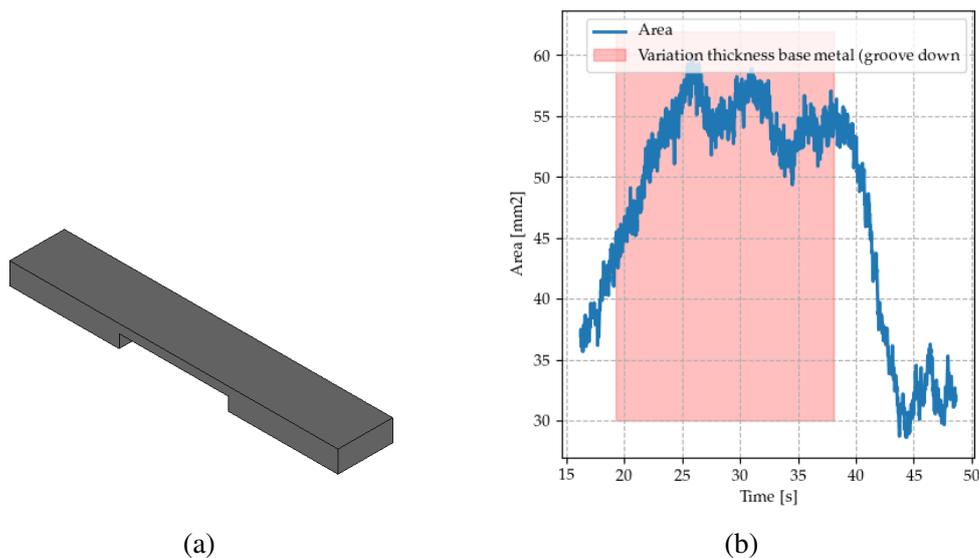


FIGURE 10 – (a) Géométrie du métal de base pour la deuxième expérience, (b) évolution de l’aire du bain de fusion au cours du temps.

La figure 11 illustre la prédiction de chaque algorithme. Dans un premier temps, les différents algorithmes ont une prédiction similaire sur l’ensemble des données injectées dans le modèle de ML. D’une part, les algorithmes classent le début de l’opération dans la bonne étiquette (classe numéro 2, cf. tableau 1). D’autre part, dans la zone de transition (évolution de la géométrie du bain de fusion), les modèles ne savent pas à quelle classe appartient cette zone, ce qui signifie une potentielle instabilité du bain de soudage. Dès lors que le bain est positionné sur la rainure, chaque algorithme classe le bain de fusion dans la catégorie numéro 3 (cf. tableau 1) ce qui correspond bien à une augmentation de la géométrie du bain. Enfin, l’observation en fin d’opération sur l’état de prédiction est similaire aux résultats montrés précédemment. Les algo DT, RF ont relativement les mêmes résultats de classification. La non-stabilité du bain et une chute de l’aire en dessous d’une aire connue pour le mode opératoire numéro 2 mais plutôt apparenté à une classification de la première classe (cf. tableau 1). Ce résultat est plus représentatif au vu de cette diminution de l’aire. Par ailleurs, la conclusion du résultat de l’algo KNN est similaire précédemment.

### 3.2.3 Modification de l’épaisseur du métal de base : rainure en face endroit

En figure 12 sont représentées la géométrie du métal de base avec la rainure en face endroit et l’évolution de l’aire du contour du bain de soudage pour l’expérience analysée. La zone deux, correspond à une modification de l’épaisseur du métal de base pouvant affecter directement la diffusion thermique (conduction) au sein même de la pièce et l’interaction entre le métal liquide et solide tout comme la géométrie précédente. De plus, l’effet de bord des rainures peut aussi affecter la zone fondue (augmentation de la mouillabilité du bain).

Comme le montre la figure 12 (b), le bain sur cette configuration n’a aussi pas le temps de se stabiliser en raison d’une modification de la diffusion de la chaleur. De plus, lors du passage du bain dans la zone de variation, l’aire du bain augmente, néanmoins certaines caractéristiques géométriques ne sont

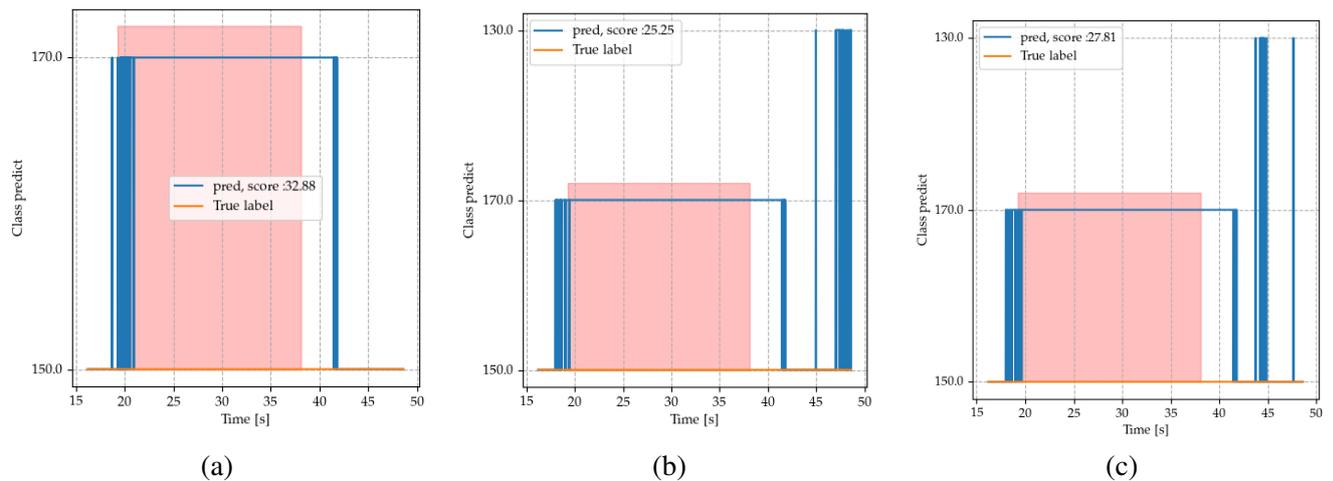


FIGURE 11 – Résultats de prédiction des différents modèles de ML lors d'un changement de l'épaisseur, (a) classification pour l'algorithme KNN, (b) classification pour l'algorithme DT, (c) classification pour l'algorithme RF.

pas modifiées. L'effet de bord de la rainure intervient sur la modification de l'aire du bain mais pas sur sa largeur. Celui-ci reste "bloqué" dans l'intervalle des deux rainures. Le bain a tendance à couler, tomber sur la hauteur de la rainure qu'à s'étaler (augmentation de la largeur du bain). Par ailleurs, ces informations déduites proviennent de la mise en place de plusieurs caméras. Enfin, lors du retour à la géométrie initiale, le bain se stabilise dans la dimension souhaitée.

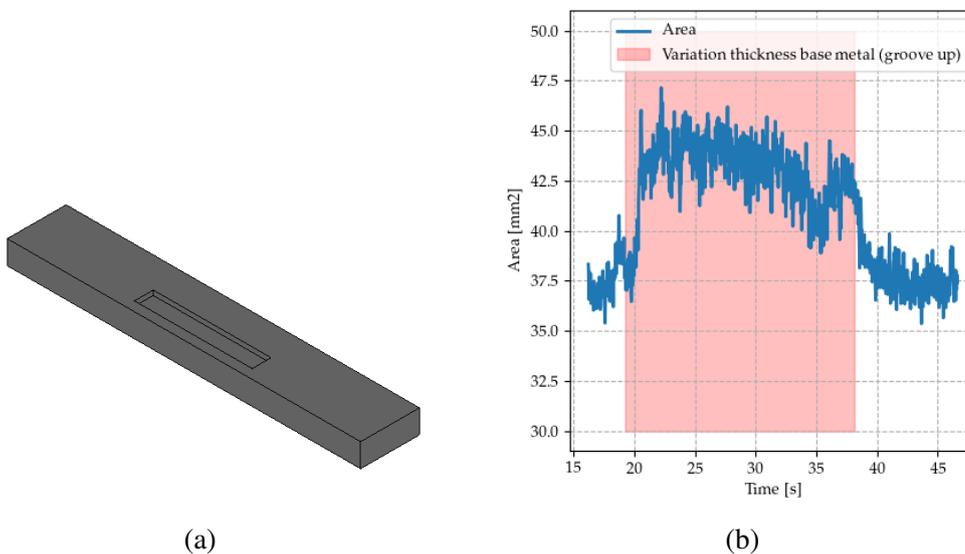


FIGURE 12 – (a) Géométrie du métal de base pour la troisième expérience, (b) évolution de l'aire du bain de fusion au cours du temps.

En figure 13 est illustrée la prédiction de chaque algorithme. Dans un premier temps, chaque algorithme a une prédiction similaire sur la partie 1 et 3 des données injectées dans le modèle de ML. Dans la zone de la rainure, les algorithmes ne savent pas à quelle classe appartient cette zone, ce qui signifie une potentielle instabilité du bain de soudage. Hormis le modèle DT qui lui classe une grande partie de cette zone dans la classe 3 (cf. tableau 1). Les conclusions sur l'impact de la rainure sur le métal de base et le bain de soudage est similaire aux résultats précédents. La diffusion de la thermique dans le volume de

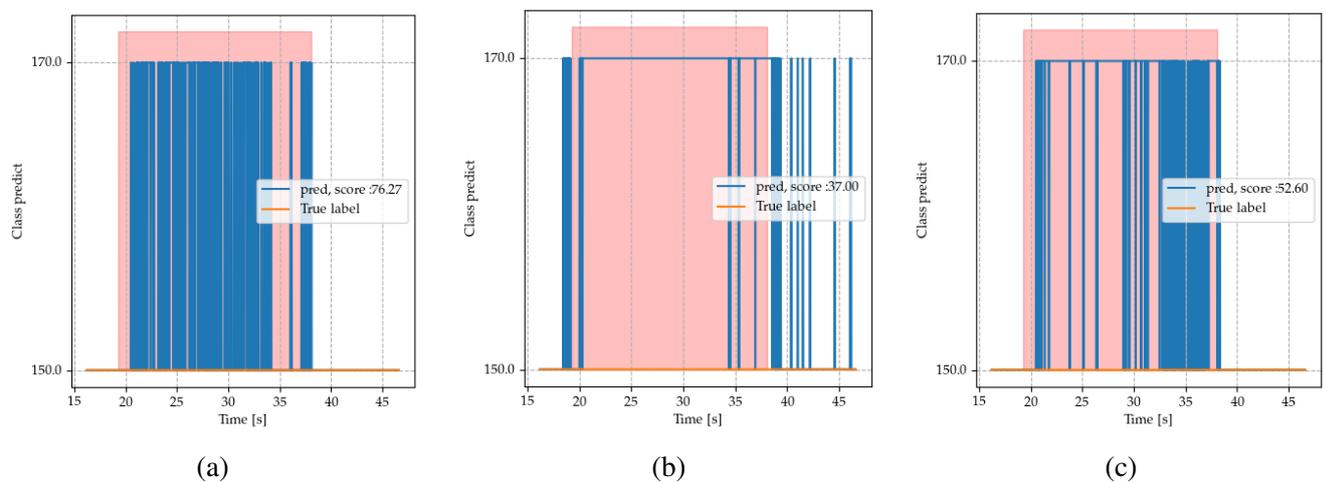


FIGURE 13 – Résultats de prédiction des différents modèles de ML lors d'un changement de l'épaisseur, (a) classification pour l'algorithme KNN, (b) classification pour l'algorithme DT, (c) classification pour l'algorithme RF.

la pièce est modifiée et donc influe aussi directement sur la stabilité et la géométrie du bain.

## 4 Conclusion

Dans cette étude un montage expérimental a été mis en place pour effectuer le contrôle in-situ d'une opération de soudage réalisée avec le procédé TIG. D'une part, l'enregistrement des paramètres procédés (tension, intensité, gaz de protection, vitesse de dévidage du fil) permet de s'assurer de la consigne fixée sur le poste de soudage. D'autre part, l'observation du bain de fusion permet de suivre l'évolution de sa géométrie. Enfin, la synchronisation des différents capteurs permet le stockage et la traçabilité des opérations de soudage dans une base de données en vue d'alimenter des modèles de machine learning.

Dans un premier temps, plusieurs algorithmes de traitement d'images sont utilisés pour extraire la géométrie du bain de fusion et ses caractéristiques en fonction des paramètres procédé utilisés. Ces données permettent la réduction de la BDD et un gain de temps lors de l'apprentissage des modèles de machines learning. De plus, les caractéristiques extraites des images brutes sont fournies comme paramètres d'entrées aux différents classificateurs pour classer, prédire l'état du cordon de soudage.

Trois algorithmes de classification ont été testés sur trois configurations de soudage présentant une diffusion thermique et une interaction entre le métal liquide et solide différentes. Les modèles, k plus proche voisin, l'arbre de décision et la forêt aléatoire ont été utilisés pour la classification et les résultats ont été comparés. De manière générale, les modèles présentent les mêmes états de prédiction dans les zones de modification d'énergie. Néanmoins, pour des zones plus transitoires, les modèles DT et RF ont présenté des résultats plus performants que le modèle KNN.

Enfin, divers chercheurs ont commencé à introduire l'apprentissage en profondeur (Deep Learning) dans la classification d'images. Un réseau neuronal convolutif (CNN) par exemple peut être utilisé pour l'analyse d'images dans la surveillance des processus de soudage. La comparaison des critères de performances sur l'état de prédiction des d'algorithmes de machine learning et deep learning peut être envisagée. De plus, l'implémentation des ces différents algorithmes peut être utilisée sur une géométrie plus complexe, plus représentative d'opérations de fabrication telles que un chanfrein avec remplissage multipasse, pouvant faire apparaître des défauts volumiques (manque de fusion).

## Références

- [1] J. Mirapeix, P. B. García-Allende, A. Cobo, O. M. Conde, and J. M. López-Higuera. Real-time arc-welding defect detection and classification with principal component analysis and artificial neural networks. *NDT and E International*, 40(4) :315–323, 2007.
- [2] J. Mirapeix, A. Cobo, O. M. Conde, C. Jaúregui, and J. M. López-Higuera. Real-time arc welding defect detection technique by means of plasma spectrum optical analysis. *NDT and E International*, 39(5) :356–360, 2006.
- [3] J. Mirapeix, R. Ruiz-Lombera, J. J. Valdiande, L. Rodriguez-Cobo, F. Anabitarte, and A. Cobo. Defect detection with CCD-spectrometer and photodiode-based arc-welding monitoring systems. *Journal of Materials Processing Technology*, 211(12) :2132–2139, 2011.
- [4] A. Sumesh, Dinu Thomas Thekkuden, Binoy B. Nair, K. Rameshkumar, and K. Mohandas. Acoustic Signature Based Weld Quality Monitoring for SMAW Process Using Data Mining Algorithms. *Applied Mechanics and Materials*, 813-814 :1104–1113, 2015.
- [5] A. Sumesh, K. Rameshkumar, K. Mohandas, and R. Shyam Babu. Use of machine learning algorithms for weld quality monitoring using acoustic signature. *Procedia Computer Science*, 50 :316–322, 2015.
- [6] R. Kovacevic and Y. M. Zhang. Real-Time Image Processing for Monitoring of Free Weld Pool Surface. *Journal of Manufacturing Science and Engineering, Transactions of the ASME*, 119(2) :161–169, 1997.
- [7] R Kovacevic, YM Zhang, and L Li. Monitoring of Weld Joint Penetrations Based on Weld Pool Geometrical Appearance. *Welding Journal-Including Welding Research Supplement*, 75(10) :317–329, 1996.
- [8] Yu M. Zhang, Radovan Kovacevic, and Lin Li. Adaptive control of full penetration gas tungsten arc welding. *IEEE Transactions on Control Systems Technology*, 4(4) :394–403, 1996.
- [9] Thomas Dietterich, Christopher Bishop, David Heckerman, Michael Jordan, Michael Kearns, and Associate Editors. *Adaptive Computation and Machine Learning*.
- [10] Thomas Dietterich, Christopher Bishop, David Heckerman, Michael Jordan, Michael Kearns, and Associate Editors. Probabilistic Machine Learning : Advanced Topics Adaptive Computation and Machine Learning.