

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

MINISTERE DE L'ENSEIGNEMENT SUPERIEUR

ET DE LA RECHERCHE SCIENTIFIQUE

UNIVERSITE ABDERRAHMANE MIRA BEJAIA

FACULTE DE TECHNOLOGIE

DEPARTEMENT DE GENIE MECANIQUE

MEMOIRE

Présenté pour l'obtention du diplôme de

MASTER

Filière : Génie Mécanique

Spécialité : Fabrication mécanique et productique

Par :

MAKHLOUFI Yacine

Thème

Etude statistique de l'influence des paramètres de coupe sur l'état de surface, cas de l'usinage périphérique de l'aluminium

Soutenu le 01 /07/ 2024 devant le jury composé de :

M.	IDIR Abdelhek	Président
M.	BELAMRI Abdelatif	Rapporteur
M.	HYMED Lynda	Examineur

Année Universitaire 2023-2024

Remercîment

Avant toute chose, je tiens à exprimer ma gratitude envers Dieu pour m'avoir donné la force et la persévérance nécessaires à la réalisation de ce travail.

Ensuite, je souhaite remercier chaleureusement tous nos professeurs pour leur écoute attentive, leur professionnalisme indéniable, et leur soutien tout au long de mes études. En particulier, je tiens à exprimer ma reconnaissance envers mon encadrant, le Dr. BELAMRI, pour sa passion, sa rigueur et son assistance précieuse tout au long de l'élaboration de ce mémoire.

Dédicace

Je souhaite exprimer ma profonde gratitude à mes parents, dont l'amour et le soutien inconditionnels ont été les piliers de mon parcours. Leur confiance et leurs encouragements ont rendu chaque défi plus abordable.

Un remerciement tout particulier va à ma petite sœur Lina. Sa complicité, notre partage quotidien et sa présence chaleureuse ont été des sources essentielles de soutien et de réconfort. Notre relation proche a enrichi mon parcours de manière inestimable.

Je remercie également mon oncle pour ses conseils précieux, tant matériels que spirituels, qui ont été d'une aide inestimable tout au long de mon cheminement.

Je n'oublie pas mes grands-parents, dont l'amour et les valeurs ont eu un impact profond sur mon éducation. À ceux qui sont encore présents, je suis particulièrement reconnaissant pour leur soutien continu. À ceux qui nous ont malheureusement quittés, je garde leur mémoire précieusement et leur influence continue de m'inspirer.

Je souhaite aussi exprimer ma gratitude envers mes amis d'enfance, Madjid et Lyna, avec qui j'ai partagé tant de moments depuis nos années à l'école primaire. Leur amitié a été un pilier tout au long de mon parcours, tant sur le plan personnel qu'académique. Leur soutien constant a été précieux non seulement pour mes études, mais aussi pour mon épanouissement personnel, enrichissant ma vie de manière significative.

Je remercie également Walid, avec qui j'ai vécu de nombreux souvenirs mémorables à l'université. Que ce soit dans les moments de joie ou lors des défis difficiles, sa présence constante et son soutien ont joué un rôle crucial. Nos échanges, nos réussites partagées et même nos épreuves nous ont permis de grandir et de prendre conscience de tant de choses.

Un remerciement particulier s'adresse à El Ghaya, non seulement pour son amitié indéfectible, mais aussi pour son aide précieuse qui a contribué de manière significative à mon parcours académique. Les moments magnifiques que nous avons partagés, qu'il s'agisse de discussions inspirantes ou de soutiens mutuels lors de défis, ont marqué mon cheminement et enrichi mon expérience.

Enfin, un grand merci à toutes les autres personnes qui ont contribué, de près ou de loin, à cette réussite. Votre soutien et vos encouragements ont été précieux et déterminants dans l'accomplissement de ce projet.

Table des matières

Table des figures	vii
Liste des tableaux	ix
Introduction général	1
1 Synthèse bibliographique	3
1.1 Introduction	3
1.2 Notion de base en fraisage	3
1.2.1 Définition	3
1.2.2 Angles de l'outil coupant	3
1.2.3 Cinématique de l'outil de coupe	5
1.2.4 Usinage sur le flanc	6
1.2.5 Formation du copeau	7
1.3 Aluminium	8
1.3.1 Classification des alliages d'aluminium	9
1.3.2 L'importance de l'aluminium	9
1.4 Qualité de surface	9
1.4.1 principaux défauts de surface	9
1.4.2 Paramètres caractéristiques d'état de surface	10
1.4.3 Paramètres influençant la qualité de surface	11
1.5 L'analyse de la variance	12
1.6 Tendances dans la modélisation et la prédiction de la rugosité	12
1.6.1 Approche statistique	13
1.6.2 Approche de l'intelligence artificielle (Machine Learning)	14
1.6.3 Approche par éléments finis	19
1.7 Conclusion	19
2 Mise en Œuvre Expérimentale : Moyens et Méthodes	21
2.1 INTRODUCTION	21
2.2 MOYENS UTILISES	21

2.2.1	Machines-outils	21
2.2.2	Pièce d'aluminium	22
2.2.3	Fraise utilisée	24
2.2.4	Rugosimètre	25
2.3	Planification des expériences	26
2.3.1	Méthode multifactorielle	26
2.3.2	La Rugosité	27
2.4	Expérience	29
2.5	Conclusion	32
3	l'influence des paramètres de coupe et modélisation par régression multiple	33
3.1	Introduction	33
3.2	Influence des condition de coupe sur la rugosité	33
3.2.1	Observations durant l'usinage	34
3.2.2	Observations au Cours du Processus d'Usinage	40
3.2.3	Analyse de l'Histogramme	40
3.2.4	Analyse des Résultats expérimentaux	41
3.2.5	Quantification de l'influence relative de chaque facteur	45
3.3	modélisation par régression multiple	51
3.3.1	Étape de modélisation	51
3.3.2	Équation de régression pour la rugosité arithmétique	51
3.3.3	Analyse des Courbes de Prédiction et de Mesure de $R_a L$	53
3.3.4	Comparaison Entre les Modèles de Deuxième et quatrième Ordre	54
3.3.5	Analyse des Courbes de Prédiction et de Mesure de $R_a T$	56
3.3.6	Comparaison Entre les Modèles de Deuxième et de quatrième Ordre	57
3.3.7	Validation du modèle de régression de quatrième ordre	57
3.4	Conclusion	58
4	Modélisation par Machine Learning	59
4.1	Introduction	59
4.2	Étapes de modélisation	59
4.3	Critères de comparaison	60
4.3.1	Écart quadratique moyen	60
4.3.2	l'erreur absolue	60
4.3.3	Erreur relative	61
4.3.4	Erreur au carré	61
4.3.5	corrélation	61
4.3.6	Le temps d'entraînement	62
4.3.7	Le temps de scoring	63

4.4	Résultat des comparaison et Interprétation	63
4.4.1	les Résultats de la rugosité arithmétique Longitudinale	64
4.4.2	Écart Quadratique Moyen	64
4.4.3	Erreur Absolue	65
4.4.4	Erreur Relative	65
4.4.5	Erreur au Carré	65
4.4.6	Corrélation	65
4.4.7	Temps d'Entraînement et de Scoring	66
4.4.8	Conclusion	66
4.5	Résultat de la modélisation par arbre de décision pour la rugosité arithmétique longi- tudinale	67
4.5.1	les Résultats de la rugosité arithmétique Transversale	68
4.6	Interprétation des Résultats pour la rugosité arithmétique Transversal	68
4.6.1	Écart Quadratique Moyen (EQM)	68
4.6.2	Erreur Absolue	69
4.6.3	Erreur Relative	69
4.6.4	Erreur au Carré	69
4.6.5	Corrélation	69
4.6.6	Temps d'Entraînement et de Scoring	70
4.7	Conclusion et remarque	70
4.8	Résultat de la Modélisation par la forêt aléatoire	71
4.9	Validation des modèles d'apprentissage automatique	72
	Conclusion générale	73
	References	75

Table des figures

1.1	Zones caractérisant l'outil de coupe en fraisage	4
1.2	Différents mouvements de l'outil de coupe	6
1.3	usinage sur le flanc	7
1.4	Formation du copeau	8
1.5	paramètres d'état de surface [13]	11
1.6	Paramètres influençant la rugosité de surface (Benardos Vosnaikos, 2003) [27]	12
1.7	processus de machine learning [15]	14
1.8	model noronal	15
1.9	Procédure d'apprentissage supervisé d'un réseau feedforward typique	16
1.10	Apprentissage Profond par Réseau de Neurones [17]	17
1.11	Exemple d'un arbre de décision	18
1.12	Schéma de l'algorithme de la forêt aléatoire (Breiman 2001) [21]	18
1.13	Shema Arbre boosté par gradient [12]	19
2.1	Centre d'usage utilise pendant les test	22
2.2	Pièce en alliage d'aluminium de la série 6000 utilisée pour les tests	22
2.3	analyse chimique Metavision-1008i	23
2.4	Duromètre Brinell FALCON 400G2	24
2.5	Shema Technique de la fraise [16]	24
2.6	Rugosimètre LiteSURF	26
2.7	Mesure longitudinale de la rugosité	29
2.8	Mesure transversale de la rugosité	30
3.1	Interprétation des valeurs de la première colonne	34
3.2	Photos prises durant les tests et un histogrammes des valeur de La rugosité longitudi- nale $R_a L$ et la rugosité transversale $R_a T$	39
3.3	Graphique $R_a L$	43
3.4	Graphique $R_a T$	45
3.5	Comparaison entre les valeurs mesurées et prédites de $R_a L$ deuxième ordre	52
3.6	Comparaison entre les valeurs mesurées et prédites de $R_a L$ quatrième ordre	53

3.7	Comparaison entre les valeurs mesurées et prédites de R_a T deuxième ordre	55
3.8	Comparaison entre les valeurs mesurées et prédites de R_a T quatrième ordre	56
4.1	Arbre de décision pour R_a longitudinale	67
4.2	Arbre de décision pour R_a transversale	71

Liste des tableaux

2.1	Mesures de dureté Vickers et moyenne calculée	23
2.2	Tableau des Niveaux de variation des facteurs	27
2.3	Matrice de planification par la méthode multifactorielle	28
2.4	Les image des différente étapes de l'expérimentation	31
3.1	Tableau croisé des variables (R_a L)	42
3.2	Tableau croisé des variables (R_a T)	44
3.3	Analyse de la variance pour moyen R_a L	47
3.4	Composantes de la variance	48
3.5	Analyse de la variance pour moyen R_a T	49
3.6	Composantes de la variance	50
4.1	tableau récapitulatif des résultats pour la rugosité arithmétique Longitudinale	64
4.2	tableau récapitulatif des résultats pour la rugosité arithmétique transversale	68

Nomenclature

f_z : Avance par dent, mm/dent.

V_c : Vitesse de coupe, m/min.

a_p : Profondeur de passe, mm.

V_f : Vitesse d'avance, mm/min.

M_c : Mouvement de coupe.

M_f : Mouvement d'avance.

R_a : La Rugosité Moyenne Arithmétique , μm .

R_{aT} : La Rugosité Moyenne Arithmétique transversal, μm .

R_{aL} : La Rugosité Moyenne Arithmétique longitudinal, μm .

ANOVA : Analyse de la variance.

ANN : Réseaux de neurones artificiels.

RMSE : L'écart quadratique moyen.

Introduction général

L'usinage est un processus de fabrication par enlèvement de matière, qui joue un rôle crucial dans de nombreux secteurs industriels, allant de l'aéronautique à l'automobile, en passant par l'électronique et la mécanique de précision. La qualité de la surface usinée, souvent caractérisée par des paramètres tels que la rugosité, est déterminante pour la performance et la durabilité des pièces fabriquées. Comprendre et contrôler les conditions de coupe pour avoir l'état de surface voulu est donc un enjeu majeur pour les ingénieurs et les chercheurs.

Dans ce contexte, ce mémoire s'intéresse particulièrement à l'étude de l'influence des conditions de coupe sur la rugosité de surface. Nous nous concentrons sur trois principaux paramètres de coupe : la vitesse de coupe (V_c), l'avance par tour (f_z), et la profondeur de passe (a_p). Ces paramètres sont étudiés non seulement à travers des analyses visuelles, mais aussi par des méthodes statistiques rigoureuses, notamment l'analyse de la variance (ANOVA).

Nous mettons également en œuvre des techniques avancées de modélisation, telles que la régression multiple et le machine learning, pour mieux comprendre et prédire la rugosité de surface. En explorant différents modèles de régression, y compris ceux de second et de quatrième ordre, nous cherchons à identifier ceux qui offrent la meilleure précision. De plus, nous comparons plusieurs modèles de machine learning, tels que les arbres de décision, les forêts aléatoires, et les méthodes de deep learning, afin de déterminer ceux qui sont les plus efficaces pour nos prédictions.

L'objectif principal de ce travail est de développer des modèles robustes et précis capables de prédire les conditions de coupe nécessaires pour obtenir la rugosité de surface souhaitée, réduisant ainsi les erreurs de fabrication et améliorant la qualité des pièces usinées. En intégrant des approches à la fois traditionnelles et modernes, nous visons à fournir des solutions pratiques et directement applicables dans le contexte industriel. Ce projet vise également à contribuer à l'avancement des connaissances dans le domaine de l'usinage, permettant aux entreprises d'optimiser leurs processus sans gaspillage de matériaux ni de temps.

Le premier chapitre propose une synthèse bibliographique, introduisant les fondements théoriques du fraisage et de l'usinage, tout en mettant l'accent sur des notions sur l'état de surface.

Le deuxième chapitre se concentre sur la mise en œuvre expérimentale, décrivant les outils et méthodes utilisés pour conduire nos expériences.

Dans le troisième chapitre, nous explorons l'influence spécifique des paramètres de coupe sur la rugosité de surface, basée sur nos observations expérimentales. Nous utilisons des techniques de régression multiple pour modéliser ces relations et évaluer la précision de différents ordres de modèles dans la prédiction de la rugosité arithmétique.

Enfin, le quatrième chapitre présente notre approche basée sur le machine learning pour la modélisation des conditions de coupe. Nous comparons plusieurs modèles, y compris les arbres de décision et les forêts aléatoires, en analysant leur capacité à prédire précisément la rugosité de surface longitudinale et transversale.

Chapitre 1

Synthèse bibliographique

1.1 Introduction

Dans le chapitre qui va suivre, nous visons à fournir une compréhension des notions de base en fraisage. Nous commencerons par définir les principes fondamentaux du fraisage et examinerons les angles de l'outil coupant ainsi que la cinématique de l'outil de coupe. Par la suite, nous définirons l'usinage sur le flanc et la formation du copeau.

L'aluminium, un matériau couramment utilisé en fraisage, sera également abordé, en mettant l'accent sur la classification de ses alliages et son importance industrielle. La qualité de surface, un critère crucial pour l'efficacité et la durabilité des pièces usinées, sera analysée à travers ses principaux défauts, les paramètres caractéristiques de l'état de surface, et les facteurs influençant cette qualité.

Enfin, nous inclurons une brève digression sur l'analyse de la variance (ANOVA) avant de discuter des tendances actuelles dans la modélisation et la prédiction de la rugosité de surface. Nous aborderons les approches statistiques traditionnelles, les méthodes innovantes basées sur l'intelligence artificielle, et la plus commune, qui est la méthode des éléments finis.

1.2 Notion de base en fraisage

1.2.1 Définition

Le fraisage est une technique de fabrication qui combine deux mouvements : la rotation d'un outil utilisé pour couper et l'avancée d'une pièce à usiner. Actuellement, on ajoute le déplacement de l'outil (toutes les directions sont possibles) par rapport à la pièce [7].

1.2.2 Angles de l'outil coupant

Les outils de coupe, outre leur matériau, sont définis par leur géométrie, notamment par les angles de coupe.

a- Angle de coupe

L'angle auquel le tranchant d'un outil est incliné par rapport à la pièce à usiner. Cela influence considérablement la formation de copeaux et la génération de chaleur pendant la coupe.

b- Angle de dépouille

L'angle entre le bord arrière d'une dent de scie à ruban et le bord arrière du matériau à couper. Cet angle permet à la dent de dégager le matériau au fur et à mesure de son déplacement dans la coupe, réduisant ainsi la friction et minimisant le risque de grippage ou de surchauffe.

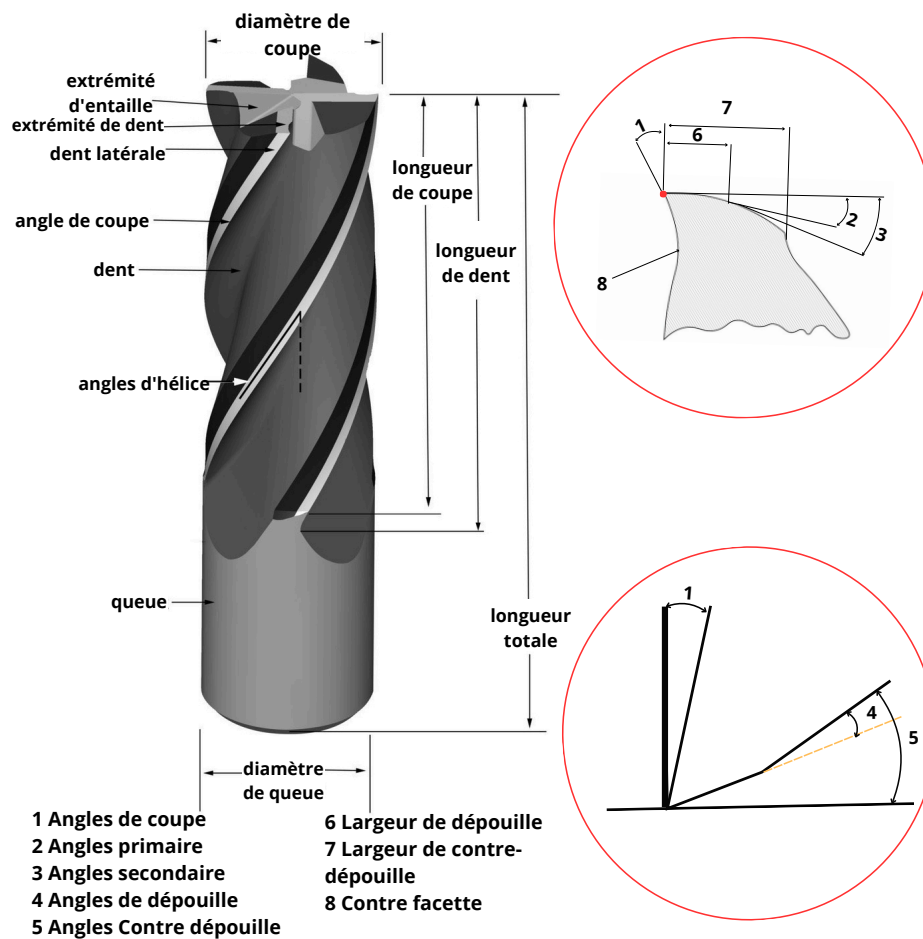


FIGURE 1.1 Zones caractérisant l'outil de coupe en fraisage

1.2.3 Cinématique de l'outil de coupe

a- Paramètres de coupe

En fabrication mécanique, trois paramètres principaux régissent le processus d'enlèvement de matière et ont un impact significatif sur les mécanismes provoquant l'usure des outils coupants. Ces paramètres sont [11] :

- **Vitesse de coupe** V_c : définie comme la vitesse tangentielle. Elle dépend du matériau à usiner et de la fréquence de rotation de l'outil (en fraisage). Elle joue un rôle majeur dans le processus de coupe, à savoir les mécanismes d'enlèvement de matière [11]. L'équation de la vitesse de coupe (V_c) est donnée par :

$$V_c = \frac{N}{1000 \times \pi \times D} \quad (1.1)$$

où

V_c : vitesse de coupe en m/min,

N : vitesse de rotation de l'outil en tours par minute (tr/min),

D : diamètre de l'outil de coupe en millimètres.

- **Avance par tour** f_z : est le second paramètre qui a une influence significative dans le procédé de coupe car il détermine la section du copeau. Il correspond au déplacement de la pièce pour une révolution de l'outil en fraisage [11].
- **Profondeur de passe** a_p : elle correspond à la différence entre le rayon de la pièce avant et après une passe [11].

b- Mouvements de l'outil coupant

Afin d'enlever la quantité de matière souhaitée, l'outil est muni de deux mouvements : un mouvement de coupe et un mouvement d'avance.

- **Mouvement de coupe** : est le mouvement relatif principal permettant à l'outil de couper la pièce. Il est régi par la vitesse de coupe V_c .
- **Mouvement d'avance** : est le mouvement permettant à l'outil de se déplacer le long de la pièce. Il est régi par la vitesse d'avance V_f .

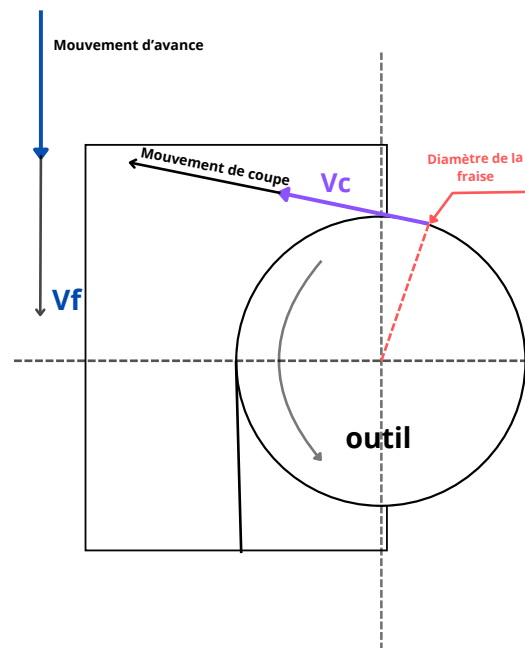


FIGURE 1.2 Différents mouvements de l'outil de coupe

1.2.4 Usinage sur le flanc

L'usinage par le flanc, également connu sous le nom d'usinage en roulement, représente une méthode d'usinage où l'outil entre en contact tangentiel avec la surface de la pièce. Contrairement à l'usinage en bout où l'outil entre en contact perpendiculairement avec la pièce, l'usinage par le flanc permet un contact linéique, améliorant ainsi le taux d'enlèvement de matière et produisant des états de surface plus fins [25].

L'objectif principal de l'usinage par le flanc est de remplacer les opérations de balayage effectuées avec des outils hémisphériques à pas faible par un nombre réduit de passages utilisant des outils cylindriques ou toriques tangent à la surface de la pièce. Cette approche permet une augmentation significative de la productivité, même dans des cas où l'usinage traditionnel en bout serait moins efficace [25].

Cette méthode trouve une application particulièrement intéressante dans des situations où la géométrie de la pièce ou les contraintes de fabrication rendent l'usinage en bout difficile ou inefficace. En permettant une meilleure utilisation de l'outil et une réduction du temps d'usinage, l'usinage par le flanc offre aux industriels une solution attractive pour améliorer leur productivité et leur compétitivité sur le marché [25].




FIGURE 1.3 usinage sur le flanc

1.2.5 Formation du copeau

La formation du copeau est un processus crucial en usinage où de la matière est enlevée d'une pièce à usiner à l'aide d'un outil tranchant. Lorsque l'outil entre en contact avec la pièce, il exerce une pression qui induit une déformation plastique du matériau le long d'une ligne spécifique, appelée *zone de cisaillement primaire*. Cette déformation entraîne la création d'un copeau qui se détache progressivement de la pièce selon un angle et une vitesse déterminés par les paramètres de coupe. Les étapes de formation du copeau avant son éjection sont les suivantes :

1. **Déformation élastique initiale** : Au contact de la fraise avec le matériau, celui-ci commence par se déformer élastiquement, c'est-à-dire que la matière tente de résister à la pénétration de l'outil.
2. **Déformation plastique** : La pression exercée par l'outil dépasse la limite élastique du matériau, provoquant une déformation plastique irréversible. Le matériau commence à se déformer de manière permanente, formant ainsi un début de copeau.
3. **Initiation de la rupture** : Sous l'effet de la pression continue de l'outil, le matériau se fend, et une zone de cisaillement se développe. Le copeau se détache progressivement de la pièce à usiner.
4. **Glissement le long de l'outil** : Le copeau se déplace le long de la face de coupe de l'outil. Il subit un frottement avec l'outil, ce qui peut entraîner une augmentation de la température à ce point.

5. **Éjection du copeau** : Une fois complètement détaché, le copeau est expulsé sous l'effet du mouvement de la fraise. La forme et la taille du copeau peuvent varier en fonction des conditions de coupe et du matériau usiné.




FIGURE 1.4 Formation du copeau

1.3 Aluminium

L'aluminium est un élément chimique, de symbole Al et de numéro atomique 13. C'est un métal pauvre, malléable, de couleur argentée, qui est remarquable pour sa résistance à l'oxydation et sa faible densité. C'est le métal le plus abondant de l'écorce terrestre et le troisième élément le plus abondant après l'oxygène et le silicium ; il représente en moyenne 8 % de la masse des matériaux de la surface solide de notre planète. L'aluminium est trop réactif pour exister à l'état natif dans le milieu naturel : on le trouve au contraire sous forme combinée dans plus de 270 minéraux différents, son minerai principal étant la bauxite, où il est présent sous forme d'oxyde hydraté dont on extrait l'alumine. [9]

1.3.1 Classification des alliages d'aluminium

Les alliages d'aluminium sont classés en deux catégories

a- Alliages coulés

- Les alliages d'aluminium coulés sont une catégorie d'alliages fabriqués par coulée. Ils sont souvent utilisés dans des applications où une grande ductilité est requise, comme dans la fabrication de pièces complexes.
- Certains alliages contenant du silicium en tant que principal élément d'alliage, ils sont plus faciles à usiner avec des angles de coupe d'outil plus élevés, des vitesses de coupe et des avances plus basses, ce qui les rend plus économiques à usiner [2].

b- Alliages forgés

- Les alliages d'aluminium forgés sont fabriqués par forgeage, un processus qui implique la mise en forme de métal solide par l'application de pression.
- Ces alliages ont souvent une meilleure résistance que les alliages coulés en raison de la structure cristalline plus fine qui résulte du processus de forgeage [2].

1.3.2 L'importance de l'aluminium

L'aluminium trouve des applications variées dans six industries clés. Dans les transports, il améliore l'efficacité énergétique des véhicules. En énergie, il remplace le cuivre dans les lignes de transmission et est utilisé dans les panneaux solaires. En construction, il supporte les structures vitrées. Dans l'alimentation, il conserve les aliments, et dans les biens de consommation, il est présent dans les appareils électroniques et ustensiles. Enfin, dans le secteur militaire, il est utilisé pour les transports et équipements. Choisir un fournisseur fiable est essentiel pour garantir la qualité de cette matière première [14].

1.4 Qualité de surface

Les états de surfaces ont une attribution cruciale dans l'aptitude d'une pièce mécanique à remplir une fonction donnée.

Des défauts sur ses surfaces peuvent être de nature géométrique ou physico-chimique [24]. Dans notre cas, on ne s'intéresse qu'aux défauts géométriques. Ces derniers sont généralement sous quatre numéros

1.4.1 principaux défauts de surface

On va en compter quatre.

a- Défauts du premier ordre

Ce sont des défauts dus à des écarts de forme (rectitude, cylindricité, etc.) et de position (perpendicularité, parallélisme, etc.). Provenant de la déformation de la pièce pendant et après l'usinage, des défauts de bridage, de la flexion des éléments de la machine, d'un mauvais guidage des éléments mobiles ou de l'usure des organes de la machine-outil [24].

b- Défauts du deuxième ordre

Défauts plus petits. Ayant l'aspect général d'une ondulation, et provenant de l'avance par tour au tournage ou de l'avance par dent en fraisage, de vibrations de basse fréquence de la pièce ou de l'outil de coupe [24].

c- Défauts du troisième ordre

Se sont des stries ou des sillons laissés par l'outil de coupe. Ils sont fonction de l'avance par dent de la fraise, ou à des vibrations haute fréquence [24].

d- Défauts du troisième ordre

Se sont des stries ou des sillons laissés par l'outil de coupe. Ils sont fonction de l'avance par dent de la fraise, ou à des vibrations haute fréquence [24].

e- Défauts du quatrième ordre

Ils sont constitués par des arrachements, fente et piqûre, ... etc. Ils sont dus à des marques d'outil ou à des vibrations de hautes fréquences. Ce type de défaut a un caractère apériodique. L'ensemble des défauts de 3^{ème} et 4^{ème} ordre constituent la rugosité de la surface [24].

1.4.2 Paramètres caractéristiques d'état de surface

Les normes et les paramètres désignant la rugosité de surface sont nombreux, on se limite à présenter le paramètre de surface fréquemment utilisées dans le domaine de la fabrication mécanique, définis selon la norme ISO 4287

Rugosité moyenne arithmétique R_a

L'équation de la rugosité arithmétique R_a est exprimée comme suit :

$$R_a = \frac{1}{l_m} \times \int_{x=l_m}^{x=0} |y(x)| dx \quad (1.2)$$

où les éléments sont :

R_a : la rugosité arithmétique,

l_m : la longueur d'évaluation.




FIGURE 1.5 paramètres d'état de surface [13]

1.4.3 Paramètres influençant la qualité de surface

La qualité d'un usinage en fraisage est influencée par plusieurs facteurs critiques, notamment les paramètres de coupe, la rigidité de la machine, et l'état de l'outil. La vitesse de coupe, l'avance, et la profondeur de passe doivent être optimisées pour chaque matériau et chaque opération afin d'éviter les vibrations, l'usure prématurée de l'outil, et les défauts de surface. Une vitesse de coupe trop élevée ou une avance excessive peuvent entraîner des forces de coupe importantes, générant des vibrations et altérant la précision dimensionnelle ainsi que la finition de surface. La stabilité de la machine et le maintien rigide de la pièce sont également cruciaux pour minimiser les erreurs de surface et maintenir les tolérances requises. De plus, l'état de la fraise, y compris sa géométrie et son affûtage, impacte directement la qualité de l'usinage ; une fraise mal entretenue ou inadéquate peut produire des surfaces rugueuses et imprécises. L'utilisation appropriée de lubrifiants et de fluides de coupe contribue également à améliorer la qualité en réduisant l'échauffement et l'usure de l'outil. En somme, un fraisage de qualité requiert une gestion précise et équilibrée de ces paramètres pour assurer des résultats optimaux.

En d'autres termes, la qualité de surface de la pièce finale est influencée par de nombreux paramètres, comme le montre le diagramme de la FIGURE 1.6.

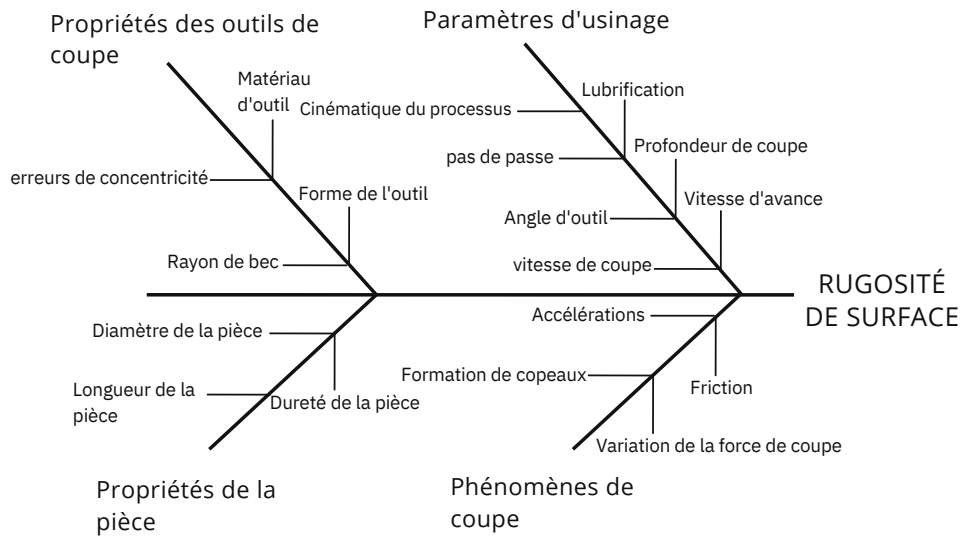


FIGURE 1.6 Paramètres influençant la rugosité de surface (Benardos Vosnaikos, 2003) [27]

1.5 L'analyse de la variance

L'analyse de la variance, également appelée ANOVA (correspondant à Analysis Of Variance en anglais) a été développée au début du XX^e siècle par Ronald Fisher, un statisticien britannique. C'est un modèle statistique qui sert à démontrer l'existence de similitudes ou différences sur des aspects précis dans une population étudiée.

Dans l'ANOVA, on étudie une variable quantitative à laquelle on attribue une ou deux variables qualitatives : les variables catégorielles.

Ces variables catégorielles sont appelées « facteurs » ou « facteurs de variabilité ». Si l'analyse de la variance se concentre sur un unique facteur on l'appelle alors analyse à un facteur ou One-way ANOVA. Si plusieurs facteurs entrent dans le test analytique, on parle alors d'analyse à deux facteurs, multifactorielle ou MANOVA pour Multivariate Analysis Of Variance.

L'ANOVA sert concrètement à mettre en lumière l'existence d'une interaction entre ces facteurs de variabilité et la variable quantitative principale étudiée, généralement une population divisée en 2 ou 3 groupes [3].

1.6 Tendances dans la modélisation et la prédiction de la rugosité

Les méthodes de prédiction de la rugosité sont classiquement catégorisées en trois approches distinctes : méthodes statistiques, méthodes basées sur l'apprentissage automatique (machine learning), et méthodes utilisant la modélisation par éléments finis.

1.6.1 Approche statistique

Une approche statistique consiste à utiliser des méthodes et des outils statistiques pour analyser et interpréter les données, en vue de décrire et de comprendre un phénomène donné. Dans notre cas, la méthode la plus appropriée serait la régression linéaire multiple.

régression linéaire multiple

Le modèle de régression linéaire multiple est l'outil statistique le plus habituellement mis en œuvre pour l'étude de données multidimensionnelles. cette technique a consisté à utiliser deux variables indépendantes ou plus pour prédire ou expliquer le résultat d'une seule variable dépendante en modélisant la relation linéaire entre elles [20].

$$Y = a + b_1X_1 + b_2X_2 + b_3X_3 + \dots + b_tX_t + u \quad (1.3)$$

Où,

Y : la variable que vous essayez de prédire (variable dépendante),

X : la variable que vous utilisez pour prédire Y (variable indépendante),

a : l'interception,

b : la pente.

pour faire l'ajustement des modèles, on se base sur la valeur du R au carré, cette mesure est importante de la bonté de l'ajustement du modèle de régression linéaire simple. La valeur R au carré varie de 0 à 1, avec des valeurs plus élevées indiquant un meilleur ajustement. La valeur R au carré représente la proportion de la variance de la variable dépendante qui s'explique par la variable indépendante [8].

Les équations suivantes décrivent comment se calcule le R carré :

$$SST = \sum_{i=1}^n (y_i - \bar{y})^2 \quad (1.4)$$

$$SSE = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 \quad (1.5)$$

$$SSR = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (1.6)$$

$$R^2 = 1 - \frac{SSR}{SST} = \frac{SSE}{SST} \quad (1.7)$$

Où :

- SST est la somme des carrés totaux, mesurant la variation totale des valeurs observées par rapport à leur moyenne.
- SSE est la somme des carrés expliqués, indiquant la variation expliquée par le modèle de régression.
- SSR est la somme des carrés résiduels, représentant la variation non expliquée par le modèle.
- R^2 est le coefficient de détermination, mesurant la proportion de la variance totale des variables dépendantes expliquée par le modèle de régression.

1.6.2 Approche de l'intelligence artificielle (Machine Learning)

Le Machine Learning est un sous-ensemble de l'intelligence artificielle (IA). Cette technologie vise à apprendre aux machines à tirer des enseignements des données et à s'améliorer avec l'expérience, au lieu d'être explicitement programmées pour le faire. Dans le Machine Learning, les algorithmes sont entraînés à trouver des patterns et des corrélations dans de grands ensembles de données, ainsi qu'à prendre les meilleures décisions et à émettre les meilleures prévisions en s'appuyant sur leur analyse. Avec la pratique, les applications du Machine Learning s'améliorent. Et plus le volume de données auxquelles elles ont accès est important, plus elles deviennent précises [19].




FIGURE 1.7 processus de machine learning [15]

a- réseaux de neurones artificiels (ANN)

Les réseaux de neurones artificiels (ANN), également connus sous le nom de réseaux neuronaux artificiels, est une méthode inspirée du comportement des neurones biologiques. Ces réseaux sont des outils statistiques fondés sur des concepts mathématiques fondamentaux, utilisés pour la modélisation et l'optimisation des processus. Cette méthode est particulièrement efficace dans les situations où des relations non linéaires sont présentes.




FIGURE 1.8 model noronal

Le réseau neuronal artificiel (ANN) le plus fréquemment utilisé dans les études est souvent un réseau feedforward, qui est entraîné à l'aide d'une variante de l'algorithme de rétropropagation. Ce type de réseau est structuré de manière à permettre le passage des informations dans une seule direction, c'est-à-dire de la couche d'entrée vers la couche de sortie, sans rétroaction, ce qui facilite la modélisation et l'apprentissage des relations entre les variables d'entrée et de sortie.

La figure 1.9 illustre une architecture typique de ces réseaux, où les neurones sont organisés en plusieurs couches distinctes, chacune ayant un rôle spécifique dans le traitement des informations. Voici une description détaillée de ces couches :

1. **La couche d'entrée** constitue le premier niveau du réseau et est responsable de l'introduction des données dans le système. Chaque neurone de cette couche représente une variable d'entrée, transmettant les valeurs des données brutes au réseau neuronal. Les neurones de la couche d'entrée n'effectuent pas de traitement mais servent simplement de points de connexion pour les données externes.

2. **La couche cachée** est située entre la couche d'entrée et la couche de sortie et joue un rôle crucial dans le traitement des informations. Elle est composée de plusieurs neurones qui effectuent des calculs internes en appliquant des fonctions d'activation aux signaux reçus de la couche précédente. Ces neurones transforment les données entrantes en une représentation intermédiaire qui est ensuite transmise à la couche suivante. L'apprentissage se produit principalement dans cette couche, où les poids des connexions sont ajustés pour minimiser l'erreur de prédiction du réseau.

3. **La couche de sortie** est la dernière couche du réseau neuronal. Elle est responsable de la production de la sortie finale du réseau. Les neurones de la couche de sortie agrègent les informations traitées par les couches précédentes et génèrent les prédictions ou les classifications finales en fonction des données d'entrée. Les résultats produits par cette couche correspondent aux réponses du réseau, telles que les classes dans une tâche de classification ou les valeurs continues dans une tâche de régression.

Le processus d'apprentissage dans un réseau feedforward utilise l'algorithme de rétropropagation, qui ajuste les poids des connexions entre les neurones en fonction des erreurs observées lors des prédictions. Ce processus itératif permet au réseau d'optimiser ses performances en minimisant l'écart entre les prédictions et les valeurs réelles. En résumé, l'architecture des réseaux feedforward, avec ses couches distinctes mais interconnectées, permet un traitement structuré des données, facilitant ainsi l'apprentissage et la modélisation des relations complexes dans divers contextes d'application.




FIGURE 1.9 Procédure d'apprentissage supervisé d'un réseau feedforward typique

b- Apprentissage profond

Ce type de Machine Learning est aussi appelé « deep learning », car il inclut de nombreuses couches du réseau de neurones artificiels et d'énormes volumes de données complexes et disparates.

Dans l'apprentissage profond, le système interagit avec plusieurs couches du réseau. Il en extrait des sorties d'un niveau de plus en plus détaillé.

Par exemple, un système d'apprentissage profond qui traite des images de la nature et recherche des marguerites jaunes va, dans la première couche, reconnaître une plante. Au fur et à mesure qu'il va avancer dans les couches, il va ensuite identifier une fleur, puis une marguerite, et enfin une marguerite jaune. Parmi les exemples d'applications d'apprentissage profond, citons la reconnaissance de discours, la classification d'images ou encore l'analyse pharmaceutique.




FIGURE 1.10 Apprentissage Profond par Réseau de Neurones [17]

c- Arbre de décision

Un arbre de décision est un schéma représentant les résultats possibles d'une série de choix interconnectés. Il permet à une personne ou une organisation d'évaluer différentes actions possibles en fonction de leur coût, leur probabilité et leurs bénéfices. Il peut être utilisé pour alimenter une discussion informelle ou pour générer un algorithme qui détermine le meilleur choix de façon mathématique [18].

Prenons l'exemple du risque d'avoir un accident cardio-vasculaire. Dans un arbre de décision, on pose des questions. On descend dans l'arbre jusqu'à obtenir la réponse "peu de risque" ou "grand risque". La figure 1.11 donne un exemple d'un arbre de décision. Il y a deux attributs : l'âge et le fait que la personne soit fumeuse. On pose d'abord la question de l'âge. Si on a moins de 30 ans, il y a peu de risque. Si on a plus de 30 ans, on pose la question si la personne est fumeuse. Si non, peu de risque. Si oui, le risque est grand [4].




FIGURE 1.11 Exemple d'un arbre de décision

d- forêt aléatoire

forêt aléatoire ou Random Forest est ce qu'on appelle une méthode d'ensemble (ou ensemble method en anglais) c'est-à-dire qu'elle « met ensemble » ou combine des résultats pour obtenir un super résultat final de différents arbres de décision qui la composent [23].

les forêts aléatoires peuvent être composées de plusieurs dizaines voire centaines d'arbres, le nombre d'arbre est un paramètre que l'on ajuste généralement par validation croisée (ou cross-validation en anglais). Pour faire court, la validation croisée est une technique d'évaluation d'un algorithme de Machine Learning consistant à entraîner et tester le modèle sur des morceaux du dataset de départ [23].

Chaque arbre est entraîné sur un sous-ensemble du dataset et donne un résultat puis ses résultats de tous les arbres de décision sont combinés pour donner une réponse finale [23].

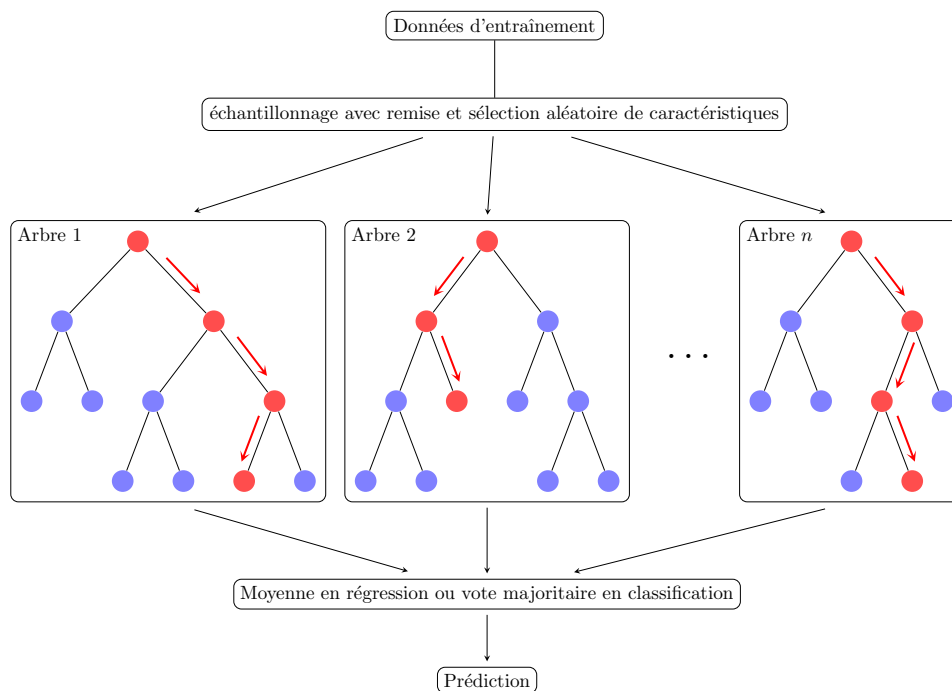


FIGURE 1.12 Schéma de l'algorithme de la forêt aléatoire (Breiman 2001) [21]

e- Arbre boosté par gradient

L'arbre boosté par gradient est un algorithme de boosting dont l'objectif est d'entraîner une forêt d'arbre de manière séquentielle afin que chaque nouvel arbre compense les faiblesses de la forêt [26].

Cette fois l'algorithme se concentre sur les résidus des précédents arbres plutôt que sur les poids des exemples [26].

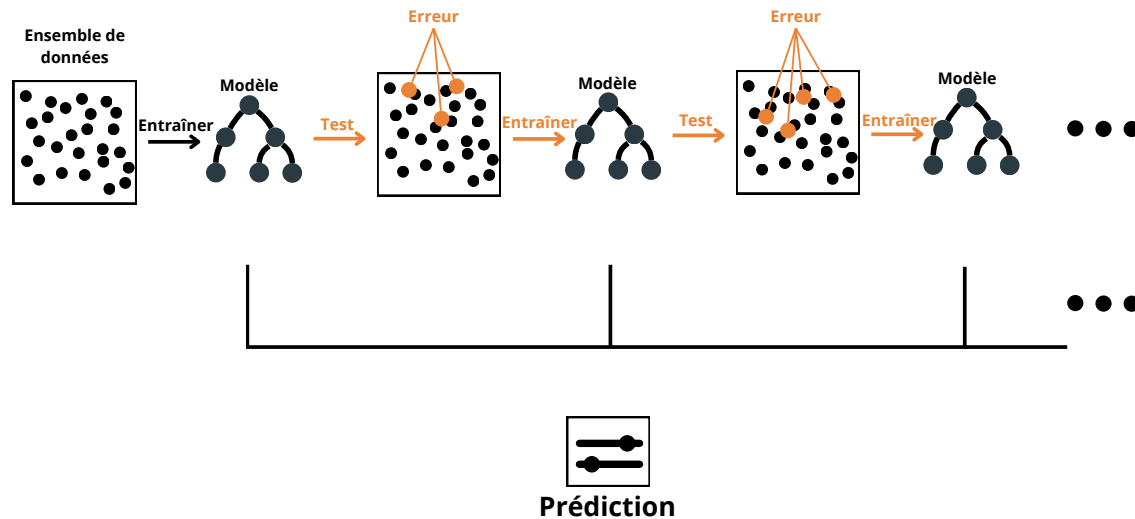


FIGURE 1.13 Schéma Arbre boosté par gradient [12]

1.6.3 Approche par éléments finis

La modélisation par éléments finis est une méthode de calcul utilisée en ingénierie pour résoudre des problèmes complexes de dynamique des structures ou des fluides en les divisant en plus petites parties ou éléments, et en prédisant les comportements sous des charges inconnues à l'aide du calcul et de l'algèbre matricielle [10].

1.7 Conclusion

ce chapitre a abordé divers aspects liés au fraisage, à l'aluminium et à la qualité de surface, ainsi que les tendances actuelles dans la modélisation et la prédiction de la rugosité. Nous avons examiné la définition du fraisage, les angles de l'outil coupant, la cinématique de l'outil de coupe et l'usinage sur le flanc, ainsi que la classification et l'importance des alliages d'aluminium. De plus, nous avons discuté des principaux défauts de surface, des paramètres caractéristiques d'état de surface et des facteurs influençant la qualité de surface. Enfin, nous avons exploré les tendances émergentes dans la modélisation et la prédiction de la rugosité, en mettant en évidence l'importance croissante de la méthodologie de la surface de réponse et de l'approche de l'intelligence artificielle dans ce domaine.

Ces avancées offrent des perspectives prometteuses pour améliorer la précision et l'efficacité des processus de fabrication.

Chapitre 2

Mise en Œuvre Expérimentale : Moyens et Méthodes

2.1 INTRODUCTION

Les ressources mobilisées et le déroulement de nos expérimentations sont présentés dans cette section. L'objectif principal de notre étude est de mesurer la rugosité des surfaces générées lors du processus de fraisage à sec sur le flanc. Nous débuterons par une description des équipements utilisés pour la réalisation des essais.

Ensuite, nous exposerons les différentes méthodes employées pour la planification et la mise en œuvre de nos expériences. Il est important de souligner que l'ensemble de nos expérimentations a été mené au sein du Hall de Technologie de l'Université de Bejaia, où nous avons bénéficié d'un accès à des installations et à un environnement favorables à la recherche.

2.2 MOYENS UTILISES

2.2.1 Machines-outils

Les expériences ont été menées sur un centre d'usinage neuf hyundai WIA KF 4600 II équipé d'une commande numérique FANUC i Series, une machine outils utilisé pour réaliser des opérations de fraisage, de perçage et d'alésage. Ce type de machine permet l'automatisation de processus grâce à des commandes numériques, ce qui améliore l'efficacité et la reproductibilité des opérations.




FIGURE 2.1 Centre d'usinage utilisé pendant les tests

2.2.2 Pièce d'aluminium

Pour déterminer la classe spécifique de l'aluminium analysé, nous nous sommes principalement basés sur les normes et spécifications des alliages d'aluminium. Les pourcentages élevés de silicium (0,8952 %) et de magnésium (0,8537%), ainsi que la présence notable de cuivre (0,5622%) et de fer (0,5439 %), suggèrent que cet aluminium appartient à la série 6000, laquelle comprend les alliages aluminium-magnésium-silicium. Cette série est connue pour ses compositions adaptées aux applications nécessitant une combinaison de résistance mécanique et de facilité de soudabilité.




FIGURE 2.2 Pièce en alliage d'aluminium de la série 6000 utilisée pour les tests

Les résultats ont été obtenus à l'aide du spectromètre Metavision-1008i qui est un instrument spécialisé utilisé pour l'analyse spectrométrique des métaux. Il utilise la technologie d'émission optique pour mesurer précisément les concentrations en éléments métalliques tels que le silicium, le magnésium, le cuivre, le fer, et d'autres. Cet appareil est largement utilisé dans divers domaines scientifiques et industriels pour ses capacités à fournir des résultats fiables et précis concernant la composition des matériaux métalliques.




FIGURE 2.3 analyse chimique Metavision-1008i

Pour des informations supplémentaires concernant notre matériau, nous évaluons sa dureté à l'aide d'un duromètre équipé d'un indenteur en forme de pyramide carrée en diamant. Les mesures de dureté Vickers (HV) obtenues sont les suivantes : 244,91 HV, 174,72 HV, 121,44 HV, 150,95 HV, et 168,91 HV. Une force de 0,5 HV a été appliquée pour ces mesures. La moyenne de ces mesures est calculée pour fournir une estimation de la dureté du matériau.

TABLE 2.1 Mesures de dureté Vickers et moyenne calculée

Mesure	Dureté Vickers (HV)
1	244,91
2	174,72
3	121,44
4	150,95
5	168,91
Moyenne	172,99

$$\text{Moyenne} = \frac{244,91 + 174,72 + 121,44 + 150,95 + 168,91}{5} = 172,986\text{HV}$$

La moyenne des valeurs mesurées est donc de 172,99 HV.




FIGURE 2.4 Duromètre Brinell FALCON 400G2

2.2.3 Fraise utilisée

Dans le cadre de notre étude, nous utilisons une fraise couramment répandue sur le marché et fréquemment employée par les industriels. Conçue pour le fraisage général de divers matériaux, notamment l'aluminium, le laiton, le bronze, le fer et l'acier, cette fraise est largement adoptée dans de nombreuses applications industrielles en raison de sa polyvalence et de son efficacité.

Elle se caractérise par un diamètre de 16 mm et quatre dents. Il s'agit d'une fraise monobloc fabriquée en acier rapide supérieur, réputée pour sa résistance à l'usure et sa capacité à maintenir des performances de coupe optimales, même dans des environnements de travail exigeants.




FIGURE 2.5 Shema Technique de la fraise [16]

2.2.4 Rugosimètre

Un rugosimètre est un appareil utilisé pour mesurer la rugosité de la surface d'un matériau. Voici un aperçu de son fonctionnement et des principaux composants impliqués :

1. **Palpeur ou Stylet :** Le rugosimètre est équipé d'un stylet ou palpeur, généralement doté d'une pointe en diamant ou en rubis. Cette pointe entre en contact avec la surface à mesurer.
2. **Déplacement du Stylet :** Le stylet est déplacé sur la surface de l'échantillon le long d'une trajectoire prédéfinie.
3. **Conversion en Signaux Électriques :** Les mouvements du stylet sont convertis en signaux électriques par un transducteur intégré. Ces signaux représentent les variations de hauteur de la surface mesurée.
4. **Analyse des Données :** Les signaux électriques sont traités par un microprocesseur qui analyse les variations pour calculer les paramètres de rugosité. Les paramètres couramment mesurés incluent R_a (rugosité moyenne arithmétique), R_z (profondeur totale de rugosité), et R_q (rugosité quadratique moyenne).
5. **Affichage des Résultats :** Les résultats sont affichés sur un écran numérique ou analogique intégré au rugosimètre. Certains modèles permettent également de transférer les données vers un ordinateur pour une analyse plus approfondie.

Pour notre mesure de la rugosité arithmétique R_a , nous utilisons le rugosimètre portable LiteSURF. Dernier-né des rugosimètres fabriqués par SM Instruments, le LiteSURF est un appareil portatif pour la mesure des états de surface qui répond aux exigences de l'industrie et qui bénéficie des dernières technologies.




FIGURE 2.6 Rugosimètre LiteSURF

2.3 Planification des expériences

Le processus d'usinage peut être influencé par une multitude de facteurs, notamment les paramètres du régime de coupe (V_c , f_z et a_p), la géométrie de la partie active de l'outil (r , α , β , γ , ε_r , κ_r , etc.), ainsi que les conditions environnementales (rigidité de la machine, lubrification) et le mode d'usinage. Tous ces éléments peuvent être considérés comme des variables d'entrée du système d'usinage. En revanche, les efforts de coupe, la durabilité de l'outil, la rugosité de surface et la température de coupe représentent les variables de sortie. Bien qu'il existe de nombreux aspects dignes d'être abordés, notre attention se concentre principalement sur l'une en particulier : l'évolution de la rugosité de surface en fonction des paramètres (V_c , f_z et a_p).

Les essais peuvent être effectués selon deux méthodes de conception expérimentale : la méthode unifactorielle, la méthode multifactorielle ou les deux simultanément. Pour notre étude, nous avons restreint notre analyse à la méthode de conception expérimentale multifactorielle. [24]

2.3.1 Méthode multifactorielle

Cette méthode permet de structurer et d'effectuer les expérimentations de manière optimale afin de déterminer des modèles mathématiques capables de simuler les processus des systèmes complexes. Qu'ils soient mono-objectifs ou multi-objectifs, le nombre d'essais requis ainsi que la méthode de traitement peuvent varier.

Dans le cadre de cette étude Pour déterminer le nombre nécessaire d’essais, nous appliquons une formule spécifique.

Ce nombre dépend du facteur de base, qui est une variable d’entrée, ainsi que du nombre de niveaux de variation de ce facteur. En utilisant cette méthode, nous pouvons rationaliser nos expérimentations et obtenir des données significatives pour développer des modèles précis.

$$N = q^k \tag{2.1}$$

où :

- N : nombre d’essais ;
- q : nombre de niveaux de variation du facteur de base ;
- k : nombre de facteurs de base.

Dans le cadre de cette étude, nous avons :

2.3.2 La Rugosité

Dans cette étude, nous avons trois facteurs de base (avec $k = 3$), et chaque facteur possède trois niveaux de variation (un niveau supérieur (+1), un niveau moyen (0) et un niveau inférieur (-1)). Par conséquent, nous obtenons $N = 3^3 = 27$ essais au total.

Ces essais sont numérotés de 1 à 27. Les différentes combinaisons des facteurs de base (exprimées en valeurs codées ou réelles), qui représentent les différents régimes de coupe, sont fournies dans la matrice de planification.

Remarque : Les valeurs de V_c , F_z et A_p utilisées correspondent aux conditions de coupe de l’aluminium généralement adoptées par les industriels. Cette étude a été entreprise en réponse directe aux besoins opérationnels de l’industrie manufacturière.

TABLE 2.2 Tableau des Niveaux de variation des facteurs

Niveau de facteur	Valeur naturelle du facteur V_c (m/min)	Valeur naturelle du facteur F_z (mm/dents)	Valeur naturelle du facteur A_p (m/min)
Niveau supérieur (+1)	Valeur maximal	Valeur maximal	Valeur maximal
Niveau Moyen (0)	Valeur moyenne	Valeur moyenne	Valeur moyenne
Niveau Inferieur(-1)	Valeur minimal	Valeur minimal	Valeur minimal

TABLE 2.3 Matrice de planification par la méthode multifactorielle

Numéro de l'essai	Valeur codée X1	Valeur codée X2	Valeur codée X3	Valeur réelle vc	Valeur réelle ap	Valeur réelle fz
1	-1	-1	-1	200	0,5	0,08
2	-1	-1	0	200	0,5	0,12
3	-1	-1	1	200	0,5	0,16
4	-1	0	-1	200	1	0,08
5	-1	0	0	200	1	0,12
6	-1	0	1	200	1	0,16
7	-1	1	-1	200	2	0,08
8	-1	1	0	200	2	0,12
9	-1	1	1	200	2	0,16
10	0	-1	-1	300	0,5	0,08
11	0	-1	0	300	0,5	0,12
12	0	-1	1	300	0,5	0,16
13	0	0	-1	300	1	0,08
14	0	0	0	300	1	0,12
15	0	0	1	300	1	0,16
16	0	1	-1	300	2	0,08
17	0	1	0	300	2	0,12
18	0	1	1	300	2	0,16
19	0	-1	-1	400	0,5	0,08
20	1	-1	0	400	0,5	0,12
21	1	-1	1	400	0,5	0,16
22	1	0	-1	400	1	0,08
23	1	0	0	400	1	0,12
24	1	0	1	400	1	0,16
25	1	1	-1	400	2	0,08
26	1	1	0	400	2	0,12
27	1	1	1	400	2	0,16

2.4 Expérience

L'étude expérimentale menée visait à évaluer la rugosité de surfaces usinées, une caractéristique cruciale dans de nombreux processus industriels. Pour ce faire, une méthodologie rigoureuse a été adoptée, alliant précision et cohérence dans chaque étape du processus. Les détails de cette démarche sont présentés ci-dessous :

Étapes

1. **Préparation du brut** : La démarche expérimentale a débuté par une phase préparatoire méticuleuse, consacrée à la manipulation soignée du brut. Cette étape visait à façonner le matériau avec précision, afin d'obtenir la forme désirée pour une fixation optimale lors des opérations ultérieures.
2. **Serrage de la pièce** : Ensuite, la pièce a été fixée sur un étau avec une précision minutieuse, en veillant à maintenir un niveau de serrage uniforme à chaque itération.
3. **Stabilité de l'outil** : Il est à noter que l'outil utilisé est resté fixé au porte-outil tout au long du processus, évitant ainsi toute perturbation susceptible d'introduire des variations dans les résultats.
4. **Mesure de la rugosité** : Une fois la pièce solidement fixée, elle a été retirée délicatement de l'étau pour permettre une évaluation méticuleuse de sa rugosité.




FIGURE 2.7 Mesure longitudinale de la rugosité

La figure illustre le positionnement du rugosimètre par rapport à la pièce, où cette dernière est disposée transversalement par rapport à l'instrument.




FIGURE 2.8 Mesure transversale de la rugosité

La figure illustre le positionnement du rugosimètre par rapport à la pièce, où cette dernière est disposée longitudinalement par rapport à l'instrument.

5. **Évaluations transversales et longitudinales** : Six évaluations de rugosité ont été réalisées au total, comprenant trois mesures dans le sens transversal et trois dans le sens longitudinal.
6. **Minutie des mesures** : Chaque mesure a été effectuée avec une grande minutie afin de garantir des données précises et fiables.
7. **Répétition du protocole** : Ce processus rigoureux a été répété pour chaque échantillon, assurant ainsi la cohérence et la robustesse des résultats obtenus.

Cette méthodologie a permis d'obtenir des données pertinentes pour l'analyse de la rugosité des surfaces usinées, contribuant ainsi à une meilleure compréhension des processus industriels impliqués.

TABLE 2.4 Les image des différente étapes de l'expérimentation

Étapes	Photo de l'étape
<p><i>Préparation du brut</i></p>	
<p><i>Montage de la nouvelle fraise pour les test</i></p>	
<p><i>Usinage</i></p>	
<p><i>Mesure de la rugosité</i></p>	

2.5 Conclusion

Nous avons examiné les divers moyens utilisés pour élaborer le plan d'expérience, ainsi que la méthodologie mise en œuvre pour l'expérimentation.

L'élaboration du plan d'expérience s'est basée sur une approche méthodique intégrant les principes de la conception expérimentale.

Pour la réalisation des expériences, nous avons suivi un protocole strict afin de garantir la reproductibilité et la précision des mesures. Les conditions expérimentales sont minutieusement contrôlées et documentées, incluant des paramètres tels que la vitesse de coupe, l'avance, et la profondeur de passe.

Les résultats expérimentaux sont collectés selon un plan préétabli et sont soumis à une analyse approfondie à l'aide de méthodes statistiques et d'outils de traitement des données avancés. L'analyse détaillée de ces données est développée dans les chapitres subséquents.

Chapitre 3

l'influence des paramètres de coupe et modélisation par régression multiple

3.1 Introduction

L'étude approfondie des paramètres de coupe est essentielle pour améliorer la précision et la qualité des processus de fabrication. Cette thèse se concentre sur l'analyse de l'influence de trois paramètres clés de coupe : la vitesse de coupe (V_c), l'avance par dent (f_z) et la profondeur de passe (a_p), sur les caractéristiques de surface telles que la rugosité longitudinale ($R_a L$) et transversale ($R_a T$).

L'approche méthodologique adoptée repose sur l'utilisation de l'analyse de variance (ANOVA) pour évaluer l'influence de chaque facteur de coupe sur la rugosité de surface. En parallèle, la modélisation par régression multiple a été employée comme technique statistique puissante pour quantifier de manière précise les relations entre les paramètres de coupe et les résultats de rugosité. Les approches méthodologiques adoptées pour cette étude ont été préalablement validées et vérifiées conformément à la thèse d'Abdel-Ali – Selaïmia, intitulée "Étude de l'usinage des aciers inoxydables lors du fraisage de face". Cette validation assure la robustesse et la pertinence de nos analyses dans le cadre de notre propre investigation.

3.2 Influence des condition de coupe sur la rugosité

Les conditions de coupe, telles que la vitesse de coupe, l'avance et la profondeur de passe, ont un impact significatif sur la rugosité de surface lors des opérations d'usinage. Une maîtrise précise de ces paramètres est essentielle pour obtenir des surfaces voulue.

3.2.1 Observations durant l'usinage

Dans cette section, nous présentons les observations directes réalisées lors des opérations d'usinage. Celles-ci incluent des observations sur la distance entre les stries présente sur la surface usiner, la forme des copeaux, leur trajectoire, ainsi que l'impact sur la rugosité. L'examen de ces informations vise à approfondir notre compréhension des relations entre les conditions de coupe et les résultats visuels obtenus.

21	←	Numéro de l'essai
400	←	Vitesse de coupe
0,16	←	Avence
0,5	←	Profondeur de passe
1,58	←	Rugosité arithmétique longitudinale
1,89	←	Rugosité arithmétique transversale

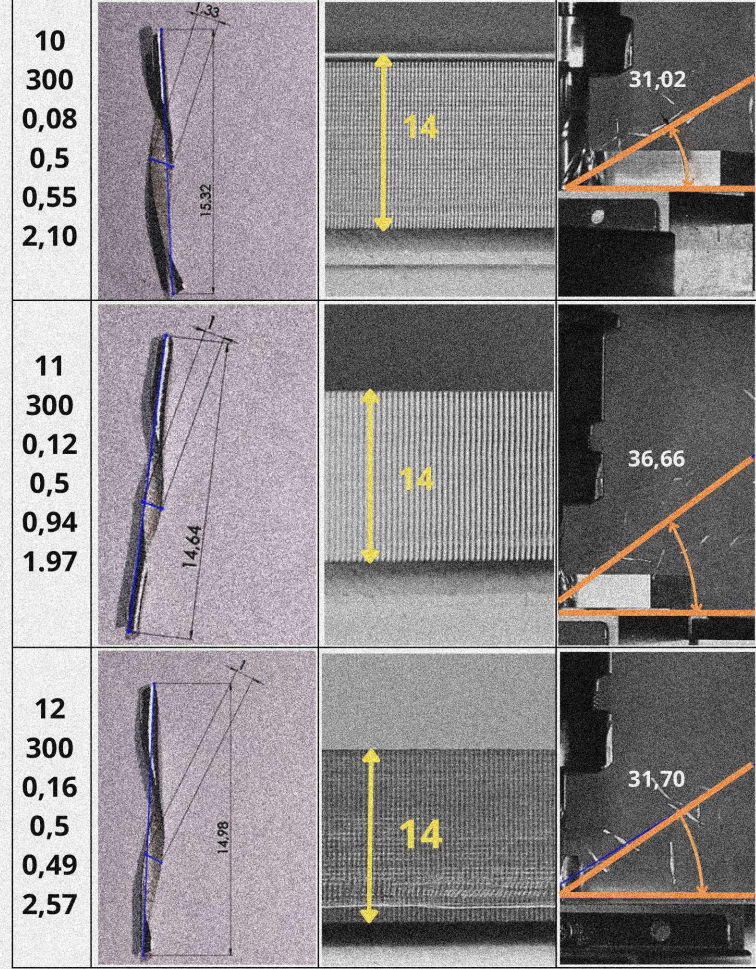

FIGURE 3.1 Interprétation des valeurs de la première colonne



Les valeurs en jaune représentent la largeur de la pièce usinée, exprimée en millimètres (mm). Les valeurs en blanc indiquent les angles de projection, mesurés en degrés (°)



Les photographies que vous avez devant les yeux ont été réalisées à l'aide d'un appareil photo Canon EOS 7D. Cet appareil, réputé pour sa capacité à capturer des images de haute résolution. Grâce à ses capacités avancées, il est possible de prendre des clichés où la fraise apparaît statique, bien qu'elle soit en réalité en rotation à des vitesses extrêmement élevées. Cette fonctionnalité est particulièrement précieuse dans le cadre de notre étude, car elle nous permet de visualiser et d'analyser les effets des conditions de coupe sur la surface de la pièce avec une clarté exceptionnelle. L'utilisation de cet équipement photographique sophistiqué contribue de manière significative à la précision et à la rigueur de nos observations expérimentales.

	copeaux	Etat de surface	
1 200 0,08 0,5 0,54 1,91			
2 200 0,12 0,5 1,08 0,87			
3 200 0,16 0,5 0,51 2			

4 200 0,08 1 0,54 1,28			
5 200 0,12 1 0,87 1,33			
6 200 0,16 1 0,86 0,98			











FIGURE 3.2 Photos prises durant les tests et un histogrammes des valeur de La rugosité longitudinale $R_a L$ et la rugosité transversale $R_a T$

3.2.2 Observations au Cours du Processus d'Usinage

- a. **Avance (f_z)** : Lors de nos expériences, nous observons que l'augmentation de l'avance par dent, passant de 0,08 mm/dent à 0,16 mm/dent, augmente directement la distance entre les stries sur l'état de surface usiné et évidemment, une diminution de l'avance par dent tendrait à réduire cette distance entre les stries.
- b. **Vitesse de Coupe (V_c)** : La vitesse de coupe influence l'angle de projection des copeaux. Nos observations montrent que des vitesses de coupe plus élevées (300 et 400 m/min) produisent généralement des copeaux projetés à des hauteurs intermédiaires ou moyennes. À une vitesse de coupe de 200 m/min, la trajectoire des copeaux est plus variable, avec une tendance à une projection haute lorsque l'avance est faible ou intermédiaire.
- c. **Profondeur de Passe (a_p)** : La profondeur de passe joue un rôle crucial dans la forme et la taille des copeaux. Nos résultats indiquent que pour une profondeur de passe de 0,5 mm, les copeaux tendent à avoir une taille relativement constante. En revanche, une profondeur de passe plus élevée, comme 2 mm, conduit à la formation de copeaux de tailles hétérogènes. Cela suggère que des profondeurs de passe plus grandes augmentent la variabilité dans la forme des copeaux, ce qui pourrait influencer la qualité de la surface usinée et la stabilité du processus d'usinage.

Les résultats de cette étude démontrent que chaque paramètre de coupe a une influence différente sur la projection, la distance entre deux stries successives et la forme des copeaux. La distance entre les stries successives est déterminée par l'avance (f_z), tandis que l'angle de projection des copeaux est influencé par la vitesse de coupe (V_c), et que la taille et la forme des copeaux sont influencées par la profondeur de passe (a_p). Ces résultats offrent une meilleure compréhension des interactions entre les paramètres de coupe et leurs impacts sur le processus d'usinage.

3.2.3 Analyse de l'Histogramme

L'histogramme présenté illustre les valeurs de deux séries de données :

- " R_a L" : Rugosité Arithmétique Longitudinale (en rouge)
- " R_a T" : Rugosité Arithmétique Transversale (en orange)

Analyse de la Série " R_a L" (Rouge) :

Dispersion : Les valeurs de la rugosité arithmétique longitudinale (" R_a L") sont réparties de manière relativement uniforme à travers les 27 catégories. Il n'y a pas de concentration notable dans une zone spécifique.

Amplitude : L'amplitude des valeurs de " R_a L" semble moins prononcée comparée à celle de la rugosité arithmétique transversale. Les écarts entre les valeurs sont plus réduits.

Tendance : Aucune tendance claire n'est observée dans les valeurs de " R_a L". Les fluctuations d'une catégorie à l'autre semblent aléatoires et sans motif apparent.

Analyse de la Série " R_a T" (Orange) :

Dispersion : Les valeurs de la rugosité arithmétique transversale (" R_a T") sont également dispersées, mais tendent à être plus élevées par rapport à " R_a L". Cette série montre une variation plus importante dans les valeurs observées.

Amplitude : L'amplitude des valeurs de " R_a T" est plus marquée que celle de " R_a L", avec des écarts plus importants entre les valeurs extrêmes.

Tendance : Il pourrait y avoir une légère tendance à la hausse dans les valeurs de " R_a T" à travers les catégories. Cependant, cette tendance nécessite une analyse statistique plus approfondie pour confirmer sa validité.

3.2.4 Analyse des Résultats expérimentaux

Pour mieux analyser les influences spécifiques des paramètres de coupe sur la rugosité, nous avons séparé les résultats en deux tableaux distincts : l'un pour R_a L (rugosité longitudinale) et l'autre pour R_a T (rugosité transversale). Cette distinction permet une lecture plus claire et une interprétation plus précise des données.

a- Analyse des résultats expérimentaux pour R_a L

Le tableau et le graphique 4D présentent les valeurs expérimentales de la rugosité R_a longitudinale, Ces données ont été recueillies à partir des différentes configurations des paramètres de coupe, selon un plan d'expérience établi par Taguchi (L_{27}), lors de l'opération de fraisage sur le flanc.

TABLE 3.1 Tableau croisé des variables (R_a L)

Essai	V_c (m/min)	f_z (mm/dents)	a_p (mm)	R_a L (μm)
1	200	0,08	0,5	0,55
2	200	0,12	0,5	1,09
3	200	0,16	0,5	0,51
4	200	0,08	1	0,54
5	200	0,12	1	0,87
6	200	0,16	1	0,86
7	200	0,08	2	0,43
8	200	0,12	2	0,98
9	200	0,16	2	0,82
10	300	0,08	0,5	0,55
11	300	0,12	0,5	0,94
12	300	0,16	0,5	0,49
13	300	0,08	1	0,42
14	300	0,12	1	0,93
15	300	0,16	1	1,85
16	300	0,08	2	0,74
17	300	0,12	2	1,21
18	300	0,16	2	1,13
19	400	0,08	0,5	0,45
20	400	0,12	0,5	0,99
21	400	0,16	0,5	1,59
22	400	0,08	1	0,48
23	400	0,12	1	1,15
24	400	0,16	1	1,76
25	400	0,08	2	0,77
26	400	0,12	2	0,84
27	400	0,16	2	0,76

La visualisation sous forme de graphique 4D offre une vue complète et précise, aidant l'analyse des des interactions entre les paramètres de coupe. et cela grâce a l'observation de ces relations de manière tridimensionnelle avec une échelle de couleur représentant la rugosité.

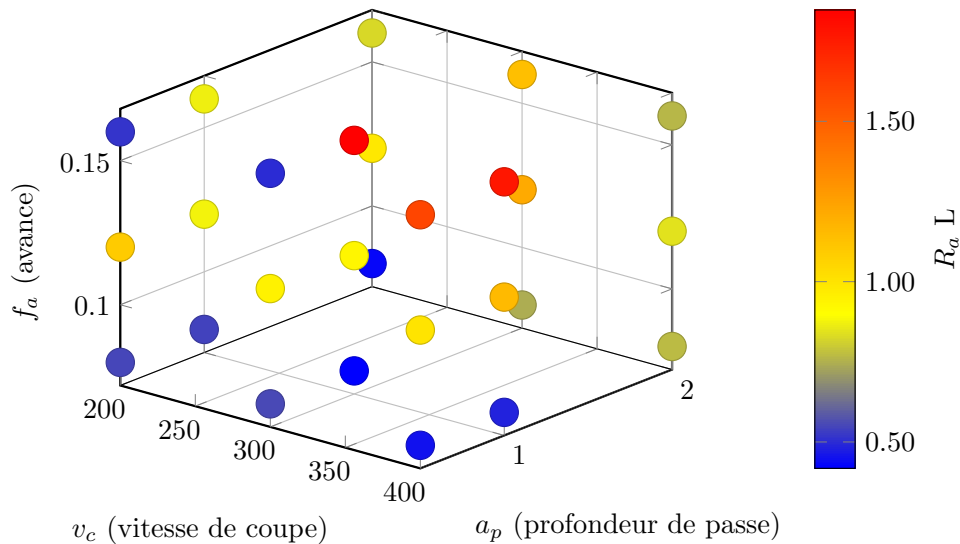


FIGURE 3.3 Graphique $R_a L$

Le graphique 4D illustre la relation entre la vitesse de coupe (V_c), la profondeur de passe (a_p), l'avancée (f_z) et la rugosité longitudinale ($R_a L$). Certaines combinaisons de vitesse de coupe, d'avance, et de profondeur de passe permettent d'obtenir une rugosité plus faible ou plus élevée.

Observations

- Rugosité faible (en bleu) :

Des vitesses de coupe plus élevées et des avances réduites tendent à produire des rugosités plus faibles.

- Rugosité élevée (en rouge) :

D'autres combinaisons de paramètres, telles qu'une avance plus élevée combinée à une vitesse de coupe plus faible, augmentent la rugosité de surface.

- L'effet de la profondeur de passe (a_p) est plus nuancé et nécessite une analyse approfondie, qui sera abordée dans la suite du chapitre.

b- Analyse des résultats expérimentaux pour R_a T

Le tableau et le graphique 4D présentent les valeurs expérimentales de la rugosité R_a transversale, Ces données ont été recueillies à partir des différentes configurations des paramètres de coupe, selon un plan d'expérience établi par Taguchi ($L27$), lors de l'opération de fraisage sur le flanc.

TABLE 3.2 Tableau croisé des variables (R_a T)

cyan Essai	V_c (m/min)	f_z (mm/dents)	a_p (mm)	R_a T (μm)
1	200	0,08	0,5	1,91
2	200	0,12	0,5	0,87
3	200	0,16	0,5	2,01
4	200	0,08	1	1,29
5	200	0,12	1	1,34
6	200	0,16	1	0,99
7	200	0,08	2	1,07
8	200	0,12	2	1,18
9	200	0,16	2	1,34
10	300	0,08	0,5	2,10
11	300	0,12	0,5	1,97
12	300	0,16	0,5	2,58
13	300	0,08	1	2,08
14	300	0,12	1	1,83
15	300	0,16	1	2,37
16	300	0,08	2	2,25
17	300	0,12	2	1,58
18	300	0,16	2	2,41
19	400	0,08	0,5	2,66
20	400	0,12	0,5	2,33
21	400	0,16	0,5	1,90
22	400	0,08	1	2,31
23	400	0,12	1	2,00
24	400	0,16	1	2,17
25	400	0,08	2	2,06
26	400	0,12	2	1,88
27	400	0,16	2	1,99

La visualisation sous forme de graphique 4D offre une vue complète et précise, aidant l'analyse des interactions entre les paramètres de coupe. et cela grâce à l'observation de ces relations de manière tridimensionnelle avec une échelle de couleur représentant la rugosité.




FIGURE 3.4 Graphique $R_a T$

Le graphique 4D illustre la variation de la rugosité transversale ($R_a T$) en fonction de la vitesse de coupe (V_c), de la profondeur de passe (a_p) et de l'avancée (f_z) lors du processus de fraisage.

Observations

- **Faible rugosité (en bleu)** : Certaines combinaisons de paramètres conduisent à des valeurs de R_a plus faibles. Par exemple, une avance plus élevée combinée à une vitesse de coupe plus faible tend à réduire la rugosité transversale.

- **Rugosité élevée (en rouge)** : Les régions en rouge montrent des combinaisons de paramètres qui augmentent la rugosité transversale. Par exemple, des vitesses de coupe plus élevées avec des avances plus faibles sont souvent associées à une rugosité transversale plus importante.

3.2.5 Quantification de l'influence relative de chaque facteur

La mesure de l'impact relatif de chaque élément est une étape cruciale dans l'étude des systèmes complexes. Son utilisation permet de mesurer de manière précise l'influence individuelle de chaque variable sur le résultat total. Afin d'accomplir cela, nous avons employé la technique ANOVA (Analyse de Variance). Le logiciel Minitab a été utilisé pour la réalisation des calculs. pour mieux comprendre les tableau qui vont suivre voici

comment les Calcul de l'ANOVA et des Composantes de la Variance ce font

Calcul de la Statistique F

Les tests F sont nommés d'après sa statistique, F du test, qui a été nommé en l'honneur de Sir Ronald Fisher. La statistique F est simplement un ratio de deux écart-types. Les écart-types sont une mesure de dispersion, ou dans quelle mesure les données sont dispersées de la moyenne. De plus grandes valeurs représentent une plus grande dispersion [6].

- **Somme des Carrés Entre (SCG) :**

$$SCG = \sum_{j=1}^k n_j (\bar{Y}_j - \bar{Y})^2 \quad (3.1)$$

où n_j est le nombre d'observations dans le groupe j , \bar{Y}_j est la moyenne du groupe j , et \bar{Y} est la moyenne globale de toutes les observations.

- **Somme des Carrés à l'Intérieur (SCE) :**

$$SCE = \sum_{j=1}^k \sum_{i=1}^{n_j} (Y_{ij} - \bar{Y}_j)^2 \quad (3.2)$$

où Y_{ij} est l'observation individuelle dans le groupe j , et \bar{Y}_j est la moyenne du groupe j .

- **Statistique F :**

$$F = \frac{SCG / (k - 1)}{SCE / (N - k)} \quad (3.3)$$

La statistique F compare la variance expliquée entre les groupes à la variance non expliquée à l'intérieur des groupes.

Construction du Tableau des Composantes de la Variance

Pour construire le tableau des composantes de la variance :

- Identifiez et détaillez les différentes composantes de la variance, telles que SCG et SCE.
- Calculez le pourcentage de variance expliquée par chaque composante :

$$\% \text{ Variance Expliquée} = \left(\frac{\text{Somme des Carrés de la Composante}}{\text{Somme des Carrés Totale (SCT)}} \right) \times 100 \quad (3.4)$$

où SCT est la somme des carrés totale, calculée comme suit :

$$SCT = SCG + SCE \quad (3.5)$$

Étapes supplémentaires pour le calcul de la p-value en ANOVA :**1. Calcul de la somme des carrés totale (SCT) :**

$$SCT = \sum_{i=1}^N (Y_i - \bar{Y})^2 \quad (3.6)$$

où Y_i sont les valeurs observées, \bar{Y} est la moyenne globale et N est le nombre total d'observations.

2. Calcul des degrés de liberté :

- DDL entre les groupes : $k - 1$
- DDL résiduels : $N - k$
- DDL totaux : $N - 1$

3. Calcul du Carré Moyen entre les groupes (Cm) :

$$Cm = \frac{SCG}{k - 1} \quad (3.7)$$

4. Calcul de la statistique F :

$$F = \frac{Cm}{Cmr} \quad (3.8)$$

5. Calcul de la p-value : La p-value est déterminée en comparant la valeur de F calculée avec une distribution de F sous l'hypothèse nulle. Elle peut être obtenue à partir d'une table de distribution de F ou en utilisant des logiciels statistiques.

a- Analyse de la variance pour moyen R_a L

Pour l'ANOVA du moyen R_a L, nous avons les sources de variation " V_c ", " f_z ", et " a_p ", ainsi que les valeurs de leurs degrés de liberté (DL), sommes des carrés, carrés moyens (CM), valeurs F et p-values (P).

TABLE 3.3 Analyse de la variance pour moyen R_a L

Source	DL	Somme des carrés	CM	F	P
V_c	2	0,2761	0,1380	0,442	0,662
f_z	6	1,8751	0,3125	3,119	0,028
a_p	18	1,8037	0,1002	-	-
Total	26	3,9548	-	-	-

L'analyse des résultats révèle les points suivants :

- V_c (**Vitesse de coupe**) :
 - **Somme des carrés** : 0,2761
 - **Carré moyen (CM)** : 0,1380
 - **F** : 0,442
 - **P-value** : 0,662
 - **Interprétation** : La source " V_c " n'a pas un effet significatif sur la variance totale du moyen R_a L, comme l'indique la p-value de 0,662 (qui est bien supérieure au seuil de 0,05).
- f_z (**Avancée**) :
 - **Somme des carrés** : 1,8751
 - **Carré moyen (CM)** : 0,3125
 - **F** : 3,119
 - **P-value** : 0,028
 - **Interprétation** : La source " f_z " a un effet significatif sur la variance totale du moyen R_a L, avec une p-value de 0,028, inférieure au seuil de 0,05. Cela indique que les variations dues à " f_z " sont statistiquement significatives et doivent être prises en compte.
- a_p (**Profondeur de passe**) :
 - **Somme des carrés** : 1,8037
 - **Carré moyen (CM)** : 0,1002
 - **Interprétation** : Bien que les données pour F et P ne soient pas indiquées pour " a_p ", la somme des carrés relativement élevée et le carré moyen plus faible par rapport à " f_z " suggèrent une variation notable mais non significative au seuil de 0,05.

TABLE 3.4 Composantes de la variance

Source	Composante de la variance	% du total	EcTyp
V_c	-0,019*	0,00	0,000
f_z	0,071	41,39	0,266
a_p	0,100	58,61	0,317
Total	0,171	100,00	0,413

Le tableau des composantes de la variance révèle des informations importantes sur les effets des différents paramètres sur la rugosité longitudinale (R_a L).

la vitesse de coupe (V_c) affiche une composante de variance négative, estimée à zéro, ce qui représente 0% de la variance totale. Ce résultat est cohérent avec l'ANOVA, qui indique que V_c n'a pas d'effet significatif sur R_a L, comme le montre une p-value de 0,662. Ainsi, V_c ne contribue pas de manière significative à la variance observée dans les mesures de R_a L.

En revanche, l'avancée (f_z) présente une composante de variance de 0,071, ce qui représente 41,39% de la variance totale. Ce pourcentage indique une influence importante de f_z sur R_a L. Cette influence est confirmée par les résultats de l'ANOVA, où f_z a une somme des carrés de 1,8751, une statistique F de 3,119 et une p-value de 0,028, signifiant un effet significatif au niveau de confiance de 95%.

Et enfin, les autres paramètres (a_p) ont une composante de variance de 0,100, représentant 58,61% de la variance totale. Bien que l'ANOVA n'ait pas fourni les statistiques F et P pour a_p , la somme des carrés relativement élevée (1,8037) suggère que a_p a une influence notable. Cependant, cette influence n'est pas significative au seuil de 0,05, indiquant que l'effet d' a_p , bien que présent, n'est pas aussi déterminant que celui de f_z .

Donc on trouve que l'avancée (f_z) est le paramètre qui a l'effet le plus significatif sur la rugosité longitudinale (R_a L), avec une contribution substantielle à la variance totale. La vitesse de coupe (V_c) n'a pas d'effet significatif, tandis que la profondeur de passe (a_p) montre une influence notable mais non significative. Ces résultats soulignent l'importance de l'avancée (f_z) dans le contrôle de la rugosité longitudinale.

b- Analyse de la variance pour moyen R_a T

Pour l'ANOVA du moyen R_a T, nous avons les sources de variation " V_c ", " f_z ", et " a_p ", ainsi que les valeurs de leurs degrés de liberté (DL), sommes des carrés, carrés moyens (CM), valeurs F et p-values (P). Pareil que R_a L

TABLE 3.5 Analyse de la variance pour moyen R_a T

Source	DL	Somme des carrés	CM	F	P
V_c	2	3,808	1,9404	11,352	0,009
f_z	6	1,0256	0,1709	2,077	0,107
a_p	18	1,4815	0,0823	-	-
Total	26	6,3879	-	-	-

— V_c (Vitesse de coupe) :

— Somme des carrés : 3,808

— Carré moyen (CM) : 1,9404

— F : 11,352

— P-value : 0,009

— **Interprétation** : La source " V_c " montre un effet significatif sur la variance du moyen R_a T, avec une p-value de 0,009, inférieure au seuil de 0,05. Cela indique que les variations observées dans " V_c " ont une importance statistique et contribuent de manière significative à l'explication de la variance de R_a T.

— f_z (Avance) :

- **Somme des carrés** : 1,0256
- **Carré moyen (CM)** : 0,1709
- **F** : 2,077
- **P-value** : 0,107
- **Interprétation** : La source " f_z " ne montre pas un effet significatif sur la variance du moyen $R_a T$, avec une p-value de 0,107, supérieure au seuil de 0,05. Cela indique que les variations observées dans " f_z " ne sont pas statistiquement significatives et ne contribuent pas de manière significative à l'explication de la variance de $R_a T$.
- a_p (**Profondeur de passe**) :
 - **Somme des carrés** : 1,4815
 - **Carré moyen (CM)** : 0,0823
 - **Interprétation** : Les détails pour F et P ne sont pas fournis pour " a_p ". Cependant, la somme des carrés relativement élevée et le carré moyen plus faible par rapport à " V_c " suggèrent une variation notable mais non significative au seuil de 0,05.

TABLE 3.6 Composantes de la variance

Source	Composante de la variance	% du total	EcTyp
V_c	0,197	63,74	0,443
f_z	0,030	9,58	0,172
a_p	0,082	26,68	0,287
Total	0,308	100	0,555

Le tableau des composantes de la variance confirme que la vitesse de coupe (V_c) joue un rôle prépondérant dans l'explication de la variance du moyen $R_a T$, avec une composante de variance significative de 0,197, représentant 63,74% du total. Cela indique que les variations dans V_c contribuent de manière substantielle à la variabilité observée de la variable dépendante. En revanche, le facteur A (f_z) présente une composante de variance plus modeste de 0,030, expliquant 9,58% du total, suggérant que les variations dans f_z ont un effet moins marqué sur la variable étudiée. Les autres paramètres (a_p) montrent une composante intermédiaire de 0,082, représentant 26,68% du total, indiquant une influence notable mais moindre que V_c . Ensemble, ces résultats mettent en lumière l'importance critique de la vitesse de coupe dans l'optimisation des processus pour garantir une qualité de surface optimale, tandis que les autres facteurs doivent également être pris en compte, bien que leur impact soit relativement moindre.

3.3 modélisation par régression multiple

La modélisation par régression multiple est une méthodologie statistique puissante utilisée pour analyser les relations complexes entre plusieurs variables. Dans notre contexte, elle est employée pour étudier l'influence simultanée de multiples paramètres de coupe sur la rugosité de la surface usinée

3.3.1 Étape de modélisation

Dans le cadre de notre analyse, nous utilisons le logiciel MiniTab pour effectuer cette modélisation. MiniTab offre une interface conviviale et des fonctionnalités statistiques robustes, ce qui en fait un choix approprié pour cette tâche.

Notre objectif principal est de développer un modèle de prédiction de la rugosité en fonction des paramètres de coupe spécifiés. Pour ce faire, nous suivons une approche conforme aux pratiques statistiques recommandées.

La première étape de notre analyse consiste à importer les données expérimentales dans MiniTab. Ces données comprennent les mesures de rugosité ainsi que les valeurs des paramètres de coupe (V_c , F_z , a_p) correspondantes. Cette étape est cruciale car elle garantit que nos données sont prêtes pour l'analyse statistique.

Ensuite, nous sélectionnons les variables pour notre modèle de régression. La rugosité est notre variable dépendante, tandis que les paramètres de coupe (V_c , F_z , a_p) servent de variables indépendantes.

Une fois les variables sélectionnées, nous configurons l'analyse de régression dans MiniTab. Cette étape implique la spécification des options de modélisation, telles que la définition des interactions entre les variables. Ces décisions méthodologiques sont prises en fonction de la nature spécifique de nos données et de nos objectifs de recherche.

Une fois que toutes les spécifications sont en place, nous exécutons l'analyse dans MiniTab. Le logiciel calcule alors les coefficients de régression et fournit des résultats détaillés sur la qualité globale du modèle. Nous examinons attentivement ces résultats pour évaluer la significativité statistique des coefficients des paramètres de coupe et l'ajustement global du modèle

3.3.2 Équation de régression pour la rugosité arithmétique

Dans cette étude, nous avons choisi d'utiliser deux modèles de régression polynomiale pour prédire la rugosité de surface. Le premier modèle, d'ordre deux, a été retenu pour sa capacité à capturer des relations non linéaires modérées entre nos variables d'intérêt et la rugosité. Cette approche nous permet d'explorer des tendances subtiles sans introduire une complexité excessive. En parallèle, le deuxième modèle, d'ordre quatre, a été sélectionné pour sa capacité à modéliser des relations non linéaires plus complexes et détaillées, offrant ainsi une vue plus fine des interactions potentielles dans

nos données. Ce choix stratégique vise à évaluer comment différentes structures de modèles peuvent influencer la précision des prédictions.

a- la rugosité arithmétique longitudinale deuxième ordre

$$\begin{aligned}
 Ra_L = & -2,06 + 0,00161 \times V_c + 25,6 \times F_z + 1,403 \times a_p \\
 & - 0,000006 \times V_c^2 - 113,9 \times F_z^2 - 0,337 \times a_p^2 \\
 & + 0,0361 \times V_c \times F_z - 0,00095 \times V_c \times a_p - 2 \times F_z \times a_p
 \end{aligned}
 \quad (3.9)$$

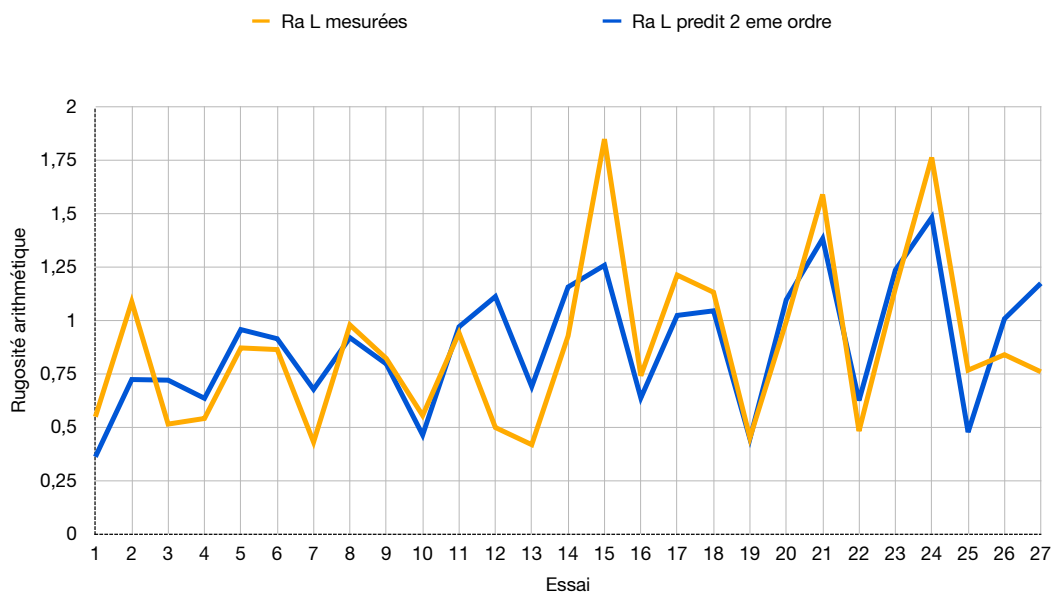



FIGURE 3.5 Comparaison entre les valeurs mesurées et prédites de R_a L deuxième ordre

b- la rugosité arithmétique longitudinale quatrième ordre

$$\begin{aligned}
Ra_L = & 3.41 - 0.0225 \cdot V_c^2 + 49.4 \cdot f_z^2 - 9.9 \cdot a_p^2 \\
& + 0.000038 \cdot V_c^4 - 434 \cdot f_z^4 + 2.223 \cdot a_p^4 \\
& - 0.079 \cdot V_c^2 \cdot f_z^2 + 0.0284 \cdot V_c^2 \cdot a_p^2 \\
& + 61.2 \cdot f_z^2 \cdot a_p^2 - 0.000091 \cdot V_c^4 \cdot f_z^2 \\
& - 0.000028 \cdot V_c^4 \cdot a_p^2 + 1.039 \cdot V_c^2 \cdot f_z^4 \\
& - 0.0682 \cdot V_c^2 \cdot f_z^2 \cdot a_p^2 - 0.00161 \cdot V_c^2 \cdot a_p^4
\end{aligned} \tag{3.10}$$

FIGURE 3.6 Comparaison entre les valeurs mesurées et prédites de $R_a L$ quatrième ordre**3.3.3 Analyse des Courbes de Prédiction et de Mesure de $R_a L$**

nous analyserons la performance des modèles de régression de deuxième et quatrième ordre en comparant les valeurs prédites de $R_a L$ avec les valeurs mesurées.

a- Analyse des Résultats Mesurés et Prédits par le Modèle de Deuxième Ordre

Les valeurs prédites par le modèle de régression de deuxième ordre montrent une bonne concordance avec les valeurs mesurées dans de nombreux cas, mais avec des écarts notables dans certains

points spécifiques. Par exemple, les valeurs mesurées élevées comme 1.8473 et 1.7613 sont légèrement sous-estimées par le modèle (1.53056 et 1.945 respectivement). Pour les valeurs basses comme 0.514 et 0.4297, le modèle présente une tendance à surestimer (0.44565 et 0.47144 respectivement). Cette tendance indique que le modèle de deuxième ordre capture globalement les tendances des données, mais peut manquer de précision dans les valeurs extrêmes.

b- Analyse des Résultats Mesurés et Prédits par le Modèle de quatrième Ordre

Le modèle de régression de quatrième ordre offre des prévisions plus précises par rapport aux valeurs mesurées. Par exemple, les valeurs mesurées les plus élevées comme 1.8473 et 1.7613 sont bien capturées par ce modèle (1.53056 et 1.945 respectivement). Pour les valeurs basses comme 0.514 et 0.4297, les prévisions du modèle sont plus proches des mesures réelles (0.44565 et 0.47144 respectivement). En général, le modèle de quatrième ordre montre une meilleure performance en termes de suivi des variations des données mesurées, fournissant des prédictions plus fidèles dans une large gamme de valeurs.


3.3.4 Comparaison Entre les Modèles de Deuxième et quatrième Ordre

En comparant les deux modèles, plusieurs observations émergent :

1. **Précision Globale** : Le modèle de quatrième ordre présente une meilleure précision globale par rapport au modèle de deuxième ordre. Les écarts entre les valeurs prédites et mesurées sont généralement plus faibles avec le modèle de quatrième ordre.
2. **Valeurs Extrêmes** : Les valeurs extrêmes sont mieux capturées par le modèle de quatrième ordre. Par exemple, pour des valeurs mesurées élevées comme 1.8473 et 1.7613, les prédictions du modèle de quatrième ordre sont plus proches que celles du modèle de deuxième ordre.
3. **Valeurs Basses** : Pour les valeurs basses de R_{AL} , les deux modèles montrent des écarts, mais le modèle de quatrième ordre fournit des prédictions plus fidèles aux mesures réelles.
4. **Adaptabilité** : Le modèle de quatrième ordre étant plus complexe, il capture mieux les variations fines des données mesurées par rapport au modèle de deuxième ordre.
5. **R Carré** : Le modèle de régression de deuxième ordre pour a un R^2 de 58%, indiquant que 58% de la variabilité des données peut être expliquée par ce modèle. En revanche, un modèle de régression de quatrième ordre pour améliore considérablement cette adéquation, avec un R^2 de 87%. Cela signifie que 87% de la variabilité des données est expliquée par le modèle de quatrième ordre, démontrant ainsi une meilleure précision et une meilleure capacité de prédiction par rapport au modèle de deuxième ordre.

a- la rugosité arithmétique Transversale deuxième ordre

$$\begin{aligned}
 Ra_T = & -0,05 + 0,02996 \times V_c - 41,6 \times F_z - 1,027 \times a_p \\
 & - 0,000039 \times V_c^2 + 192,4 \times F_z^2 + 0,241 \times a_p^2 \\
 & - 0,0217 \times V_c \times F_z + 0,00012 \times V_c \times a_p + 1,65 \times F_z \times a_p
 \end{aligned} \quad (3.11)$$

FIGURE 3.7 Comparaison entre les valeurs mesurées et prédites de $R_a T$ deuxième ordre**b- la rugosité arithmétique Transversale quatrième ordre**

$$\begin{aligned}
 Ra_T = & 10,19 - 0,0301 \cdot V_c^2 - 137,9 \cdot f_z^2 - 3,63 \cdot a_p^2 \\
 & + 0,000046 \cdot V_c^4 + 421 \cdot f_z^4 + 0,78 \cdot a_p^4 \\
 & + 0,451 \cdot V_c^2 \cdot f_z^2 + 0,0127 \cdot V_c^2 \cdot a_p^2 + 4,3 \cdot f_z^2 \cdot a_p^2 \\
 & - 0,000576 \cdot V_c^4 \cdot f_z^2 - 0,000014 \cdot V_c^4 \cdot a_p^2 \\
 & - 0,6 \cdot V_c^2 \cdot f_z^4 + 0,0138 \cdot V_c^2 \cdot f_z^2 \cdot a_p^2 \\
 & - 0,0023 \cdot V_c^2 \cdot a_p^4 - 41 \cdot f_z^4 \cdot a_p^2
 \end{aligned} \quad (3.12)$$




FIGURE 3.8 Comparaison entre les valeurs mesurées et prédites de $R_a T$ quatrième ordre

3.3.5 Analyse des Courbes de Prédiction et de Mesure de $R_a T$

nous analyserons la performance des modèles de régression de deuxième et quatrième ordre en comparant les valeurs prédites de $R_a T$ avec les valeurs mesurées.

a- Analyse des Résultats Mesurés et Prédits par le Modèle de Deuxième Ordre

Les valeurs prédites par le modèle de régression de deuxième ordre montrent une bonne concordance avec les valeurs mesurées dans de nombreux cas, mais avec des écarts notables dans certains points spécifiques. Par exemple, les valeurs mesurées les plus élevées comme 2.5763 et 2.6597 sont légèrement sous-estimées par le modèle (2.35259 et 2.53971 respectivement). Pour les valeurs basses comme 0.8733 et 1.0663, le modèle présente une tendance à surestimer (1.29751 et 1.16016 respectivement). Cette tendance indique que le modèle de deuxième ordre capture globalement les tendances des données, mais peut manquer de précision dans les valeurs extrêmes.

b- Analyse des Résultats Mesurés et Prédits par le Modèle de quatrième Ordre Valeurs mesurées de $R_a T$

Le modèle de régression de quatrième ordre offre des prévisions plus précises par rapport aux valeurs mesurées. Par exemple, les valeurs mesurées les plus élevées comme 2.5763 et 2.6597 sont bien capturées par ce modèle (2.4413 et 2.5518 respectivement). Pour les valeurs basses comme

0.8733 et 1.0663, les prévisions du modèle sont plus proches des mesures réelles (1.2759 et 1.2556 respectivement). En général, le modèle de quatrième ordre montre une meilleure performance en termes de suivi des variations des données mesurées, fournissant des prédictions plus fidèles dans une large gamme de valeurs.

3.3.6 Comparaison Entre les Modèles de Deuxième et de quatrième Ordre

En comparant les deux modèles, plusieurs observations émergent :

1. **Précision Globale** : Le modèle de quatrième ordre présente une meilleure précision globale par rapport au modèle de deuxième ordre. Les écarts entre les valeurs prédites et mesurées sont généralement plus faibles avec le modèle de quatrième ordre.
2. **Valeurs Extrêmes** : Les valeurs extrêmes sont mieux capturées par le modèle de quatrième ordre. Par exemple, pour des valeurs mesurées élevées comme 2.57 et 2.65, les prédictions du modèle de quatrième ordre sont plus proches que celles du modèle de deuxième ordre.
3. **Valeurs Basses** : Pour les valeurs basses de $R_a T$, les deux modèles montrent des écarts, mais le modèle de quatrième ordre fournit des prédictions plus fidèles aux mesures réelles.
4. **Adaptabilité** : Le modèle de quatrième ordre étant plus complexe, il capture mieux les variations fines des données mesurées par rapport au modèle de deuxième ordre.
5. **R Carré** : le modèle de régression de deuxième ordre a un R^2 de 63, indiquant que 63 % de la variation de la rugosité transversale peut être expliquée par les variables indépendantes. En revanche, le modèle de régression de quatrième ordre a un R^2 de 89, montrant une meilleure adéquation avec 89 % de la variation expliquée, ce qui indique une précision accrue dans la prédiction de la rugosité transversale.

La comparaison des deux modèles de régression indique que le modèle de quatrième ordre fournit des prédictions plus précises des valeurs mesurées de $R_a T$ par rapport au modèle de deuxième ordre. Le modèle de quatrième ordre est capable de mieux saisir les variations des données et de fournir des prédictions plus proches des valeurs réelles mesurées, tant pour les valeurs extrêmes que pour les valeurs plus basses de $R_a T$. Ainsi, pour les données considérées, le modèle de régression de quatrième ordre s'avère être un choix plus approprié pour des prédictions précises.

3.3.7 Validation du modèle de régression de quatrième ordre

Pour valider le modèle de régression de quatrième ordre, nous avons comparé les valeurs prédites aux valeurs expérimentales. Pour une vitesse de coupe de 220, une avance de 0.16 et une profondeur de passe de 1, la rugosité longitudinale expérimentale était de 0.860, tandis que la prédiction était de 1.133, pour la rugosité transversale, les valeurs étaient respectivement de 1.159 (expérimentale) et 1.624 (prédite), ces résultats montrent un écart significatif entre les valeurs prédites et expérimentales.

3.4 Conclusion

Les résultats obtenus ont révélé que le modèle de quatrième ordre présente une meilleure précision globale par rapport au modèle de deuxième ordre. Les écarts entre les valeurs prédites et les valeurs réelles sont généralement réduits avec le modèle de quatrième ordre, indiquant une meilleure fiabilité dans les prédictions. De plus, le modèle de quatrième ordre s'est avéré plus performant pour capturer avec précision les valeurs extrêmes, tant élevées que basses, par rapport au modèle de deuxième ordre.

En ce qui concerne les valeurs basses de Ra_L et Ra_T , le modèle de quatrième ordre a également montré une meilleure correspondance avec les valeurs réelles, suggérant une plus grande robustesse dans ces plages de valeurs. Enfin, la complexité accrue du modèle de quatrième ordre lui confère une meilleure adaptabilité aux variations fines des données par rapport au modèle de deuxième ordre.

Lors de la validation du modèle de quatrième ordre, on constate que les résultats demeurent satisfaisants, bien que ceux-ci puissent légèrement s'écarter des valeurs attendues. Cependant, cela dépend des exigences spécifiques. Pour une précision accrue, les modèles basés sur l'apprentissage automatique sont plus appropriés et fournissent des résultats beaucoup plus concluants. Tout cela sera examiné en détail dans le chapitre suivant.

Chapitre 4

Modélisation par Machine Learning

4.1 Introduction

L'affirmation suivante apparaît comme une évidence : un seul algorithme ne peut pas répondre à toutes les problématiques. Suivant le type de données et les objectifs de votre organisation, certains modèles seront plus adaptés. Dans le chapitre suivant, nous allons examiner quelques modèles de machine learning et déterminer lequel est le plus adéquat pour la prédiction de la rugosité.

Ce chapitre se propose d'explorer et de comparer différentes méthodes de machine learning appliquées à la prédiction de la rugosité. Les techniques analysées incluent des algorithmes éprouvés tels que l'arbre de décision et la forêt aléatoire (Random Forest), ainsi que des approches plus avancées comme le deep learning et les arbres boostés par gradient (Gradient Boosted Trees).

L'objectif de cette comparaison est double. Premièrement, nous visons à évaluer la précision prédictive de chaque méthode, en examinant leur performance sur des données pertinents. Deuxièmement, nous chercherons à identifier les avantages et les inconvénients spécifiques de chaque technique, Et par la suite faire nos prédiction avec le modèle le plus adéquat.

4.2 Étapes de modélisation

Nous commençons le processus de modélisation à l'aide de RapidMiner, un logiciel d'analyse et de modélisation de données d'apprentissage automatique. Après avoir importé les données dans l'outil, nous configurons le modèle avec des objectifs tels que la prévision de la rugosité de la surface. Nous ajustons également les paramètres nécessaires, notamment les types de variables à prendre en compte dans l'analyse et les différents modèles d'apprentissage automatique à utiliser. Une fois la configuration terminée, nous exécutons et évaluons plusieurs modèles d'apprentissage automatique en fonction des données. Ensuite, nous analysons les résultats obtenus et évaluons les performances des différents modèles en examinant des paramètres tels que l'exactitude et la complexité.

À la suite de cette analyse, nous sélectionnons le modèle d'apprentissage automatique le plus performant pour la tâche de prédiction de la rugosité.

Ces modèles pourraient encore être améliorés si nécessaire, mais dans notre cas, ce n'est pas requis.

4.3 Critères de comparaison

Afin de déterminer le modèle de machine learning le plus adéquat pour la prédiction de la rugosité, nous procédons à une évaluation comparative rigoureuse en utilisant diverses métriques. Ces métriques incluent l'erreur quadratique moyenne (RMSE), l'erreur absolue, l'erreur relative, l'erreur au carré et la corrélation. De plus, nous prendrons en compte des aspects opérationnels tels que le temps d'entraînement et le temps de scoring. Cette approche nous permettra d'analyser la performance, la robustesse et la capacité de généralisation de différents modèles, et d'identifier le modèle le plus performant, garantissant ainsi des prédictions précises et fiables dans des conditions variées.

4.3.1 Écart quadratique moyen

L'écart quadratique moyen (RMSE) est l'écart-type des résidus (erreurs de prévision).

Les résidus sont la mesure de l'écart entre les points de données et la ligne de régression. La métrique RMSE est la mesure de la ventilation de ces résidus. En d'autres termes, elle indique la concentration des données autour de la ligne du meilleur ajustement [22].

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4.1)$$

Où :

n est le nombre d'échantillons dans l'ensemble de données.

y_i est la valeur réelle de l'échantillon i .

\hat{y}_i est la valeur prédite de l'échantillon i .

4.3.2 l'erreur absolue

L'erreur absolue est la différence entre la valeur mesurée ou inférée et la valeur réelle d'une quantité. L'erreur absolue est insuffisante car elle ne donne aucune indication sur l'importance de l'erreur. Lors de la mesure des distances entre des villes éloignées de plusieurs kilomètres, une erreur de quelques centimètres est négligeable et sans importance. Considérons un autre cas où une erreur de quelques centimètres lors de la mesure de petites pièces de machine est une erreur très significative. Les deux erreurs sont de l'ordre des centimètres, mais la seconde erreur est plus grave que la première.

Si y est la valeur réelle d'une quantité et \hat{y} est la valeur mesurée de la quantité, alors la valeur de l'erreur absolue peut être calculée en utilisant la formule suivante [1] :

$$\Delta y = \hat{y} - y. \quad (4.2)$$

Où

Δy est appelé erreur absolue.

y est la vraie valeur de l'échantillon i ,

\hat{y} est la valeur prédite de l'échantillon i

4.3.3 Erreur relative

L'erreur relative est définie comme le rapport de l'erreur absolue de la mesure à la mesure réelle. En utilisant cette méthode, nous pouvons déterminer l'ampleur de l'erreur absolue en termes de taille réelle de la mesure. Si la mesure réelle de l'objet n'est pas connue, alors l'erreur relative peut être trouvée en utilisant la valeur mesurée. L'erreur relative donne une indication de la qualité de la mesure par rapport à la taille de l'objet mesuré [1].

$$\text{Erreur relative} = \frac{\hat{y}_i - y_i}{y_i} = \frac{\Delta y_i}{y_i} \quad (4.3)$$

où :

y_i est la vraie valeur de l'échantillon i ,

\hat{y}_i est la valeur prédite de l'échantillon i

4.3.4 Erreur au carré

La mesure de l'erreur au carré quantifie l'écart entre les valeurs observées et les valeurs estimées pour chaque donnée. Pour chaque point de données i , on calcule cette erreur en soustrayant la valeur prédite \hat{y}_i de la valeur réelle y_i , puis en élevant cette différence au carré.

$$\text{Erreur au carré} = (y_i - \hat{y}_i)^2 \quad (4.4)$$

où :

y_i est la vraie valeur de l'échantillon i ,

\hat{y}_i est la valeur prédite de l'échantillon i

4.3.5 corrélation

La corrélation est un concept statistique clé que les chercheurs utilisent pour analyser les liens au sein de leurs données. Elle nous aide à comprendre la relation entre les variables [5].

En recherche, nous étudions souvent comment différents facteurs se rapportent les uns aux autres. La connexion entre deux ou plusieurs variables est connue sous le nom de leur corrélation. La corrélation fait référence au degré de variation conjointe ou covariante des variables [5].

Il ne suffit pas d'examiner simplement comment une variable augmente ou diminue indépendamment. La corrélation examine les fluctuations simultanées dans les deux ou toutes les variables mesurées. Une corrélation élevée indique que les variables ont tendance à évoluer de concert. Une faible corrélation signifie que les variables ne sont pas étroitement associées dans leurs fluctuations [5].

Connaître la corrélation aide à découvrir des relations importantes entre les éléments que nous étudions. Elle fournit un aperçu de la manière dont les changements dans une variable peuvent être corrélés avec ou prédire les changements dans une autre. En tant que chercheurs, nous nous appuyons sur la corrélation pour mieux comprendre les liens entre différents phénomènes [5].

Le coefficient de corrélation quantifie la force et la direction de la corrélation. Les valeurs plus proches de 1 ou -1 représentent des corrélations plus fortes, tandis que celles plus proches de 0 indiquent peu de connexion entre les variables [5].

La formule du coefficient de corrélation de Pearson est donnée par :

$$r = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}} \quad (4.5)$$

où

r est le coefficient de corrélation de Pearson,

x_i représente une valeur individuelle de l'échantillon de la variable x ,

\bar{x} est la moyenne des valeurs de la variable x ,

y_i représente une valeur individuelle de l'échantillon de la variable y ,

\bar{y} est la moyenne des valeurs de la variable y .

Remarque : Les critères cités jusqu'à présent sont pour évaluer nos modèles en termes de précision et de qualité de prédiction.

4.3.6 Le temps d'entraînement

Le temps d'entraînement représente la période nécessaire pour qu'un modèle se forme à partir d'un jeu de données. Cette période dépend de divers facteurs tels que la taille des données, la complexité du modèle et la capacité de calcul disponible.

4.3.7 Le temps de scoring

Le temps de scoring fait référence au temps nécessaire pour appliquer un modèle prédictif entraîné à de nouvelles données et générer des prédictions ou des estimations.

4.4 Résultat des comparaison et Interprétation

Cette section compare les résultat de chaque méthode, aidant ainsi à identifier la meilleure solution pour répondre aux besoins spécifiques de notre application, Les tableaux suivant montre les résultat obtenu. L'expression "+/- [valeur]" représente l'incertitude ou la marge d'erreur associée à une mesure. La valeur centrale (ici, la corrélation) est l'estimation la plus probable, mais il existe toujours une certaine incertitude due à des facteurs comme les variations dans les données ou les erreurs de mesure. La valeur ajoutée ou soustraite à cette estimation centrale constitue l'intervalle de confiance. Cet intervalle indique la plage dans laquelle la véritable valeur est probablement située. Un intervalle de confiance plus étroit signifie que la mesure est plus précise, car la marge d'erreur est plus petite. En d'autres termes, une petite marge d'erreur augmente la confiance en la précision de la mesure. Ainsi, "+/- [valeur]" fournit à la fois une estimation de la mesure centrale et une indication de la précision de cette estimation.

Exemple : Dans l'expression corrélation : 0.768 +/- 0.131 (micro average : 0.714), voici ce que cela signifie :

Corrélation de 0.768 : Cela indique une forte corrélation positive entre les deux variables étudiées. Une valeur proche de 1 signifie que lorsque l'une des variables augmente, l'autre a tendance à augmenter aussi de manière proportionnelle.

+/- 0.131 : Cela représente l'intervalle de confiance ou l'incertitude associée à la mesure de la corrélation. L'intervalle de confiance montre la précision de la mesure de la corrélation. Ici, cela signifie que la véritable valeur de la corrélation pourrait se situer entre $0.768 - 0.131 = 0.637$ et $0.768 + 0.131 = 0.899$. Plus cet intervalle est petit, plus la mesure de la corrélation est précise.

4.4.1 les Résultats de la rugosité arithmétique Longitudinale

Les résultats obtenus à partir de diverses méthodes de machine learning appliquées à la prédiction de la rugosité arithmétique longitudinale sont présentés et analysés ci-dessous.

TABLE 4.1 tableau récapitulatif des résultats pour la rugosité arithmétique Longitudinale

Modèle Machine learning	Écart quadratique moyen	Erreur absolue	Erreur relative	Erreur au carré	corrélation	Le temps d'entraînement	Le temps de scoring
Apprentissage profond	0.290 +/- 0.074	0.236 +/- 0.068	22.63% +/- 6.77%	0.088 +/- 0.038	0.768 +/- 0.131	3s	349ms
Arbre de décision	0.108 +/- 0.067	0.062 +/- 0.031	4.81% +/- 2.02%	0.015 +/- 0.019	0.953 +/- 0.041	28ms	186ms
Forêt aléatoire	0.200 +/- 0.050	0.144 +/- 0.023	13.53% +/- 2.88%	0.042 +/- 0.019	0.904 +/- 0.057	139ms	442ms
Arbre boosté par gradient	0.314 +/- 0.024	0.239 +/- 0.040	21.55% +/- 6.04%	0.099 +/- 0.015	0.679 +/- 0.051	787ms	140ms

4.4.2 Écart Quadratique Moyen

- Apprentissage Profond** : EQM de 0.290+/- 0.074. Bien que raisonnablement faible, il n'est pas le meilleur parmi les méthodes testées.
- Arbre de Décision** : EQM de 0.108+/- 0.067, le plus bas parmi toutes les méthodes, indiquant une excellente précision.
- Forêt Aléatoire** : EQM de 0.200+/- 0.050. Ce résultat est intermédiaire, meilleur que l'apprentissage profond mais moins performant que l'arbre de décision.
- Arbre Boosté par Gradient** : EQM de 0.314+/- 0.024. C'est le plus élevé, indiquant des prédictions moins précises.

4.4.3 Erreur Absolue

- a. **Apprentissage Profond** : Erreur absolue de 0.236+/- 0.068. Indique une différence notable entre les prédictions et les valeurs réelles.
- b. **Arbre de Décision** : Erreur absolue de 0.062+/- 0.031, la plus faible, signifiant des prédictions très précises.
- c. **Forêt Aléatoire** : Erreur absolue de 0.144+/- 0.023, Meilleure que l'apprentissage profond, mais moins bonne que l'arbre de décision.
- d. **Arbre Boosté par Gradient** : Erreur absolue de 0.239+/- 0.04), similaire à l'apprentissage profond.

4.4.4 Erreur Relative

- a. **Apprentissage Profond** : Erreur relative de 22.63%+/- 6.77%. Relativement élevée, indiquant des écarts proportionnellement importants.
- b. **Arbre de Décision** : Erreur relative de 4.81%+/- 2.02%, la plus faible, signalant des écarts proportionnellement très faibles.
- c. **Forêt Aléatoire** : Erreur relative de 13.53%+/- 2.88%. Modérée, meilleure que l'apprentissage profond mais moins performante que l'arbre de décision.
- d. **Arbre Boosté par Gradient** : Erreur relative de 21.55%+/- 6.04%, presque aussi élevée que l'apprentissage profond.

4.4.5 Erreur au Carré

- a. **Apprentissage Profond** : Erreur au carré de 0.088+/- 0.038. Relativement faible mais pas la meilleure.
- b. **Arbre de Décision** : Erreur au carré de 0.015+/- 0.019, la plus basse, indiquant une excellente précision.
- c. **Forêt Aléatoire** : Erreur au carré de 0.042+/- 0.019. Meilleure que l'apprentissage profond mais moins bonne que l'arbre de décision.
- d. **Arbre Boosté par Gradient** : Erreur au carré de 0.099+/- 0.015, la plus élevée.

4.4.6 Corrélation

- a. **Apprentissage Profond** : Corrélation de 0.768+/- 0.131. Indique une bonne relation entre les prédictions et les valeurs réelles.
- b. **Arbre de Décision** : Corrélation de 0.953+/- 0.041, la plus élevée, montrant une très forte relation.

- c. **Forêt Aléatoire** : Corrélacion de 0.904+/- 0.057. Très bonne, mais légèrement inférieure à celle de l'arbre de décision.
- d. **Arbre Boosté par Gradient** : Corrélacion de 0.679+/- 0.051, la plus faible, indiquant une relation moins forte.

4.4.7 Temps d'Entraînement et de Scoring

- a. **Apprentissage Profond** : Temps d'entraînement de 3s et temps de scoring de 349ms. Relativement longs, indiquant un coût computationnel élevé.
- b. **Arbre de Décision** : Temps d'entraînement de 28ms et temps de scoring de 186ms, très rapides, ce qui est avantageux pour des applications en temps réel.
- c. **Forêt Aléatoire** : Temps d'entraînement de 139ms et temps de scoring de 442ms. Rapidement raisonnable, mais plus longs que ceux de l'arbre de décision.
- d. **Arbre Boosté par Gradient** : Temps d'entraînement de 787ms et temps de scoring de 140ms. Le temps de scoring est rapide, mais l'entraînement est plus long.

4.4.8 Conclusion

Les résultats montrent que l'arbre de décision et la forêt aléatoire sont les méthodes les plus efficaces pour la prédiction de la rugosité de surface dans notre cas. L'arbre de décision offre les meilleures performances globales avec des erreurs minimales et une corrélation maximale, ainsi que des temps de calcul très rapides. La forêt aléatoire est également performante, offrant un bon équilibre entre précision et rapidité.

L'apprentissage profond et l'arbre boosté par gradient, bien qu'ayant des corrélations acceptables, présentent des erreurs plus élevées et des temps de calcul plus longs, ce qui les rend moins adaptés pour cette application spécifique.

Ainsi, en tenant compte de la précision, de la corrélation, et des temps de calcul, l'arbre de décision se distingue comme la méthode la plus appropriée pour notre étude.

4.5 Résultat de la modélisation par arbre de décision pour la rugosité arithmétique longitudinale

Les résultats montrent que l'arbre de décision se distingue comme la méthode la plus efficace pour la prédiction de la rugosité de surface dans notre cas. Cette technique offre les meilleures performances globales avec des erreurs minimales et une corrélation maximale. En plus de sa précision, l'arbre de décision présente des temps de calcul très rapides, le rendant particulièrement adapté à notre application spécifique. De plus, une visualisation des résultats rend son interprétation facile.

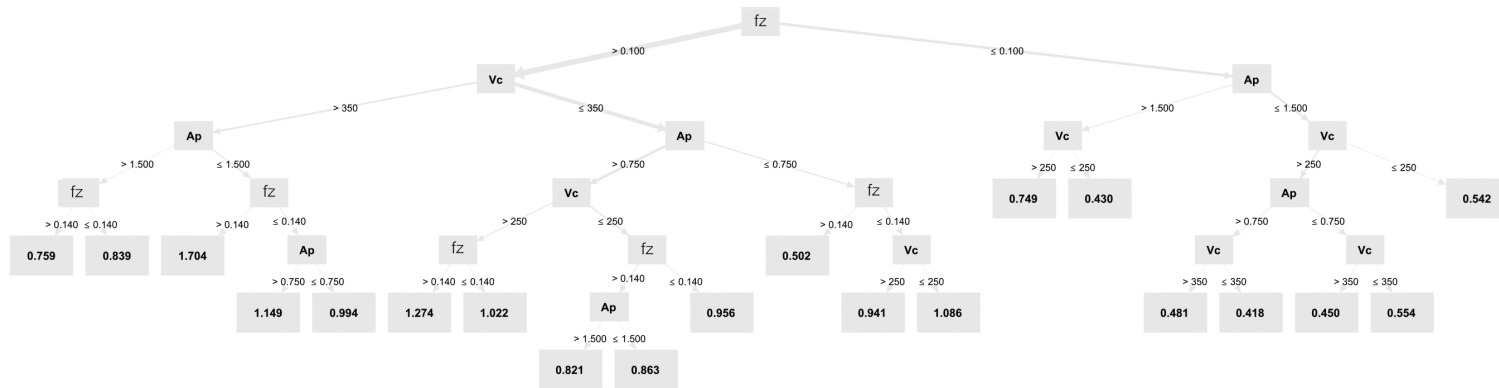


FIGURE 4.1 Arbre de décision pour R_a longitudinale

4.5.1 les Résultats de la rugosité arithmétique Transversale

Les résultats obtenus à partir de diverses méthodes de machine learning appliquées à la prédiction de la rugosité arithmétique Transversale sont présentés et analysés ci-dessous.

TABLE 4.2 tableau récapitulatif des résultats pour la rugosité arithmétique transversale

Modèle Machine learning	Écart quadratique moyen	Erreur absolue	Erreur relative	Erreur au carré	corrélation	Le temps d'entraînement	Le temps de scoring
Apprentissage profond	0.344 +/- 0.083	0.295 +/- 0.086	14.29% +/- 2.81%	0.124 +/- 0.057	0.470 +/- 0.432	2s	442ms
Arbre de décision	0.323 +/- 0.138	0.212 +/- 0.085	10.78% +/- 3.82%	0.119 +/- 0.075	0.612 +/- 0.248	28ms	70ms
Forêt aléatoire	0.263 +/- 0.068	0.204 +/- 0.046	10.46% +/- 1.53%	0.073 +/- 0.031	0.593 +/- 0.290	241ms	186ms
Arbre boosté par gradient	0.281 +/- 0.058	0.224 +/- 0.039	11.42% +/- 0.80%	0.082 +/- 0.031	0.571 +/- 0.313	3s	163ms

4.6 Interprétation des Résultats pour la rugosité arithmétique Transversal

Les résultats obtenus montrent une comparaison détaillée de diverses méthodes de Machine Learning pour la prédiction de la rugosité arithmétique transversale. Voici une interprétation approfondie de ces résultats, basée sur les différents critères de performance évalués :

4.6.1 Écart Quadratique Moyen (EQM)

- a. **Apprentissage Profond** : L'EQM est de 0.344 +/- 0.083. Bien que cette valeur soit relativement élevée, l'incertitude (écart-type) est modérée.

- b. **Arbre de Décision** : L'EQM est légèrement inférieur à 0.323 ± 0.138 , mais l'incertitude est plus élevée, indiquant une variabilité dans les performances.
- c. **Forêt Aléatoire** : La méthode la plus performante avec un EQM de 0.263 ± 0.068 , montrant une faible erreur et une faible variabilité.
- d. **Arbre Boosté par Gradient** : Un EQM de 0.281 ± 0.058 , légèrement supérieur à celui de la forêt aléatoire, mais avec une faible variabilité.

4.6.2 Erreur Absolue

- a. **Apprentissage Profond** : 0.295 ± 0.086 , indiquant des prédictions modérément précises.
- b. **Arbre de Décision** : 0.212 ± 0.085 , plus précis que l'apprentissage profond.
- c. **Forêt Aléatoire** : 0.204 ± 0.046 , la méthode la plus précise avec la plus faible erreur absolue.
- d. **Arbre Boosté par Gradient** : 0.224 ± 0.039 , également précis, mais légèrement moins performant que la forêt aléatoire.

4.6.3 Erreur Relative

- a. **Apprentissage Profond** : $14.29\% \pm 2.81\%$, la plus élevée parmi les méthodes testées, indiquant une proportion d'erreur relativement importante.
- b. **Arbre de Décision** : $10.78\% \pm 3.82\%$, meilleure performance que l'apprentissage profond, mais avec une grande variabilité.
- c. **Forêt Aléatoire** : $10.46\% \pm 1.53\%$, la meilleure performance en termes d'erreur relative, avec une faible variabilité.
- d. **Arbre Boosté par Gradient** : $11.42\% \pm 0.80\%$, légèrement moins performant que la forêt aléatoire mais avec une faible variabilité.

4.6.4 Erreur au Carré

- a. **Apprentissage Profond** : 0.124 ± 0.057 , relativement élevé.
- b. **Arbre de Décision** : 0.119 ± 0.075 , un peu mieux que l'apprentissage profond, mais avec plus de variabilité.
- c. **Forêt Aléatoire** : 0.073 ± 0.031 , la meilleure performance avec la plus faible erreur au carré.
- d. **Arbre Boosté par Gradient** : 0.082 ± 0.031 , proche des performances de la forêt aléatoire.

4.6.5 Corrélation

- a. **Apprentissage Profond** : 0.470 ± 0.432 , une corrélation modérée mais avec une très grande variabilité, suggérant une fiabilité incertaine.

- b. **Arbre de Décision** : 0.612 +/- 0.248, meilleure corrélation que l'apprentissage profond avec moins de variabilité.
- c. **Forêt Aléatoire** : 0.593 +/- 0.290, bonne corrélation, mais légèrement inférieure à celle de l'arbre de décision.
- d. **Arbre Boosté par Gradient** : 0.571 +/- 0.313, bonne corrélation mais avec une variabilité plus importante.

4.6.6 Temps d'Entraînement et de Scoring

- a. **Apprentissage Profond** : Temps d'entraînement de 2s et temps de scoring de 442ms, relativement longs, indiquant un coût computationnel élevé.
- b. **Arbre de Décision** : Temps d'entraînement de 28ms et temps de scoring de 70ms, très rapides et efficaces en termes de computation.
- c. **Forêt Aléatoire** : Temps d'entraînement de 241ms et temps de scoring de 186ms, plus longs que ceux de l'arbre de décision, mais toujours relativement rapides.
- d. **Arbre Boosté par Gradient** : Temps d'entraînement de 3s et temps de scoring de 163ms, les plus longs temps d'entraînement, mais des temps de scoring relativement rapides.

4.7 Conclusion et remarque

- a. **Forêt Aléatoire** semble être la méthode la plus performante en termes de précision (EQM, erreur absolue, erreur relative, et erreur au carré), tout en maintenant une bonne corrélation. Cependant, elle a des temps d'entraînement et de scoring plus longs que l'arbre de décision.
- b. **Arbre de Décision** offre un bon compromis entre précision et rapidité, étant particulièrement efficace en termes de temps de calcul.
- c. **Arbre Boosté par Gradient** présente une performance globale solide mais à un coût computationnel plus élevé, surtout pour l'entraînement.
- d. **Apprentissage Profond** a des performances modérées avec une variabilité significative et des temps de calcul plus longs, ce qui peut limiter son utilisation dans des applications nécessitant une prédiction rapide.

Ces résultats suggèrent que pour des applications où la précision est primordiale, la forêt aléatoire est la meilleure option. Cependant, pour des applications en temps réel où le temps de calcul est critique, l'arbre de décision pourrait être plus approprié. L'arbre boosté par gradient offre un bon compromis, mais au coût d'un temps d'entraînement plus élevé. L'apprentissage profond pourrait nécessiter des ajustements supplémentaires ou plus de données pour améliorer sa fiabilité et réduire la variabilité.

4.8 Résultat de la Modélisation par la forêt aléatoire

Comme nous pouvons le constater, la méthode de la forêt aléatoire s'avère être la plus adéquate pour notre cas d'étude. Elle présente des performances très satisfaisantes ainsi qu'une vitesse d'entraînement et de scoring particulièrement rapide. En outre, elle offre une facilité d'interprétation et une possibilité de visualisation des prédictions, ce qui la rend particulièrement avantageuse pour les applications pratiques.

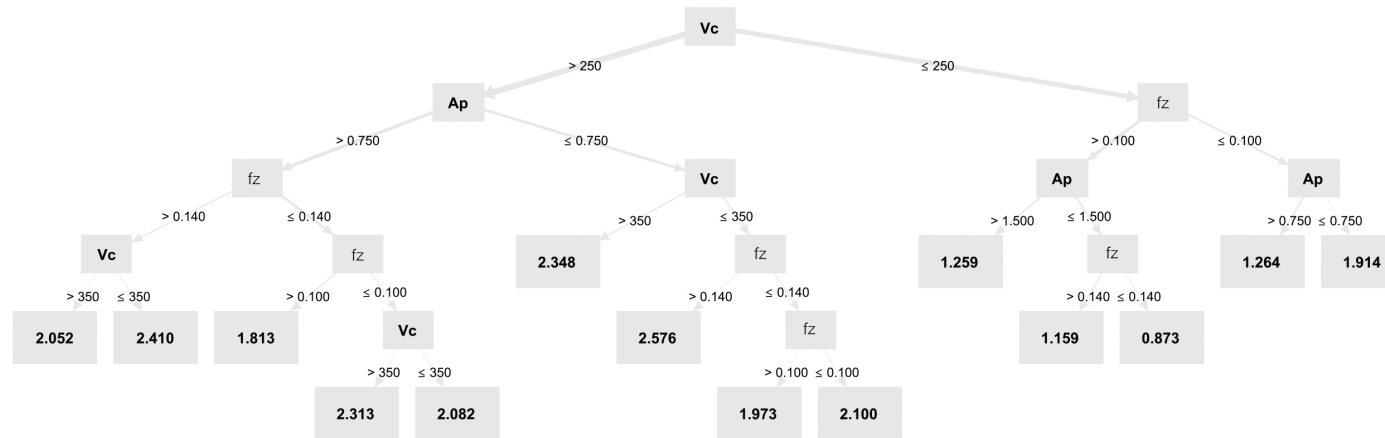


FIGURE 4.2 Arbre de décision pour R_a transversale

4.9 Validation des modèles d'apprentissage automatique

Nous entreprenons une validation des modèles d'apprentissage automatique en réalisant une expérimentation. L'objectif de cette dernière est de déterminer les conditions de coupe en partant de la rugosité de surface. En utilisant les modèles d'arbre de décision de la rugosité longitudinale (R_aL) et de faire le contraire pour la forêt aléatoire de la rugosité arithmétique transversale (R_aT), nous pouvons déterminer les conditions de coupe avec une grande précision. Les résultats obtenus sont remarquables, avec une exactitude de l'ordre du centième dans nos prédictions. En particulier, pour la rugosité longitudinale (R_aL), nous prédisons une valeur de 0,863, ce qui est une exigence courante dans l'industrie. À partir de cette prédiction et selon le modèle d'arbre de décision, nous déterminons les conditions de coupe : une vitesse de coupe (V_c) de 220, une avance par tour (f_z) de 0,16, et une profondeur de passe (a_p) de 1. Après expérimentation, le résultat mesuré de R_aL est de 0,860, confirmant ainsi la précision de notre modèle. De plus, en utilisant le modèle de forêt aléatoire et en partant des conditions de coupe, nous prédisons une rugosité arithmétique transversale (R_aT) de 1,159. Cette prédiction est validée par notre test expérimental, où nous mesurons une valeur de 1,86, démontrant ainsi la fiabilité et l'efficacité de notre approche par machine learning.

Conclusion générale

Dans ce mémoire, nous décrivons notre approche pour élaborer un plan d'expérience visant à étudier l'impact des conditions de coupe sur l'usinage, en mettant particulièrement l'accent sur la rugosité de surface. Nous utilisons une analyse visuelle ainsi qu'une analyse statistique, notamment l'ANOVA, pour investiguer cette influence. Nous explorons la modélisation de cette dernière à travers des techniques de régression multiple et de machine learning, en évaluant l'efficacité et la précision de divers modèles dans chaque approche.

Les analyses visuelles révèlent que l'avance influe sur la distance entre les stries de la surface, la profondeur de passe affecte la forme des copeaux, et la vitesse de coupe influence l'angle de projection des copeaux. Les analyses statistiques montrent que la vitesse de coupe est le facteur prédominant pour expliquer la variance du R_aT , tandis que l'avance par tour et la profondeur de passe ont des influences moindres mais notables. Pour R_aL , la vitesse de coupe n'a pas d'effet significatif, tandis que l'avance par tour a l'influence la plus significative sur la rugosité longitudinale, suivie par la profondeur de passe avec une influence notable mais non significative.

Pour techniques de régression multiple pour modéliser les relations entre les paramètres de coupe et la rugosité de surface, nous explorons des modèles de second et quatrième ordre. Nos analyses révèlent que le modèle de quatrième ordre est supérieur en termes de précision et de capacité à capturer les nuances complexes des données expérimentales.

Nous intégrons des techniques de machine learning pour améliorer encore la précision de nos prédictions. Nous comparons plusieurs modèles, y compris le deep learning, les arbres de décision, les forêts aléatoires, et l'arbre boosté par gradient, sur plusieurs critères de prédiction. Nos résultats montrent que, pour la rugosité longitudinale (R_aL), le modèle d'arbre de décision se distingue par sa performance supérieure. Ce modèle nous permet de prédire la rugosité avec une grande précision, répondant ainsi aux exigences strictes de l'industrie.

Concernant la rugosité arithmétique totale (R_aT), nous constatons que le modèle de forêt aléatoire offre les meilleurs résultats. Ce modèle démontre une capacité remarquable à capturer la variabilité des données et à fournir des prédictions fiables. En particulier, nous prédisons une rugosité arithmétique transversale (R_aT) de 1,159, validée par des tests expérimentaux où nous mesurons une valeur de 1,86, démontrant ainsi la robustesse et l'efficacité de notre approche basée sur le machine learning.

Pour finir, notre travail illustre l'importance de combiner des techniques statistiques traditionnelles avec des méthodes modernes d'apprentissage automatique pour analyser et modéliser les conditions de coupe et améliorer la qualité de l'usinage. Les résultats soulignent non seulement la précision de nos modèles, mais aussi leur applicabilité pratique dans un contexte industriel. Ces avancées ouvrent la voie à des optimisations futures et à une meilleure compréhension des processus de fabrication.

Pour les futures recherches, deux directions clés peuvent être envisagées : premièrement, la création d'un logiciel de simulation intégrant à la fois le machine learning et la méthode des éléments finis, visant à prédire avec précision et efficacité les résultats de coupe tout en minimisant l'utilisation des ressources. Cette approche permettrait de développer des outils de simulation robustes et optimisés. Deuxièmement, l'exploration des possibilités offertes par les modèles de deep learning pour le suivi en temps réel et la caractérisation de la rugosité des surfaces usinées, offrant ainsi une méthode novatrice pour améliorer la qualité des surfaces usinées et optimiser les processus de fabrication.

References

- [1] *Absolute and Relative Error- Definition, Formulas, and Examples*. URL : <https://byjus.com/maths/absolute-and-relative-error/> (visité le 25/05/2024).
- [2] *Alliages d' Aluminium*. URL : <https://www.euralliage.com/alliage.html> (visité le 10/06/2024).
- [3] *Analyse de la variance ANOVA : définition et test*. Qualtrics. URL : <https://www.qualtrics.com/fr/gestion-de-l-experience/etude-marche/analyse-variance/> (visité le 07/06/2024).
- [4] *Arbre de Décision — Wikipédia*. URL : https://fr.wikipedia.org/wiki/Arbre_de_d%C3%A9cision (visité le 24/06/2024).
- [5] Abdallah ASHRAF. *Correlation in Machine Learning — All You Need to Know*. Medium. 22 sept. 2023. URL : <https://medium.com/@abdallahashraf90x/all-you-need-to-know-about-correlation-for-machine-learning-e249fec292e9> (visité le 25/05/2024).
- [6] Julie COLAS. *Comprendre l'analyse de la variance (ANOVA) et le test F*. URL : <https://blog.minitab.com/fr/comprendre-lanalyse-de-la-variance-anova-et-le-test-f> (visité le 27/06/2024).
- [7] *Définition du fraisage : technique de fabrication | Inox Design*. URL : <https://www.inoxdesign.fr/definitions/fraisage.html> (visité le 24/06/2024).
- [8] *Destaurer la puissance de R carre expliquer le coefficient de determination*. FasterCapital. URL : <https://fastercapital.com/fr/contenu/Destaurer-la-puissance-de-R-carre--expliquer-le-coefficient-de-determination.html> (visité le 26/06/2024).
- [9] *Données techniques Aluminium*. Almet Metal. URL : <https://almet-metal.com/informations-techniques/donnees-aluminium> (visité le 09/05/2024).
- [10] *Finite Element Modeling : Meaning, Examples, Applications*. Vaia. URL : <https://www.vaia.com/en-us/explanations/engineering/solid-mechanics/finite-element-modeling/> (visité le 07/06/2024).
- [11] Mayssa GUEDICHE. “Modélisation et Simulation de l’Usure des Outils de Coupe au cours du processus d’enlèvement de matière : Approche expérimentale et numérique (MOSUOC)”. Accédé le 24 juin 2024. Thèse de doctorat. Lyon, France : Ecole Centrale de Lyon, 2017.
- [12] *Introduction to Boosted Trees – The Official Blog of BigML.Com*. URL : <https://blog.bigml.com/2017/03/14/introduction-to-boosted-trees/> (visité le 24/06/2024).
- [13] *L'actualité de La Fabrication Additive et de l'impression 3D*. URL : <http://actu-imprimante3d.blogspot.com/2014/11/technique-impression-3d-> (visité le 24/06/2024).
- [14] *Les différentes applications de l'aluminium et sa polyvalence*. 19 déc. 2023. URL : <https://www.installux-es.com/fr/blog/applications-d-aluminium-dans-l-industrie> (visité le 24/06/2024).
- [15] *Machine Learning : The Future of Intelligence | Definition, Types, and Examples*. SAP. URL : <https://www.sap.com/africa/products/artificial-intelligence/what-is-machine-learning.html> (visité le 24/06/2024).
- [16] *McMaster-Carr*. URL : <https://www.mcmaster.com/> (visité le 09/05/2024).

- [17] *Neural Network Deep Learning* | *Free SVG*. URL : <https://freesvg.org/1541102393> (visité le 19/05/2024).
- [18] *Qu'est-Ce Qu'un Arbre de Décision ?* | *Lucidchart*. URL : <https://www.lucidchart.com/pages/fr/arbre-de-decision> (visité le 17/05/2024).
- [19] *Qu'est-ce que le Machine Learning ?* | *Définition*. SAP. URL : <https://www.sap.com/france/products/artificial-intelligence/what-is-machine-learning.html> (visité le 17/05/2024).
- [20] *Régression linéaire multiple*. URL : <https://www.voxco.com/fr/blog/regression-lineaire-multiple/> (visité le 20/05/2024).
- [21] Janosh RIEBESELL. *Random Forest* | *TikZ Diagrams*. URL : <https://janosh.github.io/tikz/random-forest> (visité le 19/05/2024).
- [22] *RMSE (Erreur Quadratique Moyenne)*. URL : https://docs.oracle.com/cloud/help/fr/pbcs_common/PFUSU/insights_metrics_RMSE.htm#PFUSU-GUID-FD9381A1-81E1-4F6D-8EC4-82A6CE2A6E74 (visité le 25/06/2024).
- [23] Jérémy ROBERT. *Random Forest : Forêt d'arbre de décision- Définition et fonctionnement*. Formation Data Science | DataScientest.com. 24 sept. 2020. URL : <https://datascientest.com/random-forest-definition> (visité le 19/05/2024).
- [24] Abdel-Ali SELAÏMIA. “Étude de l'usinage des aciers inoxydables lors du fraisage de face”. Thèse de doct. Guelma, Algérie : Université du 08 Mai 45 Guelma, 2017.
- [25] Christophe TOURNIER. *Usinage à grande vitesse : Technologies, modélisations et trajectoires*. Technique et ingénierie. Existe au format livre et ebook. Paris : Dunod, 2010.
- [26] *Tout Savoir Sur Le Gradient Boosting Tree - AI for You*. URL : <https://www.aiforyou.fr/tout-savoir-sur-le-gradient-boosting-tree/> (visité le 19/05/2024).
- [27] B. VASQUES. “Étude du comportement du rayon d'arête et de son influence sur l'intégrité de surface en tournage sec”. Thèse de doct. Tours, France : Université François-Rabelais de Tours, juin 2008.

Résumé

Ce mémoire se focalise sur l'étude de l'influence des conditions de coupe sur la rugosité longitudinale et transversale lors du fraisage sur le flanc sans lubrification, ainsi que sur leur modélisation par régression multiple et machine Learning. L'analyse de cette influence repose sur des observations réalisées pendant l'usinage et l'application de la méthode ANOVA. La modélisation par régression a été effectuée à l'aide de modèles de deuxième et quatrième ordre, tandis que le machine Learning a été exploré à travers plusieurs méthodes telles que le Deep Learning, les arbres de décision, les forêts aléatoires, et les arbres boostés par gradient. L'objectif principal est de déterminer précisément comment différents paramètres de coupe affectent la qualité des surfaces usinées et ce en combinant des approches traditionnelles et modernes, Ce travail nous a permis de développer des modèles robustes permettant de prédire avec exactitude les résultats d'usinage, réduisant ainsi les erreurs de fabrication et améliorant la qualité des produits finaux.

Mots clés : Usinage sur le flanc, Rugosité, Fraise monobloc ARS, Aluminium, ANOVA, Prédiction, Régression multiple, Machine Learning.

Abstract

This thesis focuses on the study of the influence of cutting conditions on longitudinal and transverse roughness during flank milling without lubrication, as well as their modeling using multiple regression and machine learning. The analysis of this influence is based on observations made during machining and the application of the ANOVA method. The regression modeling was performed using second and fourth-order models, while machine learning was explored through several methods such as deep learning, decision trees, random forests, and gradient-boosted trees. The main objective is to precisely determine how different cutting parameters affect the quality of machined surfaces by combining traditional and modern approaches. This work has allowed us to develop robust models that accurately predict machining outcomes, thereby reducing manufacturing errors and improving the quality of final products.

Keywords: Flank milling, Roughness, Monobloc ARS cutter, Aluminum, ANOVA, Prediction, Multiple Regression, Machine Learning.