

REPUBLIQUE DU CAMEROUN  
Paix – Travail – Patrie  
-----  
UNIVERSITE DE YAOUNDE I  
-----  
ECOLE NORMALE SUPERIEURE  
D'ENSEIGNEMENT TECHNIQUE  
-----  
DEPARTEMENT DE GENIE MECANIQUE  
  
BP. 886 Ebolowa



REPUBLIC OF CAMEROON  
Peace – Work – Fatherland  
-----  
THE UNIVERSITY OF YAOUNDE I  
-----  
HIGHER TECHNICAL TEACHER  
TRAINING COLLEGE  
-----  
DEPARTMENT OF MECHANICAL  
ENGINEERING  
P.O. Box. 886 Ebolowa

## MESURE PAR APPRENTISSAGE AUTOMATIQUE DES PARAMETRES DE RUGOSITE DES SURFACES FRAISEES

Mémoire présenté en vue de l'obtention du Diplôme de Professeur des Lycées  
d'Enseignement Technique II (DIPET II)

**OPTION : FABRICATION MECANIQUE**

Par :

**NZOKOU TCHEDJOU Modeste**

**Matricule : 19W1231**

Sous la supervision de :

**Pr KANAA Thomas**

(Maitre De Conférence)

**Devant le jury constitué de :**

**Président :** - Pr NDJAKOMO Salomé (Maitre De Conférence)

**Rapporteur :** - Pr KANAA Thomas (Maitre De Conférence)

-M. NGONGANG Ludovic (assistant)

**Examineur :** - M. ATANGANA Mesmin (assistant)



Année académique : 2020-2021

---

Dédicace

---

A LA FAMILLE TCHEDJOU

---

## Remerciements

---

L'accomplissement d'un mémoire implique un effort personnel particulier, aussi il s'agit d'un travail d'équipe qui implique la participation de divers intervenants. Dans cette page je remercie toutes ces personnes qui ont contribué à l'aboutissement de ce travail.

Je tiens tout d'abord à remercier mon équipe d'encadrement : le superviseur le Professeur KANAA Thomas, pour avoir accepté la supervision de nos travaux et pour son suivi permanent ; Mon encadreur Monsieur NGONGANG Ludovic, pour ses conseils et son assistance durant ces longs mois de travaux, il a su m'inculquer la rigueur scientifique.

J'exprime aussi toute ma profonde gratitude à l'endroit de Madame le Directeur, le Professeur SALOME NDJAKOMO ESSIANE pour le cadre convivial de notre formation et au personnel enseignant et administratif de l'ENSET d'Ebolowa pour leur encadrement.

Je tiens également à remercier les membres du jury Pr NDJAKOMO Salomé, Pr KANAA Thomas, M. NGONGANG Ludovic, M. ATANGANA Mesmin pour leur collaboration durant l'examen de ce travail et leur participation à la soutenance.

A mes parents, mon père TCHEDJOU Georges et ma défunte mère TEUMEU Marie Noël ; Je ne serais jamais là sans vous, merci pour la force que vous donnez c'est dans le souci de vous rendre fière que je suis en arrivé là.

À mes frères et sœurs NKOUENJI Steve, MATSINDJOU Alvine, MBUNTCHA Chanel, YANGO Raoul, KEGNE Brice pour leur accompagnement et leur soutien moral et financier.

Je ne saurais oublier l'époux de ma grande sœur ZEFO Noël qui n'a jamais hésité à me tendre la main pour m'aider moralement et financièrement. Tu portes si bien le Prénom de notre défunte Mère.

Bien entendu, je remercie tous mes camarades de classe qui ont tous contribué, d'une manière ou d'une autre, à la réussite de ce mémoire.

Pour ceux qui n'ont pas trouvé leur nom dans cette liste et qui ont contribué à ce travail, je les en remercie et m'excuse de cet inacceptable oubli.

---

## Résumé

---

Les méthodes d'apprentissage automatique prennent de plus en plus de place dans les sciences fondamentales et en ingénierie, le vaste domaine de la métrologie n'en fait pas exception car le challenge aujourd'hui est d'intégrer les méthodes numériques de calcul dans le but d'optimiser le process de fabrication et de contrôle. Le but de ce mémoire est de mettre sur pied des méthodes de prédiction de la rugosité des surfaces fraisées par apprentissage automatique. Des modèles de Machine Learning tels que le réseau de neurones artificiel, la régression linéaire multiple, la régression par support de vecteur et la régression par arbre de décision ont été développés. Le temps de coupe, le pourcentage de carbone du matériau usiné et la nature de l'outil ont été pris comme variables d'entrée des systèmes prédictifs. L'environnement de programmation Python a servi pour le développement des algorithmes. La base de données utilisée a consisté en 3 datasets, un pour l'acier rapide, un autre pour carbure de tungstène et un dernier combinant les 2 datasets précédant. Les modèles ont été développés en utilisant 48 expériences pour le dataset combiné et 24 pour les 2 autres datasets réparties en 75% pour la phase d'entraînement, 25% pour la phase de test. L'erreur quadratique moyenne (MSE) utilisée pour évaluer la performance des systèmes prédictifs accorde un choix privilégié à l'ANN avec l'outil en carbure de tungstène en entrée avec une valeur  $MSE=0,017$ .

**Mots clés** : Rugosité de surface, Réseau de neurones artificiel, Régression linéaire multiple, Régression par support de vecteur, Régression par arbre de décision, Fraisage

---

Abstract

---

Machine learning methods are gaining more and more space in basic sciences and engineering, the vast field of metrology is no exception because the challenge today is to integrate numerical methods of calculation in order to optimize the manufacturing and control process. The aim of this thesis is to set up methods for predicting the roughness of milled surfaces by machine learning. Machine learning models such as artificial neural network, multiple linear regression, vector support regression and decision tree regression have been developed. The cutting time, the percentage of carbon of the material machined and the nature of the tool were taken as input variables of the predictive systems. The Python programming environment was used for the development of the algorithms. The database used consisted of 3 datasets, one for high speed steel, another for tungsten carbide and a last combining the 2 previous datasets. The models were developed using 48 experiments for the combined dataset and 24 for the other 2 datasets distributed in 75% for the training phase, 25% for the test phase. The root mean square error (MSE) used to evaluate the performance of predictive systems gives a preferred choice to the ANN with the tungsten carbide tool as input with an MSE value = 0.017.

**Keywords:** Surface roughness, Artificial neural network, Multiple linear regression, Vector support regression, Decision tree regression, Milling

---

SOMMAIRE

---

Dédicace.....	2
Remerciements.....	3
Résumé.....	4
Abstract.....	5
Table des matières.....	6
Liste des Tableaux.....	6
Liste des Figures.....	7
Liste des Symboles et Abréviations.....	8
CONCLUSION GÉNÉRALE ET PERSPECTIVES.....	84
BIBLIOGRAPHIE.....	85
I.1. SURFACE.....	14
I.1.1. Généralité sur la surface.....	14
I.1.2. Modes d'obtention des surfaces.....	15
I.1.3. Surface fraisée.....	19
I.1.4. Mesure de la surface.....	23
I.1.5. Méthode mécanique de mesure de la rugosité de surface.....	27
I.1.6. Méthode optique de mesure de la rugosité de surface.....	28
I.2. APPRENTISSAGE AUTOMATIQUE COMME OUTIL DE PREDICTION DE LA RUGOSITE.....	29
I.2.1. Généralité sur l'apprentissage automatique.....	29
I.2.2. Méthodes de mesure par apprentissage automatique de la rugosité.....	32
I. CONCLUSION.....	34
II.1. LE RESEAU DE NEURONES ARTIFICIEL.....	36
II.1.1. Nicholas E. Sizemore, Monica L. Nogueira, Noel P. Greis et Matthew A. Davies (2020) [21].....	36
II.1.2. Md. Shahriar Jahan Hossain et Dr. Nafis Ahmad (2012) [22].....	38
II.1.3. Marek Vrabel (2012) [23].....	39
II.1.4. Rajesh M. et Dr. R Manu (2014) [24].....	40
II.1.5. Ludovic Ngongang et al. (2021) [25].....	41
II.2. REGRESSION LINEAIRE MULTIPLE.....	42
II.2.1. Dhiren R. Patel Mysore et B. Kiran Vinay Vakharia (2019) [26].....	42
II.2.2. Ibrahim A Badi, Ali G Shetwan, Maitig A (2017) [27].....	44

II.3. REGRESSION PAR SUPPORT DE VECTEUR.....	44
II.3.1. Ulas Çaydas et Sami Ekici (2010) [28].....	44
II.3.1. JuanLu et al. (2019) [29].....	45
II.4. ARBRE DE DECISION .....	46
II.4.1. Vijay Kumar, Sanjay Kumar Et Prashant Prakash (2011) [30] .....	46
II.4.2. Juan M. Barrios and Pablo E. Romero (2019) [31] .....	47
II.5. SYNTHESE GENERALE SUR LA MESURE DE LA RUGOSITE PAR APPRENTISSAGE AUTOMATIQUE .....	49
Rajesh M. et Dr. R Manu (2014) [24] .....	50
Dhiren R. Patel Mysore et B. Kiran Vinay Vakharia (2019) [26].....	50
Ibrahim A Badi, Ali G Shetwan, Maitig A (2017) [27] .....	51
Ulas Çaydas et Sami Ekici (2010) [28] .....	52
JuanLu et al. (2019) [29] .....	52
Vijay Kumar, Sanjay Kumar Et Prashant Prakash (2011) [30] .....	52
Juan M. Barrios and Pablo E. Romero (2019) [31] .....	52
Ludovic Ngongang et al. (2021) [25].....	53
II.6. CONCLUSION.....	54
III.1. MATERIELS.....	56
III.2. MÉTHODES .....	57
III.2.1. Régression Linéaire Multiple .....	59
III.2.2. Régression par support de vecteur.....	61
III.2.3. Régression par arbre de décisions .....	61
III.2.4. Les réseaux de neurones artificiels.....	62
III.3. CONCLUSION .....	66
IV.1. RESULTATS .....	68
IV.1.1. Régression linéaire multiple.....	68
IV.1.2. Régression par support de vecteur .....	69
IV.1.3. Régression avec arbre de décision .....	70
IV.1.4. Réseaux de neurones artificiels.....	72
IV.2. BILAN DE PERFORMANCE DE CHAQUE MODELE .....	73
IV.3. DISCUSSION .....	74
IV.4. DEVELOPPEMENT D'UNE APPLICATION POUR LE DEPLOIEMENT.....	75
IV.5. CONCLUSION .....	75

---

Liste des Tableaux

---

Tableau 1 : catalogue paramètre de coupe fraisage [9] .....	24
Tableau 2 : outillage utilisé pour les deux Études .....	42
Tableau 3 : Ra moyenne et taux d'erreur pour l'ensemble de données Ge.....	42
Tableau 4 : Rq moyenne et taux d'erreur pour l'ensemble de données Ge .....	43
Tableau 5 : Rz moyenne et taux d'erreur pour l'ensemble de données Ge.....	43
Tableau 6 : taux d'erreur des différents modèles utilisés.....	44
Tableau 7 : résultats obtenus pour chaque modèle.....	47
Tableau 8 : caractéristique de l'ordinateur utilisé.....	61
Tableau 9 : dataset pour fraisage avec carbure de tungstène (Tc en s, Ra en $\mu\text{m}$ ) [28] .....	62
Tableau 10 : dataset pour fraisage avec acier rapide (Tc en s, Ra en $\mu\text{m}$ ) [28] .....	62



---

Liste des Figures

---

Figure 1.2: processus de moulage [6].....	19
Figure 1.3: schéma de principe du procédé de thermoformage [7].....	20
Figure 1.4 : schéma d'obtention d'une pièce par Injection thermoplastique [7].....	20
Figure 1.5 : fraisage en bout [8] .....	21
Figure 1.6: fraisage en roulant [8] .....	21
Figure 1.7 : fraisage combiné [8] .....	21
Figure 1.8 : Le fraisage en opposition [6] .....	21
Figure 1.9 : Le fraisage en avalant [6].....	22
Figure 1.10 : opération d'usinage en tournage [7] .....	22
Figure 1.11 : Opération de rectification [8].....	23
Figure 1.12 : paramètre de coupe [11] .....	23
Figure 1.14 : épaisseur du copeau [10] .....	26
Figure 1.15 : Signature surfaces fraisée de face [10] .....	26
Figure 1.18 : rugosité arithmétique moyenne Ra [11].....	28
Figure 1.19 : rugosité quadratique Rq [11] .....	29
Figure 1.21 : vallée la plus profonde Rv.[11] .....	29
Figure 1.22 : hauteur maximale des pics Rp.[11] .....	30
Figure 1.23 : Hauteur maximale moyenne Rz [12].....	31
Figure 1.24 : profilomètre [13].....	31
Figure 1.25: Rugosimètre digital [15] .....	32
Figure 1.27: microscope à effet tunnel électronique .....	33
Figure 1.28: Principe de l'ellipsomètre à modulation de phase (adapté de (Benatmane, 2002)). [18].....	33
Figure 1.39 : Représentation d'un réseau de neurones [20] .....	37
Figure 1.30 : Opérations au niveau de chaque neurone [20].....	38
Figure 1.31 : Régression par le Support Vecteur Machine [20].....	39
Figure II.2 : vue rapprochée de l'interaction outil-pièce de tournage au diamant.....	42
Figure II.1 : illustration de l'opération .....	42
Figure II.3 : réseau de neurones utilisés .....	42
Figure II.4 : entré et sortie du réseau de neurone utilisés.....	44

Figure II.6 : réseau de neurone utilisés .....	45
Figure II.7 : dispositifs utilisés .....	46
Figure II.8 : dispositif utilisé .....	48
Figure II.9 : précision du modèle de régression linéaire .....	49
Figure II.10 : précision du modèle de régression non linéaire .....	49
Figure II.11 : process utilisé .....	53
Figure III.1 : synoptique général de notre méthode .....	63
Figure III.2 : synoptique régression linéaire multiple .....	65
Figure III.3 : exemple de régression par support de vecteur .....	66
Figure III.4 : exemple de régression par arbre de décision .....	66
Figure III.5 : structure de base d'un réseau de neurones artificielle .....	67
Figure III. 6 : partie de notre réseau utiliser pour expliquer le fonctionnement de base .....	67
Figure III.7 : structure du réseau de neurones utilisé pour chaque dataset .....	68
Figure III.8 : structure du réseau de neurones utilisé pour les deux datasets combiné .	68
Figure III.9 : courbe de la fonction sigmoïde .....	69
Figure III.10 : courbe de la fonction Relu .....	69
Figure III.11 : courbe d'apprentissage (acier rapide) .....	70
Figure III.12 : courbe d'apprentissage (carbure de tungstène) .....	70
Figure III.13 : courbe d'apprentissage (acier rapide et carbure de tungstène) .....	70
Figure III.14 : synoptique réseau de neurone artificiel .....	71
Figure IV.1 : courbe de précision des deux datasets combiné (ARS+WC) .....	73
Figure IV. 3 : courbe de précision du dataset du carbure de tungstène (WC) .....	74
Figure IV.5 : courbe de précision du dataset de l'acier rapide (ARS) .....	75
Figure IV.6 : courbe de précision du dataset du carbure de tungstène (WC) .....	75
Figure IV.7 : courbe de précision des deux datasets combiné (ARS+WC) .....	76
Figure IV.9 : courbe de précision du dataset du carbure de tungstène (WC) .....	77
Figure IV.11 : courbe de précision du dataset de l'acier rapide (ARS) .....	78
Figure IV.12 : courbe de précision du dataset du carbure de tungstène (WC) .....	78
Figure IV.14 : interface d'utilisation .....	80

Liste des Symboles et Abréviations

<b>SYMBOLES</b>		
Pp ou p	Profondeur de passe	mm
V <sub>c</sub>	Vitesse de coupe	mm/min
f <sub>z</sub>	Avance par dent	mm/tr/dent
z	Nombre de dents de la fraise	/
V <sub>f</sub>	Vitesse d'avance	mm/min
N	Vitesse de rotation	tr/min
R <sup>2</sup>	Corrélation statistique	/
R <sub>a</sub> ,	Rugosité arithmétique moyenne	μm
R <sub>z</sub> ,	Rugosité maximale du profil	μm
R <sub>t</sub>	Rugosité totale	μm
R <sub>q</sub>	Rugosité quadratique moyenne	μm
ϕ	Diamètre de l'outil	mm
<b>ABRÉVIATIONS</b>		
<b>Sigle</b>	<b>Définition</b>	
ANN	Artificial Neural Network	
SVM	Support Vector Machine	
SVR	Support Vector Regression	
RMS	Root Mean Square	
RMSE	Root Mean Square Error	
MSE	Mean Square Error	
SVM-KM	SVM based on clustering by k-means	
ABC-SVM	Artificial Bee Colony- Support Vector Machine	
DE-SVM	Differential Evolution- Support Vector Machine	
GA-SVM	Genetic Algorithm- Support Vector Machine	
ANFIS	Adaptive Neuro-Fuzzy Inference System	
RBF kernel	Noyau de fonction de base radiale	
SSE	Sum of Squared Errors	
ENSET	Ecole Normale Supérieur d'Enseignement Technique	

---

## *INTRODUCTION GENERALE*

---

### **1. Contexte**

Dans le domaine mécanique, la qualité de surface (rugosité et texture) est un requis qualité très importante pour les pièces. Spécialement dans des secteurs tel que l'aéronautique et l'automobile, ce requis est critique pour la fiabilité en fatigue [2]. En effet, l'amorce des fissures est directement liée à la qualité de surface. La mesure de la rugosité se fait généralement dans un poste de métrologie avec des instruments et des techniques très variés et qui consomment généralement beaucoup de ressources (temps, opérateurs et équipement). Les systèmes de mesure sans contact (ex. crayon confocal) proposés aujourd'hui dans le secteur sont, non seulement sont très coûteux, mais aussi très encombrant pour une utilisation dans un poste d'usinage. La rugosité définit la profondeur caractéristique des stries sillonnant une surface. Ses principaux critères de mesure sont : la rugosité totale  $R_t$ , la rugosité moyenne arithmétique  $R_a$  et la régularité  $R_z$ . Plus souvent notée  $R_a$  et exprimée en millimètre, la rugosité est l'une des caractéristiques essentielles de l'état de surface d'un matériau solide.  $R_a$  est déterminée comme une moyenne arithmétique de la position du profil par rapport à une ligne moyenne (ou surface de référence) sur une longueur donnée. [1]

Vue cette définition, il apparaît directement qu'elle joue un rôle très important dans la tribologie qui, de par ses domaines d'études, joue un rôle significatif dans les domaines industriels. Notamment lorsqu'il s'agit de la conservation de l'énergie, la fiabilité des systèmes, la productivité, le développement et la fabrication de nouveaux équipements et même dans la mise en œuvre des matériaux ; compte tenu du fait que leurs caractéristiques mécaniques telles que la ductilité et la fragilité impose un type de contact et des lois de frottement et d'usure différentes.[3]

C'est dans l'optique de rendre aisée la mesure de la rugosité qu'il a été initié ce projet sur la mise sur pied d'une méthode de mesure par apprentissage automatique des paramètres de rugosité des surface fraisées.

### **2. Problématique et question de recherche**

Malgré l'importance de la maîtrise de l'état de surface dans la conception des pièces mécaniques, il reste encore à intégrer le concept de mesure automatique de la rugosité comme étape de fabrication des pièces mécaniques. La difficulté pour ce faire réside peut-être dans la complexité rencontrée lors de la mesure de la rugosité et le temps nécessaire pour effectuer cette prédiction.

Il nous est donc venu à l'idée de nous questionner quant au moyen de faire de la prédiction de la rugosité une réalité dans nos ateliers. En quelque sorte, comment assurer une mesure rapide, fiable et aisée de la rugosité des pièces fraisées ?

### **3. Objectifs de l'étude**

L'objectif général de ce projet est la mise sur pied d'une méthode de mesure par apprentissage automatique des paramètres de rugosité d'une surface fraisée.

Comme objectifs spécifiques nous avons :

- ✓ Elaborer la base de données de facteurs d'entrée d'algorithme
- ✓ Mettre sur pied un programme d'apprentissage automatique en python de mesure de la rugosité
- ✓ Comparer les méthodes développées sur la prédiction de rugosité
- ✓ Proposer une méthode de prédiction privilégiée en rapport avec les facteurs d'entrée

#### 4. PLAN DU MEMOIRE

Ce mémoire se subdivise en 4 chapitres que sont :

**Chapitre 1 : Présentation des surfaces et de l'apprentissage automatique** : nous y présentons la notion de surface en mécanique, les paramètres de surface, les différentes formes de surfaces pouvant être obtenues par fraisage, les paramètres machines pouvant influencer sa qualité et en fin nous donnons une aperçu générale sur l'apprentissage automatique

**Chapitre 2 : Etat de l'art sur la mesure par apprentissage automatique des paramètres de rugosités** : l'étude d'un ensemble d'articles ayant trait à l'utilisation des techniques d'apprentissage automatique dans la mesure de la rugosité y est effectuée. Les efficacités des techniques utilisées sont présentées puis comparées dans un tableau de synthèse.

**Chapitre 3 : Matériels et méthode** : nous présentons le matériel utilisé pour faire notre étude. Nous y présentons aussi sommairement le logiciel utilisé et le protocole d'implémentation de chaque méthode d'apprentissage automatique.

**Chapitre 4 : Résultats et discussions** : nous présentons des courbes de résultats obtenues. Nous comparons les données obtenues de manière expérimentale aux données prédites par les algorithmes et concevons une interface visuelle de détermination de la rugosité.

## Chapitre 1

---

# PRESENTATION DES SURFACES ET DE L'APPRENTISSAGE AUTOMATIQUE

Dans ce chapitre nous introduisons les notions nécessaires liées à la compréhension de la problématique traitée dans notre mémoire. Nous commencerons par présenter en premier, la notion de surface, ensuite, nous aborderons les différents modes de fraisage et insisterons sur l'état de surface et la rugosité des surfaces usinées, nous parlerons également de la mesure de rugosité et finirons par une généralité sur l'apprentissage automatique.

---

I.1. SURFACE.....	14
I.1.1. Généralité sur la surface .....	14
I.1.2. Modes d'obtention des surfaces .....	15
I.1.3. Surface fraisée .....	19
I.1.4. Mesure de la surface.....	23
I.1.5. Méthode mécanique de mesure de la rugosité de surface .....	27
I.1.6. Méthode optique de mesure de la rugosité de surface .....	28
I.2. L'APPRENTISSAGE AUTOMATIQUE COMME OUTIL DE PREDICTION DE LA RUGOSITE .....	29
II.2.1. Généralité sur l'apprentissage automatique .....	29
I.2.2. Méthodes de mesure par apprentissage automatique de la rugosité.....	32

---

## **I.1. SURFACE**

### **I.1.1. Généralité sur la surface**

#### **a) Définition**

La surface physique d'un matériau est la partie extérieure qui constitue la limite de l'espace qu'il occupe. C'est un mélange comprenant des zones avec des propriétés physiques et chimiques liées à l'histoire de leur préparation et à leur interaction avec l'environnement. D'un point de vue de la géométrie analytique, une surface peut être décrite sous forme explicite par l'ensemble des points de coordonnées  $x$ ,  $y$  et  $z$  vérifiant une équation de la forme  $F(x, y, z) = 0$ . Cela permet de révéler points par points les différences d'écart entre la topographie mesurée et le plan moyen.[4]

#### **b) Les surfaces élémentaires en fabrication mécanique**

Classiquement on usine, soit pour la nature des liaisons qu'elles permettent de réaliser soit pour des raisons liées au coût et à la faisabilité, des surfaces ayant les formes suivantes :

- Plane
- Cylindrique, conique ou sphérique
- Hélicoïdale
- Développante

Le principal problème du service méthodes d'usinage (BM) porte sur la réalisation des surfaces qui ne peuvent être obtenues autrement que par enlèvement de matière. Selon l'aspect considéré, la surface usinée sera prise en compte :

- Seule : elle doit être générée en tenant compte des qualités géométriques et physiques données (ex : tolérances de formes et états de surfaces). Ceci nécessite la bonne connaissance des outils, de leurs mouvements de travail, des machines-outils (MO) et de leurs cinématiques. La qualité des surfaces dépend de différents autres paramètres dont les plus importants sont la mise en position et les raideurs des pièces, outils, machines, etc. [4]
- En tant qu'élément d'un ensemble de surfaces : dans ce cas il est impératif de respecter des liaisons dimensionnelles et des tolérances de position. Ceci implique d'une part l'étude de la mise en position de la surface à générer par rapport à l'outil, à la machine et aux autres surfaces de la pièce, et d'autre part la connaissance des performances dimensionnelles et géométriques pouvant réellement être obtenues pour chaque usinage. [4]

La qualité des liaisons dimensionnelles effectivement réalisées est donc dépendantes de :

- La précision du mouvement de génération de l'outil par rapport à la machine,
- La qualité du porte-pièce et de son emplacement sur la machine,
- Les modalités adoptées pour la mise en position (et le maintien) de la pièce dans le porte-pièce.

### c) Différents types de surfaces

Nous pouvons classer les types de surface dans un tableau comme suit :

- **Surface de référence** : Surface par rapport à laquelle les spécifications géométriques sont données.
- **Surface réelle** : Surface fabriquée avec tous ses défauts
- **Surfaces spécifiées** : Surface définie par le dessin
- **Surface auxiliaire** : Surface spécifiée en contact avec un point de la surface réelle
- **Surface enveloppe** : Surface en contact complet avec la surface réelle du côté libre de la pièce.[5]




Figure 1.1: différents types de surface [5]

### I.1.2. Modes d'obtention des surfaces

#### a) Technique de coulée et de formage

##### i. Le Moulage

Le moulage permet d'obtenir des pièces complexes en coulant du métal en fusion dans un moule [6]. Nous pouvons prendre comme exemple la fabrication d'une poulie. La fabrication d'une poulie se fait à l'aide d'un moule en 3 parties. Une fois démoulée, la poulie est brute et rugueuse (surface bleue fonctionnelles (surfaces rouges).




Figure 1.2: processus de moulage [6]

##### ii. Thermoformage des thermoplastiques



Le principe du thermoformage consiste à utiliser la pression atmosphérique pour déformer une plaque de thermoplastique suffisamment souple (état obtenu par chauffage).

La plaque est tout d'abord chauffée, puis elle est transférée au-dessus d'un moule et fixée par des serre-flans. On réalise le vide entre la plaque et le moule ; sous l'action de la pression atmosphérique, la plaque se déforme et vient épouser la forme du moule.

Une fois la plaque refroidie, on la démoule. Si nécessaire, on détourne la pièce, c'est-à-dire qu'on retire la bande autour de la pièce qui a servi au maintien de la plaque.




Figure 1.3: schéma de principe du procédé de thermoformage [7]

### iii. Injection des thermoplastiques

Composition d'une presse d'injection plastique : les granulés de plastique, une fois fondus, sont introduits en force dans le moule.




Figure 1.4 : schéma d'obtention d'une pièce par Injection thermoplastique [7]

## b) Obtentions des surfaces par usinages

### i. Fraisages

Le fraisage est une technique d'usinage qui consiste à enlever, à l'aide d'un outil coupant appelé fraise de la matière sur une pièce initiale pour obtenir une pièce finale. La fraise est munie de dents et est de forme variable. Une pièce fraisée comporte des surfaces planes ou des contours ayant un très bon état de surface.

#### ➤ Surface obtenue par fraisage

Le fraisage se prête notamment à la réalisation de formes plus complexes (plan, rainure, languette, trou oblong, queues d'aronde, ...), mais aussi à l'usinage de trous et d'alésages, situés n'importe où sur la pièce à réaliser.

➤ **Principales opérations d'usinage en fraisage**

- Fraisage de face (ou en bout)

La surface usinée est obtenue en travail enveloppe par la denture du bout de la fraise. On utilise généralement une fraise 2 Tailles pour ce genre d'opérations. Cela permet de faire des épaulements et certaines opérations de contournage. [8]




Figure 1.5 : fraisage en bout [8]

- Fraisage en roulant

La surface usinée est obtenue en travail de forme par la denture latérale de la fraise. Nous pouvons obtenir des formes arrondies et des surfaces planes. Pour ce type d'usinage, la surface à réaliser est parallèle à l'axe de la fraise, elle est réalisée par une génératrice de coupe. [8]




Figure 1.6: fraisage en roulant [8]

- Fraisage combiné (Surfaçage/dressage)




Figure 1.7 : fraisage combiné [8]

La surface usinée est obtenue par l'usinage simultané de deux surfaces dont l'une est faite en fraisage de face et l'autre en profil. Le choix de la prédominance est fonction de plusieurs critères : possibilité de l'outillage ; accessibilité des surfaces ... [8]

➤ **Modes de travail en fraisage**

On distingue deux modes de travail :

- Le fraisage en opposition

Le mouvement d'avance  $M_f$  de la pièce et le mouvement de coupe  $M_c$  de la fraise dans la zone fraisée sont de sens contraire. L'épaisseur du copeau est faible à l'attaque, puis maximale en fin de trajectoire de la dent. La résultante  $R$  des efforts de coupe est dirigée dans le sens opposé au  $M_f$ . Elle tend à soulever la pièce de ses appuis. [6]




Figure 1.8 : Le fraisage en opposition [6]

- Le fraisage en avalant

Le mouvement  $M_f$  de la pièce et le mouvement de coupe  $M_c$  de la fraise dans la zone fraisée sont de même sens. L'épaisseur du copeau est maximale à l'attaque puis devient nulle en fin de trajectoire de la dent. La résultante des efforts de coupe  $R$  est dirigée dans le même sens que le  $M_f$ . Elle tend à faire plaquer la pièce sur ses appuis.[6]




Figure 1.9 : Le fraisage en avalant [6]

## ii. Tournage

Le tournage est particulièrement adapté à la réalisation de pièces cylindriques, conique et tronconiques. Celles-ci peuvent être petites ( $\phi$  de 1 mm) ou très grandes ( $\phi$  de plusieurs mètres) selon la machine utilisée. [7]

- Principales opérations d'usinage en tournage




Figure 1.10 : opération d'usinage en tournage [7]

- Paramètres d'usinage

Les paramètres d'usinage sont notamment : la vitesse de coupe  $V_c$ , la vitesse d'avance  $V_f$  et la puissance de coupe  $P_c$ .

## c) Autres méthodes d'usinage

### ➤ Usinage par abrasion

L'usinage par abrasion consiste à enlever une partie de la matière de pièces généralement métalliques au moyen d'outils constitués de particules coupantes agglomérées par un liant. Chaque particule au contact avec la pièce à grande vitesse (de l'ordre de 30 m.sec-1) génère un copeau de très petite




Figure 1.11 : Opération de rectification [8]

section (ordre de grandeur du micromètre). Le copeau n'est pas « tranché » mais « gratté ».

Les rectifieuses et les affûteuses n'utilisent pas des outils coupants mais des meules abrasives. L'usinage par abrasion correspond le plus souvent à une opération de finition qui a pour but essentiellement d'améliorer les états de surface et les tolérances dimensionnelles ; mais ne permet pas l'obtention de la géométrie des surfaces. [8]

### I.1.3. Surface fraisée

#### a) Détermination des paramètres de coupe

L'objectif final est d'obtenir une pièce usinée dans de bonnes conditions. Pour cela il faut déterminer certains paramètres spécifiques : [11]

- La vitesse de coupe :  $V_c$  ;
- La vitesse d'avance :  $F$  ;
- La profondeur de passe :  $a$  ;




Figure 1.12 : paramètre de coupe [11]

#### ➤ La vitesse de coupe : $V_c$ [m/min]

Le choix de la vitesse de coupe dépend de nombreux paramètres dont les principaux sont :

- La durée de l'outil entre deux affûtages ;
- La nature et l'état du métal à usiner ;
- La nature de l'outil ;
- La lubrification ;
- Le mode de travail de l'outil ;
- La section du copeau

Les conditions de coupe imposées dans les tableaux sont données pour une durée de vie d'outil (entre deux affûtages ou rotation de plaquette) de 60 à 90 minutes. Seuls des essais peuvent permettre de déterminer les conditions de coupe optimales. [9]

#### ➤ La vitesse d'avance : $V_f$

En usinage, la vitesse d'avance  $V_f$  est une vitesse exprimée en millimètre par minute (mm/min). Elle peut être calculé avec la formule suivante :

$$V_f = f_z * Z * N$$

$f_z$  : avance par dent ( mm/tr/dent)

$Z$  : nombre de dents de l'outil

$N$  : fréquence de rotation en tours par minute (tr/min)

Elle dépend du type d'opération effectuée, de l'outil, de l'état de surface souhaité, etc. Les valeurs de  $f_z$  sont indiquées dans le tableau ci-dessous ; elles dépendent principalement de la matière à usiner, du matériau de l'outil et du type de fraise utilisé [9]

**Tableau 1** : catalogue paramètre de coupe fraisage [9]

Fraisage de face	Outil A.R.S.			Outil carbure	
	Vc		fz	Vc	fz
	Ebauche	Finition			
Aciers Rm ≤ 70 hbar	22	26	0,15	90	0,2
Aciers Rm de 70 à 100 hbar	18	22	0,12	70	0,2
Aciers Rm de 100 à 120 hbar	16	20	0,1	60	0,15
Fonte Ft 20	22	26	0,15	7	0,25
Fonte GS	16	20	0,12	60	0,2
Laiton	60	80	0,1	220	0,3
Bronze	40	55	0,1	180	0,2
Alliages d'aluminium	100	140	0,1	250	0,2
COEFFICIENTS DE CORRECTION À APPORTER A L'AVANCE PAR DENT fz EN EBAUCHE					
Fraise 1 taille à surfacier : K = 1			Fraise 2 dents à rainurer : K = 0 ,4		
Fraise 2 taille à queue : K = 0 ,4			Fraise 3 taille : K = 0 ,4		
Fraise 2 taille à trou : K = 0 ,7			Fraise à profil constant : K = 0 ,4		
Finition : $f_z = \frac{f_z}{2}$ (ébauche)					

➤ **Profondeur de passe en fraisage : a**

La profondeur de passe (**a**) dépend de la surépaisseur à usiner, ainsi que de la nature de l'opération (ébauche ou finition). Elle tend à diminuer, lorsque les exigences dimensionnelles, géométriques et d'état de surface deviennent plus rigoureuses. Elle ne doit pas être cependant inférieure au copeau minimum. La valeur maximale de (**a**) est limitée par la rigidité de l'outil et la puissance de la machine. [9]

### ➤ Réglage des conditions de coupe

Maintenant il faut régler les conditions de coupe sur la machine. En fait on n'agit que sur 3

Paramètres :

- La fréquence de rotation de la pièce en tournage, ou de l'outil en fraisage (N) ;
- La vitesse d'avance suivant la trajectoire d'usinage (Vf) ;
- La profondeur de passe (a).

Il est donc nécessaire de déterminer les relations entre (Vc), (Vf) et (N). On fixera la profondeur de passe, a, suivant une valeur maximum donnée par le tableau.

Nous disposons d'un tableau de caractéristiques de coupe. Il permet de définir Vc, fz et a en fonction du type de machine, de l'outil, de la matière. [9]

### b) Recommandations générales en fraisages

Comme recommandation on peut citer :

- Les valeurs d'avance pour les fraises à surfacer correspondent à un angle d'attaque de 90° et 75°, pour un angle d'attaque de 45° multiplier par 1,4.
- L'avance choisie doit assurer une épaisseur moyenne des copeaux supérieure ou égale à 0,1 mm par dent et par tour.
- Pratiquer un fraisage conventionnel avec des copeaux les plus fins possibles en sortie de pièce.
- L'arrosage est déconseillé pour la plupart des matériaux, à l'exception des alliages d'aluminium, des alliages réfractaires et des alliages de titane, ainsi que pour éviter le collage dans l'acier inoxydable.

### c) Signature des surfaces fraisée

#### ➤ En fraisage de face

L'aspect d'une surface usinée en fraisage de face est caractérisé par une série de courbes sécantes appelées cycloïdes correspondant à la trace laissée par les dents de la fraise sur la pièce.

- Épaisseur des copeaux

L'intervalle compris entre deux cycloïdes consécutives représente l'épaisseur du copeau. On constate que cette épaisseur varie tout au long de la trajectoire de coupe de la dent. Dans le cas d'une fraise de diamètre supérieur à la largeur de la pièce l'épaisseur est légèrement plus faible à l'entrée et à la sortie de la surface tranchée, pour atteindre son maximum approximativement au niveau de l'axe de la fraise. [10]




Figure 1.14 : épaisseur du copeau [10]

- Etat de surface




Figure 1.15 : Signature surfaces fraisée de face [10]

### ➤ En fraisage de profil

La surface fraisée présente une série d'ondulations laissées par les dents de la fraise :

Celles-ci dépendent de l'avance et du diamètre de l'outil

- Épaisseur des copeaux

Chaque dent de la fraise taille un copeau d'épaisseur croissante :

Nulle à l'attaque au point **A** et maximale à la sortie en **B**.

- État de surface




Figure 1.16 : profile surface obtenue en fraisage de profil [10]

Au point **A**, la dent refuse la coupe et écrouit la matière, l'outil fléchit. Au point **B**, la dent est également soumise à une contrainte de flexion. Ces phénomènes provoquent une série d'ondulations ; l'état de surface est moins satisfaisant qu'en fraisage de face. [10]

#### I.1.4. Mesure de la surface

##### a) La Rugosité

C'est l'ensemble des irrégularités d'une surface à caractère micrographique et macrographique. Les surfaces usinées ne sont pas parfaites, elles présentent des irrégularités dues aux procédés d'usinage, aux outils, à la matière, etc. Le rôle fonctionnel d'une surface dépend d'un certain nombre de facteurs, notamment de l'état de surface (étanchéité, glissement, etc.)

Plus l'indice de rugosité est faible, plus il est difficile à obtenir, ce qui augmente nécessairement le coût de fabrication. [10]

##### i) Principaux paramètres de la rugosité

Un grand nombre de critères sont définis dans la normalisation pour caractériser une rugosité. En pratique, dans un profil et sur une longueur considérée, seuls trois d'entre eux sont retenus :

- **Ra** : écart moyen, c'est la moyenne arithmétique des valeurs absolues des écarts, entre les pics et les creux. "Ra" mesure la distance entre cette moyenne et la ligne centrale. On admet couramment que cette notion synthétise approximativement les différents paramètres intéressés dans la rugosité.
- **Rt** : écart total, c'est la dénivellation la plus importante entre le plus haut sommet d'un pic et le fond le plus bas d'un creux.
- **Rz** : régularité, c'est la moyenne des écarts totaux de rugosité "Rt" observés sur 5 longueurs [7]

##### ii) Les spécifications normalisées

Sur les dessins de définition, les états de surface peuvent faire l'objet de spécification.

Un symbole graphique est utilisé :




Figure 1.15 : symbole graphique de l'état de surface [10]



Ce symbole est complété d'indications relatives au paramètre de rugosité retenu, au procédé de fabrication éventuellement, ...




Figure 1.16 : Exemple de symbolisation [10]

### iii) Paramètres d'amplitude de rugosité

Il existe un grand nombre de paramètres pour la définition de la rugosité, certains sont pourtant beaucoup plus employés que d'autres :

#### ➤ Rugosité arithmétique moyenne $R_a$

Ecart moyen arithmétique. Il s'agit de l'écart moyen de tous les points du profil de rugosité par rapport à une ligne moyenne sur la longueur d'évaluation. Une manière plus ancienne de spécifier une plage de  $R_a$  s'appelle RHR. Il s'agit d'un symbole placé sur un dessin et spécifiant la valeur minimale et maximale de  $R_a$ .

$$R_a = \frac{1}{N} \sum_{j=1}^N |r_j| \quad (1)$$




Figure 1.18 : rugosité arithmétique moyenne  $R_a$  [11]

#### ➤ Rugosité moyenne quadratique $R_q$

Moyenne quadratique des écarts de hauteur sur la longueur d'évaluation et mesurés par rapport à la ligne moyenne

$$R_q = \sqrt{\frac{1}{N} \sum_{j=1}^N r_j^2} \quad (2)$$




Figure 1.19 : rugosité quadratique  $R_q$  [11]

#### ➤ Hauteur maximale du profil $R_t$

Hauteur crête-à-crête maximale. Il s'agit de la valeur absolue entre les hauteurs maximum et minimum Vallée la plus profonde. Il s'agit de la profondeur de la vallée la plus profonde du profil de rugosité sur la longueur d'évaluation

$$R_t = \left| \min_{1 \leq j \leq N} r_j \right| + \left| \max_{1 \leq j \leq N} r_j \right| \quad (3)$$




Figure 1.20 : Hauteur maximale du profil  $R_t$ . [11]

➤ **Vallée la plus profonde  $R_v$**

Il s'agit de la profondeur de la vallée la plus profonde du profil de rugosité sur la longueur d'évaluation.

$$R_v = \left| \min_{1 \leq j \leq N} r_j \right| \quad (4)$$




Figure 1.21 : vallée la plus profonde  $R_v$ . [11]

➤ **Hauteur maximale des pics  $R_p$**

Pic le plus élevé. Il s'agit de la hauteur du pic le plus élevé du profil de rugosité sur la longueur d'évaluation

$$R_p = \left| \max_{1 \leq j \leq N} r_j \right| \quad (5)$$




Figure 1.22 : hauteur maximale des pics  $R_p$ . [11]

➤ **Amplitude moyenne  $R_{tm}$**

Rugosité crête-à-crête moyenne. Elle est déterminée par la différence entre le pic le plus élevé et la vallée la plus profonde sur plusieurs échantillons le long de la longueur d'évaluation

$$R_{tm} = R_{vm} + R_{pm} \quad (6)$$

Où  $R_{vm}$  et  $R_{pm}$  sont définis plus bas. Pour les profils de données elle est basée sur cinq longueurs d'échantillon ( $m = 5$ ). Le nombre d'échantillons correspond à la norme ISO. [7]

➤ **Profondeur moyenne des vallées  $R_{vm}$**

Profondeur de vallée moyenne basée sur une vallée par longueur échantillonnée. La vallée la plus profonde est déterminée pour cinq longueurs échantillonnées ( $m = 5$ ) puis ces valeurs sont moyennées

$$R_{vm} = \frac{1}{m} \sum_{i=1}^m R_{vi} \quad R_{vi} = |\min r_j| \quad \text{for} \quad (i-1)\frac{N}{m} < j < i\frac{N}{m} \quad (7)$$

➤ **Hauteur moyenne des pics  $R_{pm}$**

Hauteur de pic moyenne basée sur une vallée par longueur échantillonnée. La vallée la plus profonde est déterminée pour cinq longueurs échantillonnées ( $m = 5$ ) puis ces valeurs sont moyennées

$$R_{pm} = \frac{1}{m} \sum_{i=1}^m R_{pi} \quad R_{pi} = |\max r_j| \quad \text{for} \quad (i-1)\frac{N}{m} < j < i\frac{N}{m} \quad (8)$$

➤ **Profondeur de rugosité de base  $R_{3z}$**

Distance entre le troisième plus haut pic et la troisième plus basse vallée. Un pic correspond à une portion de la surface située au-dessus de la ligne moyenne.

➤ **Hauteur maximale moyenne  $R_z$**

Moyenne des valeurs absolues des cinq plus hauts pics et des cinq plus basses vallées sur la longueur d'évaluation.




Figure 1.23 : Hauteur maximale moyenne  $R_z$  [12]

➤ **Asymétrie  $R_{sk}$**

L'asymétrie est un paramètre décrivant la forme de la distribution d'amplitude. Il s'agit d'une mesure de la symétrie de la variation d'un profil autour de sa ligne moyenne

$$R_{sk} = \frac{1}{NR_q^3} \sum_{j=1}^N r_j^3 \quad (9)$$

### I.1.5. Méthode mécanique de mesure de la rugosité de surface

#### a) Profilomètre

Un **profilomètre** est un instrument utilisé pour mesurer le relief d'une surface, dans le but d'évaluer la rugosité d'une surface. Bon nombre de secteur d'activités font usage de cet appareil pour avoir une meilleure précision de mesures du relief. [13]



Figure 1.24 : profilomètre [13]

- **Processus de mesure**

Il existe deux types de profilomètre et son usage dépend du modèle choisi. Pour le profilomètre a contact il est classé comme une référence ancienne. Il fonctionne à l'aide d'un contact physique entre la partie à mesurer et la pointe en diamant. Ce type de profilomètre est particulièrement employé dans les usines de semi-conducteur, mais aussi en atelier

Quant au modèle moderne, il est désigné sous le nom de profilomètre optique. Il est en mesure d'offrir une meilleure précision aux données. Pour se faire, on utilise des faisceaux lumineux sur le long d'une surface. [13]

#### b) Rugosimètre

- **Processus de mesure**

Lorsque le palpeur se déplace d'un mouvement linéaire uniforme le long de la surface à tester, il effectue des mouvements perpendiculaires, vers le haut et vers le bas, tout en gardant un contact avec la surface de travail. Son mouvement est converti en signaux électriques qui sont amplifiés, filtrés et transformés en signaux digitaux par un convertisseur A/D. Les signaux sont ensuite traités par une unité centrale pour obtenir les valeurs Ra et Rz qui s'afficheront alors sur l'écran [15].



Figure 1.25: Rugosimètre digital [15]

### I.1.6. Méthode optique de mesure de la rugosité de surface

Elles regroupent les technologies de mesure sans contact des états de surface, et ici dans la pratique cela se passe en bombardant la surface à analyser par des électrons accélérés puis à analyser la réponse de la surface. On utilise :

#### a) La microscopie confocale

Le principe ici est qu'à partir d'un microscope optique, l'idée est de détecter les points correspondants aux zones nettes dans le champ de vision de l'objectif et d'y associer la hauteur du plan de focalisation comme le montre la figure 1.26.




Figure 1.26 : principe de la mesure par microscopie confocale [16]

#### b) La microscopie de champ proche.

A la surface d'un conducteur existe un nuage d'électrons dont la densité décroît exponentiellement avec la distance à la surface. En approchant une pointe de dimension théoriquement monoatomique, les nuages d'électrons correspondant aux deux conducteurs se mélangent. Il leur est donc possible de franchir une barrière de potentiel (effet tunnel) [16].




Figure 1.27: microscope à effet tunnel électronique [16]

#### c) L'ellipsométrie spectroscopique

L'ellipsométrie spectroscopique est une technique optique d'analyse de surface permettant de caractériser les propriétés optiques des matériaux et/ou l'épaisseur des couches minces. Elle est fondée sur la mesure du changement de l'état de la polarisation d'un faisceau de lumière après réflexion sur une surface plane d'un échantillon (Figure 1.28) [(Cornet et Deville, 1998), (Bissuel, 1996), (Castellon, 2002)]. Le type




Figure 1.28: Principe de l'ellipsomètre à modulation de phase [18]

d'information accessible par cette technique dépend de la configuration et du domaine de longueur d'onde utilisé.

## **I.2. APPRENTISSAGE AUTOMATIQUE COMME OUTIL DE PREDICTION DE LA RUGOSITE**

### **I.2.1. Généralité sur l'apprentissage automatique**

#### **a) Définition**

L'**apprentissage automatique** est un champ d'étude de l'intelligence artificielle qui se fonde sur des approches mathématiques et statistiques pour donner aux ordinateurs la capacité d'« apprendre » à partir de données, c'est-à-dire d'améliorer leurs performances à résoudre des tâches sans être explicitement programmés pour chacune. Plus largement, il concerne la conception, l'analyse, l'optimisation, le développement et l'implémentation de telles méthodes.[19]

#### **b) Types d'apprentissage**

Les algorithmes d'apprentissage peuvent se catégoriser selon le mode d'apprentissage qu'ils emploient :

##### **➤ Apprentissage supervisé**

Les algorithmes d'apprentissage supervisé font des prévisions en fonction d'exemples, ex. un historique de vente pour déterminer des prix futurs. Dans un tel cas, il y a une variable d'entrée composée de données d'entraînement étiquetées et d'une variable de sortie souhaitée. Un algorithme est utilisé pour analyser les données d'entraînement afin d'apprendre la fonction qui associe l'entrée à la sortie. Cette fonction permet de procéder à une mise en correspondance de nouveaux exemples en généralisant à partir des données d'entraînement pour anticiper les résultats de situations non connues. [19]

##### **➤ Apprentissage non supervisé**

Dans l'apprentissage non supervisé, la machine reçoit des données non étiquetées. On lui demande de découvrir les schémas qui sous-tendent les données, p. ex. une structure en grappes, une variété en basses dimensions, ou un arbre et un graphique de faible densité. [19]

##### **➤ Apprentissage par renforcement**

En apprentissage automatique, l'apprentissage par renforcement consiste, pour un agent autonome (robot, etc.), à apprendre les actions à prendre, à partir d'expériences, de façon à optimiser une récompense quantitative au cours du temps. L'agent est plongé au sein d'un environnement, et prend ses décisions en fonction de son état courant. En retour,

l'environnement procure à l'agent une récompense, qui peut être positive ou négative. L'agent cherche, au travers d'expériences itérées, un comportement décisionnel optimal, en ce sens qu'il maximise la somme des récompenses au cours du temps.[19]

### c) Facteurs de pertinence et d'efficacité

La qualité de l'apprentissage et de l'analyse dépend du besoin en amont et a priori de la compétence de l'opérateur pour préparer l'analyse. Elle dépend aussi de la complexité du modèle, de son adéquation et de son adaptation au sujet à traiter.

Avant cela, la qualité du travail dépendra de facteurs initiaux contraignants, liées à la base de données :

- **Nombre d'exemples** (moins il y en a, plus l'analyse est difficile, mais plus il y en a, plus le besoin de mémoire informatique est élevé et plus longue est l'analyse) ;
- **Nombre et qualité des attributs** décrivant ces exemples. La distance entre deux « exemples » numériques (prix, taille, poids, intensité lumineuse, intensité de bruit, etc.) est facile à établir, celle entre deux attributs catégoriels (couleur, beauté, utilité...) est plus délicate ;
- **Pourcentage de données renseignées** et manquantes ;
- « **Bruit** » : le nombre et la « localisation » des valeurs douteuses (erreurs potentielles, valeurs aberrantes...) ou naturellement non-conformes au *pattern* de distribution générale des « exemples » sur leur espace de distribution impacteront sur la qualité de l'analyse.[19]

### d) Étapes d'un projet d'apprentissage automatique

L'apprentissage automatique ne se résume pas à un ensemble d'algorithmes mais suit une succession d'étapes.

- L'acquisition de données : l'algorithme se nourrissant des données en entrée, c'est une étape importante. Il en va de la réussite du projet, de récolter des données pertinentes et en quantité suffisante.
- La préparation et le nettoyage de la donnée : les données recueillies doivent être retouchées avant utilisation. En effet, certains attributs sont inutiles, d'autres doivent être modifiés afin d'être compris par l'algorithme, et certains éléments sont inutilisables car leurs données sont incomplètes. Plusieurs techniques telles que la visualisation de données, la transformation de données (en) ou encore la normalisation sont alors employées.

- La création du modèle.
- L'évaluation : une fois l'algorithme d'apprentissage automatique entraîné sur un premier jeu de donnée, on l'évalue sur un deuxième ensemble de données afin de vérifier que le modèle ne fasse pas de surapprentissage.
- Le déploiement : le modèle est déployé en production pour faire des prédictions, et potentiellement utiliser les nouvelles données en entrée pour se re-entraîner et être amélioré.[19]

**e) Algorithmes utilisés apprentissage automatique**

Ce sont, dans ce domaine :

- Les machines à vecteur de support ;
- Le boosting ;
- Les réseaux de neurones, dont les méthodes d'apprentissage profond (deep Learning en anglais) pour un apprentissage supervisé ou non-supervisé ;
- La méthode des k plus proches voisins pour un apprentissage supervisé ;
- Les arbres de décision, méthodes à l'origine des Random Forest, par extension également du boosting (notamment xgboost) ;
- Les méthodes statistiques comme le modèle de mixture gaussienne ;
- La régression logistique ;
- L'analyse discriminante linéaire ;
- Les algorithmes génétiques et la programmation génétique. [19]

**f) Domaine d'application**

L'apprentissage automatique est utilisé pour un large spectre d'applications, par exemple :

- Moteur de recherche,
- Aide au diagnostic,
- Détection de donnée aberrante,
- Détection de données manquantes,
- Détection de fraudes,
- Analyse des marchés financiers,
- Reconnaissance de la parole,
- Reconnaissance de l'écriture manuscrite,
- Analyse et indexation d'images et de vidéo, en particulier pour la recherche d'image par le contenu,
- Robotique,



## I.2.2. Méthodes de mesure par apprentissage automatique de la rugosité

L'objectif global de ces méthodes est de pouvoir prédire la rugosité d'une surface en prenant en compte uniquement ses conditions d'obtention et pour la prédire on utilise des algorithmes de machine Learning (intelligence artificielle).

Les plus utilisés à présent en mécanique sont :

### a) Le réseau de neurones artificiel

#### i) Description

Il imite le fonctionnement des neurones du cerveau. Son but est de déterminer une corrélation entre un certain nombre de données d'entrée et de données de sortie ; afin de pouvoir prédire les valeurs des données de sortie pour n'importe quelles données d'entrée. Son fonctionnement est le suivant :

- Un certain nombre d'information est enregistré comme données d'entrée puis transmis par un réseau neuronal ;
- À chacune de ces informations est affecté un poids ;
- Ces informations sont ensuite analysées, combinées et enregistrées afin d'obtenir le résultat souhaité.

Plus le nombre d'information est élevé plus la corrélation obtenue donne des résultats proches de la réalité. Le réseau de neurones artificiel peut se représenter comme suit :




Figure 1.39 : Représentation d'un réseau de neurones [20]

- La première couche (L1) constitue les données d'entrée ;
- Les couches L2, L3 sont les couches intermédiaires de neurones encore appelées couches cachées (hidden layers) ; c'est à ce niveau que sont effectués tous les calculs ;
- La couche L4 constitue les données de sorties.

L'apprentissage par le réseau de neurones nécessite l'introduction des variables d'entrée avec les valeurs de sorties correspondantes. C'est la détermination des corrélations entre ces variables d'entrées et de sorties qui permettra au réseau de neurones construit de pouvoir prédire de nouveaux résultats. Au niveau de chaque neurone des couches intermédiaires, il est additionné les valeurs précédentes affectées d'un poids dépendant des deux neurones en liaison et une constante de distorsion (bias). Une fonction d'activation est ensuite utilisée pour déterminer la valeur qui sera transmise par le neurone. [20]




Figure 1.30 : Opérations au niveau de chaque neurone [20]

## ii) Le réseau de neurones et la mesure de la rugosité

Il y'a six principales catégories de paramètres influençant la rugosité de surface des surfaces fraisées : les propriétés de l'outil, les propriétés de la pièce, les propriétés de la machine-outil, les propriétés dynamiques, les propriétés thermiques et les propriétés de coupe. Toute fois au vu de la difficulté de contrôler la plupart de ces paramètres, on retrouve plus dans la littérature des travaux déterminant la rugosité en utilisant les paramètres de coupe (profondeur de passe, vitesse d'avance, vitesse de coupe, fréquence de rotation de l'outil). Ainsi ces paramètres constituent les variables d'entrée du réseau de neurones, la rugosité étant la variable de sorties. Les valeurs des rugosités doivent être mesurées pour chaque ensemble de variables d'entrée afin pouvoir mesurer la performance du réseau de neurones.

### b) La régression à support de vecteur

#### i) Description

Considérons un ensemble de points en dimension  $N$ , le support vecteur machine (SVM) est une méthode d'apprentissage automatique qui a pour but de classer cet ensemble de points en déterminant un hyperplan de séparation entre deux ensembles distincts de ces points. Le nombre d'hyperplans de séparation étant grand, l'objectif du support vecteur machine est de déterminer l'hyperplan produisant la plus grande marge, en quelque sorte un hyperplan situé à

distance maximale de chacun de ces ensembles de points tout en minimisant l'erreur [12]. La régression à support de vecteur ou SVR (Support Vector Regression) a le même principe que le SVM ; toutefois, son but est de trouver un hyperplan de régression d'un ensemble de points, suivant une certaine tolérance ; plus faible est l'erreur plus précise sera la régression. la figure qui suit montre l'application du SVR à un ensemble de point et en fonction d'une tolérance variée.[20]

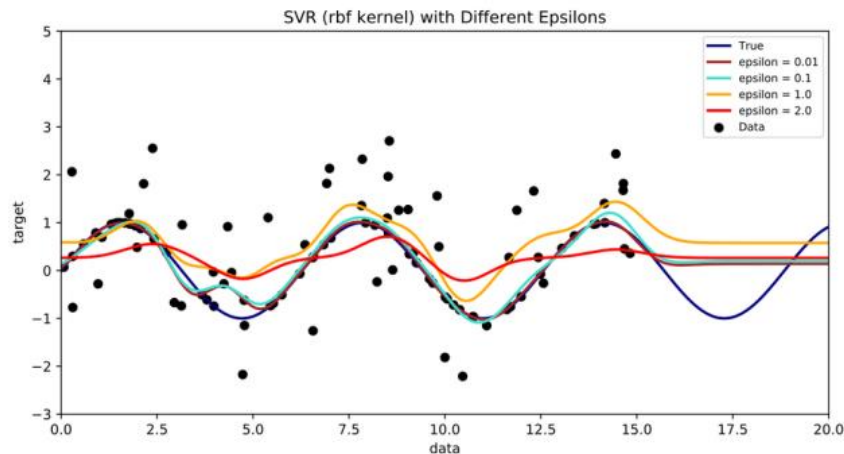


Figure 1.31 : Régression par le Support Vecteur Machine [20]

## ii) La régression à support de vecteur (SVR) et la mesure de la rugosité

Le SVR est l'une des méthodes d'apprentissage automatique utilisée dans la détermination de la rugosité. En [27] Ulas Çaydas et Sami Ekici en ont même obtenu des résultats meilleurs qu'avec le réseau neuronal en utilisant comme variables la vitesse d'avance, la vitesse de coupe et la profondeur de passe.

## I.3.CONCLUSION

Les paramètres d'état de surface et notamment de rugosité sont nombreux. Se donner pour objectif de tous les étudier en une fois serait une tâche titanesque et dépendante de la méthode choisie. Cependant, grâce aux techniques d'apprentissage automatique le poids de l'étude de ces paramètres peut être allégé. Ces dernières permettent de prédire des valeurs des paramètres en fonction de certaines variables affectants les paramètres en question. En ce qu'il s'agit de la rugosité, un certain nombre de variables peut être considéré notamment : les paramètres relatifs à la machine, ceux relatifs à l'outil de coupe et ceux relatifs aux conditions de coupe.

## Chapitre 2

---

# ETAT DE L'ART SUR LA MESURE PAR APPRENTISSAGE AUTOMATIQUE DES PARAMETRES DE RUGOSITES

Dans ce chapitre, nous nous intéresserons principalement aux travaux effectués par des auteurs en ce qui concerne la mesure par apprentissage automatique de la rugosité. Nous ferons mention de leurs objectifs, analyserons leur méthodologie et soulignerons leurs résultats et discussions. Pour ce faire nous présenterons les travaux des auteurs ayant utilisé les réseaux de neurones artificiels, ceux ayant utilisé le modèle de régression linéaire multiple, modèle de régression par support de vecteur et enfin ceux ayant utilisé un modèle d'arbre de décision. Nous allons clôturer notre chapitre en faisant une synthèse générale de tous ces travaux.

---

II.1. Le réseau de neurones artificiel	36
II.1.1. Nicholas E. Sizemore, Monica L. Nogueira, Noel P. Greis et Matthew A. Davies (2020)[18].....	36
II.1.2. Md. Shahriar Jahan Hossain et Dr. Nafis Ahmad (2012) [19] .....	38
II.1.3. Marek Vrabel (2012) [20].....	39
II.1.4. Rajesh M. et Dr. R Manu (2014) [21].....	40
II.1.5. Ludovic Ngongang et al. (2021) [28] .....	41.
II.2. Régression linéaire multiple .....	42
II.2.1. Dhiren R. Patel Mysore et B. Kiran Vinay Vakharia (2019) [22].....	42
II.2.2. Ibrahim A Badi1*, Ali G Shetwan2, Maitig A (2017) [23].....	44
II.3. Régression par support de vecteur .....	44
II.3.1. Ulas Çaydas et Sami Ekici (2010) [24] .....	44
II.3.1. JuanLu et al. (2019) [25].....	45
II.4. Arbre de décision.....	46
II.4.1. Vijay Kumar, Sanjay Kumar Et Prashant Prakash (2011) [26] .....	46
II.4.2. Juan M. Barrios and Pablo E. Romero (2019) [27] .....	47
II.5. Synthèse générale sur la mesure de la rugosité par apprentissage automatique.....	49
II.6. Conclusion .....	54

---

## II.1. LE RESEAU DE NEURONES ARTIFICIEL

Les chercheurs ci-dessous ont travaillé sur la prédiction de la rugosité des surfaces par le biais des modèles d'apprentissage automatique.

### II.1.1. Nicholas E. Sizemore, Monica L. Nogueira, Noel P. Greis et Matthew A. Davies (2020) [21]

#### a) Objectif

Dans leur article intitulé « *Application of Machine Learning to the Prediction of Surface Roughness in Diamond Machining* » Nicholas E. Sizemore, Monica L. Nogueira, Noel P. Greis et Matthew A. Davies se concentrent sur l'application et l'évaluation des méthodes d'apprentissage automatique pour mieux aider à la prédiction des paramètres de rugosité de surface du germanium (Ge) et donne une comparaison avec un matériau ductile comme le cuivre (Cu)

#### b) Matériels

L'outil utilisé est un outil en diamant monocristallin à nez rondet et les pièces utilisées sont en germanium (Ge) et en cuivre (Cu)

#### c) Méthode

Les surfaces ont été tournées sur le « Moore Nanotechnology 350FG » avec un outil diamant monocristallin à nez rond. L'outil est défini par le rayon de pointe d'outil  $R$  et l'angle de coupe  $\alpha$ . La Figure II.1 représente une opération de tournage au diamant, tandis que la Figure II.2 montre une vue rapprochée de l'interaction outil-pièce. Le tableau II.1 ci-dessous résume l'outillage utilisé pour les deux Études Cu et Ge menées dans cet article. L'outil diamant utilisé dans les expériences Cu comprenait uniquement l'outil n° 1. Les Ge des expériences ont été menées avec les outils n° 2, n° 3 et n° 4. Les modèles ML ont été formés pour capturer les huit entrées paramètres disponibles pour prédire la rugosité de la surface. Ces paramètres d'entrée comprennent : le rayon du nez d'outil  $R$  ; angle de coupe  $\alpha$  ; avance par tour  $fr$  ; profondeur de coupe  $ad$  ; vitesse de coupe  $Vd$  ; l'avance  $vf$  ; épaisseur de copeau  $td$  ; et vitesse de broche  $\Omega$ . L'avance  $vf$  est simplement calculée en multipliant les  $fr$  et  $\Omega$  résultant en une avance par minute.



Figure II.1 : illustration de l'opération




Figure II.2 : vue rapprochée de l'interaction outil-pièce de tournage au diamant

Tableau 2 : outillage utilisé pour les deux Études

Tool no.	R (mm)	Rake angle, $\alpha$ (deg)			$f_r$ ( $\mu\text{m}/\text{rev}$ )	$a_{\text{doc}}$ ( $\mu\text{m}$ )	$V_c$ (m/s)
		0	-15	-25			
no.1	0.25	x			0.1 - 40	1, 10	0.3, 3
no.2	0.50		x	x	0.1 - 5.0	5, 25	0.5, 2, 6
no.3	1.00		x	x	0.1 - 6.5	5, 25	0.5, 2, 6
no.4	5.00		x	x	0.3 - 10	5, 25	0.5, 2, 6




Figure II.3 : réseau de neurones utilisés

#### d) Résultats

Les résultats pour toutes les configurations de modèle ANN testées avec les données Ge sont présentés dans le tableau II.2, II.3, II.4. Semblable aux résultats obtenus pour Cu.

Tableau 3 : Ra moyenne et taux d'erreur pour l'ensemble de données Ge

ML Algorithm	EVS		RSME		MAE		Max error	
	Train	Test	Train	Test	Train	Test	Train	Test
DT (2)	0.375	0.399	2.954	3.389	0.611	0.850	30.535	19.294
DT (5)	0.850	0.660	1.446	2.565	0.212	0.317	15.588	19.149
DT (8)	0.973	0.866	0.620	1.607	0.081	0.250	5.626	8.025
DT (11)	0.999	0.887	0.111	1.474	0.000	0.223	1.125	5.936
RF (8)	0.971	0.893	0.634	1.428	0.086	0.218	7.757	9.889
RF (11)	0.963	0.880	0.716	1.518	0.139	0.244	7.788	10.155
AB (8)	0.997	0.811	0.236	1.890	0.151	0.285	0.957	5.245
AB (11)	0.999	0.800	0.147	1.942	0.045	0.227	0.715	5.245
SVR (RBF)	0.883	0.869	1.286	1.612	0.100	0.203	22.736	13.669
SVR (Poly)	0.846	0.801	1.471	1.977	0.258	0.379	23.347	12.811
SVR (Sig)	0.209	0.167	3.509	4.328	0.200	0.279	31.490	20.308
Analytical (Eq.4)		0.136		4.118		0.701		20.409

Tableau 4 : Rq moyenne et taux d'erreur pour l'ensemble de données Ge

ML Algorithm	EVS		RSME		MAE		Max error	
	Train	Test	Train	Test	Train	Test	Train	Test
DT (2)	0.407	0.329	5.842	8.044	1.250	0.890	46.222	60.290
DT (5)	0.812	0.615	3.292	6.119	0.388	0.530	37.577	51.645
DT (8)	0.971	0.826	1.296	4.138	0.136	0.377	9.573	20.304
DT (11)	0.999	0.850	0.287	3.829	0.000	0.303	2.612	18.716
RF (8)	0.978	0.827	1.125	4.104	0.156	0.376	10.140	31.092
RF (11)	0.968	0.814	1.360	4.255	0.236	0.395	10.628	31.217
AB (8)	0.996	0.846	0.517	3.846	0.314	0.522	1.681	29.463
AB (11)	0.999	0.879	0.233	3.426	0.060	0.400	1.461	24.855
SVR (RBF)	0.891	0.784	2.513	4.623	0.148	0.277	31.494	42.196
SVR (Poly)	0.870	0.778	2.738	4.649	0.379	0.541	29.317	42.393
SVR (Sig)	0.162	0.097	7.634	10.060	0.358	0.409	50.166	64.134
Analytical (Eq.5)		0.077		9.562		1.052		50.319

Tableau 5 : Rz moyenne et taux d'erreur pour l'ensemble de données Ge

ML Algorithm	EVS		RSME		MAE		Max error	
	Train	Test	Train	Test	Train	Test	Train	Test
DT (2)	0.469	0.440	182.864	171.016	79.054	88.804	865.547	671.303
DT (5)	0.799	0.587	112.384	146.739	22.160	37.598	723.462	558.628
DT (8)	0.955	0.662	52.981	133.678	5.840	20.193	466.056	610.000
DT (11)	0.996	0.512	15.892	160.923	0.000	19.902	95.590	607.520
RF (8)	0.978	0.835	37.223	93.083	9.188	21.726	306.394	495.432
RF (11)	0.962	0.830	48.868	94.400	11.981	20.887	418.541	491.790
AB (8)	0.993	0.810	20.716	99.380	4.940	15.580	85.266	596.329
AB (11)	0.999	0.760	8.135	111.574	0.033	16.497	54.956	606.034
SVR (RBF)	0.807	0.776	111.039	107.500	28.298	40.603	772.918	552.451
SVR (Poly)	0.850	0.813	97.379	98.039	28.239	38.879	860.206	620.271
SVR (Sig)	0.009	0.010	297.648	267.548	17.678	17.843	1262.711	935.752
Analytical (Eq.6)		0.009		331.984		28.916		1284.205

## II.1.2. Md. Shahriar Jahan Hossain et Dr. Nafis Ahmad (2012) [22]

### a) Objectif

Md. Shahriar Jahan Hossain et Dr. Nafis Ahmad ont présenté un article ayant pour thème : « *artificial intelligence based surface roughness prediction modeling for three dimensional end milling* ». L'objectif de cet article est de d'entraîner plusieurs modèles d'apprentissage automatique dont les réseaux de neurones artificiels en faisaient partie et de tous les comparer en vue d'en tirer le meilleur modèle.

### b) Matériel

Le matériel utilisé pour cette étude est :

- Une fraiseuse verticale
- Une plaque d'aluminium de taille 9 cm x 1 cm x 4 cm
- Une fraise en carbure à deux dents de 8 mm de diamètre

### c) Méthode

Pour pouvoir prédire de façon efficace la rugosité moyenne de surface Ra (valeur) pour l'aluminium après l'opération de fraisage en bout, 84 expériences ont été menées par eux en variant l'angle d'inclinaison de l'axe de la fraise ( $\phi$  degré), la vitesse de la broche (S tr / min), la vitesse d'avance ( $f_y$  mm / min), la profondeur de coupe radiale (avance  $f_x$  mm), la profondeur de coupe axiale (t mm) en afin de trouver Ra. Ces données ont été divisées en deux ensembles sur une base aléatoire ; 68 jeux de données d'entraînement et 16 jeux de données de test. L'ensemble de données d'entraînement a été utilisé pour entraîner différents modèles ANN et

ANFIS pour la prédiction  $R_a$ . Et un ensemble de données de test a été utilisé pour valider les modèles.




Figure II.4 : entré et sortie du réseau de neurone utilisés

#### d) Résultat

Après leur test ils ont constaté que Le modèle ANFIS pourrait prédire la rugosité de surface pour les données d'entraînement avec un taux d'erreur de 0,003014%, tandis que le modèle ANN pourrait prédire la rugosité de surface pour les données d'entraînement avec une erreur de 0,0314%. Le taux d'erreur des différents modèles est présenté par le tableau qui suit :

Tableau 6 : taux d'erreur des différents modèles utilisés

Model	For Training Data		For Testing Data	
	RMSE	MAPE	RMSE	MAPE
Theoretical equation	0.934292	42.02314	1.364	43.884
<b>ANFIS</b>	<b><math>9.9845 \times 10^{-5}</math></b>	<b>0.003014</b>	<b>1.146</b>	<b>38.605</b>
RSM	0.630641	27.72202	0.900	29.612
ANN	$7.2355 \times 10^{-4}$	0.0314	0.9158	34.5351

### II.1.3. Marek Vrabel (2012) [23]

#### a) Objectifs

Dans un article intitulé « *Surface roughness prediction using artificial neural networks when drilling Udimet 720* » ; Marek Vrabel se donne pour but de mettre sur pied une stratégie efficace de prédiction de la rugosité des surfaces usinées grâce à l'apprentissage automatique.

#### b) Matériel

Les éprouvettes sont en super alliage au Nickel utilisé dans les moteurs d'avion : l'UDIMET 720

#### c) Méthode

Les auteurs utilisent deux systèmes neuronaux en série. Le premier utilise comme variables d'entrée la vitesse d'avance, la vitesse de rotation et la force de poussée de perçage



pour prédire l'usure de l'outil ; et le second utilise la charge sur l'outil en plus des variables d'entrées utilisées précédemment pour prédire la rugosité de la surface. La figure 2-1 illustre le schéma de principe de la méthode.

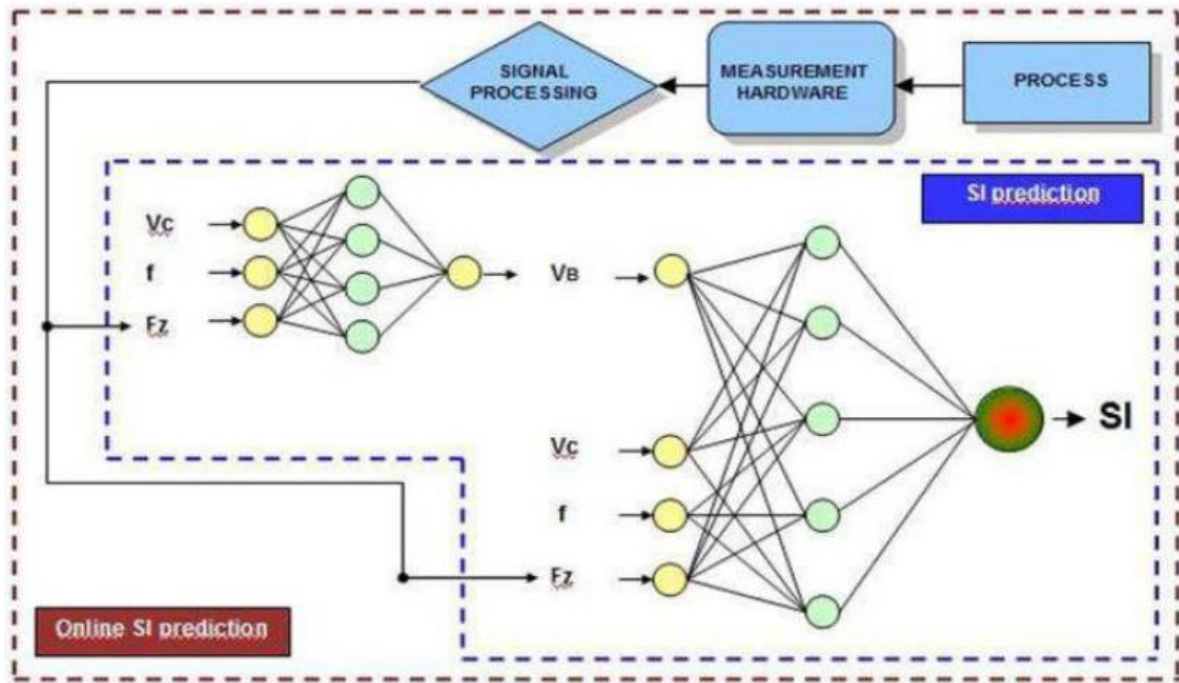


Figure II.6 : réseau de neurone utilisés

#### d) Résultat

Il en ressort de cet article que le réseau de neurones est un outil efficace dans le suivi des charges sur l'outil durant les opérations de perçage, ainsi que dans la prédiction de la rugosité. Le système de prédiction des charges sur l'outil produit des résultats appréciables avec une erreur RMS de 12,7% pour un système à trois variables d'entrée, une couche intermédiaire de 5 neurones et une variable de sortie (système 3-5-1). Le système de prédiction de la rugosité produit des résultats appréciables pour la phase d'entraînement du réseau avec une erreur RSM de 2,64% pour un système à quatre variables d'entrée, deux couches intermédiaires de 6 et 4 neurones respectivement et une variable de sortie (système 4-6-4-1). Le type de variables d'entrée affecte les résultats du réseau de neurones.

#### II.1.4. Rajesh M. et Dr. R Manu (2014) [24]

##### a) Objectif

Dans un article intitulé « *Prediction of surface roughness of freeform surfaces using Artificial Neural Network* », Rajesh M. et Dr. R Manu se donnent pour objectif de prédire la rugosité des surfaces complexes obtenues par fraisage en considérant comme paramètres : la vitesse de coupe, la vitesse d'avance, la profondeur de passe et le pas latéral.

### b) Matériels

- Une fraiseuse à axe verticale
- Système FANUC

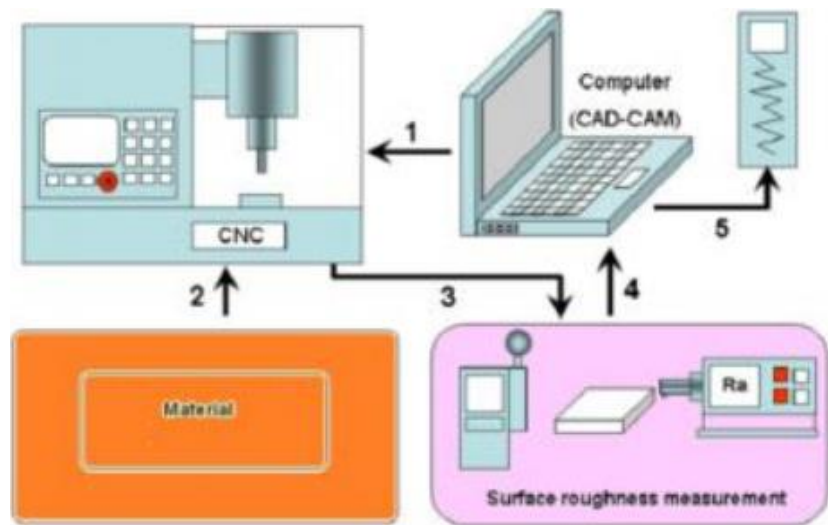


Figure II.7 : dispositifs utilisés

### c) Méthodes

Les paramètres de coupe (la vitesse de coupe, la vitesse d'avance et la profondeur de passe.) sont modifiés et les rugosités moyennes et totales sont mesurées expérimentalement par les méthodes de réplcation (Response surface method (RSM)). Ces données mesurées sont ensuite utilisées pour entraîner et tester l'algorithme génétique dans MATLAB 2010.

### d) Résultat

Trente-trois (33) données sont utilisées pour l'expérimentation dont 25 pour entraîner le réseau de neurones et 7 pour le tester. Le réseau de neurones est entraîné par 10 à 16 neurones et le neurone produisant une valeur de régression proche de 1 est sélectionné pour simuler les données de sortie. Les résultats obtenus sont favorables avec une erreur maximale de 6,42% pour Ra et 3,62% pour Rt. Ceci montre une capacité du réseau de neurones à prédire la rugosité arithmétique et la rugosité totale avec une précision de 93.58% et 96.37 % respectivement.

## II.1.5. Ludovic Ngongang et al. (2021) [25]

### a) Objectif

Dans un article intitulé, « *Remote Monitoring of Surface Roughness on Turned and Milled Carbon Steels with High-Speed Steel and Tungsten Carbide Tools* », Ludovic Ngongang et al. se donnent pour objectif de faire une étude sur la prédiction de rugosité des surfaces fraisées et tournées en prenant comme variable d'entrée le pourcentage de carbone du matériau usiné, le temps de coupe et la nature de l'outil. Pour leurs études ils ont développé deux algorithmes de logique floue et de réseaux de neurones artificiels et on faire une étude comparative de chaque modèle.

### b) Matériels

- Aciers au carbone 1010, 1015, 1020, 1035
- Spectromètre Foundry Master Optik 01N0096
- Machine Comec LGA180N
- Outil en acier rapide : HS6-5-2 (M2)
- Outil en carbure de tungstène : PCLNR 2525-M12 avec plaquette carbure CNMG 12 04 08
- Fraiseuse Tiger FU90
- Chronomètre Sienoc Digital Professional LCD
- Rugosimètre SRT6210
- Microscope MV900
- Matlab, version étudiante R2017a
- Ordinateur portable HP (Hewlett Packard) Intel © Core™ i7-8550U à 1,80 GHz - 1,99 GHz

#### c) Méthodes

Après avoir usiné 96 surfaces, ils ont prélevé les valeurs de rugosité en tournage et au fraisage qui leur ont servi de base de données. Ils ont appliqué leur algorithme de logique floue et de réseaux de neurones artificiel à une seule couche cachée de 10 neurones sur les données obtenues et ont fait une comparaison de performances entre les 2 modèles.

#### d) Résultat

Les résultats de la prédiction ont été évalués en utilisant le MSE, l'outil ARS donne un MSE=0,032 en logique floue et MSE=0,254 en ANN. L'outil WC donne un MSE=0,014 en logique floue et MSE=0,037 en ANN.

## II.2. REGRESSION LINEAIRE MULTIPLE

### II.2.1. Dhiren R. Patel Mysore et B. Kiran Vinay Vakharia (2019) [26]

#### a) Objectif

Dans leur article intitulé « *Modeling and prediction of surface roughness using multiple regressions : A noncontact approach* » **Dhiren R. Patel Mysore et B. Kiran Vinay Vakharia** ont développé des modèles de régression multiple pour prédire l'estimation subjective du paramètre de rugosité de surface (Ra) et la détection qualitative du degré de rugosité de surface.

#### b) Matériel

- Profilomètre de type contact
- Acier à faible teneur en carbone ayant un diamètre de 30 mm et une hauteur de 18 mm
- Machine de tournage CNC

### c) Méthodes

Dans leurs travaux, ils ont utilisé un système de vision industrielle qui vas capturer des images et extrait les caractéristiques de texture de surface des surfaces usinées. Les paramètres des caractéristiques de texture sont extraits à l'aide de la matrice de cooccurrence de niveaux de gris et corrélés avec différents paramètres de rugosité de surface enregistrés par un profilomètre de surface de type contact. L'acquisition d'image est réalisée à différents niveaux de rugosité afin d'extraire les caractéristiques de texture. La variation entre chaque caractéristique de texture et le paramètre de rugosité de surface est étudiée. Des modèles de régression multiple sont développés pour prédire l'estimation subjective du paramètre de rugosité de surface ( $R_a$ ) et la détection qualitative du degré de rugosité de surface.




Figure II.8 : dispositif utilisé

### d) Résultats

Ils ont pu observer que le modèle de régression linéaire présente de meilleures caractéristiques de performance par rapport à un modèle de détection non linéaire. La comparaison entre les résultats mesurés et prédits montre que le modèle de régression linéaire avait une erreur relative maximale de 2,01%, nettement meilleure que le modèle de détection non linéaire de 9,60% de taux d'erreur, indiquant ainsi une meilleure capacité de détection de surface par rapport au modèle de détection non linéaire. Les résultats démontrent que la prédiction de la rugosité de surface à l'aide d'un modèle de régression linéaire est une approche fiable de la mesure sans contact.

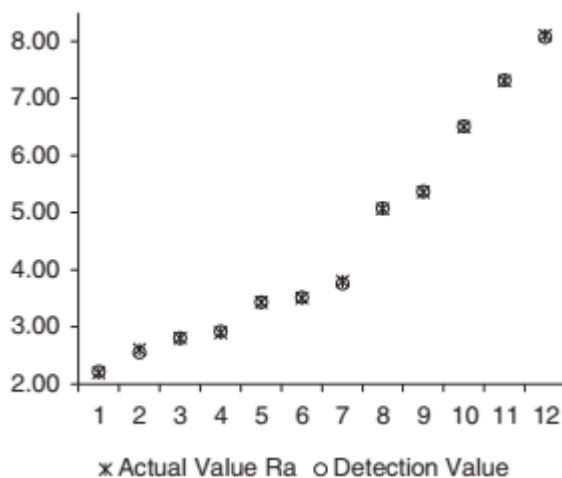


Figure II.9 : précision du modèle de régression linéaire

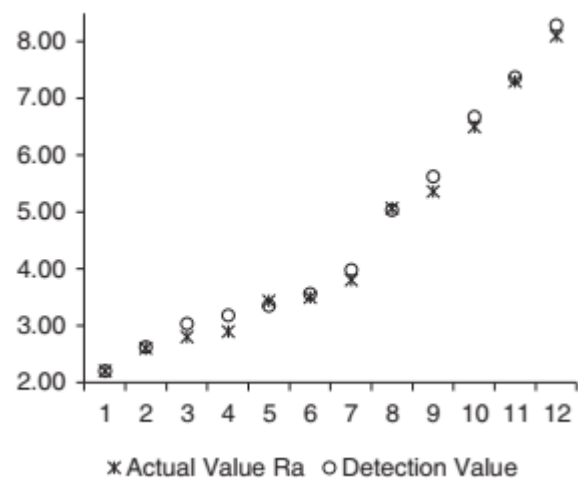


Figure II.10 : précision du modèle de régression non linéaire

### **II.2.2. Ibrahim A Badi, Ali G Shetwan, Maitig A (2017) [27]**

#### **a) Objectif**

Dans l'article "*Using Multiple Linear Regression and Artificial Neural Network to Predict Surface Roughness in Turning Operations*", Ibrahim A Badi, Ali G Shetwan, Maitig A se donnent pour objectif de développer un modèle de régression linéaire multiple puis un modèle de réseaux de neurones artificiel capable de prédire de façon efficiente la rugosité des surfaces tourner et ensuite ils décident de comparer la précision de chaque modèle

#### **b) Matériels**

- Pièces d'alliage d'acier HRC15
- Centre de tournage
- Ordinateur
- Rugosimètre

#### **c) Méthode**

Dans cet article, la rugosité de surface est mesurée pendant l'opération de tournage à différents paramètres de coupe tels que la vitesse de coupe, la vitesse d'avance et la profondeur de passe. Deux modèles mathématiques sont développés pour prédire la rugosité de surface et pour sélectionner la rugosité de surface requise en utilisant le modèle multi-régression et les réseaux de neurones artificiels (ANN). Pour tester les modèles développés, 27 pièces d'alliage d'acier HRC15 ont été utilisées et la rugosité de leurs surfaces a été mesurée.

#### **d) Résultats**

Les valeurs prédites obtenues à partir du modèle de réseau neuronal artificiel étaient meilleures que le modèle de régression linéaire multiple avec une erreur de 1% et 20%, respectivement. La variable la plus importante lors du développement du réseau dans le modèle de réseau de neurones artificiels était les époques, où le taux d'erreur était de 11% au nombre d'itérations de 1000 à 1% au nombre d'itérations de 10 000. Les modèles proposés peuvent être utilisés efficacement pour prédire la rugosité de surface dans le processus de tournage. Compte tenu des avantages de l'ANN par rapport à la régression multiple sont la simplicité, la vitesse et la capacité d'apprentissage, l'ANN est une approche puissante pour prédire la rugosité de surface.

## **II.3. REGRESSION PAR SUPPORT DE VECTEUR**

### **II.3.1. Ulas Çaydas et Sami Ekici (2010) [28]**

#### **a) Objectif**

Dans l'article "Support vector machines models for surface roughness prediction in CNC turning of AISI 304 austenitic stainless steel", les auteurs considèrent trois différents types de support vecteur machine : le Least Square SVM (LS-SVM) le Spider SVM et le SVM-KM qu'ils comparent à un réseau de neurones artificiel. Les variables utilisées ici sont la vitesse de coupe, la vitesse d'avance, et la profondeur de passe.

#### b) Matériels

- Tour programmable JOHNFORD TC-35
- Cylindre de 40 mm de diamètre et 120 mm de long et dont le matériau est l'acier inoxydable AISI 304

#### c) Méthode

27 expérimentations sont effectuées et chaque expérimentation consiste en la variation de la vitesse de coupe, la vitesse d'avance, et la profondeur de passe et à la mesure de la valeur de la rugosité correspondante. La vitesse de coupe, la vitesse d'avance, et la profondeur de passe sont choisies suivant les intervalles respectifs : 30-60-90, 0.15-0.25-0.35 et 0.5-1-1, comme variables d'entrée ( $x_i$ ) du support à vecteur de machine. La rugosité de la surface étant considéré comme sortie ( $y_i$ ) et l'implémentation se fait par MATLAB.

#### d) Résultats

Le tableau 7 donne une comparaison sommaire des performances des quatre techniques de prédiction utilisée. Il en ressort que les méthodes de régression à support vecteur machine expérimentées produisent des résultats meilleurs que le réseau de neurones dans l'ordre décroissant de précision : le spider SVM avec un degré de corrélation  $R^2$  de 0,95715 ; le SVMKM ( $R = 0.95602$ ), le LS-SVM ( $R = 0.94496$ ) et le réseau de neurones ( $R = 0.91451$ ).  
Tableau 7 : taux d'erreur des différents modèles utilisés comme le montre le tableau 7

Tableau 7 : résultats obtenus pour chaque model

	LS-SVM	Spider SVM	SVM-KM	ANN
Erreur moyenne	0.2997	0.2748	0.2832	0.3275
Temps (s)	0.45	0.42	0.25	122.93

#### II.3.1. JuanLu et al. (2019) [29]

##### a) Objectif

JuanLu et al. Dans l'article « *An Effective ABC-SVM Approach for Surface Roughness Prediction in Manufacturing Processes* » se donnent pour objectif, d'évaluer les paramètres

internes du SVM nécessaires pour la prédiction de la rugosité en fraisage et en tournage ; puis de déterminer l'algorithme le plus performant dans la prédiction de la rugosité arithmétique moyenne. Ils considèrent comme paramètres : la vitesse de coupe, l'avance, la profondeur de passe, le diamètre de l'outil.

#### **b) Matériels**

Les opérations de tournage s'effectuent sur de l'acier AISI 1045 et celle de fraisage sur l'alliage au titane TC18.

#### **c) Méthode**

Le SVM est utilisé pour prédire les valeurs de la rugosité et quatre algorithmes (Artificial Bee Colony (ABC) ; Differential Evolution (DE), Genetic Algorithm (GA), Particle Swarm Optimization (PSO)) sont utilisés et comparés pour déterminer les paramètres internes optimums à utiliser pour le SVM.

#### **d) Résultats**

Le ABC-SVM s'avère être la méthode la plus efficace en termes de précision de la prédiction et temps de compilation.

### **II.4. ARBRE DE DECISION**

#### **II.4.1. Vijay Kumar, Sanjay Kumar Et Prashant Prakash (2011) [30]**

##### **a) Objectifs**

Dans leur article intitulé « *data exploitation application using decision tree and year for prediction of roughness of milling surface in the manufacturing process* », VIJAY KUMAR, SANJAY KUMAR et PRASHANT PRAKASH décide de compare deux model de prédiction par apprentissage de la rugosité : l'arbre de décision et le réseau de neurones artificiel.

##### **b) Matériel**

- Capteur de déplacement capacitif cylindrique
- Fraise en acier rapide
- Aluminium 6061
- Profilomètre à stylet

##### **c) Méthode**

Les arbres de décision sont des algorithmes d'apprentissage prédictif simples et efficaces. Apprendre en utilisant l'arbres de décision se composent de deux étapes. Dans la première étape, un arbre est construit à l'aide des données d'apprentissage. Ensuite, pour chaque

enregistrement, l'arborescence est parcourue pour déterminer la classe à laquelle appartient l'enregistrement. Chaque nœud interne de l'arbre indique un test sur un attribut, chaque branche représente un résultat du test

#### d) Résultat

Le résultat de la prédiction est favorable avec un pourcentage d'erreur moyen de 6,42%, ce qui signifie que les neurones Le réseau est capable de prédire la rugosité de surface avec une précision de 93,58%. En conclusion, artificiel Le réseau neuronal a fourni une meilleure précision pour prédire la rugosité de surface dans le processus de fraisage CNC.

### II.4.2. Juan M. Barrios and Pablo E. Romero (2019) [31]

#### a) Objectif

Dans leur article intitulé « *Decision Tree Methods for Predicting Surface Roughness in Fused Deposition Modeling Parts* », Juan M. Barrios and Pablo E. Romero se donne pour objectif de comparer les modèles générés par les algorithmes d'arbre de décision (C4.5, forêt aléatoire, et arbre aléatoire) et d'analyser qui fait la meilleure prédiction de la rugosité de surface dans les pièces en polyéthylène téréphtalate glycol (PETG) imprimées en 3D en utilisant la technique d'impression à l'aide de la modélisation de dépôt par fusion.

#### b) Matériel

- Ordinateur
- Pièces en polyéthylène téréphtalate glycol (PETG)
- Imprimante 3D (FMD)

#### c) Méthode

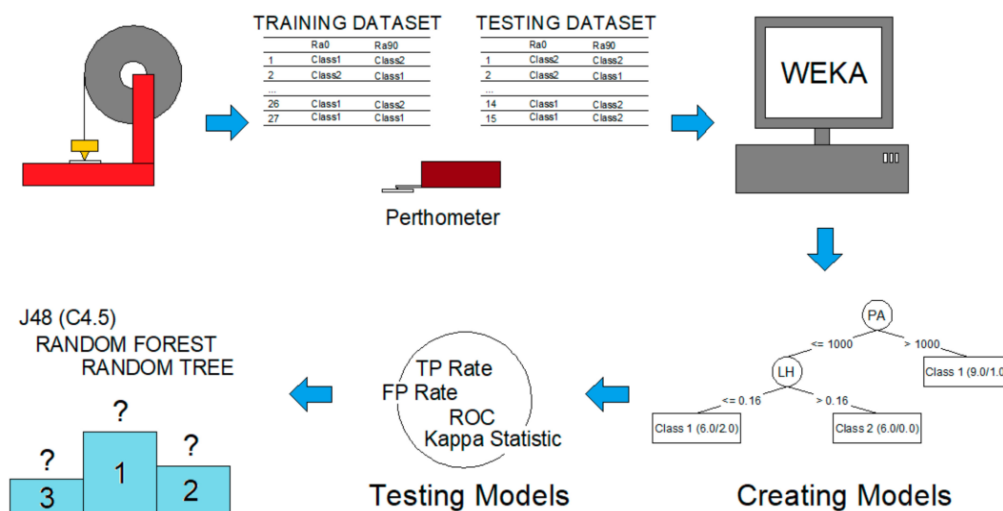


Figure II.11 : process utilisé



Les modèles ont été créés à l'aide d'un jeu de données de 27 instances avec les attributs suivants : hauteur de couche, température d'extrusion, vitesse d'impression, accélération d'impression et débit. De plus, un jeu de données a été créé pour évaluer les modèles, composé de 15 instances supplémentaires

**d) Résultats**

Les modèles générés par l'algorithme d'arbre aléatoire permettent d'obtenir les meilleurs résultats pour prédire la rugosité de surface dans les pièces FDM avec une précision de 86.67%.

## II.5. SYNTHÈSE GÉNÉRALE SUR LA MESURE DE LA RUGOSITÉ PAR APPRENTISSAGE AUTOMATIQUE

Le tableau ci-dessous constitue une synthèse d'un certain nombre de travaux ayant été effectués dans le sens du thème que nous traitons et présentés dans ce document.

Auteurs	Matériels	Paramètres variables considérées	Méthode(s) d'apprentissage automatique utilisé	Paramètres de rugosité mesurés	Observations
<p><b>Nicholas E. Sizemore, Monica L. Nogueira, Noel P. Greis et Matthew A. Davies (2020) [21]</b></p>	<ul style="list-style-type: none"> <li>• Outil en diamant monocristallin</li> <li>• Pièces en germanium (Ge) et en cuivre (Cu)</li> </ul>	<ul style="list-style-type: none"> <li>• Le rayon du nez d'outil <math>R</math> ;</li> <li>• Angle de coupe <math>\alpha</math> ;</li> <li>• Avance par tour <math>fr</math> ;</li> <li>• Profondeur de coupe <math>ad</math> ;</li> <li>• Vitesse de coupe <math>Vd</math> ;</li> <li>• L'avance <math>vf</math> ;</li> <li>• Épaisseur de copeau <math>td</math> ;</li> <li>• Vitesse de broche <math>\Omega</math></li> </ul>	<p>Les réseaux de neurone artificiel</p>	<p><b>Ra, Rq et Rz</b></p>	<p>Taux de précision de 94% pour les données d'entraînement et un taux de 60% pour les données de test</p>
<p><b>Md. Shahriar Jahan Hossain et Dr. Nafis Ahmad (2012) [22]</b></p>	<ul style="list-style-type: none"> <li>• Une fraiseuse verticale</li> <li>• Une plaque d'aluminium de taille 9 cm x 1 cm x 4 cm</li> </ul>	<ul style="list-style-type: none"> <li>• L'angle d'inclinaison de l'axe de la fraise (<math>\phi</math> degré),</li> <li>• La vitesse de la broche (<math>S</math> tr / min),</li> </ul>	<ul style="list-style-type: none"> <li>➤ Les réseaux de neurone artificiel</li> <li>➤ ANFIS</li> </ul>	<p><b>Ra</b></p>	<p>Le modèle ANFIS pourrait prédire la rugosité de surface pour les données</p>

	<ul style="list-style-type: none"> <li>• Une fraise en carbure à deux dents de 8 mm de diamètre</li> </ul>	<ul style="list-style-type: none"> <li>• La vitesse d'avance (fy en mm / min), la profondeur de coupe radiale (avance fx en mm), la profondeur de coupe axiale (t en mm)</li> </ul>			d'entraînement avec un taux d'erreur de 0,003014%, tandis que le modèle ANN prédire avec un taux d'erreur de 0,0314
<b>Marek Vrabel (2012) [23]</b>	Éprouvettes en super alliage au Nickel	<ul style="list-style-type: none"> <li>• La vitesse de coupe,</li> <li>• La vitesse d'avance</li> <li>• La profondeur de passe</li> </ul>	Les réseaux de neurone artificiel	<b>Ra</b>	Le système de prédiction de la rugosité produit des résultats appréciables pour la phase d'entraînement du réseau avec une erreur de 2,64%.
<b>Rajesh M. et Dr. R Manu (2014) [24]</b>	<ul style="list-style-type: none"> <li>• Une fraiseuse à axe verticale</li> <li>• Système FANUC</li> </ul>	<ul style="list-style-type: none"> <li>• La vitesse de coupe,</li> <li>• La vitesse d'avance</li> <li>• La profondeur de passe</li> </ul>	Les réseaux de neurone artificiel	<b>Ra et Rt</b>	Capacité du réseau de neurones à prédire la rugosité arithmétique et la rugosité totale avec une précision de 93.58% et 96.37 % respectivement
<b>Dhiren R. Patel Mysore et B. Kiran Vinay Vakharia (2019) [26]</b>	<ul style="list-style-type: none"> <li>• Profilomètre de type contact</li> </ul>	Image (caractéristiques de texture de surface)	Régression linéaire multiple	<b>Ra</b>	Le modèle de régression linéaire avait une erreur relative maximale de

	<ul style="list-style-type: none"> <li>• Acier à faible teneur en carbone ayant un diamètre de 30 mm et une hauteur de 18 mm</li> <li>• Machine de tournage CNC</li> </ul>				2,01%, nettement meilleure que le modèle de détection non linéaire de 9,60% de taux d'erreur
<p><b>Ibrahim A Badi, Ali G Shetwan, Maitig A (2017) [27]</b></p>	<ul style="list-style-type: none"> <li>• Pièces d'alliage d'acier HRC15</li> <li>• Centre de tournage</li> <li>• Ordinateur</li> <li>• Rugosimètre</li> </ul>	<ul style="list-style-type: none"> <li>• La vitesse de coupe,</li> <li>• La vitesse d'avance</li> <li>• La profondeur de passe</li> </ul>	<ul style="list-style-type: none"> <li>➤ Régression linéaire multiple</li> <li>➤ Les réseaux de neurone artificiel</li> </ul>	<b>Ra</b>	Les valeurs prédites obtenues à partir du modèle de réseau neuronal artificiel étaient meilleures que le modèle de régression linéaire multiple avec une erreur de 1% et 20%

<p><b>Ulas Çaydas et Sami Ekici (2010) [28]</b></p>	<ul style="list-style-type: none"> <li>• Tour programmable JOHNFOR D TC-35</li> <li>• Cylindre en acier inoxydable AISI 304</li> </ul>	<ul style="list-style-type: none"> <li>• La vitesse de coupe,</li> <li>• La vitesse d'avance</li> <li>• La profondeur de passe</li> </ul>	<ul style="list-style-type: none"> <li>➤ La régressions par support de vecteur (SVR)</li> <li>➤ Les réseaux de neurone artificiel</li> </ul>	<p><b>Ra</b></p>	<p>Il en ressort que les méthodes de régression à support vecteur machine produisent des résultats meilleurs que les réseaux de neurones</p>
<p><b>JuanLu et al. (2019) [29]</b></p>	<ul style="list-style-type: none"> <li>• Acier AISI 1045</li> <li>• Alliage au titane TC18</li> </ul>	<ul style="list-style-type: none"> <li>• La vitesse de coupe,</li> <li>• L'avance,</li> <li>• La profondeur de passe,</li> <li>• Le diamètre de l'outil.</li> </ul>	<p>La régressions par support de vecteur (SVR)</p>	<p><b>Ra</b></p>	<p>Le ABC-SVM s'avère être la méthode la plus efficace en termes de précision de la prédiction et temps de compilation.</p>
<p><b>Vijay Kumar, Sanjay Kumar Et Prashant Prakash (2011) [30]</b></p>	<ul style="list-style-type: none"> <li>• Capteur de déplacement capacitif cylindrique</li> <li>• Fraise en acier rapide</li> <li>• Aluminium 6061</li> <li>• Profilomètre à stylet</li> </ul>	<ul style="list-style-type: none"> <li>• La vitesse de coupe,</li> <li>• La vitesse d'avance</li> <li>• La profondeur de passe</li> </ul>	<p>Arbre de décision</p>	<p><b>Ra</b></p>	<p>Le résultat de la prédiction est favorable avec un pourcentage d'erreur moyen de 6,42%,</p>
<p><b>Juan M. Barrios and Pablo E. Romero (2019) [31]</b></p>	<ul style="list-style-type: none"> <li>• Ordinateur</li> </ul>	<ul style="list-style-type: none"> <li>• Hauteur de couche,</li> <li>• Température d'extrusion,</li> </ul>	<p>Arbre de décision</p>	<p><b>Ra</b></p>	<p>Les modèles générés par l'algorithme d'arbre</p>

	<ul style="list-style-type: none"> <li>• Pièces en polyéthylène téréphtalate glycol (PETG)</li> <li>• Imprimante 3D (FMD)</li> </ul>	<ul style="list-style-type: none"> <li>• Vitesse d'impression,</li> <li>• Accélération d'impression et débit</li> </ul>			aléatoire permettent d'obtenir les meilleurs résultats pour prédire la rugosité de surface dans les pièces FDM avec une précision de 86.67%.
<b>Ludovic Ngongang et al. (2021) [25]</b>	<p>Aciers au carbone Spectromètre Outil en ARS Outil en WC Fraiseuse Chronomètre Rugosimètre Microscope Matlab Ordinateur portable</p>	<ul style="list-style-type: none"> <li>• Temps de coupe</li> <li>• Pourcentage de carbone</li> <li>• Nature de l'outil</li> </ul>	Logique flou et ANN	<b>Ra</b>	L'ARS donne un MSE=0,032 en logique flou et MSE=0,254 en ANN. Le WC donne un MSE=0,014 en logique flou et MSE=0,037 en ANN.

## **II.6. CONCLUSION**

Les travaux cités ci-dessus montrent entes que l'apprentissage automatique s'avère être un outil moderne puissant pour la prédiction de la rugosité des pièces usinées en générale et fraisées en particulier. Cette étude se penchera donc de manière plus approfondie à la détermination des valeurs de rugosité des pièces fraisées grâce aux différentes méthodes d'apprentissage automatique tel que les réseaux de neurones artificiels, la régression par support de vecteur, la régression linéaire multiple et enfin l'arbre de décision par la suite nous allons faire une analyse comparative de toutes ces méthodes afin de sauvegarder le meilleur modèle pour déploiement. De ce fait, nous investiguerons les valeurs obtenues des rugosités en considérant comme paramètres principaux le temps de coupe, le pourcentage de carbone du matériaux usinés et nature de l'outil.

## Chapitre 3

---

### MATERIELS ET METHODES

La réalisation de notre travail se fait par l'étude des techniques d'apprentissage automatique dans la détermination de la rugosité moyenne (Ra). Les paramètres variables étant : le temps de coupe (Tc), le pourcentage de carbone du matériau usiné(%C) et enfin la nature de l'outil (WC/HSS). Nous présentons ainsi le matériel nécessaire pour le parachèvement de cette étude, définissons une méthode d'étude dans le but ultime d'implémenter la méthode de mesure par apprentissage automatique de la rugosité sous PYTHON.

---

III.1. MATERIELS .....	56
III.2. MÉTHODES .....	57
III.2.1. Régression Linéaire Multiple .....	59
III.2.2. Régression par support de vecteur .....	61
III.2.3. Régression par arbre de décisions .....	61
III.2.4. Les réseaux de neurones artificiels .....	62
III.3. CONCLUSION .....	66

---



### III.1. MATERIELS

#### a) Environnement de programmation

Un ordinateur dont les caractéristiques sont les suivants :

Tableau 8 : caractéristique de l'ordinateur utilisé

Marque	Système d'exploitation	Type de système	RAM	Processeur
<b>LENOVO T450</b>	Windows 10 Professional	Système 64 bits	8Go	Intel(R) Core™i5-5200u CPU@ 2.20 GHz

#### b) Plateforme d'apprentissage

##### ➤ Langage de programmation utilisé

Le langage de programmation utilisé est python C'est premièrement un langage de haut niveau (langage très proche du langage humain). La version de python utilisée est **3.8**.

##### ➤ Interface de développement utilisée (IDE)

Basé sur le langage python **PYCHARM** est un IDE très intuitif et efficace pour coder en python c'est pour ces raisons que nous avons décidé de l'utiliser.

#### c) Le datasets

Les données utilisées sont ceux de Ludovic Ngongang et al. (2021) [28] mise à notre entière disposition. Ce dataset est constitué 24 échantillons de mesures conventionnel de la rugosité (Ra) en fonction du temps de coupe (Tc) et le taux de carbone du matériau usiné (%C) pour chaque matériau d'outil utilisé.Ces données sont répertoriées sur un tableau Excel comprenant 3 colonnes constitue respectivement du temps coupe **Tc**, le taux de carbone du matériau usiné (%C) et enfin la rugosité **Ra** comme le montre les tableaux 9 et 10.

**Tableau 9** : dataset pour fraisage avec carbure de tungstène (Tc en s, Ra en  $\mu\text{m}$ ) [28]

N° EXP	Tc	%C	Ra
1	95	0.1	0.61
2	190	0.1	0.44
3	285	0.1	0.44
4	380	0.15	0.47
5	475	0.15	0.46
6	570	0.15	0.33
7	665	0.25	0.46
8	760	0.25	0.21
9	885	0.25	0.55
10	940	0.35	0.637
11	1045	0.35	0.32
12	1140	0.35	0.68
13	1235	0.1	0.16
14	1330	0.1	0.38
15	1425	0.1	0.159
16	1520	0.15	0.26
17	1615	0.15	0.29
18	1710	0.15	0.207
19	1805	0.25	0.36
20	1900	0.25	0.24
21	1995	0.25	0.291
22	2090	0.35	0.26
23	2185	0.35	0.38
24	2280	0.35	0.16

**Tableau 10** : dataset pour fraisage avec acier rapide (Tc en s, Ra en  $\mu\text{m}$ ) [28]

N° EXP	Tc	%C	Ra
1	282	0.1	5.4
2	188	0.1	2.28
3	376	0.15	2.98
4	470	0.15	3.62
5	564	0.15	3.94
6	658	0.25	2.76
7	752	0.25	0.128
8	846	0.25	4.28
9	940	0.35	2.53
10	1034	0.35	2.28
11	1128	0.35	2.9
12	1222	0.1	3.04
13	1316	0.1	2.82
14	1410	0.1	1.61
15	1504	0.15	1.85
16	1598	0.15	3.66
17	1692	0.15	1.86
18	1786	0.25	2.84
19	1880	0.25	2.15
20	1974	0.25	1.36
21	2068	0.35	2.15
22	2162	0.35	3.98
23	2256	0.35	3.42
24	94	0.1	2.27

### III.2. MÉTHODES

La méthodologie générale de conception des modèles qui vont être développés ci-dessous peut être décrite comme suit :

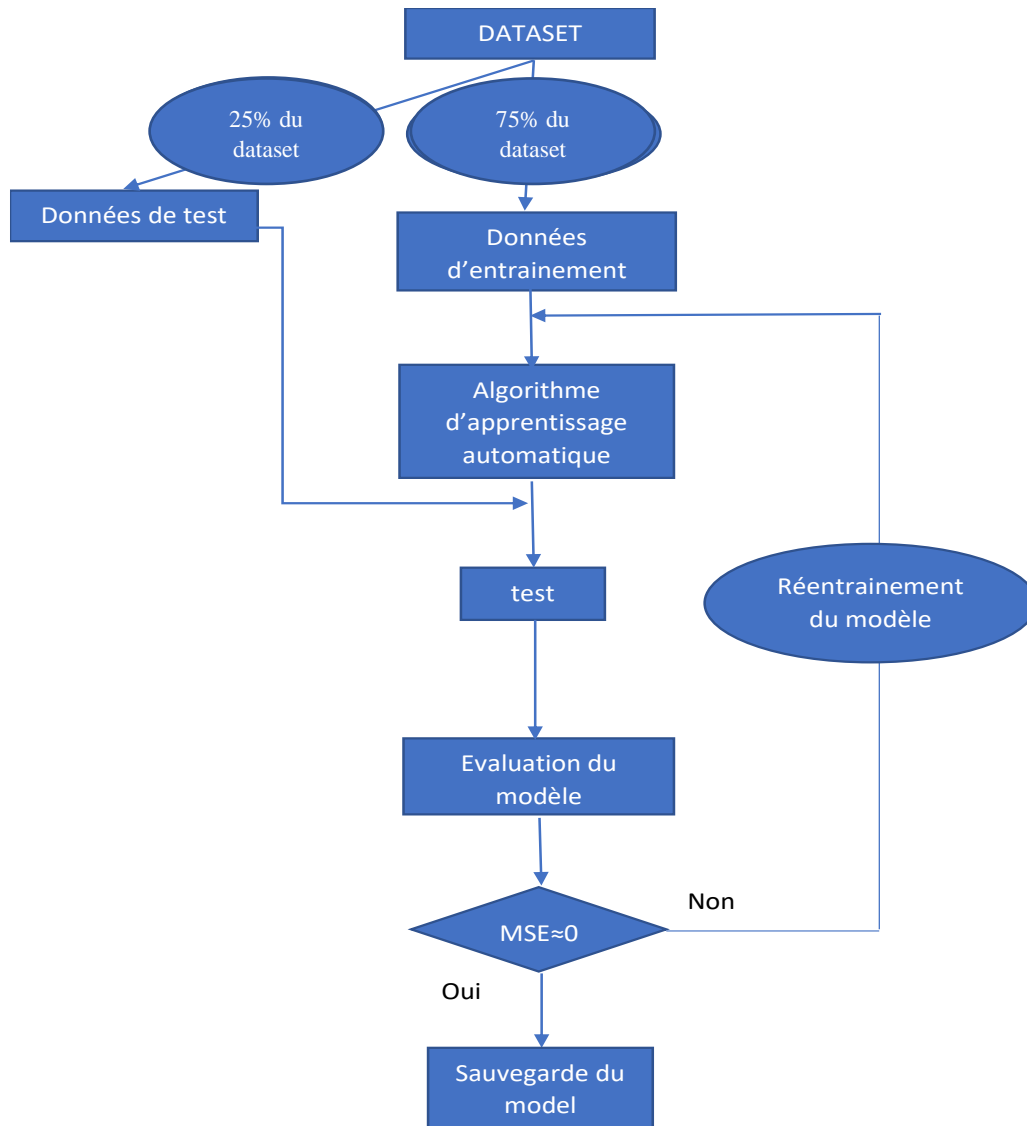


Figure III.1 : synoptique général de notre méthode

Les bibliothèques communes à tous les modèles développés sont les suivants :

➤ **NUMPY**

NumPy est une bibliothèque pour langage de programmation Python, destinée à manipuler des matrices ou tableaux multidimensionnels ainsi que des fonctions mathématiques opérant sur ces tableaux. Plus précisément, cette bibliothèque logicielle libre et open source fournit de multiples fonctions permettant notamment de créer directement un tableau depuis un fichier ou au contraire de sauvegarder un tableau dans un fichier, et manipuler des vecteurs, matrices et polynômes. Dans le cadre de notre travail elle nous a permis de gérer les matrices de données mises à notre disposition.

Syntaxes pour l'importer : `import numpy as np`

➤ **MATPLOTLIB**

Matplotlib est une bibliothèque du langage de programmation Python destinée à tracer et visualiser des données sous formes de graphiques. Elle peut être combinée avec les bibliothèques python de calcul scientifique NumPy et SciPy. Dans le cadre de notre travail elle nous a permis de visualiser nos données

Syntaxes pour l'importer : `import matplotlib.pyplot as plt`

➤ **PANDAS**

Pandas est une bibliothèque écrite pour le langage de programmation Python permettant la manipulation et l'analyse des données. Elle propose en particulier des structures de données et des opérations de manipulation de tableaux numériques et de séries temporelles.

Dans le cadre de notre travail elle nous a permis d'importer notre dataset.

Syntaxes pour l'importer : `import pandas as pd`

**III.2.1. Régression Linéaire Multiple**

La régression linéaire multiple est une méthode de régression mathématique étendant la régression linéaire simple pour décrire les variations d'une variable de sortie associée aux variations de plusieurs variables d'entrée.

La méthode mathématique peut être explicité comme suit :

- Elle revient à résoudre l'équation suivante et à déterminer les paramètres **a1, a2, ..., a20** pour pouvoir définir le modèle, le paramètre  $\epsilon$  permet de cristallisé tous les imperfections du modèle. Cette équation peut s'écrire sous la forme  **$Ra_i = a_i X + \epsilon_i$**

$$\text{Soit : } \mathbf{X} = \begin{bmatrix} 1 & Tc1 & \%C1 \\ 1 & Tc2 & \%C2 \\ \vdots & \vdots & \vdots \\ 1 & Tc20 & \%C20 \end{bmatrix}, \mathbf{a}_i = \begin{pmatrix} a1 \\ a2 \\ \vdots \\ a20 \end{pmatrix}, \mathbf{\epsilon}_i = \begin{pmatrix} \epsilon1 \\ \epsilon2 \\ \vdots \\ \epsilon20 \end{pmatrix} \text{ et } \mathbf{Ra}_i = \begin{pmatrix} Ra1 \\ Ra2 \\ \vdots \\ Ra20 \end{pmatrix} \quad (10)$$

$$\begin{pmatrix} Ra1 \\ Ra2 \\ \vdots \\ Ra20 \end{pmatrix} = \begin{bmatrix} 1 & Tc1 & \%C1 \\ 1 & Tc2 & \%C2 \\ \vdots & \vdots & \vdots \\ 1 & Tc20 & \%C20 \end{bmatrix} \begin{pmatrix} a1 \\ a2 \\ \vdots \\ a20 \end{pmatrix} + \begin{pmatrix} \epsilon1 \\ \epsilon2 \\ \vdots \\ \epsilon20 \end{pmatrix} \quad (11)$$

- Le rôle l'ordinateur dans notre étude est de trouver le meilleur paramètre **a<sub>i</sub>** et **ε<sub>i</sub>** pour avoir une meilleure prédiction en utilisant l'algorithme de régression linéaire multiple

**a) Bibliothèque particulière utilisée**

- **Scikit-learn**

**Scikit-learn** est une bibliothèque libre Python destinée à l'apprentissage automatique. Elle est développée par de nombreux contributeurs notamment dans le monde académique par des instituts français d'enseignement supérieur et de recherche comme Inria. Elle propose dans son framework de nombreuses bibliothèques d'algorithmes à implémenter, clé en main.

➤ **linear\_model**

**linear\_model** est une sous bibliothèque de Scikit-learn permettant d'appeler dans notre algorithme un modèle de régression linéaire multiple.

b) **Synoptique**

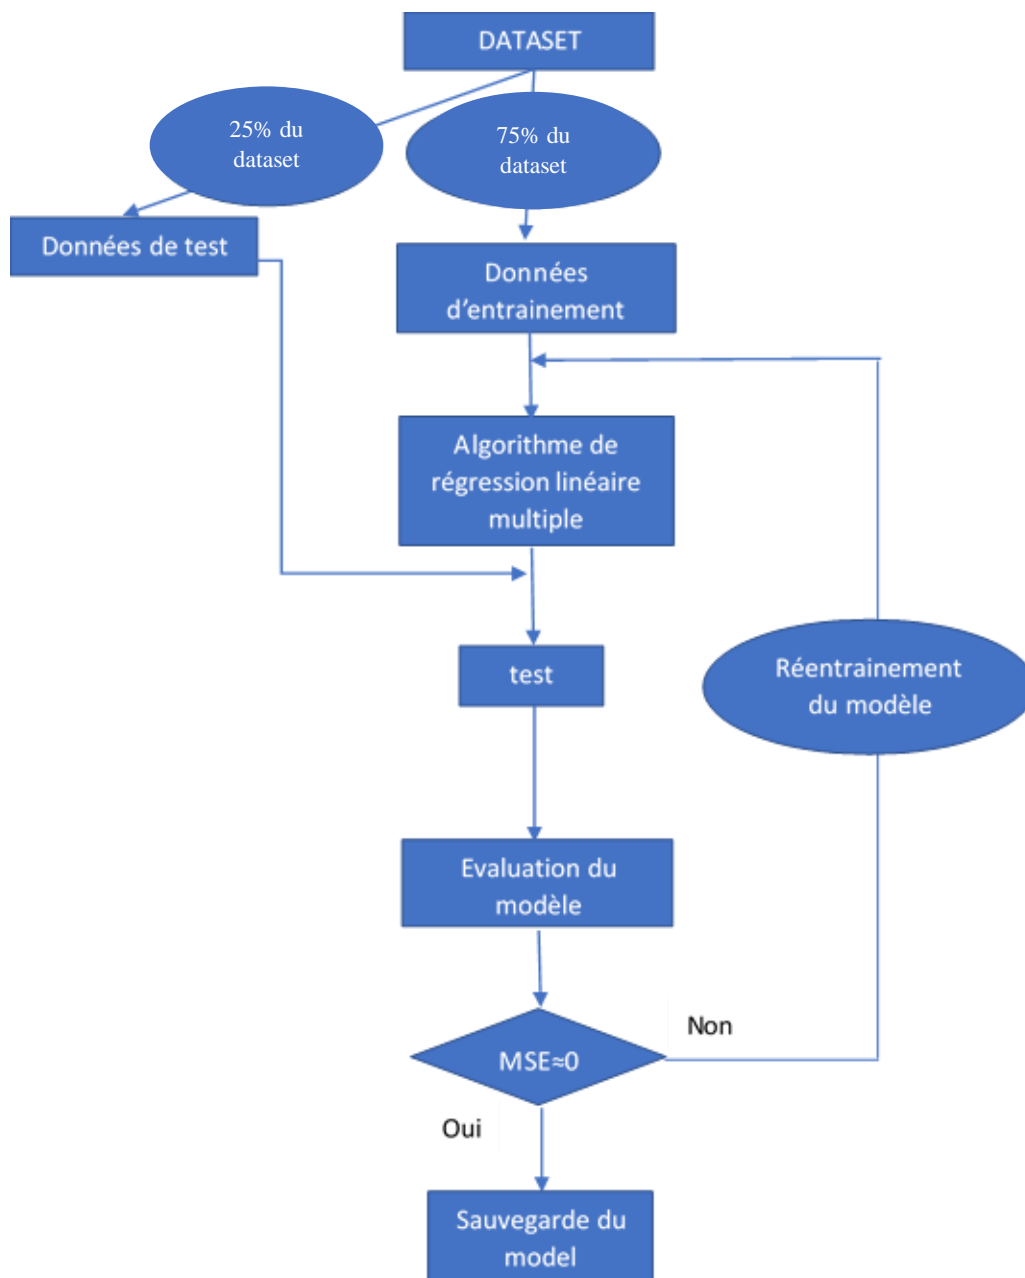


Figure III.2 : synoptique régression linéaire multiple

### III.2.2. Régression par support de vecteur

Les machines à vecteurs de support ou séparateurs à vaste marge (en anglais support vector machine, SVM) sont un ensemble de techniques d'apprentissage supervisé destinées à résoudre des problèmes de discrimination et de régression. Les SVM sont une généralisation des classifieurs linéaires.




Figure III.3 : exemple de régression par support de vecteur

#### a) Bibliothèque particulière utilisée

La seule bibliothèque particulière ayant été utilisée est SVR qui est la bibliothèque permettant d'appliquer une régression par support de vecteur.

#### b) Synopsis

Le synopsis est presque identique à celui de la régression linéaire multiples sauf qu'à la passé d'importer le modèle linear\_model nous importons plus tôt le modèle svm.SVR qui est le modèle de régression par support de vecteur.

### III.2.3. Régression par arbre de décisions

Les arbres de régression (Regression Tree) permettent de prédire une quantité réelle (par exemple, le prix d'une maison ou la durée de séjour d'un patient dans un hôpital), dans ce cas la prédiction est une valeur numérique.




Figure III.4 : exemple de régression par arbre de décision

**a) Bibliothèque particulière utilisée**

La seule bibliothèque particulière ayant été utilisée est `tree.DecisionTreeRegressor` qui est la bibliothèque permettant d'appliquer une régression par arbre de décision.

**b) Synopsis**

Le synopsis est presque identique à celui de la régression linéaire multiples sauf qu'à la place d'importer le modèle `linear_model` nous importons plus tôt le modèle `DecisionTreeRegressor` qui est le modèle de régression en utilisant l'arbre de décision.

**III.2.4. Les réseaux de neurones artificiels**

Un réseau de neurones artificiels ou Neural Network est un système informatique s'inspirant du fonctionnement du cerveau humain pour apprendre.

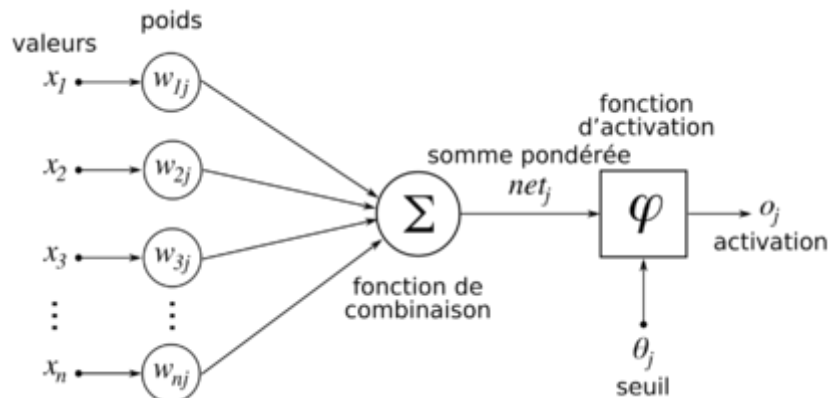


Figure III.5 : structure de base d'un réseau de neurones artificielle

Pour expliquer la mathématique qui se cache derrière notre réseau de neurones nous allons étudier juste une branche de notre réseau qui peut être représenté dans la figure ci-dessous où :

- **W** représente les poids initialisés par l'algorithme
- **B** représente le biais initialisé par l'algorithme
- **f** représente la fonction de combinaison
- **g** représente la fonction d'activation




Figure III. 6 : partie de notre réseau utiliser pour expliquer le fonctionnement de base

Le calcul de la valeur de sortie peut se faire par les équations suivantes :

$$f(T_c, \%C) = T_c \times W_1 + \%C \times W_2 + b_1 \quad (12)$$

$$Ra = g(f(T_c, \%C)) = g(T_c \times W_1 + \%C \times W_2 + b_1) \quad (13)$$

**a) Structure du notre réseau de neurones**

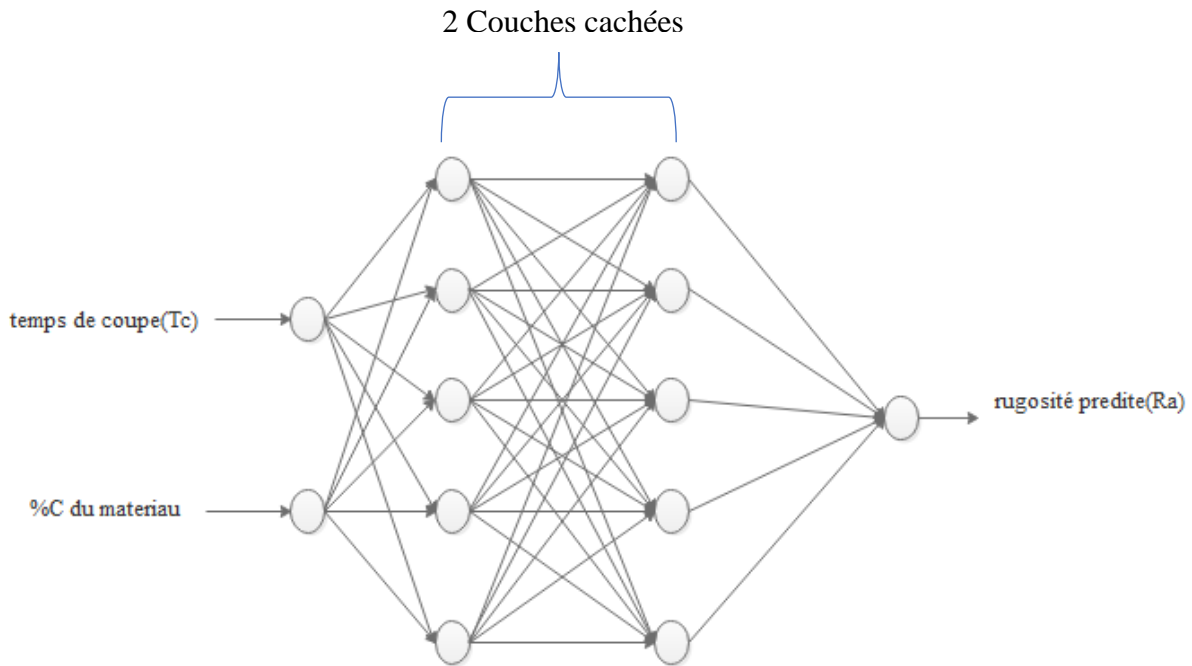


Figure III.7 : structure du réseau de neurones utilisé pour chaque dataset




Figure III.8 : structure du réseau de neurones utilisé pour les deux datasets combiné



**b) Fonction de combinaison utilisée**

Vue que notre réseau est du type MLP (multi-layer perceptron) la fonction de combinaison est une combinaison linéaire des entrées, c'est-à-dire que la fonction de combinaison renvoie le produit scalaire entre le vecteur des entrées et le vecteur des poids synaptiques.

**c) Fonction d'activation utilisée**

Il existe plusieurs fonctions d'activation, mais dans le cas de notre étude il était possible d'en utiliser 2 :

➤ **La fonction sigmoïde**

Pour utiliser cette fonction d'activation dans notre code il était d'abord nécessaire de standardiser nos données (transformer nos données d'entrée en donné compris entre 0 et 1) pour que la fonction d'activation puisse les laisser passer. Cette fonction a pour expression (14) et est représenté à la figure III.9 .

➤ **La fonction Relu**

Cette fonction aurait pu être utilisé dans notre réseau sauf qu'elle rendait l'entraînement et le test beaucoup trop long. Cette fonction a pour expression (14) et est représenté à la figure III.10 .

$$f(x) = \frac{1}{1 + e^{-x}} \quad (14)$$

$$f(x) = \begin{cases} 0 & \text{si } x < 0 \\ x & \text{si } x \geq 0 \end{cases} \quad (13)$$




Figure III.9 : courbe de la fonction sigmoïde




Figure III.10 : courbe de la fonction Relu

**d) Décence de gradient (Learning rate)**

La Décence de gradient est un algorithme de minimisation de la fonction erreur. En fait le but de cet algorithme est d'atteindre le minimum de la courbe coût. Le Learning rate est considéré comme le pas permettant à l'algorithme d'atteindre le fond de la courbe erreur.

Dans le cas de notre étude le Learning rate a été pris de façon expérimentale et c'est après plusieurs test que nous avons pu affiner sa valeur à  $lr=0.009$ .

**e) Le nombre d'epochs (nombre de générations d'entraînement)**

Le nombre d'epochs est le nombre de fois que nous allons faire passer nos données d'entraînement dans le réseau de neurones dans le but de l'entraîner. Pour ce fait nous avons opté pour 60 epochs pour l'acier rapide, 400 epochs pour le carbure de tungstène et 1000 epochs pour le dataset combiné. Nous avons obtenu les courbes du taux d'erreur en fonction du nombre d'itération suivantes :




Figure III.11 : courbe d'apprentissage (acier rapide)



Figure III.12 : courbe d'apprentissage (carbure de tungstène)




Figure III.13 : courbe d'apprentissage (acier rapide et carbure de tungstène)

Ces courbes d'apprentissage nous montrent qu'après un certain nombre d'epochs il n'est plus nécessaire d'entraîner notre modèle car elle a déjà atteint son taux minimal d'erreur.

f) Synoptique

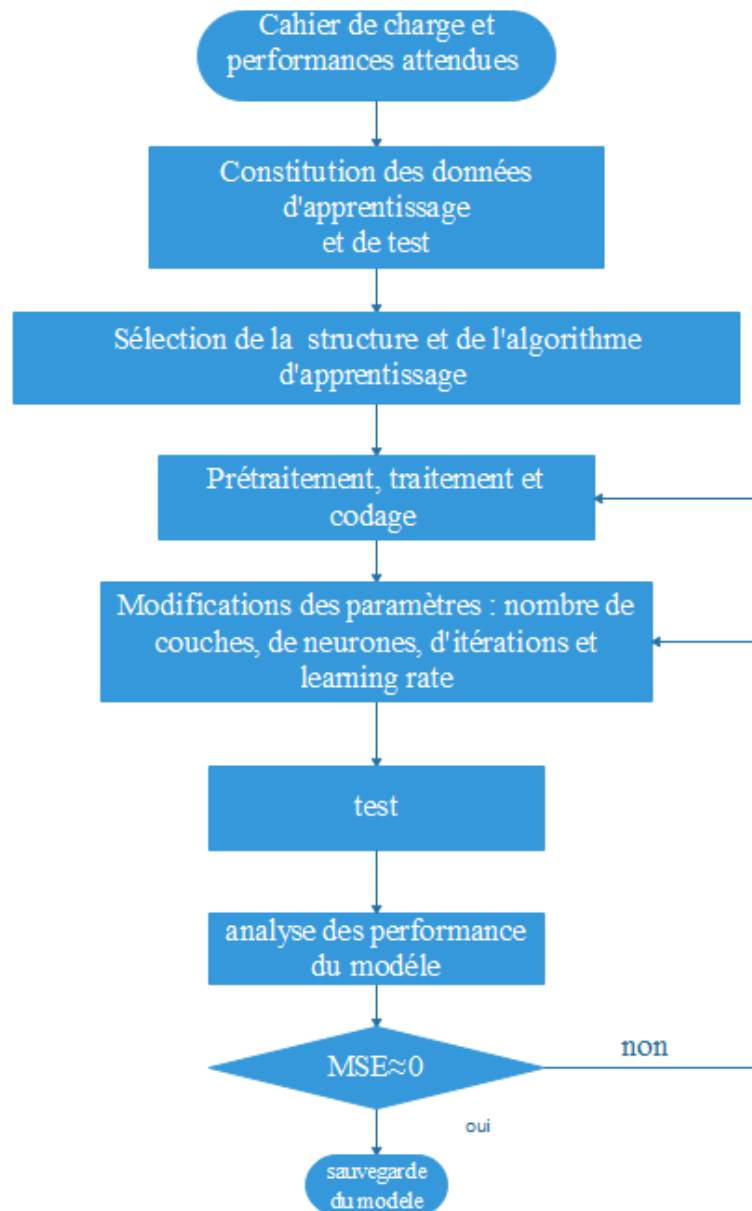


Figure III.14 : synoptique réseau de neurone artificiel

III.3. CONCLUSION

La mise sur pied de notre méthode de détermination par apprentissage automatique de la rugosité nécessite une expérimentation et un ensemble de données à utiliser pour entrainer tous nos modèles. Pour cela il était nécessaire de décrire dans les détails les différents paramètres utilisés dans notre expérimentation. Nous avons ainsi présenté les méthodes algorithmes utilisées pour pouvoir développer tous nos modèles. La suite nous demande obligatoirement de faire une comparaison des résultats que vas nous fournir chaque modèle puis sélectionner le meilleur modèle pour déploiement.

## Chapitre 4

---

# RESULTATS ET DISCUSSIONS

La réalisation de notre travail se fait par l'étude de l'efficacité de la technique d'apprentissage automatique choisie sur les 3 datasets, notamment la régression linéaire multiple, la régression par support de vecteur, la régression par arbre de décision et enfin le réseau de neurones artificiel dans la détermination de la rugosité moyenne ( $R_a$ ). Les paramètres variables étant : le temps de coupe, le pourcentage de carbone du matériau à usiné et la nature de l'outil. Nous présentons ainsi le matériel nécessaire pour le parachèvement de cette étude, définissons un design expérimental et une méthode d'étude dans le but ultime d'implémenter les méthodes de mesure par apprentissage automatique des paramètres de rugosité sous python.

---

IV.1. RESULTATS .....	68
IV.1.1. Régression linéaire multiple.....	68
IV.1.2. Régression par support de vecteur .....	69
IV.1.3. Régression avec arbre de décision .....	70
IV.1.4. Réseaux de neurones artificiels.....	72
IV.2. BILAN DE PERFORMANCE DE CHAQUE MODELE .....	73
IV.3. DISCUSSION .....	74
IV.4. DEVELOPPEMENT D'UNE APPLICATION POUR LE DEPLOIEMENT.....	75
IV.5. CONCLUSION .....	75

---

## IV.1. RESULTATS

### IV.1.1. Régression linéaire multiple

Après avoir testé notre modèle de régression linéaire multiple avec les données de test des 3 datasets, nous avons obtenus les courbes de précision de la prédiction et les MSE (mean square error) représentés aux Figure IV.1, IV.2, IV.3.




Figure IV.1 : courbe de précision des deux datasets combiné (ARS+WC)




Figure IV.2 : courbe de précision du dataset de l'acier rapide (ARS)




Figure IV. 3 : courbe de précision du dataset du carbure de tungstène (WC)

Ce résultat nous montre de façon claire que la régression linéaire simple brille par sa polyvalence sur tous les 3 datasets car on peut se rendre que tous ces MSE sont moyennement proche de 0.

#### IV.1.2. Régression par support de vecteur

Après avoir testé notre modèle de régression linéaire multiple avec les données de test des 3 datasets, nous avons obtenus les courbes de précision de la prédiction et les MSE (mean square error) représentés aux Figure IV.4, IV.5, IV.6.




Figure IV.4 : courbe de précision des deux datasets combiné (ARS+WC)




Figure IV.5 : courbe de précision du dataset de l'acier rapide (ARS)




Figure IV.6 : courbe de précision du dataset du carbure de tungstène (WC)

La régression par support de vecteur nous à fournir est notre algorithme qui nous à donner la plus base précision de manière générale, mais il nous quand même fournir la meilleure précision sur le carbure de tungstène.

#### IV.1.3. Régression avec arbre de décision

Après avoir testé notre modèle de régression linéaire multiple avec les données de test des 3 datasets, nous avons obtenus les courbes de précision de la prédiction et les MSE (mean square error) représentés aux Figure IV.7, IV.8, IV.9.




Figure IV.7 : courbe de précision des deux datasets combiné (ARS+WC)




Figure IV.8 : courbe de précision du dataset de l'acier rapide (ARS)






Figure IV.9 : courbe de précision du dataset du carbure de tungstène (WC)

La régression par arbre de décision n'a pas vraiment été polyvalent sur les 3 datasets mais nous a quand même donné la meilleure précision sur le dataset de l'acier rapide avec un MSE=0.713.

#### IV.1.4. Réseaux de neurones artificiels

Après avoir testé notre modèle de régression linéaire multiple avec les données de test des 3 datasets, nous avons obtenus les courbes de précision de la prédiction et les MSE (mean square error) représentés aux Figure IV.10, IV.11, IV.12.




Figure IV.10 : courbe de précision des deux datasets combiné (ARS+WC)




Figure IV.11 : courbe de précision du dataset de l'acier rapide (ARS)




Figure IV.12 : courbe de précision du dataset du carbure de tungstène (WC)

Tout comme la régression linéaire multiple le réseau de neurone artificielle s'avère être très polyvalent et nous présente de manière générale des MSE proche de 0 on peut dire avec certitude que ce modèle est celui qui s'adapte le mieux.

#### IV.2. BILAN DE PERFORMANCE DE CHAQUE MODELE

	Acier rapide	Carbure de tungstène	datasets combinés
MSE régression linéaire multiple	0,7848	0,097	0,4238
MSE régression par support de vecteur	0,862	0,0217	1,516
MSE régression par arbre de décision	0,713	0,0345	1,305
MSE réseaux de neurone artificiel	0,7704	0,017	0,5355

Ce bilan de performance montre que premièrement qu'avec un  $MSE=0,017$  l'ANN sur le dataset WC donnent la meilleure précision de notre étude, deuxièmement le dataset WC présente de façons générales des MSE très bas sur les 4 modèles par rapport aux autres dataset et enfin on peut constater que le dataset combiné avec un  $MSE=0,4238$  sur la régression linéaire multiple et un  $MSE=0,5355$  sur l'ANN présente une meilleure précision sur ces deux modèles par rapport au dataset ARS malgré le fait que celui-ci présente des MSE tous inférieur à 1.

### **IV.3. DISCUSSION**

Comme nous l'avons rappelé dans les chapitres précédent le choix des paramètres d'entrée tel que le temps de coupe, le pourcentage de carbone du matériau usiné et la nature de l'outil ont été influencé par le fait que ces paramètres d'entrée n'ont quasiment pas été utilisé par la plupart des auteurs que nous avons présenté au chapitre 2, le seul article ayant pris en compte ces paramètre est celui de **Ludovic Ngongang et al. (2021) [28]** et leur model d'ANN un  $MSE=0,254$  avec l'ARS ce qui est plus performant que notre modèle puisque nous avons eu un  $MSE=0,7704$ , mais notre modèle d'ANN s'est avéré plus efficace que les leur en utilisant le WC comme outil puisque nous avons eu un  $MSE =0,017$  contre  $MSE=0,037$  qu'ils ont obtenus.

Les résultats obtenus nous renseignent qu'avec un MSE de **0,42** le modèle de régression linéaire multiple est plus précis avec les deux datasets combiné malgré le fait qu'il soit moins précis que celui de Dhiren R. Patel Mysore et B. Kiran Vinay Vakharia (2019) [22] qui a seulement une marge d'erreur de 2,01% et Ibrahim A Badi1, Ali G Shetwan2, Maitig A (2017) [23] qui a une marge d'erreur de 1% , le modelé de régression par arbre de décision avec un MSE de **0.71** est plus précis quand on utilise un outil d'acier rapide mais reste quand même moins efficace que celui de Vijay Kumar, Sanjay Kumar Et Prashant Prakash (2011) [26] qui s'en sort mieux et enfin on constate qu'avec un MSE de **0.017** le modèle de réseaux de neurones artificiel s'en sort mieux pour la prédiction de la rugosité en utilisant un outil de carbure de tungstène et à une meilleur précision que [18 19 20 21].

Vue ces résultats nous avons entamé une réflexion sur le modèle capable de prédire de manière efficace la rugosité et nous avons convenus que le meilleur modèle seras celui qui s'en sort le mieux en prenant en compte le temps de coupe, le % de carbone et aussi la nature de l'outil. Donc nous avons donc choisi le modèle qui était plus efficace sur les deux datasets

combiné il en ressort que le modèle qui sera déployé par la suite est le modèle de régression linéaire multiples.

#### IV.4. DEVELOPPEMENT D'UNE APPLICATION POUR LE DEPLOIEMENT

Afin de pouvoir utiliser ce modèle pour une variété de données nous avons mis sur pied une application web dénommée « *intelligence artificiel de mesure de rugosité enset\_ebolowa\_gme* » et pouvant être stocker sur un serveur en ligne pour pouvoir être utiliser dans tous les coins du monde.

##### a) Interface visuelle

L'interface d'utilisation de notre application se présente comme suit :



Figure IV.14 : interface d'utilisation

- (1) Récupère le temps de coupe en seconde entré par l'utilisateur
- (2) Récupère le pourcentage de carbone du matériau usiné entré par l'utilisateur
- (3) Récupère la nature de l'outil (0 pour l'acier rapide et 1 pour le carbure de tungstène) entré par l'utilisateur
- (4) Actionne la prédiction de la rugosité

#### IV.5. CONCLUSION

Les résultats fournis par nos modèles d'apprentissage automatique, une discussion sur ceux-ci et une présentation de l'interface d'utilisation ont été établi dans ce chapitre. Il en ressort de manière claire et directe que la plupart de ces algorithmes sont capable prédire avec une précision acceptable la rugosité d'une surface fraiser. Nous pouvons aussi affirmer que l'application web qui a été développé à cet effet peut faire partie intégrante des outils de mesure de la rugosité.

---

*CONCLUSION GÉNÉRALE ET PERSPECTIVES*

---

Nous avons étudié dans ce mémoire des méthodes d'apprentissage automatique de détermination de la rugosité. Il s'agissait de mettre sur pied des algorithmes de prédiction de la rugosité arithmétique moyenne des surfaces fraisées à l'aide des méthodes d'apprentissage automatique : le réseau de neurones artificiel (ANN), la régression linéaire multiple, la régression par arbre de décision et enfin la régression par supports de vecteur. Pour ce faire, il nous a fallu dans un premier chapitre étudier les notions relatives aux surfaces fraisées : les paramètres de surface ; les formes, qualités d'états de surface obtenues par fraisage et une généralité sur l'apprentissage automatique. Dans un second chapitre nous nous sommes attelés à résumer et évaluer certaines recherches basées sur la mesure intelligente de la rugosité. Le chapitre suivant nous a permis de mettre sur pied les bases de notre travail. Nous y avons présenté le matériels et la méthode des algorithmes utilisés lors de nos expérimentations. Quarante (40) combinaisons de variables d'usinage que sont le pourcentage de carbone du matériau usinés, le temps de coupe et la nature de l'outil ; nous ont permis de mettre sur pied une base de données des rugosités Ra. L'ultime chapitre a été réservé à la présentation des résultats d'implémentation. Les données d'entrée étant les variables d'usinage et la valeur de sortie la rugosité arithmétique moyenne (Ra). 75% des données ont été utilisées pour l'entraînement, 25% pour les tests afin d'éviter le phénomène de surentraînement et garantir une globalisation des résultats. L'erreur quadratique moyenne (MSE) utilisée pour évaluer la performance des systèmes prédictifs accorde un choix privilégié à l'ANN avec l'outil en carbure de tungstène en entrée avec une valeur  $MSE=0,017$ . La réalisation de ce travail ouvre un vaste champ pour de prochaines recherches notamment :

- L'utilisation d'un nombre bien plus important de données expérimentales afin d'améliorer la précision des résultats ;
- L'utilisation des réseaux de neurones convolutionnelles pour déterminer la rugosité à partir de l'image de la surface.
- La globalisation aux autres paramètres de rugosité

## BIBLIOGRAPHIE

- [1] Leroy, B. (2013). La mesure de la microrugosité en environnement industriel : cas des pièces mécaniques. edp sciences.
- [2] wikipedia. (S.d.). Récupéré sur <https://fr.m.wikipedia.org/wiki/rugosit%C3%A9> ; consulté le 15 juillet 2020.
- [3] Ozcelik, B., Oktem, H., & Kurtaran, H. (2005). optimum surface roughness in end milling inconel 718 by coupling neural network model and genetic algorithm. springer-verlag london limited, page 235.
- [4] - <https://www.maxicours.com/se/cours/etat-de-surface-et-indice-de-rugosite-1/>. Vue le 15/02/2021 à 18h05
- [5] - <http://leslubrifiants.com/2016/04/15/les-surfaces-elementaires-en-fabrication-mecanique/> vue le 02/01/2021 à 18h50.
- [6] -y. schoefs, s. fournier, j-j léon, productique mécanique, delagrave 1999.
- [7] - cours procédés d'obtention de pièces, lycée jules ferry versailles.
- [8] - procédés d'obtention des surfaces par enlèvement de matière, cpge - pti - ch. coffin,26 pages.
- [9] - Nica Dorina, détermination des paramètres de coupe, royaume du Maroc, office de la formation professionnelle et de la promotion du travail, 1992 ,33 pages
- [10] - Florea Florian, fabrication de pièces d'usinage simples en fraisage, royaume du Maroc, office de la formation professionnelle et de la promotion du travail, 1992 ,93 pages
- [11] - Badji Mokhtar Annaba (2017), l'influence des paramètres de coupe sur l'état de surface lors de l'usinage de l'acier xc55, université badji mokhtar annaba. : mémoire présenté à la faculté des sciences de l'ingénierat.
- [12] -Toukap Taka Brice Charnel (2020), dispositif in-situ de mesure surfacique de rugosité et d'acquisition d'images sur pièces fraisées, mémoire présenté en vue de l'obtention du diplôme de professeur d'enseignement technique grade II (dipet II) en construction mécanique, université de Yaoundé 1, Cameroun.

[13] - <http://194.27.49.11/makine/sebreg/lab/profilometre.html>. Vue le 17/10/2020 à 14h50.

[14] - Ngnimboha Nguepi Stephane (2019), système d'acquisition online des données en vue de l'étude de l'impact des conditions d'usinage sur la rugosité des surfaces en fraisage, mémoire présenté en vue de l'obtention du diplôme de professeur d'enseignement technique grade ii (dipet II), université de Yaoundé 1, Cameroun.

[15] - Nlend Bisseck Ruben Hervé (2020), mesure et prédiction des paramètres de rugosité, mémoire soutenu en vue de l'obtention mémoire présenté en vue de l'obtention du diplôme de professeur d'enseignement technique grade II (dipet II) en construction mécanique, université de Yaoundé, Cameroun.

[16] - [https://www.keyence.eu/fr/fr/ss/products/microscope/roughness/line/tab01\\_c.jsp](https://www.keyence.eu/fr/fr/ss/products/microscope/roughness/line/tab01_c.jsp). Vue le 12/02/2021 à 11h35

[17] - [http://robert.cireddu.free.fr/ressources/prod/les\\_modes\\_de\\_generation/les\\_modes\\_de\\_generation.htm](http://robert.cireddu.free.fr/ressources/prod/les_modes_de_generation/les_modes_de_generation.htm). Vue le 02/02/2021 à 11h35

[18] [https://www.google.com/search?q=rugosim&sxsrf=alekk03etwj4derxzm3zbmeqxdfxvupig:1613314363233&source=lnms&tbn=isch&sa=x&ved=2ahukewjk5ps0onuahuq3iukhfkdv\\_gq\\_auoaxoecauqaw&biw=1777&bih=852&dpr=0.9#imgrc=5itlshmk6gumm](https://www.google.com/search?q=rugosim&sxsrf=alekk03etwj4derxzm3zbmeqxdfxvupig:1613314363233&source=lnms&tbn=isch&sa=x&ved=2ahukewjk5ps0onuahuq3iukhfkdv_gq_auoaxoecauqaw&biw=1777&bih=852&dpr=0.9#imgrc=5itlshmk6gumm). Vue le

[19] [https://fr.wikipedia.org/wiki/apprentissage\\_automatique#:~:text=%c2%ab%20apprentissage%20machine%20%20c2%bb\)%2c%20apprentissage,d%27am%c3%a9liorer%20leurs%20performances%20c3%a0](https://fr.wikipedia.org/wiki/apprentissage_automatique#:~:text=%c2%ab%20apprentissage%20machine%20%20c2%bb)%2c%20apprentissage,d%27am%c3%a9liorer%20leurs%20performances%20c3%a0). vue le 02/11/2020 à 14h50

[20] - [https://fr.wikipedia.org/wiki/apprentissage\\_automatique](https://fr.wikipedia.org/wiki/apprentissage_automatique). Vue le 15/02/2021 à 17h35

[21] Nicholas E. Sizemore, Monica L. Nogueira, Noel P. Greis Et Matthew A. Davies (2020), application of machine learning to the prediction of surface roughness in diamond machining, department of mechanical engineering, university of north carolina at charlotte, charlotte, nc 28223, usa

[22] Md. Shahriar Jahan Hossain Et Dr. Nafis Ahmad (2012), artificial intelligence-based surface roughness prediction modeling for three-dimensional end milling, vit university, school of mechanical and building sciences, chennai campus, chennai-600127, india

[23] Marek Vrabel, (2012), surface roughness prediction using artificial neural networks when drilling udimet 720, elsevier ltd.

- [24] Rajesh M. Et Dr. R Manu (2014), prediction of surface roughness of freeform surfaces using artificial neural network, 5th international & 26th all india manufacturing technology, design and research conference (aimtdr 2014) december 12th–14th.
- [25] Ludovic Ngongang, Thomas Kanaa, Ebenezer Njeugna, Atangana Ateba (2021). Remote Monitoring of Surface Roughness on Turned and Milled Carbon Steels with High-Speed Steel and Tungsten Carbide Tools. Vol. 5, No. 1, 2021, pp. 44-56. doi: 10.11648/j.ae.20210501.17, 13 pages.
- [26] Dhiren R. Patel Mysore Et B. Kiran Vinay Vakharia (2019), modeling and prediction of surface roughness using multiple regressions: a noncontact approach, department of mechanical engineering, pandit deendayal petroleum university, gujarat, india
- [27] Ibrahim A Badi<sup>1</sup>, Ali G Shetwan<sup>2</sup>, Maitig A (2017), using multiple linear regression and artificial neural network to predict surface roughness in turning operations, mechanical engineering department, misurata university, libya
- [28] U. Çaydas; S. Ekici (2010), support vector machines models for surface roughness prediction in cnc turning of aisi 304 austenitic stainless steel, springer science+business media, llc 2010.
- [29] Juanlu (2019), an effective abc-svm approach for surface roughness prediction in manufacturing processes, wiley hindawi, volume 2019, article id 3094670, 13 pages.
- [30] Vijay Kumar, Sanjay Kumar Et Prashant Prakash (2011), data exploitation application using decision tree and year for prediction of roughness of milling surface in the manufacturing process, department of mechanical engineering, nitttr bhopal, india
- [31] Juan M. Barrios Et Pablo E. Romero (2019), decision tree methods for predicting surface roughness in fused deposition modeling parts, department of mechanical engineering, university of cordoba, medina azahara avenue, 5–14071 cordoba, spain