

# **TESIS**

## **PENGEMBANGAN SISTEM KLASIFIKASI KEKASARAN PERMUKAAN MENGGUNAKAN *MACHINE LEARNING***



**CINDY HARTITA**

**03032622327002**

**PROGRAM STUDI MAGISTER TEKNIK MESIN**

**JURUSAN TEKNIK MESIN**

**FAKULTAS TEKNIK**

**UNIVERSITAS SRIWIJAYA**

**2024**

**TESIS**

**PENGEMBANGAN SISTEM KLASIFIKASI  
KEKASARAN PERMUKAAN MENGGUNAKAN  
*MACHINE LEARNING***

**Diajukan Sebagai Salah Satu Syarat Untuk Mendapatkan Gelar Magister  
Teknik Pada Fakultas Teknik Universitas Sriwijaya**



**OLEH  
CINDY HARTITA  
03032622327002**

**PROGRAM STUDI MAGISTER TEKNIK MESIN  
JURUSAN TEKNIK MESIN  
FAKULTAS TEKNIK  
UNIVERSITAS SRIWIJAYA  
2024**

## HALAMAN PENGESAHAN

# PENGEMBANGAN SISTEM KLASIFIKASI KEKASARAN PERMUKAAN MENGGUNAKAN *MACHINE LEARNING*

## TESIS

**Diajukan Untuk Melengkapi Salah Satu Syarat  
Memperoleh Gelar Magister Teknik  
Pada Fakultas Teknik Universitas Sriwijaya**

**Oleh:**  
**CINDY HARTITA**  
**03032622327002**

Palembang, Mei 2024  
Pembimbing

Irsyadi Yani, S. T., M. Eng., PhD.  
NIP. 197112251997021001



## **HALAMAN PENGESAHAN**

# **PENGEMBANGAN SISTEM KLASIFIKASI KEKASARAN PERMUKAAN MENGGUNAKAN *MACHINE LEARNING***

## **TESIS**

**Diajukan Untuk Melengkapi Salah Satu Syarat  
Memperoleh Gelar Magister Teknik  
Pada Fakultas Teknik Universitas Sriwijaya**

**Oleh:**  
**CINDY HARTITA**  
**03032622327002**

Palembang, Mei 2024  
Pembimbing

Irsyadi Yan, S. T., M. Eng., PhD.  
NIP. 197112251997021001

Mengetahui,  
Koordinator Program Studi Magister Teknik Mesin

Agung Mataram, S.T., M.T., Ph.D.  
197901052003121002

## HALAMAN PERSETUJUAN

Karya tulis ilmiah berupa Tesis ini dengan judul “Pengembangan Sistem Klasifikasi Kekasaran Permukaan Menggunakan *Machine Learning*” telah dipertahankan di hadapan Tim Penguji Karya Tulis Ilmiah Fakultas Teknik Program Studi Magister Teknik Mesin Universitas Sriwijaya pada tanggal Mei 2024.

Palembang, Mei 2024

Tim Penguji Karya Tulis Ilmiah berupa Tesis:

1. Zulkarnain, S.T., M.Sc., Ph.D.  
NIP 198105102005011005

(.....*Zulkarnain*.....)

2. Dr. H. Ismail Thamrin, S.T., M.T.  
NIP 197209021997021001

(.....*H. Ismail Thamrin*.....)



Mengetahui,  
Ketua Jurusan Teknik Mesin  
Irsyadi Yani, S.T., M.Eng., Ph.D. IPM.  
NIP. 197112251997021001

## HALAMAN PERSETUJUAN

Karya tulis ilmiah berupa Tesis ini dengan judul “Pengembangan Sistem Klasifikasi Kekasaran Permukaan Menggunakan *Machine Learning*” telah dipertahankan di hadapan Tim Penguji Karya Tulis Ilmiah Fakultas Teknik Program Studi Magister Teknik Mesin Universitas Sriwijaya pada tanggal Mei 2024.

Palembang, Mei 2024

Tim Penguji Karya Tulis Ilmiah berupa Tesis:

1. Zulkarnain, S.T., M.Sc., Ph.D.  
NIP 198105102005011005

(.....  


2. Dr. H. Ismail Thamrin, S.T., M.T.  
NIP 197209021997021001

(.....  


Mengetahui,  
Koordinator Program Studi Magister Teknik Mesin

  
Agung Mataram, S.T., M.T., Ph.D.  
197901052003121002

## KATA PENGANTAR

Puji Syukur penulis curahkan kehadiran Allah SWT karena berkat rahmat dan karunia-Nya sehingga penulis dapat menyelesaikan Tesis yang dibuat untuk memenuhi syarat mengikuti Seminar dan Sidang Magister pada program studi Teknik Mesin Fakultas Teknik Universitas Sriwijaya dengan judul **“Pengembangan Sistem Klasifikasi Kekasarahan Permukaan Menggunakan Machine Learning”**.

Pada kesempatan ini, penulis setulus hati menyampaikan rasa syukur dan terimakasih yang sebesar-besarnya kepada Allah SWT atas rahmat-Nya, anugerah ilmu pengetahuan, kesempatan dan kesehatan dari-Nya yang diberikan kepada penulis dalam proses penyusunan tesis ini sehingga penulis mampu menyelesaikan Tesis, dan juga tak lupa penulis mengucapkan terimakasih kepada:

1. Kedua orang tua saya yang telah tanpa lelah selalu memberi dukungan dalam segala bentuk, materil maupun moril.
2. Irsyadi Yani, S.T., M.Eng, Ph.D. IPM. sebagai dosen pengajar sekaligus dosen pembimbing tesis.
3. Ketua program studi Magister dan dosen-dosen program studi Magister Teknik Mesin Universitas Sriwijaya yang telah membekali saya dengan ilmu-ilmu yang bermanfaat sebelum menyusun tesis ini.
4. Keluarga serta teman-teman yang telah membantu dalam penyelesaian tesis ini.

Semoga tesis ini dapat memberikan manfaat serta berkontribusi di dalam dunia pendidikan dan industri.

Palembang, Mei 2024

Penulis

## **HALAMAN PERNYATAAN PERSETUJUAN PUBLIKASI**

Yang bertanda tangan dibawah ini:

Nama : Cindy Hartita

NIM : 03032622327002

Judul : Tesis

Memberikan izin kepada Pembimbing dan Universitas Sriwijaya untuk mempublikasikan hasil penelitian saya untuk kepentingan akademik apabila dalam waktu 1 (satu) tahun tidak mempublikasikan karya penelitian saya. Dalam kasus ini saya setuju untuk menempatkan Pembimbing sebagai penulis korespondensi (*Corresponding author*).

Demikian, pernyataan ini saya buat dalam keadaan sadar dan tanpa ada paksaan dari siapapun.

Palembang, Mei 2024



## RINGKASAN

### PENGEMBANGAN SISTEM KLASIFIKASI KEKASARAN PERMUKAAN MENGGUNAKAN *MACHINE LEARNING*

Karya Tulis Ilmiah berupa Tesis, Mei 2024

Cindy Hartita; dibimbing oleh Irsyadi Yani, S.T. M.Eng. Ph.D. IPM.

xxiii + 63 Halaman, 26 Tabel, 11 Gambar

## RINGKASAN

Proses pemesinan adalah proses pembentukan material menggunakan alat potong untuk mengubah benda kerja menjadi bentuk yang diinginkan. Proses pemotongan suatu benda kerja dengan cara memutar benda kerja dan meletakkannya pada pahat yang bergerak sejajar dengan sumbu putar benda kerja merupakan proses pembubutan. Salah satu cara untuk mencapai tingkat kekasaran permukaan yang diinginkan adalah dengan mengontrol variabel pemesinan seperti laju pemakanan ( $f$ ), kecepatan potong ( $V_c$ ), kedalaman potong ( $a$ ), dan kekasaran permukaan ( $R_a$ ). Kekasaran permukaan suatu material adalah simpangan rata-rata aritmatika permukaan benda kerja yang diukur dari garis rata-rata atau garis acuan. Untuk mengurangi keausan mata pahat dan dampak limbah cairan pemotongan yang dihasilkan selama proses pemesinan, dilakukan proses pemesinan yang ramah lingkungan (*green machining*) menggunakan sedikit cairan pemotongan atau disebut dengan *Minimum Quantity Lubricant* (MQL).

Naive Bayes adalah salah satu metode yang belum banyak digunakan untuk memprediksi hubungan antara variabel independen dan variabel dependen. Pada penelitian ini digunakan metode Naive Bayes untuk mengklasifikasi hubungan antar ke-dua variabel proses pemesinan sehingga nilai yang dihasilkan mendekati nilai yang diinginkan. Setelah proses pembubutan selesai dilakukan kemudian mengukur kekasaran permukaan benda kerja. Setelah diperoleh data uji kekasaran permukaan, data tersebut dapat dikelompokkan sehingga tercipta hubungan linier antara dua variabel atau korelasi antara atribut variabel dependen dan independen ( $X_1$ ,  $X_2$ ,  $X_3$ ,  $X_4$ ) dan kelasnya (Y). Perhitungan korelasi atribut atau fitur data dilakukan dengan mengubah data variabel non-numerik menjadi data numerik.

Analisis korelasi Pearson dilakukan untuk mengetahui kekuatan hubungan antara variabel independen dan variabel dependen.

Hasil analisis koefisien korelasi Pearson menunjukkan bahwa nilai variabel independen yang paling dominan adalah laju pemakanan ( $f$ ), dan variabel independen yang paling tidak dominan adalah kedalaman potong ( $a$ ). Hasil analisa membuktikan bahwa nilai kekasaran permukaan dipengaruhi oleh variabel laju pemakanan ( $f$ ). Hal ini sesuai dengan hasil analisis korelasi Spearman yang menunjukkan bahwa laju pemakanan merupakan faktor yang paling berpengaruh dalam menentukan kekasaran permukaan dengan nilai sebesar 86,36%. Sedangkan kecepatan potong dan kedalaman potong yang merupakan variabel bebas lainnya yang ada dalam proses pemesinan, namun bukan merupakan faktor utama yang menentukan kekasaran permukaan pada proses pemesinan. Nilai akurasi yang diperoleh dari hasil klasifikasi dan analisis pengukuran kekasaran benda kerja menggunakan metode Naïve Bayes adalah sebesar 87,50%. Metode Naïve Bayes dapat secara efektif mengklasifikasi pengelompokan kekasaran permukaan dengan menetapkan kecepatan potong, laju pemakanan, dan kedalaman pemotongan sebagai variabel masukan. Untuk penelitian mendatang sebaiknya ditambahkan lebih banyak variabel independen seperti  $F_z$ ,  $F_y$ ,  $R_z$ , dan  $R_t$ . Selain itu, dapat menggunakan metode klasifikasi lain seperti K-NN, Fuzzy Naive Bayes, dan lain-lain.

**Kata Kunci:** Naïve Bayes, Kekasaran Permukaan, Klasifikasi  
**Kepustakaan:** 87

## SUMMARY

### DEVELOPMENT OF SURFACE ROUGHNESS CLASSIFICATION SYSTEM USING MACHINE LEARNING

Scientific Manuscript, Mei, 2024

Cindy Hartita; Supervise by Irsyadi Yani, S.T. M.Eng. Ph.D. IPM.

xxiii + 63 pages, 26 Table, 11 Figure

### SUMMARY

The machining process is a material forming process using cutting tools to transform the workpiece into the desired shape. The process of cutting a workpiece by rotating the workpiece and placing it on a tool that moves parallel to the workpiece's rotating axis is a turning process. One way to achieve the desired level of surface roughness is to control machining variables such as feed rate( $f$ ), cutting speed ( $V_c$ ), depth of cut ( $a$ ), and surface roughness ( $R_a$ ). The surface roughness of a material is the arithmetic mean deviation of the workpiece surface measured from an average line or reference line. To reduce tool blade wear and the impact of cutting fluid waste generated during the machining process, an environmentally friendly machining process (*green* machining) is carried out using a small amount of cutting fluid or called *Minimum Quantity Lubricant* (MQL).

Naive Bayes is one method that has not been extensively utilized to predict the relationship between independent and dependent variables. In this research, the Naive Bayes method is used to classify the relationship between the two machining process variables so that the resulting value is close to the desired value. After the turning process is complete, then measure the surface roughness of the workpiece. After obtaining the surface roughness test data, the data can be grouped so as to create a linear relationship between the two variables or a correlation between the attributes of the dependent and independent variables ( $X_1, X_2, X_3, X_4$ ) and the class (Y). Calculation of attribute correlation or data features is done by converting non-numeric variable data into numeric data. Pearson correlation analysis was conducted to determine the strength of the relationship between the independent variable and the dependent variable.

The results of the Pearson correlation coefficient analysis show that the most dominant independent variable value is the feed rate( $f$ ), and the least dominant independent variable is the depth of cut( $a$ ). The analysis results prove that the surface roughness value is influenced by the variable feed rate( $f$ ). This is in accordance with the results of the Spearman correlation analysis which shows that the feed rate is the most influential factor in determining surface roughness with a value of 86.36%. While cutting speed and depth of cut are other independent variables that exist in the machining process, but are not the main factors that determine surface roughness in the machining process. The accuracy value obtained from the prediction and analysis of workpiece roughness measurements using the Naïve Bayes method is 87.50%. The Naïve Bayes method can effectively predict surface roughness groupings by setting cutting speed, feed rate, and depth of cut as input variables. For future research, more independent variables such as  $F_z$ ,  $F_y$ ,  $R_z$ , and  $R_t$  should be added. In addition, other prediction methods such as K-NN, Fuzzy Naive Bayes, and others can be used.

**Keywords:** Naïve Bayes, Surface Roughness, Classification

Reference: 87

## DAFTAR ISI

HALAMAN PENGESAHAN.....	v
HALAMAN PENGESAHAN.....	vii
HALAMAN PERSETUJUAN.....	ix
KATA PENGANTAR.....	xi
HALAMAN PERNYATAAN PERSETUJUAN PUBLIKASI.....	xiii
RINGKASAN .....	xv
SUMMARY .....	xvii
DAFTAR ISI .....	xix
DAFTAR GAMBAR .....	xxi
DAFTAR TABEL.....	xxiii
BAB 1_PENDAHULUAN .....	1
1.1 Gambaran Umum .....	1
1.2 Latar Belakang Masalah.....	1
1.3 Perumusan Masalah.....	6
1.4 Ruang Lingkup Penelitian .....	6
1.5 Tujuan Penelitian .....	7
1.6 Manfaat Penelitian.....	7
1.7 Kerangka Pemikiran Konseptual.....	7
BAB 2_TINJAUAN PUSTAKA.....	11
2.1 Proses Pemesinan .....	12
2.2 Pemesinan Bubut.....	13
2.3 AISI 1045 .....	14
2.4 Pahat Karbida .....	14
2.5 Kekasaran Permukaan .....	15
2.6 Naïve Bayes.....	16
2.7 <i>State of The Art</i> .....	19
2.8 <i>Green Machining</i> .....	22
2.9 <i>Research Gap</i> .....	22
BAB 3_METODOLOGI.....	29
3.1 Diagram Alir Penelitian.....	29
3.2 Persiapan Benda Kerja .....	30

3.3 Persiapan Pahat.....	30
3.4 Persiapan Mesin Bubut.....	31
3.5 Pengukuran Kekasaran Permukaan .....	31
3.6 Desain Eksperimen.....	32
3.8 Pemodelan dengan Naïve Bayes .....	35
3.9 Uji Korelasi Spearman .....	38
BAB 4 HASIL DAN PEMBAHASAN.....	39
4.1 Analisis Korelasi Pearson .....	46
BAB 5 <u>KESIMPULAN DAN SARAN</u> .....	51
5.1 Kesimpulan.....	51
5.2 Saran .....	51
DAFTAR PUSTAKA .....	53
LAMPIRAN .....	63

## **DAFTAR GAMBAR**

Gambar 1. Kerangka Pemikiran Konseptual.....	8
Gambar 2. Klasifikasi Proses Pembuangan Material (Groover, 2013) .....	13
Gambar 3. Pemesinan Bubut (Groover, 2013).....	13
Gambar 4. Perkembangan Penggunaan Material Pahat (Laperriere dan Reinhart, 2014) .....	15
Gambar 5. Deviasi dari Permukaan Nominal (Groover, 2013).....	15
Gambar 6. Perbandingan Nilai Kekasaran Permukaan Teoretis dan Eksperimental .....	27
Gambar 7. Diagram Alir Penelitian.....	29
Gambar 8. Mesin Bubut .....	31
Gambar 9. Alat Uji Kekasaran Permukaan .....	32
Gambar 10. Experiment Setup for Multi-jet Polishing (Wang, dkk., 2022) .....	35
Gambar 11. Korelasi Determinasi Variabel Independen .....	49

## DAFTAR TABEL

Tabel 1. Ekuivalensi Tingkat Kekasaran Permukaan ISO/R 468-1966 .....	16
Tabel 2. Deskripsi Algoritma Penggalian Data yang Digunakan dalam Penelitian Ini .....	23
Tabel 3. Perbandingan Kinerja Model DNN, SVM, dan NB dalam Hal Akurasi Pelatihan dan Pengujian .....	26
Tabel 4. Kinerja Berbagai Model Pembelajaran Mesin .....	26
Tabel 5. Ukuran Maksimum Keausan Pahat dan Kekasaran Permukaan Baja AISI 1045 .....	26
Tabel 6. Komposisi Kimia Baja AISI 1045 (%).....	30
Tabel 7. Sifat Mekanik Baja AISI 1045 .....	30
Tabel 8. Sifat Termal Pahat Karbida .....	30
Tabel 9. Konduktivitas Termal Karbida Insert (Suhu Dependent) .....	31
Tabel 10. Spesifikasi Mesin Bubut.....	31
Tabel 11. Spesifikasi Alat Uji Kekasaran .....	32
Tabel 12. Variabel Bebas pada Eksperimen .....	33
Tabel 13. Desain Eksperimen Penelitian.....	33
Tabel 14. Rancangan Pengkodean Eksperimen Penelitian .....	34
Tabel 15. Hasil Pengujian dan Pengukuran.....	40
Tabel 16. Data Korelasi Antar Variabel Dependen Terhadap Variabel Independen .....	41
Tabel 17. Nilai R-Square dari $X_1$ , $X_2$ , $X_3$ dan $X_4$ Terhadap Y untuk Data Pengujian 1 .....	43
Tabel 18. Prior Probabilitas.....	43
Tabel 19. Data Uji 1 .....	44
Tabel 20. Probabilitas Kemunculan $R_1$ dan $R_2$ .....	45
Tabel 21. Hasil Pengujian .....	45
Tabel 22. Korelasi Pearson.....	46
Tabel 23. Korelasi Spearman .....	47
Tabel 24. Data Tingkat Pengaruh Variabel Independen Terhadap Dependens .....	47
Tabel 25. Nilai Regressi SS.....	48
Tabel 26. Nilai Korelasi Determinasi .....	49

## BAB 1

### PENDAHULUAN

#### 1.1 Gambaran Umum

Pada penelitian ini, *Minimum Quantity Lubrication* (MQL) akan dipergunakan untuk mengevaluasi performansi dari pembubutan material AISI 1045. Secara umum, AISI 1045 digolongkan sebagai baja karbon menengah atau dikenal sebagai material *High Strength Low Alloy* (HSLA). Material ini diaplikasikan untuk pembuatan komponen mesin seperti poros, batang penghubung, roda gigi, dan juga dongkrak hidrolik, dikarenakan material ini memiliki sifat tahan impak yang baik. Namun demikian, sifat tahan impak ini memiliki hubungan yang erat dengan kualitas pembuatan dari komponen mesin tersebut.

Kualitas pembuatan komponen mesin sangat dipengaruhi oleh kekasaran permukaan dari komponen tersebut. Kekasaran permukaan sangat bergantung dengan variabel-variabel pemotongan, baik variabel independen maupun variabel dependennya. Hubungan antara variabel independen dan variabel dependen dapat dicari dengan menggunakan pemodelan matematika seperti menggunakan metode Naïve Bayes, KNN, Decision Tree, dan lain-lain.

#### 1.2 Latar Belakang Masalah

Proses pembentukan benda kerja menjadi berbentuk silinder dapat dilakukan menggunakan pemesinan bubut. Proses pemakanan benda kerja yang sayatannya dilakukan dengan cara memutar benda kerja kemudian dikenakan pada pahat yang digerakkan secara translasi sejajar dengan sumbu putar dari benda kerja merupakan suatu proses pembubutan (Dewangga, Nugraha dan Dantes, 2017). Secara umum, terdapat dua proses pembentukan benda kerja menggunakan pemesinan bubut, yaitu pembubutan kering dan pembubutan dengan cairan pemotong (*cutting fluid*). Dewasa ini, pembubutan kering dalam proses pembentukan benda kerja banyak digunakan di dunia industri dikarenakan lebih ramah lingkungan dibanding proses-proses pembubutan dengan cairan pemotong.

Untuk menyelesaikan masalah cairan pemotong atau yang dikenal dengan *Metal Working Fluids* (MWF), proses manufaktur yang berkelanjutan (*sustainable manufacture*) memperkenalkan berbagai kondisi pemesinan. Menurut Rahim, dkk. (2016), kondisi-kondisi pemesinan pada proses manufaktur adalah *dry machining*, *near dry machining* dikenal juga dengan *Minimum Quantity Lubrication* (MQL) dan pemesinan kriogenik. Proses manufaktur ini dipergunakan pada berbagai kondisi pemotongan seperti pemotongan material *superalloy*.

Salah satu alternatif yang dapat digunakan dalam proses pembubutan logam untuk material yang sulit dipotong seperti *superalloy*, paduan titanium (*titanium alloys*) dan keramik (*ceramics*) adalah metode MQL. Dikarenakan material tersebut memiliki sifat mekanik yang tinggi dan konduktivitas termal yang rendah, mengakibatkan terjadinya gaya potong dan suhu pemotongan yang berlebih selama proses pemesinan, sehingga dapat mengurangi umur mata pahat (Sofuoğlu, dkk., 2018).

Dewasa ini, telah banyak penelitian yang mempelajari kekasaran permukaan dengan tujuan untuk mengurangi pengaruh keausan pada mata pahat akibat gaya potong, kecepatan pemakanan, dan lain-lain. Salah satu metode yang dipergunakan untuk mengurangi pengaruh keausan pada mata pahat adalah metode MQL. Akan tetapi, masih sedikit penelitian mengenai pemodelan kekasaran permukaan menggunakan metode MQL dengan mempertimbangkan parameter pemesinan. Karena itu, menurut Mia dan Dhar (2016a), untuk memprediksi kekasaran permukaan dengan jalan mengontrol parameter pada proses pemesinan tidak dapat dihindari.

Beberapa hal yang mempengaruhi laju keausan mata pahat selain suhu pemotongan adalah integritas permukaan benda kerja seperti tegangan sisa, kekerasan, dan kekasaran permukaan. Akan tetapi, menurut Elmaraghy, dkk. (2014) dan Ratnasingam, dkk. (2010), suhu pemotongan merupakan salah satu faktor yang sangat penting dalam proses pembubutan. Sehingga dengan mengendalikan suhu pemotongan, mekanisme keausan pahat dalam proses pembubutan dapat dikendalikan, hal ini dikarenakan peningkatan suhu pemotongan akan menurunkan tingkat kekerasan dan ketangguhan dari material tersebut. Beberapa faktor yang menyebabkan peningkatan suhu pemotongan di tepi mata

pahat adalah kecepatan potong (*cutting speed*,  $V_c$ ), laju pemakanan (*feed rate*,  $f$ ), kedalaman potong (*depth of cut*,  $a$ ), bahan mata pahat dan benda kerja yang memberikan pengaruh pada keausan mata pahat, sehingga besarnya variabel ini harus dijaga secara konstan.

Salah satu parameter penting dari proses pemesinan selain suhu serta keausan mata pahat adalah kekasaran permukaan suatu benda kerja (Sahoo dan Mishra, (2014), Siddique, Dilwar dan Nayeem, (2018)). Untuk meningkatkan efektivitas operasi pemesinan sehingga dapat mengurangi waktu dan biaya produksi pada industri manufaktur adalah dengan menggunakan teknik pemodelan. Teknik pemodelan tersebut bersifat non-linier. Teknik pemodelan berbasis *Artificial Intelligence* (AI) banyak dipergunakan oleh peneliti untuk memprediksi kondisi optimal dalam pembubutan logam. Pendekatan teknik pemodelan berbasis *Artificial Intelligence* (AI) disarankan untuk aplikasi *real-time* dan telah berhasil diaplikasikan serta menghasilkan temuan yang dapat diterima (Anuja Beatrice, dkk., (2014). Salah satu metode yang banyak dipergunakan pada pemodelan berbasis AI adalah metode Naïve Bayes.

Berdasarkan uraian diatas, kualitas benda kerja dengan proses pembubutan sangat dipengaruhi oleh keausan mata pahat dan peningkatan suhu mata pahat yang disebabkan oleh kecepatan potong (*cutting speed*,  $V_c$ ), laju pemakanan (*feed rate*,  $f$ ), kedalaman potong (*depth of cut*,  $a$ ), bahan pahat dan benda kerja karena dapat menimbulkan panas berlebih pada mata pahat dan benda kerja, sehingga menghasilkan kekasaran permukaan benda kerja yang tidak sesuai dengan standar proses pemesinan. Karena itu, perlu dilakukan teknik pemodelan untuk mengetahui pengaruh penerapan MQL terhadap hasil kekasaran permukaan pada proses pemesinan bubut AISI 1045 dengan menggunakan metode Naïve Bayes.

Beberapa hasil penelitian menunjukkan pentingnya metode pemesinan yang dipilih dan menunjukkan bagaimana sifat tepi pahat yang ditentukan atau metode abrasif dan kondisi pergerakan pahat dan benda kerja dapat menghasilkan permukaan komponen. Selain itu, pengaruh dari variasi variabel pemotongan kecepatan potong (*cutting speed*,  $V_c$ ), laju pemakanan (*feed rate*,  $f$ ), kedalaman potong (*depth of cut*,  $a$ ), diperiksa dalam semua proses pemesinan, dimana faktor-faktor tersebut mempengaruhi munculnya topografi terhadap variasi sudut secara

signifikan. Karena itu, selain untuk memperoleh analisis kekasaran dengan pemesinan yang berbeda, penelitian yang bertujuan untuk memprediksi dan merencanakan nilai kekasaran menjadi semakin penting.

R. Wang, dkk., (2022) telah mengembangkan model prediksi kekasaran permukaan yang kuat berdasarkan pembelajaran ensembel dengan algoritma genetik (ELGA), yang dapat digunakan untuk prediksi kekasaran permukaan pada MJP baja tahan karat 316L yang dicetak dengan cetakan 3D. Penelitian ini pertama-tama memberikan tinjauan singkat tentang status terkini dari metode prediksi kekasaran permukaan.

Kekasaran permukaan dipengaruhi oleh banyak faktor dan sulit untuk diprediksi secara akurat berdasarkan model fisik. Algoritma pembelajaran mesin memiliki kemampuan yang sangat baik untuk memodelkan hubungan yang kompleks dan memprediksi kekasaran permukaan dengan akurasi dan efisiensi yang tinggi.

Menurut Abburri dan Dixit, (2006), Pontes, dkk., (2012), Camposeco-Negrete, (2015), dan Asiltürk dan Mehmet, (2011) keuntungan besar dari menggunakan sistem berbasis pengetahuan untuk memprediksi kekasaran permukaan adalah bahwa seperangkat aturan yang ringkas dapat ditingkatkan, sehingga dapat membantu dalam memahami sifat proses. Meskipun memiliki keterbatasan dalam proses pembubutan sistem berbasis pengetahuan untuk saat ini pada kekasaran permukaan, metode ini dapat digunakan dalam membangun sistem berbasis pengetahuan yang komprehensif untuk pembubutan atau proses serupa.

Teknik *Genetic Algorithm* (GA) mengungguli teknik-teknik RSM dengan menemukan permukaan terbaik (minimum) dan nilai prediksi kekasaran terbaik (minimum). Dengan kecepatan tinggi, laju pemakanan sedang dan sudut rake radial yang lebih rendah dari skala kondisi pemotongan (Selaimia, dkk., (2017), (Zain, dkk., (2010), dan Yu dan Liu, (2020)).

Hubungan antara parameter pemesinan utama ((jarak,  $D$ ), (kecepatan,  $V$ ), dan (sudut kemiringan,  $I$ )) dan respon (tekanan dan kekasaran permukaan roda gigi) diselidiki dalam proses pemolesan. Pengaruh tiga parameter pemesinan terhadap proses pemolesan dilakukan dengan melakukan simulasi dan eksperimen. Hasil

percobaan mengilustrasikan bahwa kekasaran permukaan dicapai paling kecil pada area tekanan maksimum ((Nguyen, dkk., 2020).

Dalam proses pemolesan, hubungan antara parameter pemesinan utama (jarak,  $D$ ), (kecepatan,  $V$ ), dan (sudut kemiringan,  $I$ ) dan respon (tekanan dan kekasaran permukaan roda gigi) dipelajari. Pengaruh tiga parameter ini terhadap proses pemolesan dipelajari melalui simulasi dan eksperimen. Hasil percobaan menunjukkan bahwa area tekanan maksimum memiliki kekasaran permukaan yang paling kecil. Algoritma genetika yang terintegrasi dengan jaringan syaraf tiruan digunakan untuk mempelajari parameter proses yang terbaik untuk berbagai tujuan optimasi. Selain itu, penelitian ini meletakkan dasar bagi pengembangan sistem pakar pemolesan (Wang, dkk., 2012).

Algoritma pembelajaran mesin seperti *Support Vector Machine* (SVM), algoritma Naïve Bayes, pohon keputusan, algoritma AdaBoost, penyusutan absolut terkecil dan operator seleksi (LASSO), semuanya memiliki kinerja yang sangat baik dalam kaitannya dengan permasalahan regresi. Karena itu, telah banyak penelitian yang bertujuan untuk menggunakan pendekatan ini untuk memprediksi kekasaran permukaan. Salgado dan Alonso, (2007) memperlihatkan sebuah prosedur estimasi dalam proses untuk memprediksi kekasaran permukaan pada proses pembubutan berdasarkan *Support Vector Machine* kuadrat terkecil (LS-SVM).

Literatur melaporkan banyak karya ilmiah tentang penggunaan teknik kecerdasan buatan seperti jaringan syaraf atau logika *fuzzy* untuk memprediksi kekasaran permukaan. Model-model ini sesuai sebagai teknik prediksi karena non-linearitas proses pemesinan menuntut algoritma yang sangat baik dan dapat diandalkan untuk menangani semua tren tak terlihat yang ada saat benda kerja mengalami proses pemesinan. Uji eksperimental yang diperoleh dari proses pembuatan kontur *milling* berkecepatan tinggi menganalisis indikator *goodness* dengan menggunakan algoritma Naïve Bayes dan Tree-Augmented Network. Akurasi hingga 81,2% dicapai dalam hasil klasifikasi  $R_a$ . Karena itu, pengklasifikasi berbasis jaringan Bayesian dapat menjadi alat yang sangat baik dan fleksibel dalam pemesinan berkecepatan tinggi (Correa, dkk., 2008).

Correa, dkk., (2008) mengembangkan model-model klasifikasi Bayesian yang berfokus pada struktur yang digunakan, yaitu Naïve Bayes dan Tree-

Augmented Naïve Bayes (TAN). Kualitas permukaan suatu benda diukur dengan integritas permukaannya, selain dari permukaan topografi, juga memperhitungkan sifat mekanik dan sifat metalurgi. Sifat-sifat ini sangat penting dalam kelelahan, ketahanan korosi atau umur pakai dari bagian tersebut.

Correa, dkk., (2008) pada penelitiannya mengusulkan salah satu model untuk memprediksi  $R_a$  berdasarkan data yang diamati tetapi juga mempertimbangkan model fisik dari proses pemesinan. Singkatnya, tidak ada kesepakatan tentang konsep prediksi umum dan model yang akan digunakan, karena penelitian yang dilakukan hingga saat ini belum memenuhi kebutuhan nyata industri. Selain itu, tidak ada perangkat yang dapat diandalkan di pasaran untuk mengukur kekasaran permukaan secara *on-line*. Penggunaan instrumen pengukuran kekasaran permukaan secara *off-line* berarti efisiensi lini produksi terpengaruh karena kurangnya kontrol waktu secara langsung. Hal ini terutama terlihat pada waktu yang diperlukan untuk pemeriksaan pasca-proses dan pemborosan material dan waktu produksi untuk membuat benda kerja yang salah.

### **1.3 Perumusan Masalah**

Adapun perumusan masalah dalam penelitian ini adalah sebagai berikut:

1. Apakah variabel pemesinan (kecepatan potong, laju pemakanan, dan kedalaman potong) memiliki kontribusi dalam mengurangi variasi dari respon kekasaran permukaan?
2. Bagaimana pemodelan matematika dari kekasaran permukaan benda kerja menggunakan metode Naïve Bayes pada proses pembubutan AISI 1045 dengan MQL?
3. Bagaimana mengklasifikasi nilai kekasaran permukaan benda kerja dengan menggunakan Naïve Bayes?
4. Bagaimana pengaruh MQL terhadap variabel kecepatan potong, laju pemakanan, dan kedalaman potong yang berbeda?

### **1.4 Ruang Lingkup Penelitian**

Ruang lingkup penelitian ini adalah:

1. Material benda kerja yang digunakan adalah AISI 1045.

2. Material mata pahat yang digunakan adalah *cemented carbide*. Dilakukan pergantian mata pahat untuk setiap benda kerja.
3. Variabel pemesinan bubut yang digunakan adalah kecepatan potong ( $V_c$ ) 100–150 m/min, kedalaman potong ( $a$ ) 0,5–1,5 mm, laju pemakanan ( $f$ ) 0,035–0,14 mm/rev.
4. Kekasaran permukaan benda kerja diukur menggunakan Handysurf Accretech E-35B.
5. Pemodelan menggunakan metode Naïve Bayes.
6. Penggunaan  $R_a$  (kekasaran permukaan dalam arah *axial*) sebagai variabel ukur karena alat pengukur kekasaran permukaan yang terdapat pada Laboratorium Produksi dapat mengukur dalam arah *axial* nya.

### **1.5 Tujuan Penelitian**

Tujuan penelitian ini berdasarkan perumusan masalah adalah:

1. Mendapatkan dan menganalisis klasifikasi terbaik dari kekasaran benda kerja berdasarkan metode Naïve Bayes.
2. Mengetahui besarnya kontribusi variabel pada proses bubut yaitu kecepatan potong, laju pemakanan, kedalaman potong, dalam mengurangi variasi dari respon kekasaran permukaan.
3.  $R_a$  dapat diklasifikasi secara efektif dengan menggunakan kecepatan potong, laju pemakanan, dan kedalaman potong sebagai variabel *input*.

### **1.6 Manfaat Penelitian**

Manfaat yang dapat diperoleh dari penelitian ini adalah (1) mendapatkan persamaan model matematika baru untuk kekasaran permukaan pada proses MQL AISI 1045 dengan menggunakan metode Naïve Bayes; (2) dan dapat mengklasifikasi kekasaran permukaan dengan metode Naïve Bayes.

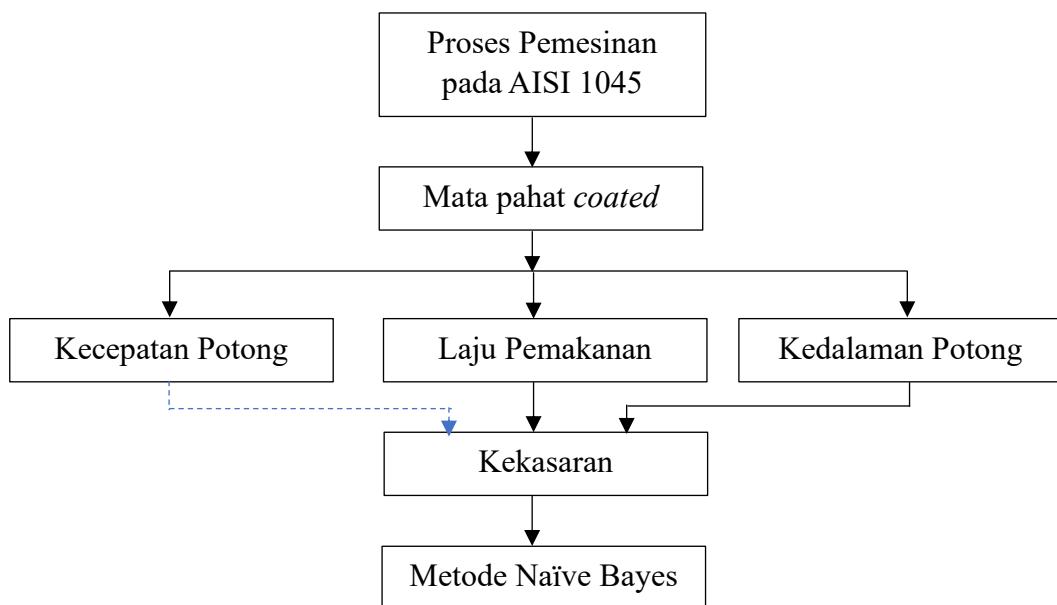
### **1.7 Kerangka Pemikiran Konseptual**

Mesin bubut adalah salah satu dari mesin produksi yang banyak digunakan di dunia industri. Proses MQL dapat mempengaruhi tingkat kekerasan dan akurasi dimensi permukaan benda kerja sehingga kekasaran permukaan benda kerja tidak

sesuai dengan standar proses pemesinan. Pada penelitian sebelumnya, beberapa faktor utama yang mempengaruhi kekasaran permukaan adalah kecepatan potong, laju pemakanan, dan kedalaman pemakanan (Sahoo dan Mishra, (2014), (Siddique, Dilwar dan Nayeem, (2018)). Hasil yang berbeda ditemukan oleh (Sahoo, Rout dan Das, 2015), laju pemakanan berpengaruh pada kekasaran permukaan, sedangkan kekuatan pemesinan dipengaruhi oleh laju pemakanan dan kedalaman potong, sementara kecepatan potong mempengaruhi keausan mata pahat.

Azam, dkk., (2015), Suresh, dkk., (2012), dan Gupta, dkk., (2014) mencari hubungan antara  $R_a$  dan variabel pemesinan seperti laju pemakanan, kecepatan potong, dan kedalaman potong dengan menggunakan *Response Surface Methodology* (RSM). Sementara Ozkan, Ulas dan Bilgin, (2014), Morales Tamayo, dkk., (2018), dan Widiantoro, Fikri dan Mahardika, (2014) menggunakan Artificial Neural Network (ANN) untuk memprediksi keausan *cutting tool*.

Dalam proses MQL yang dilakukan pada penelitian sebelumnya, terdapat perbedaan yang ditemukan dalam penggunaan metode penentuan banyaknya variabel dan penggunaan Naïve Bayes (Correa dkk., (2008), Koç, dkk., (2022), Molero, dkk., (2020), Azmi, dkk., (2021)) untuk memprediksi kekasaran permukaan benda kerja. Berikut kerangka konseptual yang dituangkan dalam Gambar 1.



Gambar 1. Kerangka Pemikiran Konseptual

Secara tradisional, studi eksperimental tentang kualitas suku cadang yang diproduksi telah dilakukan dengan alat bantu statistik, seperti metode Taguchi dan analisis varians (ANOVA). Namun, besarnya data yang saat ini dihasilkan oleh industri 4.0, serta kebutuhan untuk menggunakan algoritma yang mampu memodelkan masalah non-linear telah mengakibatkan perlunya kecerdasan buatan seperti penggunaan teknik data *mining* yang juga dikenal sebagai teknik pembelajaran mesin atau *Machine Learning* (ML) (Molero, dkk., 2020).

Perhitungan yang dilakukan secara analitis pada kekasaran permukaan tidak mudah untuk dijalankan sehingga untuk menyelesaikan perhitungan ini digunakan metode komputasi lunak (*soft computing*). Salah satu dari metode komputasi lunak adalah metode kecerdasan buatan atau *Artificial Intelligence* (AI) seperti metode pemrograman ekspresi genetik yang dapat diterapkan (Kundrák, Felhő dan Nagy, 2022).

Correa, dkk., (2008) menggunakan pengklasifikasi yang didasarkan pada jaringan Bayesian untuk mengestimasi variabel  $R_a$  pada pemesinan berkecepatan tinggi. Mereka menggunakan metode Naïve Bayes dan struktur TAN untuk mengembangkan model empiris dalam memprediksi kekasaran dengan menggunakan data yang diperoleh dari proses pemotongan yang sesungguhnya.

## DAFTAR PUSTAKA

- Ab Razak, M., Mahmud, O., Mohd Nazari, A. B., Khairul Adilah, A., & Tajul Rosli, R. (2014). Fuzzy ripening mango index using RGB colour sensor model. *Journal of Arts, Science & Commerce*, 5(2), 1–9.  
[http://www.researchersworld.com/vol5/issue2/Paper\\_01.pdf](http://www.researchersworld.com/vol5/issue2/Paper_01.pdf)
- Abburi, N. R., & Dixit, U. S. (2006). A knowledge-based system for the prediction of surface roughness in turning process. *Robotics and Computer-Integrated Manufacturing*, 22(4), 363–372. <https://doi.org/10.1016/j.rcim.2005.08.002>
- Aha, D. W., Kibler, D., & Albert, M. K. (1991). Instance-Based Learning Algorithms. *Machine Learning*, 6(Springer), 37--66.
- Anuja Beatrice, B., Kirubakaran, E., Ranjit Jeba Thangaiah, P., & Leo Dev Wins, K. (2014). Surface roughness prediction using artificial neural network in hard turning of AISI H13 steel with minimal cutting fluid application. *Procedia Engineering*, 97, 205–211. <https://doi.org/10.1016/j.proeng.2014.12.243>
- Arief Bustomi, M., Faricha, A., Ramdhan, A., & Faridawati. (2018). Integrated image processing analysis and Naïve Bayes Classifier method for lungs X-ray image classification. *ARPN Journal of Engineering and Applied Sciences*, 13(2), 718–724.
- Asiltürk, I., & Mehmet, Ç. (2011). *Modeling and prediction of surface roughness in turning operations using artificial neural network and multiple regression method\_2011\_Expert-System.pdf*.
- Awad, M., & Khanna, R. (2015). *Efficient Learning Machines: Theories, Concepts, and Applications for Engineers and System Designers*.
- Azam, M., Jahanzaib, M., Wasim, A., & Hussain, S. (2015). Surface roughness modeling using RSM for HSLA steel by coated carbide tools. *International Journal of Advanced Manufacturing Technology*, 78(5–8), 1031–1041. <https://doi.org/10.1007/s00170-014-6707-5>
- Azmi, S., Mohd, B., Komuniti, K., & Batas, K. (2021). *Prediction of Surface Roughness in CNC Lathe Using Naive Bayes Classifier*. June 2016.

- Balbaa, M., Nasr, M. N. A., & Elgamal, H. (2017). A Sensitivity Analysis on the Effect of Laser Power on Residual Stresses When Laser-assisted Machining AISI 4340. *Procedia CIRP*, 58, 31–36. <https://doi.org/10.1016/j.procir.2017.03.182>
- Bounhas, M., Ghasemi Hamed, M., Prade, H., Serrurier, M., & Mellouli, K. (2013). Naive possibilistic classifiers for imprecise or uncertain numerical data. *Fuzzy Sets and Systems*, 239, 137–156. <https://doi.org/10.1016/j.fss.2013.07.012>
- Braga, C., Da Silva, L. R., Barbosa, E. J. A., & Corrêa, E. C. S. (2017). Surface integrity characterization of hardened AISI 4340 steel in grinding process with biodegradable formulations of cutting fluids. *Materials Research*, 20(2), 496–501. <https://doi.org/10.1590/1980-5373-MR-2016-0658>
- Breiman, L. (2001). Random Forests. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 12343 LNCS, 503–515. [https://doi.org/10.1007/978-3-030-62008-0\\_35](https://doi.org/10.1007/978-3-030-62008-0_35)
- Camposeco-Negrete, C. (2015). Optimization of cutting parameters using Response Surface Method for minimizing energy consumption and maximizing cutting quality in turning of AISI 6061 T6 aluminum. *Journal of Cleaner Production*, 91, 109–117. <https://doi.org/10.1016/j.jclepro.2014.12.017>
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 13-17-Augu, 785–794. <https://doi.org/10.1145/2939672.2939785>
- Cheng, C. L., Shalabh, & Garg, G. (2014). Coefficient of determination for multiple measurement error models. *Journal of Multivariate Analysis*, 126, 137–152. <https://doi.org/10.1016/j.jmva.2014.01.006>
- Cleary, J. G. (1995). K\*: An Instance-based Learner Using an Entropic Distance. *Elsevier*. <https://www.sciencedirect.com/science/article/pii/B9781558603776500220>
- Correa, M., Bielza, C., Ramirez, M. D. J., & Alique, J. R. (2008). A Bayesian network model for surface roughness prediction in the machining process. *International Journal of Systems Science*, 39(12), 1181–1192. <https://doi.org/10.1080/00207720802344683>

Deepthi Kavila, S., & Radhika, Y. (2016). Research Domain Selection using Naive Bayes Classification. *International Journal of Mathematical Sciences and Computing*, 2(2), 14–23. <https://doi.org/10.5815/ijmsc.2016.02.02>

Dewangga, S. P. F., Nugraha, I. N. P., & Dantes, K. R. (2017). Pengaruh Variasi Kecepatan Putaran Mesin Bubut Terhadap Keausan pada Alat Potong Pahat HSS Tipe Bohler MO 1/2X4. *Jurnal Pendidikan Teknik Mesin Undiksha*, 7(1).

Elmaraghy, H., Deif, A. M., Systems, I. M., & Program, S. E. (2014). CIRP Encyclopedia of Production Engineering. In *CIRP Encyclopedia of Production Engineering*. <https://doi.org/10.1007/978-3-642-20617-7>

Ferreira, J. A., Soares, E. A. M. G., Machado, L. S., & Moraes, R. M. (2015). Assessment of Fuzzy Gaussian Naive Bayes for Classification Tasks. *PATTERNS 2015 : The Seventh International Conferences on Pervasive Patterns and Applications*, 1(2), 64–69.

Freedman, D. A. (2009). Statistical models: Theory and practice. *Statistical Models: Theory and Practice*, 1–442. <https://doi.org/10.1017/CBO9780511815867>

Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *Annals of Statistics*, 29(5), 1189–1232. <https://doi.org/10.1214/aos/1013203451>

Geurts, P., Ernst, D., & Wehenkel, L. (2006). Extremely randomized trees. *Machine Learning*, 63(1), 3–42. <https://doi.org/10.1007/s10994-006-6226-1>

Groover, M. P. (2013). Fundamentals of Modern Manufacturing Material, Processes, and Systems, 5th Edition. In *Journal of Chemical Information and Modeling*.

Gupta, M., Barber, D. G., Scharien, R. K., & Isleifson, D. (2014). Detection and classification of surface roughness in an Arctic marginal sea ice zone. *Hydrological Processes*, 28(3), 599–609. <https://doi.org/10.1002/hyp.9593>

Han, J., Kamber, M., & Pei, J. (2012). Techniques to Improve Classification Accuracy. In *Data Mining, Concepts and Techniques*.

Hernández-González, L. W., Dumitrescu, L., Quesada-Estrada, A. M., & Reyes-Camareno, R. (2020). Cutting parameters determination in milling of aisi 1045 steel. *Universidad y Sociedad*, 12(6), 207–214.

Hilt, D. E., & Seegrist, D. W. (1977). *RIDGE: A COMPUTER PROGRAM FOR CALCULATING RIDGE REGRESSION ESTIMATES*.

Huang, B., & Chen, J. C. (2003). An in-process neural network-based surface roughness prediction (INN-SRP) system using a dynamometer in end milling operations. *International Journal of Advanced Manufacturing Technology*, 21(5), 339–347. <https://doi.org/10.1007/s001700300039>

Ito, Y., Kizaki, T., Shinomoto, R., Ueki, M., Sugita, N., & Mitsuishi, M. (2017). High-efficiency and precision cutting of glass by selective laser-assisted milling. *Precision Engineering*, 47, 498–507. <https://doi.org/10.1016/j.precisioneng.2016.10.005>

John, G. H., & Langley, P. (2013). *Estimating Continuous Distributions in Bayesian Classifiers*. 338–345. <http://arxiv.org/abs/1302.4964>

Koç, E., Zeybek, S., Kısasöz, B. Ö., Çalışkan, C. İ., & Bulduk, M. E. (2022). Estimation of surface roughness in selective laser sintering using computational models. *International Journal of Advanced Manufacturing Technology*, 123(9–10), 3033–3045. <https://doi.org/10.1007/s00170-022-10406-w>

Kundrák, J., Felhő, C., & Nagy, A. (2022). Analysis and Prediction of Roughness of Face Milled Surfaces using CAD Model. *Manufacturing Technology*, 22(5), 558–572. <https://doi.org/10.21062/mft.2022.061>

Landwehr, N., Hall, M., & Frank, E. (2005). Logistic Model Trees. *Machine Learning*, 59(1–2), 161–205. <https://doi.org/10.1007/s10994-005-0466-3>

Laperriere, L., & Reinhart, G. (2014). *CIRP Encyclopedia of Production Engineering*.

Liang, L., Quan, Y., & Ke, Z. (2011). Investigation of tool-chip interface temperature in dry turning assisted by heat pipe cooling. *International Journal of Advanced Manufacturing Technology*, 54(1–4), 35–43. <https://doi.org/10.1007/s00170-010-2926-6>

Mia, M., & Dhar, N. R. (2016). Response surface and neural network based predictive models of cutting temperature in hard turning. *Journal of Advanced Research*, 7(6), 1035–1044. <https://doi.org/10.1016/j.jare.2016.05.004>

Molero, E., Fernández, J. J., Rodríguez-Alabanda, O., Guerrero-Vaca, G., & Romero, P. E.

(2020). Use of data mining techniques for the prediction of surface roughness of printed parts in polylactic acid (PLA) by fused deposition modeling (FDM): A practical application in frame glasses manufacturing. *Polymers*, 12(4).

<https://doi.org/10.3390/POLYM12040840>

Moraes, R. M., & Machado, L. S. (2015). A Fuzzy Poisson Naive Bayes Classifier for Epidemiological Purposes. *FCTA 2015 - 7th International Conference on Fuzzy Computation Theory and Applications*.

Morales Tamayo, Y., Zamora Hernández, Y., Beltrán Reyna, R. F., López Cedeño, K. M., López Bustamante, R. J., & Terán Herrera, H. C. (2018). Comparison of two methods for predicting surface roughness in turning stainless steel AISI 316L | Comparación de dos métodos para la predicción de la rugosidad superficial en el torneado del acero inoxidable AISI 316L. *Ingeniare*, 26(1), 97–105.

Napid, S. (2019). *Analisis Kekasaran Permukaan Termesin*.

Negnevitsky, M. (2005). *Artificial Intelligence: A Guide to Intelligent Systems*.

Nguyen, D. N., Dao, T. P., Prakash, C., Singh, S., Pramanik, A., Krolczyk, G., & Pruncu, C. I. (2020). Machining parameter optimization in shear thickening polishing of gear surfaces. *Journal of Materials Research and Technology*, 9(3), 5112–5126.

<https://doi.org/10.1016/j.jmrt.2020.03.028>

Ozkan, M. T., Ulas, H. B., & Bilgin, M. (2014). Experimental design and artificial neural network model for turning the 50CrV4 (SAE 6150) alloy using coated carbide/Cermet cutting tools. *Materiali in Tehnologije*, 48(2), 227–236.

Pathan, khan layequzzama, & Bhisvane, S. . (2018). *Experimental Analysis and Investigation of Machining Parameters in Finish Hard Turning of AIAI 4340 Steel* (pp. 265–270). Elsevier Ltd. <https://doi.org/10.1016/j.promfg.2018.02.039>

Pontes, F. J., Paiva, A. P. De, Balestrassi, P. P., Ferreira, J. R., & Silva, M. B. Da. (2012). Optimization of Radial Basis Function neural network employed for prediction of surface roughness in hard turning process using Taguchi's orthogonal arrays. *Expert Systems with Applications*, 39(9), 7776–7787.

<https://doi.org/10.1016/j.eswa.2012.01.058>

- Quinlan, J. R. (1993). *C4.5: PROGRAMS FOR MACHINE LEARNING*.
- Rahim, E. A., Rahim, A. A., Ibrahim, M. R., & Mohid, Z. (2016). Experimental Investigation of Supercritical Carbon Dioxide (SCCO<sub>2</sub>) Performance as a Sustainable Cooling Technique. *Procedia CIRP*, 40, 637–641. <https://doi.org/10.1016/j.procir.2016.01.147>
- Ratnasingam, J., Pew Ma, T., & Ramasamy, G. (2010). *Tool Temperature and Cutting Forces during the Machining of Particleboard and Solid Wood*.
- Resti, Y. (2015). Dependence in Classification of Aluminium Waste. *Journal of Physics: Conference Series*, 622, 012052. <https://doi.org/10.1088/1742-6596/622/1/012052>
- Resti, Y., Mohruni, A. S. A. S., Burlan, F., Yani, I., & Amran, A. (2017). A probability approach in cans identification. *MATEC Web of Conferences*, 101(03012), 1–6. <https://doi.org/10.1051/matecconf/201710103012>
- Resti, Y., Mohruni, A. S., Rodiana, T., & Zayanti, D. A. (2019). Study in Development of Cans Waste Classification System Based on Statistical Approaches. *Journal of Physics: Conference Series*, 1198(9). <https://doi.org/10.1088/1742-6596/1198/9/092004>
- Resti, Y., Saladin M, A., Burlan, F., Yani, I., & Amran., A. (2017). Automation of a Cans Waste Sorting System Using the Ejector System. *Modern Applied Science*, 11(3), 48. <https://doi.org/10.5539/mas.v11n3p48>
- Revathi, K., Jawahar, M., & Rinstituteforeengineeringandtechnology, K. S. (2015). *Efficiency Improvement in Classification Tasks using Naive Bayes Tree and Fuzzy Logic*. 6(1), 167–170.
- Ripley, B. B. D. (1996). *Pattern Recognition and Neural Networks (B.D.Ripley)* (Issue January, pp. 0–2).
- Sahoo, A. K., & Mishra, P. C. (2014). A response surface methodology and desirability approach for predictive modeling and optimization of cutting temperature in machining hardened steel. *International Journal of Industrial Engineering Computations*, 5(3), 407–416. <https://doi.org/10.5267/j.ijiec.2014.4.002>
- Sahoo, A. K., Rout, A. K., & Das, D. K. (2015). Response surface and artificial neural network prediction model and optimization for surface roughness in machining.

*International Journal of Industrial Engineering Computations*, 6(2), 229–240.

<https://doi.org/10.5267/j.ijiec.2014.11.001>

Salgado, D. R., & Alonso, F. J. (2007). An approach based on current and sound signals for in-process tool wear monitoring. *International Journal of Machine Tools and Manufacture*, 47(14), 2140–2152. <https://doi.org/10.1016/j.ijmachtools.2007.04.013>

Selaimia, A. A., Yallese, M. A., Bensouilah, H., Meddour, Ik., Khattabi, R., & Mabrouki, T. (2017). Modeling and optimization in dry face milling of X2CrNi18-9 austenitic stainless steel using RMS and desirability approach. *Measurement: Journal of the International Measurement Confederation*, 107, 53–67.  
<https://doi.org/10.1016/j.measurement.2017.05.012>

Sequera, M. S., Guiraldo, S. A., & Permites, I. D. (2017). Naïve bayes classifier and fuzzy logic system for computer – Aided detection and classification of mammographic abnormalities. *Journal of Theoretical and Applied Information Technology*, 95(2), 381–392.

Shalev-Shwartz, S., Singer, Y., Srebro, N., & Cotter, A. (2011). Pegasos: Primal estimated sub-gradient solver for SVM. *Mathematical Programming*, 127(1), 3–30.  
<https://doi.org/10.1007/s10107-010-0420-4>

Siddique, R. A., Dilwar, F., & Nayeem, K. R. (2018). Experimental investigation of the effect of cutting parameters on cutting temperature using RSM and ANN in turning AISI 1040. *Global Scientific Journol*, 6(8), 47–60.

Snell, J., Montgomery, D. C., & Runger, G. C. (1995). Applied Statistics and Probability for Engineers. In *Journal of the Royal Statistical Society. Series A (Statistics in Society)* (Vol. 158, Issue 2). <https://doi.org/10.2307/2983314>

Soares, E. A. M. ., & Moraes, R. M. (2018). Fusion of Online Assessment Methods for Gynecological Examination Training: a Feasibility Study. *Tend'encias Em Matem'atica Aplicada e Computacional*, 19, N. 3 (2018), 1-14, 1–14. <https://doi.org/001>

Soares, E. A. M. G., & Moraes, R. M. (2016). Assessment of Poisson Naive Bayes Classifier with Fuzzy Parameters Using Data from Different Statistical Distributions. *Cbsf 2016*, 12. [https://www.ime.unicamp.br/~cbsf4/Papers\\_IVCBSF/CBSF\\_2016\\_paper\\_44.pdf](https://www.ime.unicamp.br/~cbsf4/Papers_IVCBSF/CBSF_2016_paper_44.pdf)

- Sofuoğlu, M. A., Fatih, H. C., Selim, G., Sezan, O., & Melih, C. K. (2018). Numerical investigation of hot ultrasonic assisted turning of aviation alloys. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, 40(122).
- Sulaiman, S., Roshan, A., & Ariffin, M. K. A. (2013). Finite Element Modelling of the effect of tool rake angle on tool temperature and cutting force during high speed machining of AISI 4340 steel. *IOP Conference Series: Materials Science and Engineering*, 50(1). <https://doi.org/10.1088/1757-899X/50/1/012040>
- Suresh, R., Basavarajappa, S., Gaitonde, V. N., & Samuel, G. L. (2012). Machinability investigations on hardened AISI 4340 steel using coated carbide insert. *International Journal of Refractory Metals and Hard Materials*, 33, 75–86. <https://doi.org/10.1016/j.ijrmhm.2012.02.019>
- Tibshirani, R. (1996). Regression Shrinkage and Selection Via the Lasso. *Journal of the Royal Statistical Society: Series B (Methodological)*, 58(1), 267–288. <https://doi.org/10.1111/j.2517-6161.1996.tb02080.x>
- Tsai, Y. H., Chen, J. C., & Lou, S. J. (1999). An in-process surface recognition system based on neural networks in end milling cutting operations. *International Journal of Machine Tools and Manufacture*, 39(4), 583–605. [https://doi.org/10.1016/S0890-6955\(98\)00053-4](https://doi.org/10.1016/S0890-6955(98)00053-4)
- Ulfah, I. O., Kusumawardani, M., & Mas'udia, P. E. (2018). Pencarian Lokasi Terdekat Merchants E-Money Menggunakan Algoritma Floyd Warshall di Kota Malang. *Jartel*, 6(1), 82–88.
- Visa, S., Ramsay, B., Ralescu, A., & van deer Knaap, E. (2011). Confusion Matrix-based Feature Selection. *ConfusionMatrix-Based Feature Selection Sofia*, 710(January), 8.
- Wang, G., Wang, Y., Zhao, J., & Chen, G. (2012). Process optimization of the serial-parallel hybrid polishing machine tool based on artificial neural network and genetic algorithm. *Journal of Intelligent Manufacturing*, 23(3), 365–374. <https://doi.org/10.1007/s10845-009-0376-5>
- Wang, R., Cheng, M. N., Loh, Y. M., Wang, C., & Fai Cheung, C. (2022). Ensemble learning with a genetic algorithm for surface roughness prediction in multi-jet polishing. *Expert*

*Systems with Applications*, 207. <https://doi.org/10.1016/j.eswa.2022.118024>

Wang, X., & Feng, C. X. (2002). Development of empirical models for surface roughness prediction in finish turning. *International Journal of Advanced Manufacturing Technology*, 20(5), 348–356. <https://doi.org/10.1007/s001700200162>

Widiantoro, H., Fikri, A. A., & Mahardika, M. (2014). MONITORING KEAUSAN PAHAT MENGGUNAKAN ARTIFICIAL NEURAL NETWORKS PADA PROSES TURNING. *Seminar Nasional IENACO*, 248–256.

Witten, I. H., Frank, E., Hall, M. A., & Pal, C. J. (2016). Data Mining: Practical Machine Learning Tools and Techniques. *Data Mining: Practical Machine Learning Tools and Techniques*, 1–621.

Yang, J. L., & Chen, J. C. (2001). A systematic approach for identifying optimum surface roughness performance in end-milling operations. *Journal of Industrial Technology*, 17(2), 1–8.

Yang, L. D., Chen, J. C., Chow, H. M., & Lin, C. T. (2006). Fuzzy-nets-based in-process surface roughness adaptive control system in end-milling operations. *International Journal of Advanced Manufacturing Technology*, 28(3–4), 236–248.  
<https://doi.org/10.1007/s00170-004-2361-7>

Yani, I., Basri, H., & Marsil, H. I. (2016). Fatigue Life Prediction in Journal Bearing,. *International Journal on Smart Material and Mechatronics*, 1(1), 34–37.  
<https://doi.org/10.20342/ijsm.2.1.37>

Yani, I., & Budiman, I. (2015). Development of Identification System of cans And Bottle. *Journal of Physics: Conference Series*, 622, 012053. <https://doi.org/10.1088/1742-6596/622/1/012053>

Yani, I., Hannan, M. A., Basri, H., & Scavino, E. (2009). Detecting Object Using Combination of Sharpening and Edge Detection Method. *European Journal of Scientific Research*, 32(1), 121–127.

Yanis, M., Mohruni, A. S., Sharif, S., Yani, I., Arifin, A., & Khona'Ah, B. (2019). Application of RSM and ANN in Predicting Surface Roughness for Side Milling Process

under Environmentally Friendly Cutting Fluid. *Journal of Physics: Conference Series*, 1198(4). <https://doi.org/10.1088/1742-6596/1198/4/042016>

Yasril, A. I., & Fatma, F. (2021). Penerapan Uji Korelasi Spearman Untuk Mengkaji Faktor Yang Berhubungan Dengan Kejadian Diabetes Melitus Di Puskesmas Sicincin Kabupaten Padang Pariaman. *Human Care Journal*, 6(3), 527. <https://doi.org/10.32883/hcj.v6i3.1444>

Yu, J., & Liu, G. (2020). Knowledge-based deep belief network for machining roughness prediction and knowledge discovery. *Computers in Industry*, 121, 103262. <https://doi.org/10.1016/j.compind.2020.103262>

Zain, A. M., Haron, H., & Sharif, S. (2010). Application of GA to optimize cutting conditions for minimizing surface roughness in end milling machining process. *Expert Systems with Applications*, 37(6), 4650–4659. <https://doi.org/10.1016/j.eswa.2009.12.043>

Zou, H., & Hastie, T. (2005). Regularization and variable selection via the elastic net. *Journal of the Royal Statistical Society. Series B: Statistical Methodology*, 67(2), 301–320. <https://doi.org/10.1111/j.1467-9868.2005.00503.x>