

ANALISIS KEKASARAN PERMUKAAN HASIL PROSES SIDE MILLING MENGGUNAKAN ARTIFICIAL NEURAL NETWORKS (ANN)

Muhammad Yanis^(1*), Ahmad Mujaddid An-Najiy⁽¹⁾

⁽¹⁾Jurusan Teknik Mesin Fakultas Teknik Universitas Sriwijaya

^(*)E-mail Corresponding Author: yanis@unsri.ac.id

Abstrak

Kekasaran permukaan adalah salah satu penyimpangan yang disebabkan oleh kondisi pemotongan pada proses pemesinan. Pada pengujian ini pemberian cairan pemotongan dilakukan dengan metode MQL (*minimum quantity lubricant*) dengan benda kerja AISI 1045. Eksperimental pengujian dilakukan berdasarkan *Central Composite Design* dengan titik level yang disesuaikan dengan kondisi mesin freis vertikal yang digunakan, dengan Variabel kecepatan potong (V_c), gerak makan (f_z) dan kedalaman potong (a). Prediksi kekasaran permukaan dilakukan dengan menggunakan metode *Artificial Neural Networks*. Syarat yang ditetapkan dalam ANN yaitu struktur jaringan dengan 3 input, n *hidden layer* dan 1 output, algoritma jaringan *feed forward backpropagation*, training dan fungsi learning dengan Levenberg-Marquardt dan performansi dikalkulasikan dengan MSE. Hasil yang didapatkan bahwa pengaruh kecepatan potong terhadap kekasaran berbanding terbalik, semakin tinggi kecepatan potong maka akan menghasilkan nilai keasaran yang halus dan sebaliknya, sedangkan pengaruh gerak makan dan kedalaman makan terhadap kekasaran berbanding lurus, semakin tinggi nilai gerak makan dan kedalaman makan maka nilai kekasaran yang didapat akan semakin kasar. Prediksi kekasaran permukaan menghasilkan MSE terendah pada jaringan struktur 3-8-1 dengan MSE 0,001648738 dengan prediksi eror sebesar 3,2415% pada keseluruhan data training dan data testing. Dan pada data test mendapatkan rentang nilai penyimpangan 0,99% sampai 15,199%.

Kata Kunci: *Side Milling*, Kekasaran Permukaan, Jaringan Saraf Tiruan (JST)

Abstract

Surface roughness is one of the aberrations caused by cutting conditions in the machining process. In this test, the application of cutting fluid was carried out using the MQL (minimum quantity lubricant) method with the AISI 1045 workpiece. Experimental testing was carried out based on the Central Composite Design with a level point adjusted to the conditions of the vertical freis machine used, with variable cutting speed (V_c), motion feed (f_z) and depth of cut (a). Surface roughness prediction is done using Artificial Neural Networks method. The requirements set in ANN are a network structure with 3 inputs, n hidden layers and 1 output, feed forward back propagation network algorithms, training and learning functions with Levenberg-Marquardt and performance calculated by MSE. The results show that the effect of cutting speed on roughness is inversely proportional, the higher the cutting speed will produce a smooth roughness value and vice versa, while the effect of feeding motion and feeding depth on roughness is directly proportional, the higher the value of feeding motion and the depth of feeding, the higher the roughness value. the more rough it gets. Surface roughness prediction resulted in the lowest MSE in the 3-8-1 structural network with MSE 0.001648738 with an error prediction of 3.2415% in all training data and testing data. And the test data get a deviation value range of 0.99% to 15.199%.

Keywords: *Side Milling*, Surface Roughness, Artificial Neural Networks (ANN)

1 PENDAHULUAN

Dengan melihat perkembangan teknologi dimasa moderen, dapat kita amati bahwa hal tersebut membuat kalangan industri manufaktur perlu meningkatkan kualitas produk hasil produksi, penghematan waktu produksi dan penghasilan produk yang banyak dengan keakuratan dimensi yang tinggi. Selain kualitas dan kuantitas dalam industri moderen pada umumnya menginginkan *cost* yang

serendah rendahnya agar mudah diterima konsumen dipasaran.

Mesin frais merupakan salah satu dari proses pemesinan yang ada. Dalam proses pengefraisan (*milling*), hasil yang dicapai selain ukuran yang presisi adalah harga kekasaran. Dari harga kekasaran permukaan ini dapat dilakukan evaluasi apakah produk yang dibuat tersebut diterima atau tidak. Semakin halus harga kekasaran yang dihasilkan,

maka kriteria benda tersebut semakin baik. Jika harga kekasaran yang diperoleh semakin kasar maka akan berdampak kepada komponen atau elemen mesin yang saling bergesekan. Gesekan akan meningkat jika kualitas permukaan tidak halus. Kualitas permukaan yang halus akan membuat sedikit gesekan dari pada permukaan yang kasar [1].

Untuk meminimalisir kekasaran yang timbul pada material yang dikerjakan diperlukan pelumas atau cairan pendingin. Cairan pendingin atau *cutting fluid* adalah bagian paling mendasar dan penting dalam industri pengerjaan logam. Cairan pendingin banyak digunakan karena kemampuannya untuk mengurangi gesekan, suhu pemotongan, panas yang dihasilkan dan juga untuk meningkatkan kualitas permukaan benda kerja. Tetapi penggunaan cairan pendingin sintesis dan semi sintesis memunculkan ancaman terhadap kesehatan pekerja dan lingkungan. Oleh karena itu untuk mencari alternatif yang ramah penggunaannya dan ramah lingkungan untuk cairan pemotongan menggunakan *cutting fluid* berbasis *vegetable oil*. Karena itu, peningkatan kesadaran tentang aspek lingkungan dan kesadaran terhadap kesehatan operator harus ditingkatkan, cairan pemotongan ramah lingkungan harus dipilih dengan sangat hati-hati untuk meminimalkan hal yang tidak diinginkan. Selain itu *cutting fluid* berfungsi memperhalus kekasaran pada permukaan [2].

Kekasaran permukaan adalah salah satu penyimpangan yang disebabkan oleh kondisi pemotongan dari proses pemesinan. Salah satu proses pemesinan yang biasa digunakan pada industri manufaktur adalah pemesinan freis. Proses pemesinan freis adalah proses penyayatan logam menggunakan alat potong dengan mata potong jamak yang berputar [3].

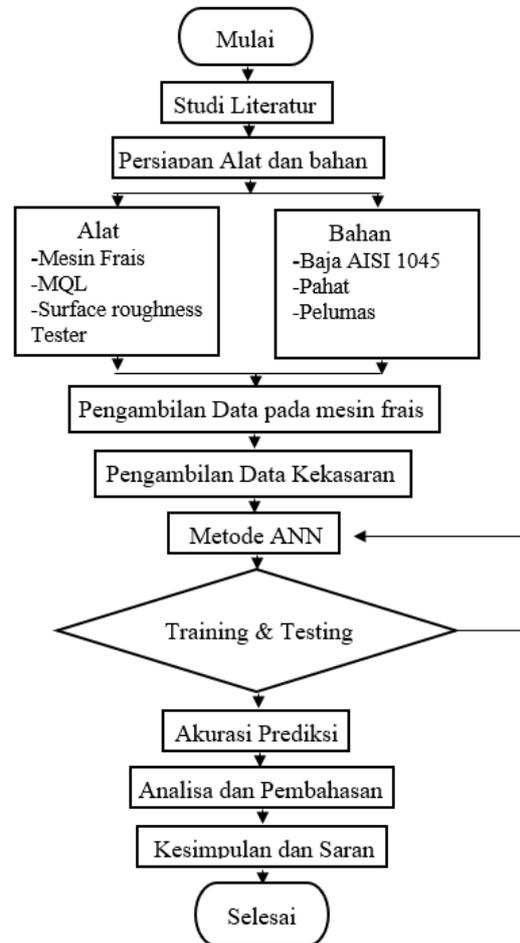
Untuk memperoleh hasil prediksi pada kekasaran permukaan hasil proses menggunakan metode *artificial neural network*. Dengan menggunakan metode *neural network*, dapat memprediksi *surface roughness* dengan tingkat eror yang relatif kecil. Karena dengan metode tersebut mampu memberikan gambaran kuantitatif pemilihan kombinasi parameter pemesinan yaitu kecepatan pemotongan, kecepatan pemakanan, dan kedalaman potong untuk mendapatkan kekasaran permukaan hasil pemotongan yang optimum [4].

2 METODE PENELITIAN

Metode yang digunakan dalam penelitian ini adalah *Artificial Neural Networks*, ANN adalah jaringan dari sekelompok unit pemroses yang dimodelkan berdasarkan sistem saraf manusia. ANN merupakan sistem adaptif yang dapat mengubah strukturnya untuk memecahkan masalah berdasarkan informasi eksternal maupun internal yang mengalir melalui jaringan tersebut. Pada penelitian ini yang menjadi variabel bebasnya yaitu, *cutting speed* (V_c), *feed rate*

(f_z), *depth of cut* (a) dan yang menjadi variabel terikatnya yaitu nilai kekasaran (R_a).

Proses penelitian dilakukan dengan tahap-tahap seperti yang ditunjukkan berdasarkan diagram alir penelitian pada gambar 1.



Gambar 1. Diagram Alir

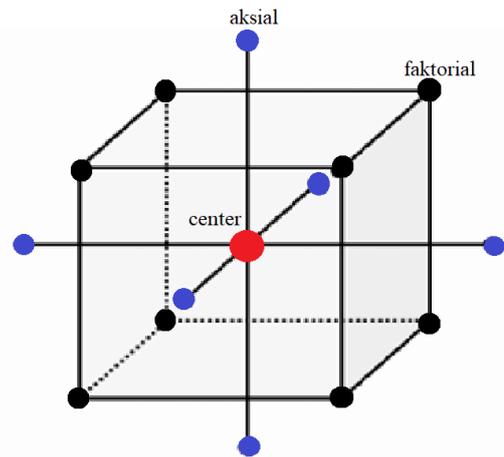
2.1 Persiapan Alat dan Bahan

Pada pengujian ini menggunakan mesin frais vertikal dengan mata potong berbahan karbida *endmill* dengan 4 flute. Adapun material yang digunakan dalam penelitian ini adalah baja AISI 1045 berbentuk balok dengan ukuran 10 x 10 x 2,8 mm yang termasuk dalam kategori baja karbon menengah. Pada saat pengujian frais cairan pendingin yang digunakan berbasis *vegetable oil* yaitu dengan minyak kelapa sebagai pelumas. pada saat pemotongan berlangsung, pemberian pelumas menggunakan metode MQL (*minimum quantity lubricant*). Dan kekasaran pada material yang dihasilkan akan diuji dengan alat Mitutoyo SJ-210.

2.2 Prosedur Pengujian Kekasaran

1. Siapkan material baja karbon sedang yang telah difreis.

2. Menandai 3 titik untuk mengukur kekasaran permukaan dengan titik (A, B, C) pada permukaan.
3. Siapkan alat uji *roughness tester* dan mengkalibrasi alat untuk mengukur akurasi.
4. Memastikan bahwa benda kerja dalam posisi diam agar meminimalisir kesalahan pengukuran.
5. Ujung *stylus* diletakkan diatas posisi material dengan titik yang ditandai sebelumnya.
6. Menekan tombol measurement agar ujung *stylus* akan bergerak balik jika proses pengukuran telah dilakukan.
7. Tunggu sampai *stylus* berhenti dan pada layer alat Mututoyo SJ-210 akan menampilkan nilai Ra.
8. Selanjutnya ulangi proses 5-7 hingga 6 kali pengujian.
9. Rekap hasil pengujian.



Gambar 2. *Central Composite Design*

2.3 Prosedur percobaan

1. Mempersiapkan alat dan bahan yang akan digunakan dalam penelitian.
2. Pengfreisan benda kerja baja karbon sedang dengan menggunakan pahat *endmill* karbida berdiameter 10 mm dengan proses *side milling*.
3. Proses pengambilan data berdasarkan parameter *cutting speed* (V_c), *feed rate* (f_z) dan kedalaman makan radial (a_r) menggunakan baja karbon sedang.
4. Mencari nilai kekasaran Ra dengan material yang telah difreis menggunakan alat kekasaran permukaan.
5. Mencari dan menganalisa prediksi *Surface Roughness* menggunakan *artificial neural network*.

2.4 Variabel Proses

Pengumpulan data yang dilakukan pada penelitian ini menggunakan metode *central composite design* (CCD), yang menjadi variabel bebasnya yaitu *cutting speed* (V_c), *feed rate* (f_z), *radial depth of cut* (a_r) sedangkan variabel terikatnya yaitu *surface roughness* (Ra). Langkah pertama yaitu menentukan batas-batas dari titik percobaan untuk di selidiki agar sesuai dengan keadaan mesin yang ada. Batasan yang dibuat diatur sejauh mungkin agar mendapat respon yang jelas dari parameter pemotongan yang telah ditetapkan. Perbedaan level parameter Digambarkan pada tabel 3.4, yang menunjukkan faktor-faktor yang akan diuji pada penelitian. Langkah selanjutnya dengan membuat perancangan percobaan dengan menggunakan *central composite design* yang ditunjukkan pada gambar 3.9, dengan tiga variabel dan 16 percobaan.

Tabel 1 Hasil Getaran Berdasarkan FFT pada Variasi Kondisi Pemotongan untuk Pahat HSS 4 Flute dan 2 Flute

	Unit	Level			
		-1,68	-1	1	1,68
Vc	m/min	8,9	16,3	31,1	38,5
fz	mm/rev	0,0365	0,053	0,086	0,1025
a	mm	0,2	0,3	0,5	0,6

2.5 Metode Pengujian

Untuk mendapatkan prediksi kekasaran permukaan hasil proses *side milling* pada baja AISI 1045 dilakukan menggunakan metode *artificial neural networks* (ANN). Jaringan syaraf tiruan mampu memprediksi kekasaran permukaan dengan memasukkan parameter sebagai inputnya dan output sebagai kekasaran permukaan. Dengan melatih jaringan yang akan dipakai lalu mengujinya dengan memasukkan data test sebagai data ujinya.

2.5.1 Metode Pemodelan ANN

Dengan menggunakan metode *neural network* ada beberapa faktor yang dapat mempengaruhi bentuk dari pemodelan *neural network*, diantaranya yaitu algoritma *training* dan *learning*, algoritma jaringan, struktur jaringan dan fungsi aktivasi yang dipakai. Ada beberapa syarat yang telah ditetapkan untuk menganalisa prediksi yang akan dilakukan dengan ANN yaitu sebagai berikut:

1. Struktur yang akan digunakan adalah dengan 3 input, satu *hidden layer* dengan jumlah neuron yang akan diuji coba dari 1 sampai 15 dan menghasilkan 1 output layer (3-n-1).
2. Untuk menentukan jumlah *neuron* pada *hidden layer* dilakukan *training* hingga mendapatkan nilai maksimum pada range 1 sampai 15.

3. Algoritma jaringan yang dipakai adalah *feedforward backpropagation*. *Backpropagation* melatih jaringan untuk mendapatkan keseimbangan antara kemampuan jaringan untuk mengenali pola yang digunakan selama pelatihan serta kemampuan jaringan untuk memberikan respon yang benar terhadap pola masukan yang serupa (tapi tidak sama) dengan pola yang dipakai selama pelatihan. Dengan menyebarkan penurunan bobot dari *output* ke *input*. Selain itu *back propagation* dapat mengecilkan nilai MSE pada keluaran [5].
4. *Learning* dan fungsi *training* yang digunakan adalah algoritma Levenberg-Marquardt atau disingkat menjadi *trainlm*. Algoritma Levenberg-Marquardt memiliki keakuratan yang tinggi dalam perkiraan fungsi yang serupa. Selain itu juga dapat bekerja lebih cepat ketika melatih *feedforward* neuron ukuran menengah yang dapat menampung hingga ratusan bobot dan mensupport pelatihan vector validasi dan uji [6].
5. Fungsi aktivasi yang digunakan yaitu fungsi *hyperbolic tangent* (tansig) pada *hidden layer* dan *output layer*. dapat diketahui bahwa fungsi tansig memiliki sifat yang simetris dan menghasilkan MSE yang relatif kecil [7].
6. Fungsi performansi dikalkulasikan menggunakan *Mean Square Error* (MSE) dan *Mean Absolute Percentage Error* (MAPE) [8].

3 HASIL DAN PEMBAHASAN

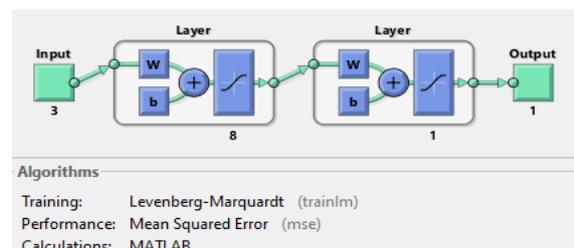
3.1 Hasil Pengujian Kekasaran

Pada penelitian ini proses pengefreisan dilakukan pada mesin freis vertikal dengan metode *side milling* dan arah makan *down milling* yang mana pahat berputar searah dengan pergerakan meja kerja sehingga menghasilkan permukaan yang relatif halus. Pemakanan proses frais dilakukan dengan memotong benda kerja dengan panjang 100 mm dan kedalaman potong *axial* yang tetap yaitu 10 mm pada setiap eksperimen yang dilakukan dengan menggunakan mata pahat *end milling* karbida. Benda kerja yang digunakan yaitu baja AISI 1045 yang pada umumnya digunakan untuk membuat elemen-elemen mesin seperti roda gigi, poros dan *spare part* mesin yang lainnya. Baja yang digunakan berjumlah 4 balok dengan ukuran masing masing 100 mm x 100 mm x 25 mm. Pengujian ini dilakukan 16 kali pengujian dan setiap pengujiannya menggunakan cairan pendingin berbasis *vegetable oil* yaitu dengan menggunakan minyak kelapa dengan parameter *Cutting speed* (Vc), *feed rate* (fz) dan *radial depth of cut* (ar). Data hasil kekasarannya didapatkan melalui uji kekasaran pada benda kerja yang telah di freis menggunakan alat Mitutoyo SJ-210 *roughness tester* pada tiga titik, yaitu bagian awal, tengah dan akhir pada benda kerja. Prediksi dianalisa menggunakan *artificial neural networks*. Hasil pengujian nilai kekasaran (Ra) yang dihasilkan disajikan pada tabel 3.1.

Tabel 2 Hasil Pengukuran Kekasaran

No	Vc	fz	ar	Ra
1	16.3	0.053	0.3	0.626
2	31.1	0.053	0.3	0.281
3	16.3	0.086	0.3	0.677
4	31.1	0.086	0.3	0.266
5	16.3	0.053	0.5	0.762
6	31.1	0.053	0.5	0.397
7	16.3	0.086	0.5	0.689
8	31.1	0.086	0.5	0.714
9	8.9	0.0695	0.4	0.565
10	38.5	0.0695	0.4	0.278
11	23.7	0.0365	0.4	0.818
12	23.7	0.1025	0.4	1.202
13	23.7	0.0695	0.2	0.899
14	23.7	0.0695	0.6	1.092
15	23.7	0.0695	0.4	0.921
16	23.7	0.0695	0.4	0.900

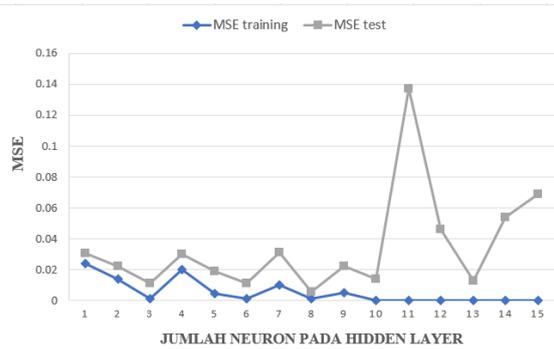
3.2 Hasil Pemodelan dengan ANN



Gambar 3. Skematik Jaringan

Dengan memasukkan data dari data percobaan yang telah didapat, yang mana kecepatan potong (Vc), gerak makan (fz) dan kedalaman makan radial (ar) sebagai input dan Ra sebagai target, data input dinormalisasikan dengan angka-angka kecil dengan range -1 sampai 1 setiap antar neuron memiliki bobot yang ditentukan dengan algoritma *backpropagation* dan dimasukkan menuju ke hidden layer dan memproses data yang diterima dengan fungsi *hyperbolic tangent*, lalu menuju lapisan *output* dengan proses yang sama seperti pada *hidden layer*, lalu memproses keluaran ini untuk menghasilkan hasil akhir, hasil akhir pada hidden layer dan output dihitung dengan fungsi transfer tansig. Jika hasil yang dihasilkan pada output masih memiliki nilai penyimpangan yang cukup tinggi, maka hasil pada output dikembalikan ke input dengan dilatih kembali agar mempunyai nilai dengan tingkat penyimpangan yang kecil, training dilakukan berulang-ulang pada *command standard* MATLAB sampai menemukan titik dengan penyimpangan terendah pelatihan dan learning ini dinamakan *Trainlm* atau singkatan dari Levenberg-Marquardt. Pada awalnya Input dan target dimasukkan bersama dan bobot ditetapkan secara acak dengan struktur jaringan yang telah ditetapkan yaitu 3-n-1 dengan percobaan neuron pada hidden

layer 1 sampai 15, kemudian mengambil performansi terbaik dari jaringan struktur sebagai prediksi.



Gambar 4. Performansi Training dan Testing.

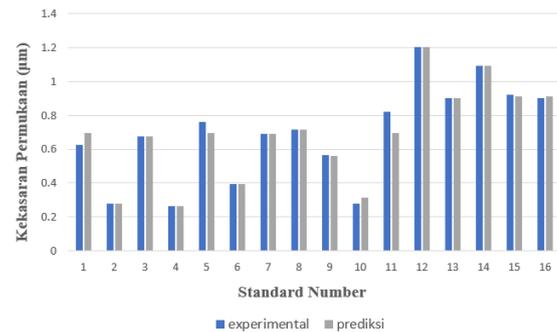
Pada gambar 4.2 dapat dilihat pelatihan dan testing telah dilakukan dengan struktur jaringan pada hidden layer yang berbeda-beda, yaitu dengan jumlah neuron pada range 1 sampai 15. Setelah dikukannya training dan testing, didapatkannya bahwa jaringan dengan jumlah neuron 3, 6, 8, 10 dan 13 pada *hidden layer* mempunyai nilai MSE *training* dan *testing* lebih kecil dibandingkan dengan yang lainnya. Ditinjau dari hasil prediksi ANN bahwa neuron dengan struktur 3-8-1 adalah struktur yang paling mendekati data hasil eksperimental yang ada dengan performansi MSE 0,001648738 dan didapatkan pada iterasi ke 578 dengan *epoch* maksimal 1000. Semakin kecil penyimpangan yang didapat maka semakin dekat prediksi ANN dengan hasil eksperimental yang dihasilkan. Berikut adalah hasil prediksi oleh ANN dan nilai eksperimental.

Tabel 3 Hasil Pengukuran Kekasaran

Std	Eksperiment	ANN	Error
1	0.62566667	0.693667	10.86840727
2	0.28133333	0.281333	0.00000439
3	0.67666667	0.676667	0.00000016
4	0.26633333	0.266344	0.00395351
5	0.76166667	0.693667	8.92778994
6	0.397	0.397	0.00000002
7	0.689	0.689	0.00000016
8	0.714	0.714	0.00000770
9	0.565	0.559401	0.99105823
10	0.278	0.315509	13.49258283
11	0.818	0.693667	15.19967418
12	1.2018	1.201789	0.00089191
13	0.899	0.899	0.00000246
14	1.09166667	1.091667	0.00000062
15	0.92133333	0.9105	1.17583563
16	0.89966667	0.9105	1.20414610
Rata-rata			3,2415

Perbandingan antara nilai eksperimental dan prediksi pada tabel diatas dikalkulasikan dengan *Mean Absolute percentage Error* (MAPE) atau dikenal dengan rata-rata kesalahan absolut, nilai MAPE menggambarkan bentuk penyimpangan titik-titik

pada regresi yang didapat. Dari data yang diperoleh rata-rata penyimpangan yang didapat adalah 3,2415 % dengan penyimpangan terkecil ada pada *standard number* 6 dengan nilai 0,00000002 % dan penyimpangan terbesar ada pada *standard number* 11 dengan nilai 15,1997 %. Naik atau turunnya nilai error yang didapatkan tergantung dari jauh atau dekatnya nilai eksperimental dengan prediksinya, hal ini dikarenakan perubahan bobot pada saat training yang membuat nilai outputnya tidak dapat memberikan hasil yang mendekati nilai eksperimental. Perbandingan data eksperimental dengan prediksi digambarkan pada grafik dibawah ini.

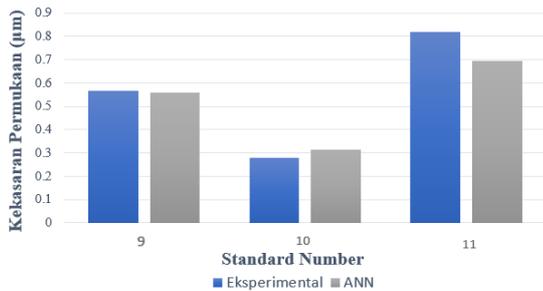


Gambar 5. Perbandingan Data Eksperimental dan Prediksi.

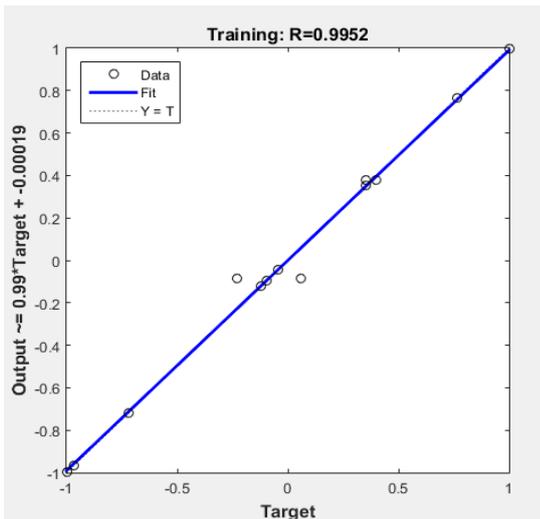
Selain dengan data pelatihan, dalam ANN juga dibutuhkan data test yang berfungsi menguji kinerja dari training yang telah dilakukan. Data test adalah data yang tidak tergantung pada data training, tetapi mengikuti distribusi probabilitas yang sama dengan data training. Jika model cocok dengan data training dan data testing maka akan mendapatkan prediksi yang baik. Dengan menggunakan titik aksial pada central composite design sebagai data yaitu standard number 9, 10 dan 11 dan mendapatkan nilai error 0,99%, 13,49% dan 15,199%. Dengan MSE 0,005632 menunjukkan bahwa data training dan data test yang ada cukup dapat diterima. Grafik serta nilai eksperimental dan prediksi data test dapat dilihat pada tabel dan gambar dibawah ini.

Tabel 4 Hasil Pengukuran Kekasaran

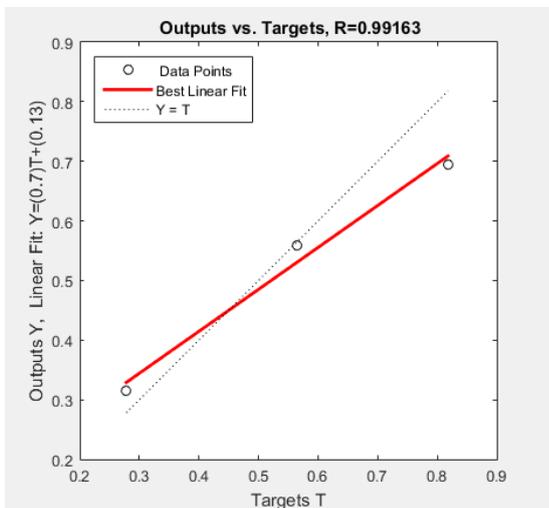
Std	Experiment	ANN
1	0.565	0.559401
2	0.278	0.315509
3	0.818	0.693667



Gambar 6. Perbandingan Data Test Data Test Eksperimental dan Prediksi.



Gambar 7. Grafik regresi data training.

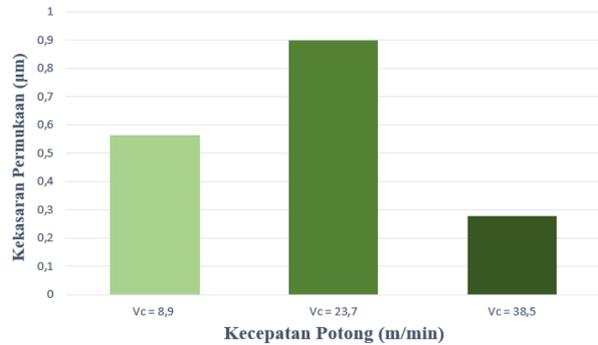


Gambar 8. Grafik regresi data test.

Untuk mendapatkan MSE terbaik sebagai performansinya kita dapat melihat dengan persamaan gradien, nilai untuk persamaan gradien harus mendekati atau sama dengan $1.0 * T$ dan nilai konstanta harus mendekati nol. Jika mendapatkan coefisien regresi (R) yang mendekati 1, hal itu mengidentifikasi bahwa nilai prediksi mendekati nilai eksperimental, tetapi jika persamaan gradien tidak mendekati nol maka bisa dikatakan nilai MSE yang dihasilkan belum bagus.

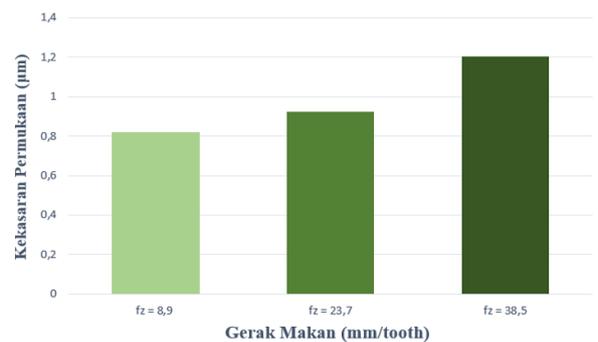
3.3 Pengaruh Parameter Pemotongan Terhadap Kekasaran Permukaan

Pada penelitian ini, nilai kekasaran permukaan dipengaruhi oleh variasi dari kondisi pemotongan, adapun parameter pemotongan diantaranya yaitu, kecepatan potong (V_c), gerak makan (f_z) dan kedalaman potong (a) sehingga menghasilkan nilai surface roughness (μm) yang bervariasi.



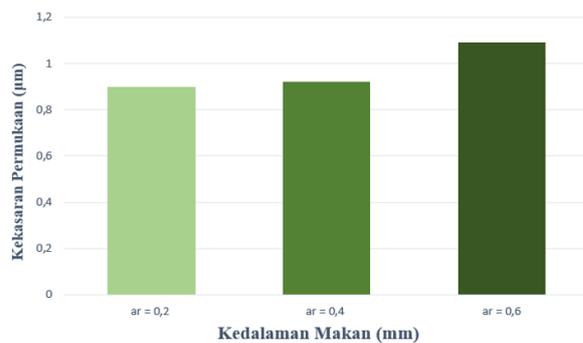
Gambar 9. Grafik kecepatan potong terhadap kekasaran permukaan.

Dari grafik diatas, kecepatan potong 8,9, 23,7 dan 38,5 dengan dengan gerak makan 0,0695 mm/tooth dan kedalaman potong 0,4 mm secara berturut-turut menghasilkan kekasaran permukaan 0,565 μm , 0,8997 μm dan 0,278 μm dari data tersebut dapat kita simpulkan bahwa nilai kecepatan potong tertinggi menghasilkan penurunan nilai kekasaran. Jika kita perhatikan kecepatan potong pada std 1,3,5 dan 7 yang memiliki kecepatan potong 16,3 jika dibandingkan dengan kecepatan potong pada std 2,4,6 dan 8 yang memiliki kecepatan potong 31,1 maka akan terlihat bahwa semakin besar nilai kecepatan potong maka akan semakin menurun nilai kekasaran permukaan yang dihasilkan.



Gambar 10. Grafik Gerakan makan terhadap kekasaran permukaan

Dari grafik diatas, gerak makan 0,0365, 0,0695 dan 0,1025 mm/tooth dengan kecepatan potong 23,7 m/min dan kedalaman potong 0,4 mm/ secara berturut-turut menghasilkan kekasaran permukaan 0,818 μm , 0,9213 μm dan 1,2018 μm . Dengan demikian dapat disimpulkan bahwa semakin besar nilai gerak makan maka semakin besar kekasaran permukaan yang dihasilkan, hal ini sesuai dengan teori yang ada.



Gambar 11. Grafik kedalaman makan terhadap kekasaran permukaan.

Dari grafik diatas, kedalaman makan 0,2 mm, 0,4 mm dan 0,6 mm dengan kecepatan potong 23,7 m/min dan gerak makan 0,0685 mm/tooth secara berturut-turut menghasilkan kekasaran permukaan 0,899 µm, 0,921 µm dan 1,0917 µm. Dengan demikian dapat disimpulkan bahwa semakin besar nilai kedalaman makan maka semakin besar kekasaran permukaan yang dihasilkan.

4 KESIMPULAN

Berdasarkan hasil dan pembahasan maka dapat ditarik kesimpulan, yaitu :

1. Semakin besar kecepatan potong maka akan semakin rendah nilai kekasaran permukaan yang didapat sedangkan semakin besar gerak makan dan kedalaman potong maka akan semakin tinggi nilai kekasaran permukaan.
2. Prediksi terbaik berdasarkan artificial neural network back propagation dengan algoritma Levenberg-marquardt, MSE terkecil untuk kekasaran permukaan ada pada struktur 3-8-1.
3. Nilai kekasaran minimum pada pengujian baja AISI 1045 ada pada kondisi pemesian $V_c = 31,1$ m/min, $f_z = 0,086$ mm/tooth dan $a = 0,3$ mm dan nilai kekasaran maksimum ada pada kondisi $V_c = 23,7$ m/min, $f_z = 0,1025$ dan $a = 0,4$ mm.
4. Hasil analisis kekasaran permukaan menggunakan artificial neural network backpropagation dengan menggunakan software MATLAB menghasilkan persentase eror dengan rata-rata 3,242 %.

UCAPAN TERIMA KASIH

Terima kasih kepada Jurusan Teknik Mesin, para Dosen dan bapak Muhammad Yanis selaku Dosen Pembimbing. Terimakasih juga kepada Bapak Abdul Hadi, Ibu Murniati dan saudara-saudari yang selalu membantu dan mendoakan.

DAFTAR PUSTAKA

- [1] A. W. Widiatoro, M. Khumaedi, and W. Sumbodo, "Pengaruh Jenis Material Pahat Potong Dan Arah Pemakanan Terhadap Kekasaran Permukaan Baja Ems 45 Pada Proses

Cnc," *Pendidik. Tek. mesin universitas semarang*, 2017.

- [2] K. Kumar Gajrani and M. Ravi Sankar, "Past and Current Status of Eco-Friendly Vegetable Oil Based Metal Cutting Fluids," *Mater. Today Proc.*, vol. 4, pp. 3768–3795, 2017, doi: 10.1016/j.matpr.2017.02.275.
- [3] T. Rochim, *Proses Pemesinan Buku 1 Klarifikasi Proses, Gaya dan Daya Pemesinan*. ITB, 2007.
- [4] V. T. Widyaningrum, "Artificial Neural Network Backpropagation Dengan Momentum Untuk Prediksi Surface Roughness Pada CNC Milling," *Pros. Conf. Smart-Green Technol. Electr. Inf. Syst.*, vol. C, no. 008, pp. 153–158, 2013.
- [5] K. S. Sangwan, S. Saxena, and G. Kant, "Optimization of machining parameters to minimize surface roughness using integrated ANN-GA approach," *Procedia CIRP*, vol. 29, pp. 305–310, 2015, doi: 10.1016/j.procir.2015.02.002.
- [6] M. Mia and N. R. Dhar, "Prediction of surface roughness in hard turning under high pressure coolant using Artificial Neural Network," *Meas. J. Int. Meas. Confed.*, vol. 92, pp. 464–474, 2016, doi: 10.1016/j.measurement.2016.06.048.
- [7] Mohammad Hossain, L. S. P. Gopiseti, and M. S. Miah, "Artificial neural network modelling to predict international roughness index of rigid pavement," *J. Chem. Inf. Model.*, vol. 53, no. 9, pp. 1689–1699, 2018.
- [8] M. Yanis, A. S. Mohrni, S. Sharif, I. Yani, A. Arifin, and B. Khona'Ah, "Application of RSM and ANN in Predicting Surface Roughness for Side Milling Process under Environmentally Friendly Cutting Fluid," *J. Phys. Conf. Ser.*, vol. 1198, no. 4, 2019, doi: 10.1088/1742-6596/1198/4/042016.