

Optimasi Kekasaran Permukaan dan Laju Pemotongan pada Mesin *Laser cutting* Menggunakan Material SUS 316L dengan Metode Taguchi dan *Neural Network*

Putri Amalia Maviroh^{1*}, Bayu Wiro Karuniawan², Farizi Rachman³

Program Studi Teknik Desain dan Manufaktur, Jurusan Teknik Permesinan Kapal, Politeknik Perkapalan Negeri Surabaya,
Surabaya, 60111, Indonesia

^{1*,2,3}

Email: putriamalia@student.ppns.ac.id¹

Abstract – *Laser cutting machine is able to cutting hard material and having complicated patterns. In the cutting process in the laser cutting machine has several parameters, they are the laser beam focus point, cutting gas pressure and cutting speed. These parameters can cause cutting defects. Starting from the roughness surface until the product is not cut. So we need an optimization process through research methods. The optimization method in this research use the $L_9(3^4)$ orthogonal matrix with 3 levels on each parameter of taguchi and neural network prediction. From the taguchi optimization process, it produces an optimal parameter combination for the surface roughness response at the laser beam focus point -14 mm, gas cutting pressure 17 bar and cutting speed 0.4 m / min. And for the response of the cutting rate at the laser beam focus point -17 mm, gas pressure cutting 20 bar and cutting speed 0.6 m / min. While the optimal parameter settings using a neural network, for the response of surface roughness at the laser beam focus point -14 mm, gas pressure cutting 20 bar and cutting speed 0.2 m / minute. And for the response of the cutting rate at the laser beam focus point -20 mm, gas pressure cutting 17 bar and cutting speed 0.6 m / minute. In optimal parameter settings using the taguchi method, the laser beam focus point parameters have the greatest contribution, with a percentage of 46.5061% for the response of surface roughness. While cutting speed has a significant contribution in reducing the variation of the cutting rate response, with a contribution percentage of 66.0430%.*

Keyword: Surface Roughness, Cutting Rate, laser cutting, SUS 316L, Taguchi, Artificial Neural Network

Nomenclature

v	= kecepatan pemotongan (mm/min)
L	= luas penampang pemotongan (mm ²)
n	= jumlah pengulangan dari suatu percobaan.
n	= jumlah percobaan
y	= data yang diperoleh dari percobaan
S _i	= jumlah kuadrat faktor ke-i
SS _t	= jumlah kuadrat total
SS _m	= jumlah kuadrat karena mean
DF ₁	= derajat kebebasan faktor i
SS _{factor}	= sum of square due to factor
SS _e	= sum of square due to error
MS _e	= mean sum of square due to error
V _e	= rata-rata jumlah kuadrat error
i	= respon kekasaran permukaan atau laju pemotongan
A _x	= nilai pada variabel A pada level x
B _y	= nilai pada variabel B pada level y
C _z	= nilai pada variabel C (<i>cutting speed</i>) pada level z
T	= mean nilai kekasaran permukaan yang digunakan untuk perhitungan
X'	= data hasil normalisasi
X	= data asli atau data awal
a	= nilai maksimum data asli
F _i	= nilai prediksi dengan range nilai asli

F' _i	= nilai prediksi dari data yang dinormalisasi
X	= data aktual

1. PENDAHULUAN

Di era industri saat ini, teknologi yang ada semakin modern dan semakin meluas. Pada industri manufaktur terdapat beberapa proses permesinan, salah satunya adalah proses pemotongan. Salah satu mesin yang umum digunakan untuk proses pemotongan adalah mesin CNC (*Computer Numerical Control*). Pada proses pemotongan material lembaran digunakan mesin CNC berjenis CNC *laser cutting*. Mesin *laser cutting* mampu memotong material yang bersifat keras dan memiliki pola yang rumit. Pada proses pemotongan dimesin *laser cutting* memiliki beberapa parameter yaitu titik fokus, tekanan gas *cutting*, dan *cutting speed*. Menurut Yushi (2017), parameter-parameter tersebut yang mengakibatkan kecacatan pemotongan. Kecacatan tersebut diantaranya adalah permukaan kasar sampai tidak terpotongnya produk.

Pada penelitian ini menggunakan data dari penelitian Riskita Rakasita (2016) jurusan Teknik Desain dan Manufaktur, Teknik Permesinan Kapal, Politeknik Perkapalan Negeri

Surabaya. Metode yang digunakan pada penelitian Riskita Rakasita (2016) yaitu Taguchi *Grey Relational Analysis*. Metode Taguchi *Grey Relational Analysis* merupakan metode yang digunakan untuk mengoptimasikan respon yang jumlahnya lebih dari satu secara serentak. Sedangkan pada penelitian ini dilakukan proses optimasi per respon yaitu respon kekasaran dan respon laju pemotongan. Disisi lain Metode *Artificial Neural Network* juga memiliki kemampuan untuk melakukan optimasi per respon melalui prediksi hasil *testing*. Sehingga metode Taguchi *Grey Relational Analysis* tidak sesuai jika digabungkan dengan Metode *Artificial Neural Network*.

2. METODOLOGI

2.1 Metode Taguchi

Desain eksperimen dengan metode Taguchi termasuk kelompok *fractional factorial* eksperimen. Taguchi menyusun *orthogonal array* untuk tata letak eksperimennya. Keuntungan dari *orthogonal array* (OA) adalah kemampuan untuk mengevaluasi beberapa faktor dengan jumlah *test* yang minimum.

Perancangan eksperimen adalah proses evaluasi terhadap dua atau lebih faktor kontrol (parameter) terhadap kemampuan mempengaruhi variabilitas hasil gabungan dari hasil karakteristik produk. Tiga tahapan utama Taguchi untuk pendekatan eksperimen, yaitu:

A. Tahap Perencanaan Eksperimen

1. Perumusan masalah, mengidentifikasi permasalahan yang terjadi untuk kemudian dilakukan usaha untuk perbaikan kualitas.
2. Tujuan eksperimen harus bisa dijawab pada perumusan masalah.
3. Penentuan variabel, dengan menentukan variabel bebas dan variabel terikat. variabel bebas adalah variabel yang perubahannya tidak dapat dipengaruhi oleh variabel lain. Sedangkan variabel terikat adalah variabel yang perubahannya dapat dipengaruhi oleh variabel lain.
4. Menentukan jumlah level dan nilai faktor. Semakin banyak level yang dilibatkan dalam eksperimen maka semakin valid data yang akan didapatkan.
5. Perhitungan derajat kebebasan, dilakukan untuk mengetahui jumlah eksperimen yang akan dilakukan.
6. Perhitungan *orthogonal array*, digunakan untuk mendeskripsikan jumlah eksperimental yang dilakukan. Desain OA sering digunakan dalam desain eksperimen dengan multilevel faktor.

7. Penempatan faktor dan level ke matriks orthogonal. Elemen-elemen matriks disusun menurut baris dan kolom pada matriks orthogonal. Baris adalah keadaan suatu faktor sedangkan kolom adalah faktor yang dapat diubah dalam eksperimen.

B. Tahapan Pelaksanaan

1. Jumlah replikasi adalah jumlah proses pengulangan eksperimen yang dilakukan pada kondisi yang sama untuk memperoleh data yang lebih valid agar terhindar dari kesalahan.
2. Randomisasi, pelaksanaan eksperimen terletak pada urutan eksperimen yang tidak berurutan untuk mengurangi faktor kesalahan yang tidak terkendali. Faktor dan nilai level dimasukkan sesuai dengan matriks orthogonal. Pelaksanaan eksperimen berdasarkan matriks orthogonal $L_9(3^4)$ seperti yang ditunjukkan pada Tabel 1.

Tabel 1. Matriks Orthogonal $L_9(3^4)$

Eksperimen	$L_9(3^4)$			
	1	2	3	4
1	1	1	1	1
2	1	2	2	2
3	1	3	3	3
4	2	1	2	2
5	2	2	3	1
6	2	3	1	2
7	3	1	3	2
8	3	2	1	3
9	3	3	2	1

C. Tahap Analisa

Melakukan pengumpulan dan pengolahan data sesuai eksperimen yang akan dilakukan. Setelah itu mengambil data dengan rasio S/N.

1. Rasio S/N

Menurut Soejanto, I. (dalam[1]), Rasio S/N digunakan untuk memilih faktor yang memiliki pengaruh atau kontribusi pada pengurangan variasi suatu respon atau untuk mengetahui level faktor yang paling berpengaruh pada hasil eksperimen.

a. *Smaller the better*

Smaller the better, adalah karakteristik kualitas terukur dengan nilai non-negatif dan targetnya adalah nilai yang sekecil-kecilnya (no). Yang ditunjukkan pada persamaan 1.

$$\eta = 10 \text{ Log (M.S.D.)}$$

$$\text{M. S. D} = \frac{1}{n} [\sum_{i=1}^n y_i^2] \quad (1)$$

b. Tertuju pada nilai tertentu

S/N memiliki nilai yang mendekati suatu nilai tertentu ($S/N \rightarrow k$). Sehingga menjadi persamaan 2.

$$\eta = 10 \log \left(\frac{\mu^2}{\sigma^2} \right)$$

$$\eta = \frac{1}{n} \sum_{i=1}^n (y_i - \mu)^2 \quad (2)$$

c. *Higher the better*

Higher the better adalah karakteristik kualitas terukur dengan nilai non-negatif yang mempunyai kondisi ideal dan nilai targetnya adalah nilai yang sebesar-besarnya (tak terbatas). Yang ditunjukkan pada persamaan 3:

$$\eta = -10 \text{Log (M.S.D.)}$$

$$\text{M.S.D} = \left(\frac{1}{n} \sum_{i=1}^a \frac{1}{y_i^2} \right) \quad (3)$$

2. Analysis of Varians (ANOVA)

Perhitungan yang dibutuhkan untuk mendukung pengolahan data dalam ANOVA adalah sebagai berikut:

Langkah 1: menghitung rata-rata respon setiap eksperimen sesuai persamaan 4:

$$\bar{y}_i = \frac{\sum x}{n} \quad (4)$$

Langkah 2: menghitung rata-rata total seluruh eksperimen dengan persamaan 5:

$$\bar{Y} = \frac{\sum y}{n} \quad (5)$$

Langkah 3: membuat tabel respon, perbedaan dapat diketahui dengan cara melakukan pengurangan nilai tertinggi dengan nilai terendah dari tiap-tiap level kemudian dirangking dari nilai tertinggi sampai nilai terendah kemudian dimasukkan dalam tabel respon seperti Tabel 2 di bawah ini.

Tabel 2. Respon Faktor

	Faktor A	Faktor B	Faktor X
Level 1				
Level 2				
.....				
Level Y				
Different				
Rank				

Langkah 4: menghitung *the total sum of squares* dengan persamaan 6:

$$SS_T = \sum_{i=1}^n y^2 \quad (6)$$

Langkah 5: menghitung *the sum of squares due to the mean* dengan persamaan 7:

$$SS_m = ny^2 \quad (7)$$

Langkah 6: menghitung *the sum of squares due to the factors* dengan persamaan 8:

$$SS_{factor} = (n_{i1} \times i1^{-2} + n_{i2} \times i2^{-2} + \dots + n_{ij} \times ij^{-2}) \quad (8)$$

Langkah 7: menghitung *the sum of squares due to the error* dengan persamaan 9:

$$SS_e = SS_T - SS_m - (SA + SB + \dots + S_i) \quad (9)$$

Langkah 8: menghitung derajat kebebasan atau *Degree of Freedom* dengan persamaan 10:

$$DF_i = \text{jumlah level} - 1 \quad (10)$$

Langkah 9: menghitung *the mean sum of squares* dengan persamaan 11:

$$MS_{factor} = \frac{SS_{factor}}{DF_i} \quad (11)$$

Langkah 10: menghitung *F-ratio* dengan menggunakan persamaan 12 dan persamaan 13:

$$MS_e = \frac{SS_e}{DF_e} \quad (12)$$

$$Fi = \frac{MS_{factor}}{MS_e} \quad (13)$$

Langkah 11: menghitung *pure sum of squares* dengan menggunakan persamaan 14:

$$SS_i' = SS_i - (DF_i \times V_e) \quad (14)$$

Langkah 12: menghitung *percent contribution* dengan menggunakan persamaan 15:

$$\rho_i = \frac{SS_i}{SS_T} \times 100\% \quad (15)$$

Langkah 13: membuat tabel analisa variansi hasil perhitungan.

3. Uji F

Pengujian ini dilakukan dengan membandingkan variasi yang disebabkan masing-masing faktor dan variasi eror. Nilai F_{hitung} dibandingkan dengan F tabel pada harga α dengan derajat kebebasan ((k-1)-(N-k)). Dengan k adalah jumlah variabel dan N adalah total perlakuan.

Hipotesa pengujian dalam percobaan adalah:

H_0 : tidak ada pengaruh perlakuan, sehingga $\mu_1 = \mu_2 = \dots = \mu_j = \mu_k$

H_1 : ada perlakuan, sehingga sedikitnya ada satu μ_i yang tidak sama.

Apabila nilai $F_{hitung} < F_{tabel}$ maka H_0 (hipotesa nol) akan diterima yang artinya tidak ada pengaruh perlakuan. Apabila $F_{hitung} > F_{tabel}$ maka H_0 (hipotesa nol) akan ditolak yang artinya ada pengaruh perlakuan.

2.2 Artificial Neural Network (ANN)

Artificial Neural Network (ANN) adalah suatu metode pembelajaran yang diinspirasi dari jaringan sistem pembelajaran biologis yang terjadi dari jaringan sel syaraf (neuron) yang terhubung satu dengan yang lainnya. Menurut Bilgil & Altun (dalam[1]), metode ini memiliki dasar matematis yang kuat, objektif dan algoritma ini mendapatkan bentuk persamaan dan nilai koefisien dalam formula dengan meminimalkan jumlah kuadrat galat *error* melalui model yang dikembangkan pada *training set*. Pembuatan struktur jaringan saraf tiruan diilhami oleh struktur jaringan otak manusia, dengan neuron sebagai satuan unit pemroses terkecil pada otak, bentuk sederhana sebuah neuron yang oleh pada ahli dianggap sebagai satuan unit pemroses.

Algoritma *Backpropagation Neural Network* (BPPN) merupakan metode sistematis untuk *training* (kalibrasi) pada *multilayer* jaringan syaraf atau *perceptron* berlapis banyak (*multilayer perceptrons*). Lapisan (*layer*) pertama terdiri dari satu set *input* dan lapisan akhir merupakan *output* (*target*). Diantara lapisan input dan lapisan output terdapat lapisan ditengah, yang juga dikenal dengan lapisan tersembunyi (*hidden layers*).

Proses pembelajaran suatu *neural network* terdiri dari proses *Forward*, *Backward*, dan *Update* Bobot. 1 kali *training* bila melawati 3 proses tersebut. Proses ini akan dilakukan terus menerus namun, *training* harus dihentikan apabila kesalahan mulai naik. Ini berarti jaringan mulai mengambil sifat yang spesifik yang terjadi pada data *training*, dan bukan generalisasi dari sifat data.

Sebelum dilakukan proses *training*, data dinormalisasi terlebih dahulu. Menurut [2], jika menggunakan fungsi aktivasi *sigmoid biner* (*logsig*), data harus ditransformasikan dulu karena range keluaran fungsi aktivasi *sigmoid* adalah [0,1]. Tapi akan lebih baik jika ditransformasikan ke interval yang lebih kecil, misal pada interval [0.1, 0.9]. Ini mengingat fungsi *sigmoid* merupakan fungsi asimtotik yang nilainya tidak pernah mencapai 0 ataupun 1. Untuk mentransformasikan data dapat menggunakan persamaan 16.

$$X' = \frac{0,8(X-b)}{(a-b)} + 0,1 \quad (16)$$

Setelah dilakukan proses *training* akan diperoleh data *output*, akan tetapi data tersebut masih dalam bentuk data hasil normalisasi. Sehingga dibutuhkan proses denormalisasi untuk mentransformasikan data olahan menjadi nilai yang skalanya sesuai dengan sebenarnya. Proses denormalisasi menggunakan persamaan 17.

$$F_i = \left[\frac{(F'_i) - 0,1}{0,8} \right] \times (\max(X) - \min(X)) + \min(X) \quad (17)$$

3. HASIL DAN PEMBAHASAN

3.1 Pengumpulan Data Sekunder

Data eksperimen yang digunakan merupakan data sekunder dari penelitian Riskita Rakasita (2016) jurusan Teknik Desain dan Manufaktur, Teknik Permesinan Kapal, Politeknik Perkapalan Negeri Surabaya.

Data yang didapat berupa nilai kekasaran permukaan dengan jumlah 9 sampel data dan 9 sampel data laju pemotongan. Data hasil eksperimen yang akan digunakan untuk proses optimasi ditunjukkan pada Tabel 3 dan Tabel 4.

Tabel 3. Nilai Kekasaran Permukaan Hasil Pengukuran Riskita Rakasita

Nomor Eksperimen	Parameter Proses			Kekasaran Permukaan (μm)
	TF (mm)	TGC (bar)	CS (m/menit)	
1	-14	23	0,6	5,0283
2	-14	20	0,4	3,4225
3	-14	17	0,2	2,8983
4	-17	23	0,4	7,5767
5	-17	20	0,2	3,9342
6	-17	17	0,6	4,4183
7	-20	23	0,2	9,5058
8	-20	20	0,6	10,3592
9	-20	17	0,4	4,2583

Keterangan: TF = Titik Fokus; TGC = Tekanan Gas *Cutting*; CS = *Cutting Speed*

Tabel 4. Nilai Laju Pemotongan Hasil Pengukuran Riskita Rakasita

Nomor Eksperimen	Parameter Proses			Laju Pemotongan (mm^3/detik)
	TF (mm)	TGC (bar)	CS (m/menit)	
1	-14	23	0,6	30,5109
2	-14	20	0,4	19,0797
3	-14	17	0,2	14,8248
4	-17	23	0,4	25,0768
5	-17	20	0,2	17,5270
6	-17	17	0,6	39,3372
7	-20	23	0,2	18,4785
8	-20	20	0,6	25,1417
9	-20	17	0,4	29,7569

Keterangan: TF = Titik Fokus; TGC = Tekanan Gas *Cutting*; CS = *Cutting Speed*

3.2 Proses Optimasi Menggunakan Metode Taguchi

Signal to Noise digunakan untuk mengukur karakteristik kualitas deviasi dari nilai yang diinginkan dengan menggunakan karakteristik kualitas *Smaller the Better* pada respon kekasaran permukaan dan *Higher the Better* untuk respon laju pemotongan, maka menggunakan persamaan 1 dan persamaan 3. Hasil perhitungan SNR untuk semua eksperimen dapat dilihat pada Tabel 5.

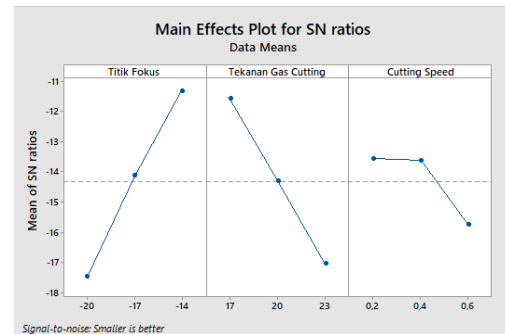
Tabel 5. Nilai SNR

Nomor Eksperimen	Kekasaran Permukaan	Laju Pemotongan
1	-14,03	29,69
2	-10,69	25,61
3	-9,24	23,42
4	-17,59	27,99
5	-11,90	24,87
6	-12,91	31,90
7	-19,56	25,33
8	-20,31	28,01
9	-12,59	29,47

Rasio S/N diformulasikan untuk memilih nilai level faktor terbesar untuk mengoptimalkan karakteristik kualitas. Walaupun karakteristik kualitas kekasaran permukaan adalah semakin kecil semakin baik, tetapi rasio S/N didefinisikan sedemikian hingga selalu dapat ditransformasikan karakteristik kualitas semakin besar, semakin baik. Setelah menentukan nilai rasio S/N, didapatkan nilai level optimum pada parameter permesinan terhadap respon dengan memisahkan masing-masing parameter berdasarkan rasio S/N pada level yang berbeda. Pada Tabel 6 dan Gambar 1 menunjukkan parameter dengan level optimum pada kekasaran permukaan, sedangkan Tabel 7 dan Gambar 2 menunjukkan parameter dengan level optimum pada laju pemotongan.

Tabel 6. Respon Table SN Ratio Kekasaran Permukaan

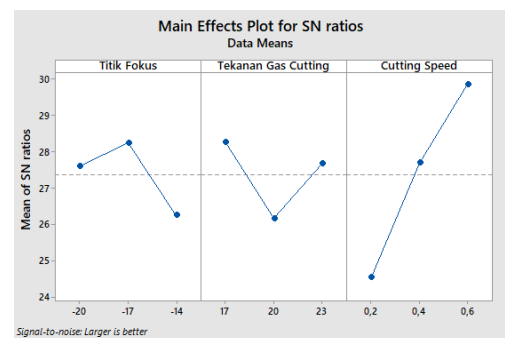
Level	Titik Fokus Sinar Laser	Tekanan Gas Cutting	Cutting Speed
1	-11,32	-17,06	-15,75
2	-14,13	-14,30	-13,62
3	-17,48	-11,58	-13,57
Delta	6,16	5,48	2,18
Rank	1	2	3



Gambar 1. Plot SNR Taguchi dari Nilai Kekasaran Permukaan

Tabel 7 Respon Table SN Ratio Nilai Laju Pemotongan

Level	Titik Fokus Sinar Laser	Tekanan Gas Cutting	Cutting Speed
1	26,2401	27,6693	29,8644
2	28,2519	26,1645	27,6895
3	27,6043	28,2625	24,5424
Delta	2,0118	2,0980	5,3219
Rank	3	2	1



Gambar 2 Plot SNR Taguchi dari Nilai Laju Pemotongan

Pada Gambar 1 hasil plot *mean* menunjukkan bahwa respon nilai kekasaran permukaan yang memberikan nilai tertinggi ditunjukkan pada kombinasi parameter proses $A_1B_3C_3$ dan pada Gambar 2 hasil plot *mean* menunjukkan bahwa respon nilai laju pemotongan yang memberikan nilai tertinggi ditunjukkan pada kombinasi parameter proses $A_2B_3C_1$.

Analisis varians digunakan untuk menginterpretasikan data-data hasil eksperimen, yaitu teknik perhitungan yang memungkinkan secara kuantitatif memperkirakan kontribusi dari setiap faktor pada semua pengukuran respon. Tingkat kepercayaan yaitu 95% . Berikut ini merupakan hasil analisis varians hasil perhitungan menggunakan persamaan 4 sampai persamaan 15 yang ditunjukkan pada Tabel 8 untuk respon kekasaran permukaan dan Tabel 9 untuk respon laju pemotongan.

Tabel 8. Hasil Perhitungan ANOVA Kekasaran Permukaan

Sumber	SS	MS	F Rasio	% Kontribusi	F Tabel
TF	57,14	28,57	4,60	46,11	5,14
TGC	45,07	22,54	3,63	36,37	5,14

CS	9,28	4,64	0,75	7,49	5,14
Error	12,43	6,22		10,03	
SS _{total}	1967,23				

Keterangan: TF = Titik Fokus; TGC = Tekanan Gas *Cutting*; CS = *Cutting Speed*

Tabel 9. Hasil Perhitungan ANOVA Laju Pemotongan

Sum-ber	SS	MS	F Rasio	% Kontribusi	F Tabel
TF	6,33	3,16	1,65	10,52	5,14
TGC	7,02	3,51	1,83	11,67	5,14
CS	42,96	21,48	11,19	71,43	5,14
Error	3,84	1,92		6,38	
SS _{total}	6799,95				

Keterangan: TF = Titik Fokus; TGC = Tekanan Gas *Cutting*; CS = *Cutting Speed*

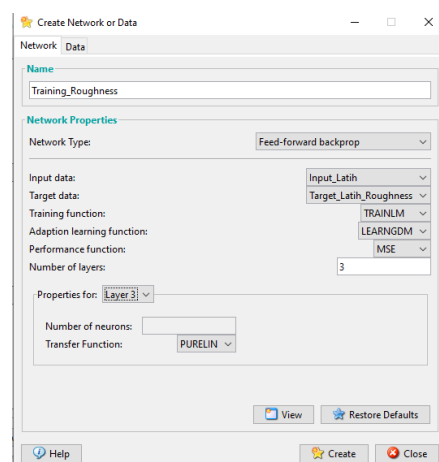
Pada Tabel 8 dan Tabel 9, nilai hasil perhitungan manual ini sudah sesuai dengan hasil analisa DoE metode Taguchi dengan menggunakan *software* Minitab®.

Dari Tabel 8 ANOVA respon kekasaran permukaan, bisa diketahui bahwa persentase kontribusi untuk faktor titik fokus sinar laser memiliki nilai yang paling besar, dengan persentase kontribusi sebanyak 46,1108%, kemudian tekanan gas *cutting* memiliki persentase sebesar 36,3713% dan *cutting speed* memiliki persentase kontribusi paling kecil yaitu sebesar 7,4856%. Sedangkan pada Tabel 9 ANOVA respon laju pemotongan, faktor *cutting speed* memiliki persentase kontribusi paling besar, dengan persentase kontribusi sebanyak 71,4280%, kemudian tekanan gas *cutting* memiliki persentase kontribusi sebesar 11,6696% dan titik fokus sinar laser memiliki persentase paling kecil yaitu sebesar 10,5216%. Hasil persentase kontribusi ini juga sesuai dengan analisa pada Tabel 8 *response mean* bahwa titik fokus sinar laser berada pada peringkat pertama dalam memberikan pengaruh terhadap nilai kekasaran permukaan dan pada Tabel 9 *response mean* bahwa *cutting speed* berada pada peringkat pertama dalam memberikan pengaruh terhadap nilai laju pemotongan. Nilai F rasio pada respon laju pemotongan untuk parameter titik fokus sinar laser dan tekanan gas *cutting* memiliki nilai lebih kecil daripada F tabel ($F_{0,05;2;6}$) = 5,14 dan untuk parameter *cutting speed* memiliki nilai lebih besar daripada F tabel ($F_{0,05;2;6}$) = 5,14. Sedangkan pada respon kekasaran permukaan nilai F rasio masing-masing parameter memiliki nilai lebih kecil daripada F tabel ($F_{0,05;2;6}$) = 5,14. Sehingga dapat ditarik kesimpulan bahwa pada kekasaran permukaan, ketiga parameter tidak mempunyai pengaruh yang signifikan terhadap respon kekasaran permukaan.

3.3 Proses Optimasi Menggunakan Neural Network

3.3.1 Proses Pelatihan atau Training

Tipe jaringan yang digunakan pada proses pelatihan yaitu *feedforward neural network* dengan algoritma *backpropagation*. Arsitektur ini terdiri dari satu lapisan *input* dengan 3 neuron, satu lapisan *hidden layer* dengan 3 neuron dan lapisan *output* dengan satu neuron. Fungsi aktivasi yang digunakan pada lapis tersembunyi yang pertama dan kedua (*hidden layer 1* dan *hidden layer 2*) yaitu *sigmoid biner* (*logsig*) dan pada lapisan *output* yang digunakan adalah fungsi aktivasi linear (*purelin*). Pengaturan arsitektur jaringan *neural network backpropagation* ditunjukkan pada Gambar 3.



Gambar 3. Pengaturan Arsitektur Jaringan

Data yang digunakan dalam proses pelatihan ANN merupakan data hasil eksperimen. Sebelum dilakukan pelatihan, data *input* dan data *target output* harus dinormalisasi terlebih dahulu menggunakan persamaan 18. Data setelah dilakukan proses normalisasi dapat dilihat pada Tabel 10 dan Tabel 11.

Tabel 10. Data Hasil Normalisasi pada Respon Kekasaran Permukaan

Nomor Eksperimen	Parameter Proses			Mean Kekasaran Permukaan
	TF (mm)	TGC (bar)	CS (m/menit)	
1	0,1	0,1	0,1	0,3284
2	0,1	0,5	0,5	0,1562
3	0,1	0,9	0,9	0,1000
4	0,5	0,1	0,5	0,6016
5	0,5	0,5	0,9	0,2111
6	0,5	0,9	0,1	0,2630
7	0,9	0,1	0,9	0,8085
8	0,9	0,5	0,1	0,9000
9	0,9	0,9	0,5	0,2458

Keterangan: TF = Titik Fokus; TGC = Tekanan Gas *Cutting*; CS = *Cutting Speed*

Tabel 11. Data Hasil Normalisasi pada Respon Laju Pemotongan

Nomor Eksperimen	Parameter Proses			Mean Laju Pemotongan
	TF (mm)	TGC (bar)	CS (m/menit)	
1	0,1	0,1	0,1	0,6119
2	0,1	0,5	0,5	0,2389
3	0,1	0,9	0,9	0,1000
4	0,5	0,1	0,5	0,4346
5	0,5	0,5	0,9	0,1882
6	0,5	0,9	0,1	0,9000
7	0,9	0,1	0,9	0,2192
8	0,9	0,5	0,1	0,4367
9	0,9	0,9	0,5	0,5873

Keterangan: TF = Titik Fokus; TGC = Tekanan Gas *Cutting*; CS = *Cutting Speed*

Setelah melakukan normalisasi kemudian perencanaan struktur jaringan, langkah selanjutnya adalah proses pelatihan data yang digunakan untuk membentuk pola. Pola jaringan yang dipilih ketika nilai R diatas atau sama dengan 0,9. Proses *training* dilakukan sebanyak 5 kali untuk respon kekasaran permukaan dan 3 kali untuk repon laju pemotongan.

Hasil dari proses pembelajaran ini berupa data prediksi target dan *error*. Berikut ditampilkan perbandingan nilai rata-rata data *output* hasil *training* dengan hasil eksperimen dan nilai MSE untuk respon kekasaran permukaan dan laju pemotongan, setelah dilakukan proses denormalisasi dengan persamaan 19 terdapat pada Tabel 12 dan Tabel 13.

Tabel 12. Perbandingan Data Hasil *Training* ANN pada Respon Kekasaran Permukaan

Nomor Eksperimen	Mean Kekasaran Permukaan		MSE
	Eksperimen	ANN	
1	5,02	5,02	0,00010346
2	3,42	3,42	0,00000632
3	2,89	2,89	0,00000638
4	7,57	7,49	0,008825
5	3,93	3,93	0,00020596
6	4,41	4,31	0,011477
7	9,50	9,49	0,00072451
8	10,35	10,35	0,00085196
9	4,25	4,36	0,0116
Rata-Rata MSE			0,00375696

Keterangan: TF = Titik Fokus; TGC = Tekanan Gas *Cutting*; CS = *Cutting Speed*

Tabel 13. Perbandingan Data Hasil *Training* ANN pada Respon Laju Pemotongan

Nomor Eksperimen	Mean Kekasaran Permukaan		MSE
	Eksperimen	ANN	
1	30,51	31,00	0,020154
2	19,08	18,93	0,0011693
3	14,83	16,90	0,072279
4	25,08	21,84	0,10219
5	17,53	16,91	0,015674

6	39,34	39,29	0,00012283
7	18,48	18,23	0,0045387
8	25,14	25,49	0,014408
9	29,76	29,63	0,0047434
Rata-Rata MSE			0,026142

Keterangan: TF = Titik Fokus; TGC = Tekanan Gas *Cutting*; CS = *Cutting Speed*

Data pembelajaran yang dilakukan dengan *neural network* ini memiliki nilai koefisien korelasi (R) rata-rata untuk 5 kali pelatihan pada respon kekasaran permukaan sebesar 0,999802. Pada Tabel 12, menunjukkan nilai *Mean Square of Error* selama 5 kali pelatihan 0,00375696 untuk respon kekasaran permukaan.

3.3.2 Proses Pengujian atau Testing

Setelah melakukan proses *training* atau pembelajaran. Selanjutnya dilakukan proses pengujian data atau untuk mencari nilai yang optimum. Langkahnya dengan membuat kombinasi parameter sebelum dinormalisasi dan setelah dinormalisasi. Kombinasi parameter sebelum dilakukan proses normalisasi dapat dilihat pada Tabel 14. Sedangkan kombinasi parameter setelah dilakukan proses normalisasi dapat dilihat pada Tabel 15. Data ini yang selanjutnya akan diprediksi nilai kekasaran permukaan dengan menggunakan pola arsitek yang telah dibentuk sebelumnya dalam proses pembelajaran.

Tabel 14. Kombinasi Parameter Sebelum Proses Normalisasi

Nomor Eksperimen	Denormalisasi		
	TF (mm)	TGC (bar)	CS (m/menit)
10	-14	23	0,4
11	-14	23	0,2
12	-14	20	0,6
13	-14	20	0,2
14	-14	17	0,6
15	-14	17	0,4
16	-17	23	0,6
17	-17	23	0,2
18	-17	20	0,6
19	-17	20	0,4
20	-17	17	0,4
21	-17	17	0,2
22	-20	23	0,6
23	-20	23	0,4
24	-20	20	0,4
25	-20	20	0,2
26	-20	17	0,6
27	-20	17	0,2

Keterangan: TF = Titik Fokus; TGC = Tekanan Gas *Cutting*; CS = *Cutting Speed*

Tabel 15. Kombinasi Parameter Setelah Proses Normalisasi

Nomor Eksperimen	Normalisasi		
	TF (mm)	TGC (bar)	CS (m/menit)
10	0,1	0,1	0,5
11	0,1	0,1	0,9
12	0,1	0,5	0,1
13	0,1	0,5	0,9
14	0,1	0,9	0,1
15	0,1	0,9	0,5
16	0,5	0,1	0,1
17	0,5	0,1	0,9

18	0,5	0,5	0,1
19	0,5	0,5	0,5
20	0,5	0,9	0,5
21	0,5	0,9	0,9
22	0,9	0,1	0,1
23	0,9	0,1	0,5
24	0,9	0,5	0,5
25	0,9	0,5	0,9
26	0,9	0,9	0,1
27	0,9	0,9	0,9

Keterangan: TF = Titik Fokus; TGC = Tekanan Gas Cutting; CS = Cutting Speed

Data ini yang selanjutnya akan diprediksi nilai kekasaran permukaan dengan menggunakan pola arsitek yang telah dibentuk sebelumnya dalam proses pembelajaran. Data *output* pengujian untuk respon kekasaran permukaan ditunjukkan pada Tabel 16 dan untuk respon laju pemotongan ditunjukkan pada Tabel 17.

Tabel 16. Data *Output* Hasil *Training* untuk Respon Kekasaran Permukaan

Nomor Eksperimen	TF (mm)	TGC (bar)	CS (m/menit)	Nilai Kekasaran Permukaan
10	-14	23	0,4	3,90
11	-14	23	0,2	3,13
12	-14	20	0,6	4,14
13	-14	20	0,2	2,99
14	-14	17	0,6	4,02
15	-14	17	0,4	3,25
16	-17	23	0,6	10,55
17	-17	23	0,2	4,21
18	-17	20	0,6	5,27
19	-17	20	0,4	4,26
20	-17	17	0,4	4,22
21	-17	17	0,2	3,71
22	-20	23	0,6	10,87
23	-20	23	0,4	10,75
24	-20	20	0,4	6,66
25	-20	20	0,2	4,44
26	-20	17	0,6	4,66
27	-20	17	0,2	4,49

Keterangan: TF = Titik Fokus; TGC = Tekanan Gas Cutting; CS = Cutting Speed

Tabel 17. Data *Output* Hasil *Training* untuk Respon Laju Pemotongan

Nomor Eksperimen	TF (mm)	TGC (bar)	CS (m/menit)	Nilai Laju Pemotongan
10	-14	23	0,4	21,58
11	-14	23	0,2	16,65
12	-14	20	0,6	33,48
13	-14	20	0,2	16,61
14	-14	17	0,6	35,79
15	-14	17	0,4	17,04
16	-17	23	0,6	22,92
17	-17	23	0,2	16,89
18	-17	20	0,6	25,67
19	-17	20	0,4	19,80
20	-17	17	0,4	18,41
21	-17	17	0,2	16,63
22	-20	23	0,6	22,14
23	-20	23	0,4	21,91
24	-20	20	0,4	22,35
25	-20	20	0,2	16,70
26	-20	17	0,6	37,69
27	-20	17	0,2	16,75

Keterangan: TF = Titik Fokus; TGC = Tekanan Gas Cutting; CS = Cutting Speed

Setelah didapatkan nilai *output* dari proses pengujian, data dalam Tabel 16 dan Tabel 17 terlebih dahulu dilakukan proses denormalisasi. Bisa diketahui bahwa dari prediksi *neural network* nilai kekasaran permukaan yang optimum terjadi pada kombinasi parameter proses titik fokus sinar laser -14 mm, tekanan gas *cutting* 20 bar dan *cutting speed* 0,2m/menit. Sedangkan prediksi *neural network* untuk nilai laju pemotongan yang optimum terjadi pada kombinasi parameter proses titik fokus sinar laser -20 mm, tekanan gas *cutting* 17 bar dan *cutting speed* 0,6m/menit.

4. KESIMPULAN

Kesimpulan yang dapat diambil dari penelitian ini adalah sebagai berikut:

1. Pengaturan parameter yang tepat menggunakan metode taguchi untuk respon kekasaran permukaan adalah pada titik fokus sinar laser -14 mm, tekanan gas *cutting* 17 bar dan *cutting speed* 0,4 m/menit.
2. Untuk respon laju pemotongan menggunakan metode taguchi, terletak di titik fokus sinar laser -17 mm, tekanan gas *cutting* 20 bar dan *cutting speed* 0,6 m/menit.
3. Pengaturan parameter yang tepat menggunakan *neural network* untuk respon kekasaran permukaan terletak pada titik fokus sinar -14 mm, tekanan gas *cutting* 20 bar dan *cutting speed* 0,2m/ detik.
4. Sedangkan pengaturan parameter yang tepat menggunakan *neural network* untuk respon laju pemotongan terletak pada titik fokus sinar laser -20 mm, tekanan gas *cutting* 17 bar dan *cutting speed* 0,6m/menit.
5. Dalam pengaturan parameter menggunakan metode taguchi untuk memperoleh respon kekasaran permukaan yang minimum, parameter titik fokus sinar laser memiliki kontribusi paling besar yakni 46,5061%.
6. Dalam pengaturan parameter menggunakan metode taguchi untuk memperoleh respon laju pemotongan yang maksimum, parameter *cutting speed* memiliki kontribusi yang terbesar yakni 66,0430%.

5. UCAPAN TERIMA KASIH

Penulis menyampaikan rasa terima kasih kepada :

1. Orang tua penulis (Bapak Samsul Wafan dan Ibu Sumilah), adik penulis (Nurul Nabila Fadiyah), dan seluruh keluarga yang senantiasa memberikan doa, dukungan, perhatian, nasihat, saran, serta mencukupi segala kebutuhan penulis.
2. Bapak Bayu Wiro Karuniawan, S.T., M.T. selaku Dosen Pembimbing 1 yang telah berkenan memberikan petunjuk, pengarahan, dan bimbingan yang penuh kesabaran,

- kesungguhan, dan dorongan dalam menyelesaikan Tugas Akhir ini.
3. Bapak Farizi Rachamn, S.Si., M.Si. selaku Dosen Pembimbing II yang telah berkenan memberikan petunjuk, pengarahannya, dan bimbingan yang penuh kesabaran, kesungguhan, dan dorongan dalam menyelesaikan Tugas Akhir ini sekaligus selaku Koordinator Tugas Akhir Program Studi Teknik Desain dan Manufaktur.
 4. Seluruh teman seperjuangan Teknik Desain dan Manufaktur angkatan 2016 yang senantiasa membantu dan memberikan semangat kepada penulis untuk menyelesaikan Tugas Akhir ini.
 5. Mas Arif Rachman Hakim, selaku editor video *youtube* penulis dan juga yang telah memberikan semangat kepada penulis dan mengingatkan penulis untuk segera menyelesaikan Tugas Akhir ini.
 6. Emilia Regina Widiananda, selaku sahabat penulis yang selalu membantu penulis dalam menyelesaikan Tugas Akhir ini.
 7. Diajeng R. Amelia dan Ridhani Anita F., selaku teman sekelas penulis, teman diskusi penulis saat mengerjakan Tugas Akhir dan teman curhat penulis saat kesulitan mengerjakan Tugas Akhir.
 8. Seluruh pihak yang telah memberikan bantuan baik secara langsung maupun tidak langsung pada penulis dalam mengerjakan Tugas Akhir.

6. PUSTAKA

- [1] M. K. Damayanti, “Desain Parameter Eksperimen Untuk Optimasi Nilai Frangibility Factor Material Komposit Dengan Metode Taguchi dan Neural Network” Institut Teknologi Sepuluh Nopember, 2017.
- [2] M. Febrina, F. Arina, and R. Ekawati, “Peramalan Jumlah Permintaan Produksi Menggunakan Metode Jaringan Syaraf Tiruan (JST) Backpropagation,” *Jurnal Teknik Industri*, vol. 1, no. 2, pp. 174–179, 2013.
- [3] Kowalczyk Małgorzata, “Application of Taguchi and Anova Methods in Selection of Process Parameters for Surface Roughness in Precision Turning of Titanium,” *Advances Manufacturing Science Technolgy*, vol. 38, no. 2, pp. 22–35, 2014.
- [4] D. C. Montgomery, *Design and Analysis of Experiments*, Eight, vol. 2. New York: Wiley & Sons, Inc., 2012.
- [5] F. Pilarian dan E. P. Purwanti, “Optimasi Parameter Proses Pemotongan Stainless Steel SUS 304 untuk Kekasaran Permukaan dengan Metode Response Surface,” pada *Seminar Nasional Matematika dan Pendidikan Matematika FMIPA UNY Yogyakarta*, 2013, vol. 4, no. 11, pp. 1–16.
- [6] R. Rakasita, “Optimasi Parameter Mesin *Laser cutting* Terhadap Kekasaran dan Optimasi Parameter Mesin *Laser cutting* Terhadap Kekasaran dan Laju Pemotongan pada SUS 316L Menggunakan Metode Taguchi Grey Relational Analysis,” *Jurnal Teknik Industri*, vol. 11, no. 2, pp. 97–106, 2016.
- [7] J. J. Siang, *Pemrograman Menggunakan Matlab*. Yogyakarta: Andi, 2005.
- [8] J. N. Sukanto and G. Dewantoro, “Implementasi Kendali PID Menggunakan Jaringan Syaraf Tiruan Backpropagation,” *ELKHA*, vol. 11, no. 1, pp. 12–18, 2019.
- [9] F. Yushi, I. R. A, and P. Sidi, “Optimasi Parameter Mesin *Laser cutting* terhadap Kekasaran dan Laju Pemotongan pada Alumunium 5083 Menggunakan Desain Eksperimen Taguchi Grey Analysis Method,” *Proceedings Conference on Design and Manufacture Engineering and Its Application*, vol. 1, no. 1, pp. 330–335, 2018.