MODEL *ANFIS* DAN *MLR* UNTUK MEMPREDIKSI KEAUSAN MATA BOR PADA MESIN *CNC DRILLING* DENGAN INPUT *CUTTING SPEED* DAN *FEEDING RATE*

Muhammad Fatih A A, Nur Iksan
Teknik Elektro, Fakultas Teknik, Universitas Negeri Semarang
fatih.azhari@mail.unnes.ac.id
DOI: https://doi.org/10.15294/bte.v1i1.372
QRCBN 62-6861-4195-455

ABSTRAK
Proses permesinan pada industri sangat bergantung pada kinerja alat untuk menghasilkan produk dengan ukuran presisi. Selama proses berlangsung, alat dapat mengalami keausan akibat gesekan. Keausan seringkali sulit untuk dimonitor secara langsung karena terjadi secara bertahap. Pendekatan dengan prediksi keausan dikembangkan untuk *monitoring* dengan parameter *cutting speed* dan *feeding rate*. Penelitian dilakukan pada proses *drilling* untuk mendapatkan model dengan tingkat akurasi yang tinggi. Tingkat keausan diprediksi menggunakan model *Adaptive Neuro Fuzzy Inference System* (ANFIS) dan dibandingkan dengan *Multiple Linear Regresion* (MLR) menggunakan simulasi MATLAB. Parameter *Cutting Speed* dan *Feeding Rate* sebagai input, dan output berupa *Flank wear*. Data set input output dari referensi data-set digunakan untuk *training* dan *testing*. Simulasi ANFIS fuzzy sugeno menggunakan aturan *if-then* untuk memodelkan hubungan output-input dan *neuro-network* untuk merepresentasikan prediksi nilai output. Simulasi MLR menggunakan teknik regresi linear untuk memprediksi nilai output. Tingkat keakurasian dihitung menggunakan RMSE. Hasil dari simulasi prediksi *flank wear* menunjukan model ANFIS lebih akurat namun kurang stabil dibanding MLR. Model MLR masih relevan digunakan pada data dengan

parameter terbatas dan parameter input yang saling mempengaruhi. Prediksi keausan berbasis dua input menunjukan keakuratan model mampu memprediksi nilai keausan dengan input sederhana.

Kata Kunci: ANFIS, Cutting Speed, Feeding Rate, Flank Wear, MATLAB, MLR, RMSE

PENDAHULUAN

Peralatan elektronik sudah banyak digunakan manusia untuk menyelesaikan berbagai pekerjaan sehari-hari. Perkembangan teknologi yang sangat cepat menggantikan system kendali peralatan yang dilakukan secara manual oleh pengguna menjadi system kendali otomatis dengan komputer terutama pada bidang industri dan manufaktur, salah satu contohnya adalah penggunaan mesin CNC untuk peralatan manufaktur yang dapat bekerja secara otomatis. Pengendalian alat dengan computer dapat memberikan hasil dengan tingkat presisi yang tinggi. Dengan ditemukanya system kendali alat secara otomatis seperti mesin CNC dapat memberikan dampak dalam bidang manufaktur baik dari segi kualitas produksi maupun dari segi ekonomi/biaya.

Mesin CNC bekerja dengan mengendalikan alat menggunakan perangkat computer yang telah diprogram. Pada industry manufaktur, mesin CNC digunakan untuk membuat suatu bentuk tertentu dengan ukuran yang presisi. Mesin dijalankan dengan suatu prosedur untuk *drilling* (pengeboran), *spreading* (penyebaran), *weaning,* dan *threading* (penguliran). Mesin CNC memiliki berbagai jenis bergantung dengan proses yang dilakukan, salah satunya adalah pengeboran atau *drilling*. Proses permesinan *drilling* memiliki peran penting pada proses manufaktur saat ini untuk membuat banyak lubang dengan ukuran presisi.

Pada proses permesinan, mata bor bergesekan dengan material untuk membuat lubang, gesekan yang terjadi terus menerus dapat menyebabkan kenaikan suhu. Gesekan akan mengubah sifat material dari mata bor dan jika terus menerus akan terjadi keausan pada mata bor. Mata bor yang aus akan berakibat pada hasil bentuk yang tidak presisi. Keausan pada

mata bor perlu untuk dimonitor sehingga dapat dilakukan tindakan ketika nilai keausan mencapai tingkat tertentu. Nilai keausan akan terus berubah seiring dengan proses permesinan yang dilakukan. Keausan ini seringkali sulit untuk dimonitor secara langsung karena terjadi secara bertahap dan juga sulit untuk diamati secara langsung. Sebuah model dapat digunakan untuk memprediksi nilai keausan menggunakan parameter dari proses permesinan.

Pendekatan dengan model prediksi dapat dilakukan dengan menggunakan parameter permesinan yang dapat diukur menggunakan sensor untuk memprediksi keausan berdasarkan pengaruh parameter terhadap keausan. Parameter *cutting speed* yang dapat diukur berdasarkan kecepatan putaran *spindle* menggunakan sensor rotary dan parameter *feeding rate* dapat dihitung berdasarkan gaya tekan *feed* (*Feed Force*) yamg dapat diukur menggunakan *load cell*. Dari data pengukuran oleh sensor dapat di hitung parameter *cutting speed* dan *feeding rate* sebagai input model dalam memprediksi *flank wear*.

Beberapa penelitian telah dilakukan untuk memprediksi *flank wear* dengan berbagai metode yang berbeda dan dengan berbagai kombinasi input (getaran, suhu, Gaya, feed, cutting speed). Artificial neural network dan variasinya digunakan untuk memprediksi flank wear. Dari penelitian terdahulu dapat disimpulkan bahwa pengalikasian ANFIS dan ANN menghasilkan performa untuk mrmodelkan hubungan kompleks dan non-linier antara prediksi parameter permesinan dengan tingkat keausan pahat. Beberapa penelitian belum banyak menggunakan model MLR untuk memprediksi *flank wear,* sebagian besar model prediksi menggunakan ANFIS.

Permasalahan utama yang dihadapi sehingga penelitian ini dilakukan adalah tingkat keausan yang sulit untuk dimonitor secara langsung, sehinnga perlu suatu desain model system untuk membuat prediksi keausan dari mata bor berdasarkan pada parameter yang umum digunakan pada mesin pengeboran.

Penelitian ini menjadi penting dilakukan untuk memberikan prediksi sebagai upaya untuk mengetahui lebih awal tingkat keausan yang terjadi untuk mendapatkan kualitas

hasil yang sesuai dan konsisten, serta untuk memaksimalkan kerja alat dengan pengaturan parameter yang sesuai.

Tujuan dari penelitian yang dilakukan adalah dengan mengembangkan model yang dapat digunakan untuk memprediksi keausan pada matabor dalam proses permesinan CNC jenis *drilling* atau pengeboran. Penelitian juga bertujuan untuk membandingkan dua model ANFIS dan MLR dengan menghitung nilai akurasinya menggunakan RMSE.

KAJIAN PUSTAKA

Mesin CNC drilling

Proses permesinan seperti pembubutan (*Turning*), pengeboran (*Drilling*), dan penggerindaan (*Grinding*) adalah metode untuk menghilangkan material yang telah digunakan secara luas dalam industri manufaktur sejak revolusi industri. Dalam waktu terakhir, otomatisasi penuh pada mesin-mesin perkakas menjadi sangat penting di industri manufaktur. Hal ini terjadi karena teknologi permesinan telah berkembang pesat, dari mesin yang dioperasikan secara manual menjadi pusat mesin CNC yang canggih dan modern. Dari beberapa jenis operasi permesinan, pengeboran (*drilling*) adalah salah satu operasi yang umum di industry manufaktur jika mempertimbangkan pengulangan pada prosesnya. Pengeboran lubang adalah salah satu bagian penting dalam proses manufaktur dan sering menjadi bagian dari rencana produksi. Karena lubang dibuat pada tahap akhir, kualitas yang buruk dapat menyebabkan produk ditolak dan menimbulkan kerugian besar. Selain itu, jika alat bor rusak atau aus, benda kerja sering harus diproses ulang atau bahkan dibuang, yang juga menambah biaya produksi.

Sebagai salah satu upaya agar hasil pengeboran lubang teteap berkualitas baik, perlu dilakukan control dan monitor dari alat bor. Prediksi tingkat keausan menjadi salah satu metode untuk menjaga agar alat bor tetap berfungsi dan menghasilkan kualitas hasil pengeboran yang diinginkan. Pada penelitian parameter *cutting speed*, *feeding* rate dan *flank wear* digunakan untuk menghitung nilai prediksi. *Flank wear* atau keausan tepi terjadi pada bagian pahat yang berkontak langsung dengan benda kerja. Flank merupakan sisi samping muka pahat potong dimana terletak pada tepi sisi potong

utama.

Model ANFIS

Adaptive Neuro-Fuzzy Inference System (ANFIS) atau system inferensi fuzzy yang diterapkan dalam kerangka jaringan adaptif merupakan metode yang menggunakan pembelajaran gabungan untuk membangun hubungan antara input dan output. Hubungan input dan output dibangun berdasarkan data yang tersedia, dan aturan fuzzy yang berasal dari pengetahuan manusia. Dalam system kerjanya, ANFIS digunakan untuk memodelkan fungsi non-linier dan memprediksi pola yang kompleks seperti deret waktu *chaos*.

Pada penelitian ini, ANFIS digunakan untuk memprediksi *Flank Wear* dengan menggunakan input *cutting speed* dan *feeding rate*, dengan output *flank wear*. Simulasi dilakukan dengan menggunakan *software* MATLAB untuk membuat model dan prediksi dari *flank wear*.

Arsitektur ANFIS

ANFIS (*Adaptive Neuro-Fuzzy Inference System*) menggabungkan logika fuzzy dan jaringan syaraf tiruan / neuro network untuk membangun sisten inferensi adaptif. Model sesuai untuk digunakan pada system non-linear dengan data yang terbatas karena dapat mengekstrak informasi aturan fuzzy secara otomatis dan mengoptimalkan parameter melalui training data.

Pada proses fuzzifikasi, variable angka/numerik diubah menjadi *variable linguistic*. *Variable linguistic* menggunakan kata dalam Bahasa umum (besar, kecil, tinggi, rendah) untuk menjelaskan suatu nilai dan direpresentasikan dalam himpunan fuzzy, dalam satu himpunan hanya termuat anggota yang berasal dari satu parameter yang dibagi menjadi beberapa anggota berdasarkan *range* tertentu.

Model ANFIS menggunakan lima lapisan jaringan untuk melaksanakan interferensi fuzzy, lima lapisan jaringan tersebut adalah 1) fuzzifikasi data input, 2) konstruksi fuzzy database, 3)konstruksi fuzzy *rule base* (peraturan), 4) pengabilan keputusan (*decision making*), 5)defuzzyfikasi output.

Tiap lapisan jaringan pada ANFIS terdiri dari beberapa node yang dijelaksan oleh fungsi node. Input pada tiap lapisan didapatkan dari node pada lapisan sebelumnya. Rule base atau

peraturan ANFIS terdapat peraturan fuzzy *if-then* tipe sugeno. Sistem interferensi fuzzy orde pertama dapat dimisalkan memiliki 2 input, x dan y, dan satu output, dua aturan dengan fuzzy if-the dapat dinyatakan dengan:

$$\boldsymbol{Aturan\ 1 : if(x\ adalah\ A_1) dan\ (y\ adalah\ B_1) then(f_1 = p_1x + q_1y + r_1)}$$

$$\boldsymbol{Aturan\ 2 : if(x\ adalah\ A_2) dan\ (y\ adalah\ B_2) then(f_2 = p_2x + q_2y + r_2)}$$

Dimana x dan y adalah input A1 dan B1 adalah himpunan fuzzy, *f* adalah output dalam daerah fuzzy yang dipengaruhi oleh aturan fuzzy p, q, dan r adalah parameter yang ditentukan saat proses *training*.

Pada lapisan pertama, semua node adalah adaptif node. Output pada lapisan pertama adalah tingkat keanggotaan fuzzy dari input:

$$\boldsymbol{O_i^1 = \mu_{A_i}(x), \quad i = 3,4}$$

$$\boldsymbol{O_i^1 = \mu_{B_{i-2}}(y), \quad i = 3,4}$$

Dimana x adalah input node *i*, dan A1 adalah label yang terasosiasi dengan fungsi node. Pada umumnya, $\boldsymbol{\mu_{A_i}(x)}$ dan $\boldsymbol{\mu_{B_{i-2}}(y)}$ dipilih untuk menjadi berbentuk bel/lonceng dengan maksimum nilai 1 dan mimimum sama dengan 0.

Jika menggunakan segitiga maka:

$$\boldsymbol{\mu_{A_i}(x) = \frac{1}{1 + [(x - c_1/a_1)]^{b_1}}}$$

Jika yang digunakan adalah Gaussian maka:

$$\boldsymbol{\mu_{A_i}(x) = exp\left[-\left(\frac{x - c_1}{a_1}\right)^2\right]}$$

Dimana *ai, bi, ci* merupakan parameter fungsi keanggotaan yang mengatur fungsi sesuai denagn bentuknya.

Pada lapisan ke dua, semua node adalah node tetap, dan diberi tanda Π yang mengindikasikan bahwa node melaksanakan perkalian sederhana. Output pada lapisan ini dapat ditunjukan sebagai berikut:

$$\boldsymbol{O_i^2 = \mu_{A_i}(x)\mu_{B_i}(y), \quad i = 1,2}$$

Pada lapisan ke tiga semua node juga node tetap, dan dineri tanda N, yang mengindikasikan bahwa node berperan dalam menormalisasikan *firing strength* lapisan sebelumnya. Output pada lapisan ini dapat ditunjukan sebagai:

$$O_i^3 = w_1 = \frac{w_1}{w_1+w_2}, \qquad i = 1, 2$$

Pada lapisan ke empat node menjadi adaptif, output tiap node adalah hasil sederhana dari normalisasai *firing strength* dan *polynomial* orde pertama (model sugeno orde pertama). Output pada lapisan ini dapat ditunjukan sebagai:

$$O_i^4 = w_1 f_1 = w_1(p_1 x + q_1 y + r_1), \qquad i = 1, 2$$

Pada lapisan ke lima, hanya ada node tunggal yang tetap dengan label Σ. Pada node ini semua sinyal yang masuk dijumlahkan. Model output ditunjukan sebagai berikut:

$$O_i^5 = \sum_{i=1}^{2} w_1 f_1 = \frac{\sum_{i=1}^{2} w_1 f_1}{w_1 + w_2}), \qquad i = 1, 2$$

Dari kelima lapisan ANFIS terdapat dua lapisan adaptif, yaitu lapisan pertama dan keempat. Pada lapisan pertama terdapat tiga parameter yang dapat diubah (*ai, bi, ci*) yang berhubungan dengan input fungsi keanggotaan. Pada lapisan keempat juga terdapat tiga parameter yang dapat diubah (*pi, qi, ri*) yang menyinggung orde pertama *polynomial*. Parameter tersebut adalah parameter akibat (*consequent*).

Model MLR (Multiple Linear Regresion)

Regresi merupakan konsep sederhana untuk meneliti hubungan fungsi antara output dan input berdasarkan variable untuk pemilihan keputusan dari suatu proses dan memungkinkan untuk memproses deskripsi data manufaktur, estimasi dan control. (Montgomery, 2001). Kriteria untuk menepatkan garis data pada regresi linear sederhana adalah dengan meminimalisasikan jumlah sisa kuadrat antara nilai yang dihitung dari respond dan nilai respon yang dihitung dengan model regresi. Respon linear dapat ditunjukan dengan:

$$Y = a_0 + a_1 X$$

Dimana Y adalah nilai respond an X adalah nilai variable. *Multiple Linear Regresion* yang digunakan jika respon adalah fungsi linear dari dua atau lebih variable independen. Pada umumnya, respon variable y dapat dihubungkan dengan variable regresi k. Model *Multiple Linear Regresion* dengan variable regresi k dapat dutunjukan dengan:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_\varepsilon x_\varepsilon + \varepsilon$$

Parameter β_1 (j= 0, 1, 2, … , k) disebut koefisien regresi.

METODE

Penelitian dengan Simulasi MATLAB

Penelitian dilakukan dengan model ANFIS menggunakan perangkat lunak MATLAB dengan input *cutting speed* dan *feeding rate* dengan output *Flank Wear*. Data parameter input dilakukan fuzzifikasi dengan 3 *membership function* sehingga mendapatkan 9 rules, dan menggunakan 100 epoch untuk melakukan traning data. Data hasil dapat dilakukan sebagai dasar untuk presiksi tingkat keausan.

Data hasil dilakukan perbandingan antara simulasi menggunakan ANFIS dan MLR. Perbandingan dilakukan untuk memperoleh model yang lebih akurat dengan membandingkan nilai error terkecil.

Simulasi ANFIS

ANFIS (*Adaptive Neuro-Fuzzy Inference System*) menggabungkan logika fuzzy dan jaringan syaraf tiruan / *neuro network* untuk membangun sisten inferensi adaptif. Dengan menggunakan referensi dataset menggunakan data *cutting speed*, *feeding rate*, dan *flank wear*, dilakukan pembagian data untuk training 70 % dan testing 30%.

Pada model ANFIS yang digunakan, data input berupa nilai *cutting speed* dan *feeding rate* yang diubah menjadi *variable linguistic* dengan beberapa aturan. Aturan fuzzy direpresentasikan dalam format IF-THEN dengan kombinasi input anggota himpunan.

Pada simulasi parameter setting yang digunakan sebagai berikut: Inference System: Type Sugeno, Training Least Square dan BackPropagation (Hybrid), Epoch: 100, Output Flank Wear, Validasi: RMSE.

Model aturan untuk ANFIS adalah sebagai berikut:

$$\boldsymbol{Aturan\ 1 : if(x\ adalah\ A_1) dan\ (y\ adalah\ B_1) then(f_1 = p_1 x + q_1 y + r_1)}$$

Dengan x adalah cutting speed, y adalah feeding rate, dan f adalah flank wear, A dan B adalah data input dalam himpunan fuzzy, p,q,r adalah parameter yang didapatkan setelah proses training.

Data referensi dapat disajikan dalam range sebagai berikut:

Cutting speed (low, med, high) Dapat disimbolkan dengan Vc,

Feeding rate (low, med, high) Dapat disimbolkan dengan Vf,

Flank wear (low, med, high) Dapat disimbolkan dengan VB,

Membership function akan menghasilkan aturan berdasarkan input cutting speed (Vc) yang memiliki tiga jangkauan nilai.

	Vc1	Vc2	Vc3
Vf1	VB1	VB4	VB7
Vf2	VB2	VB5	VB8
Vf3	VB3	VB6	VB9

Tabel 1. Aturan yang dari dua parameter dengan 3 range

Dari table aturan tersebut dapat dibuat aturan sebagai berikut:

$$\textbf{Aturan 1} : \textbf{if}(V_c \textbf{ adalah } A_1)\textbf{dan}\ (V_f \textbf{ adalah } B_1)\textbf{then}(V_B = p_1V_c + q_1V_f + r_1)$$
$$\textbf{Aturan 2} : \textbf{if}(V_c \textbf{ adalah } A_1)\textbf{dan}\ (V_f \textbf{ adalah } B_2)\textbf{then}(V_B = p_2V_c + q_2V_f + r_2)$$
$$\textbf{Aturan 3} : \textbf{if}(V_c \textbf{ adalah } A_1)\textbf{dan}\ (V_f \textbf{ adalah } B_3)\textbf{then}(V_B = p_3V_c + q_3V_f + r_3)$$
$$\textbf{Aturan 4} : \textbf{if}(V_c \textbf{ adalah } A_2)\textbf{dan}\ (V_f \textbf{ adalah } B_1)\textbf{then}(V_B = p_4V_c + q_4V_f + r_4)$$
$$\textbf{Aturan 5} : \textbf{if}(V_c \textbf{ adalah } A_2)\textbf{dan}\ (V_f \textbf{ adalah } B_2)\textbf{then}(V_B = p_5V_c + q_5V_f + r_5)$$
$$\textbf{Aturan 6} : \textbf{if}(V_c \textbf{ adalah } A_2)\textbf{dan}\ (V_f \textbf{ adalah } B_3)\textbf{then}(V_B = p_6V_c + q_6V_f + r_6)$$
$$\textbf{Aturan 7} : \textbf{if}(V_c \textbf{ adalah } A_3)\textbf{dan}\ (V_f \textbf{ adalah } B_1)\textbf{then}(V_B = p_7V_c + q_7V_f + r_7)$$
$$\textbf{Aturan 8} : \textbf{if}(V_c \textbf{ adalah } A_3)\textbf{dan}\ (V_f \textbf{ adalah } B_2)\textbf{then}(V_B = p_8V_c + q_8V_f + r_8)$$
$$\textbf{Aturan 9} : \textbf{if}(V_c \textbf{ adalah } A_3)\textbf{dan}\ (V_f \textbf{ adalah } B_3)\textbf{then}(V_B = p_9V_c + q_9V_f + r_9)$$

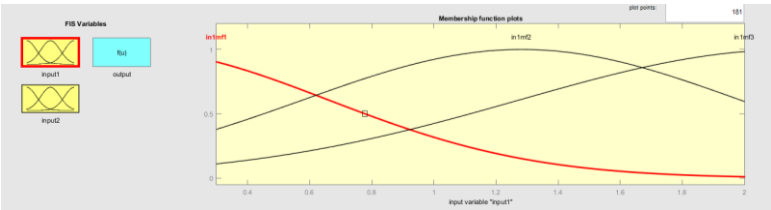

Gambar 1. Input 1 :feeding rate

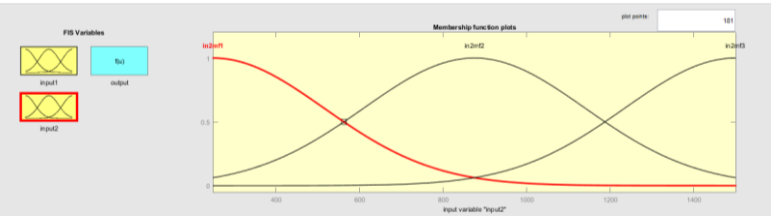

Gambar 2. Input 2 : cutting speed

Dengan 2 input, fungsi keanggotaan dapat dibuat grafik seperti gambar dengan input 1 feeding rate dan inout 2 cutting speed.

Langkah Simulasi menggunakan MATLAB

ANFIS menggunakan konsep neuro network dan fuzzy untuk menentukan hubungan antara output dan input berdasarkan input secara non-linear. Pada simulasi digunakan parameter sebagai berikut: Input: cutting speed dan feeding rate, Output: Flank Wear, Training: Least Square, Epoch: 100, Validasi: RMSE.

Langkah kerja

a) Analysis masalah

Masalah utama yang dibahas dalam penelitian ini adalah tentang flankwear yang dimonitor untuk dikontrol menggunakan model ANFIS, dalam hal ini input menggunakan nilai cutting speed dan feeding rate, output berupa nilai flank wear.

b) Desain model

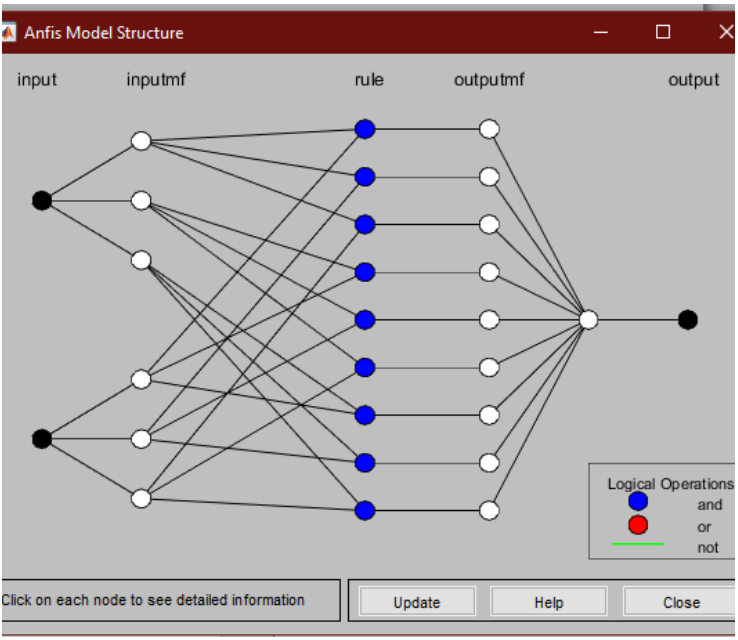

Gambar 3. Struktur ANFIS dengan 5 lapisan

Pada model ANFIS yang digunakan, input berupa *cutting speed* dan *feeding rate* dengan input keanggotaan yang berjumlah tiga untuk tiga *range* nilai. Dari dua input yang masing masing memiliki tiga fungsi keanggotaan menghasilkan tiga aturan. Dari aturan tersebut dapat dihasilkan output nilai *flank wear* yang berdasarkan *range* nilai dari kedua input.

c) Pengumpulan data

Data diperoleh melalui referensi data set dengan jumlah data sebanyak total 6000 data yang masing-masing *Cutting Speed*, Data *Feeding Rate*, dan data *Flank Wear* memiliki 2000 nilai.. Matriks data training berisi tiga kolom data sebanyak 70 % data (4200 data) yang dibagi menjadi 3 kolom. Dan 30 % (1800) data sisanya digunakan untuk testing/pengujian.

d) Simulasi MATLAB untuk ANFIS

a. Menyiapkan dan Memasukan data

	1	2	3	4	5
1	0.7000	250	0.3935		
2	0.7000	500	0.4673		
3	0.7000	750	0.5410		
4	0.7000	1000	0.6148		
5	0.7000	1250	0.6885		
6	0.8000	500	0.5355		
7	0.8000	750	0.6093		
8	0.8000	1000	0.6830		
9	0.8000	1250	0.7568		
10	0.8000	250	0.8305		
11	0.9000	750	0.6775		
12	0.9000	1000	0.7513		
13	0.9000	1250	0.8250		
14	0.9000	250	0.8088		

Gambar 4. Data yang akan dilakukan training dan testing

Data dalam bentuk table dalam file *excel* dimasukkan pada *workspace* matlab dengan label 'dataTrain' dan 'dataTest'.

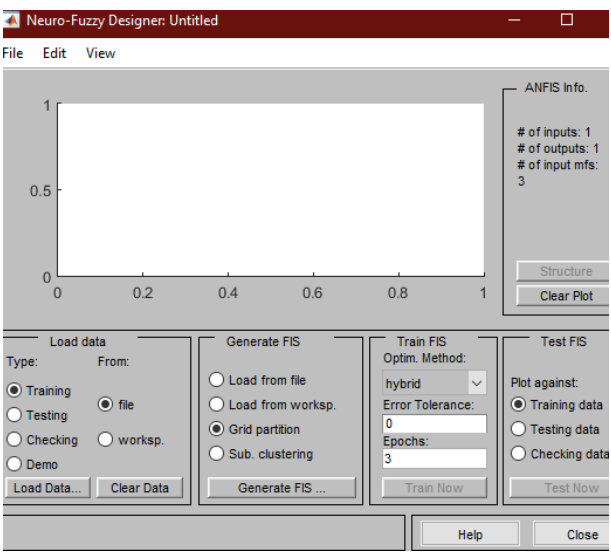

Gambar 5. Neuro fuzzy designer untuk setting training dan testing data

Pada *command windows* dapat dituliskan 'anfisedit' atau dengan membuka Neuro-fuzzy designer pada kolom APPS

matlab.

b. Inisialisasai ANFIS

Struktur awal anfis dibuat dengan mengatur jumlah input, banyaknya fungsi keanggotaan dan jenis fungsi keanggotaan. Pada neuro fuzzy designer, data dimasukkan dengan menekan 'load data' dari *workspace*.

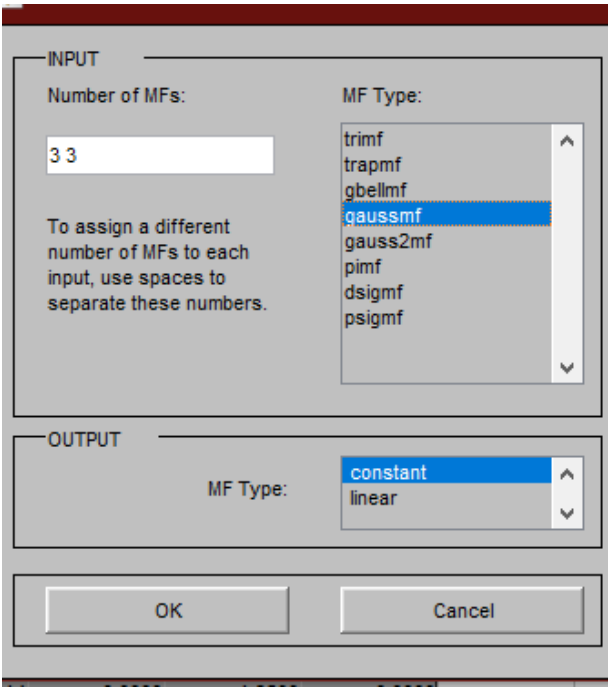

Gambar 6. Bagian generate fis untuk setting jenis keanggotaan

Generate FIS dapat dipilih fungsi kenaggotaan tipe Gaussian. Dan output dapat dipilih constant.

c. *Training* data dengan *Hybrid least square* dan *back propagation*

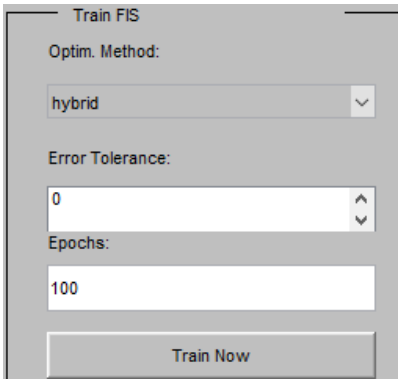

Gambar 7. Tipe *training* data dan banyak *epoch* yang digunakan

Training dilakukan dengan metode *hybrid* menggunakan *Least square* untuk *training* maju dan *back propagation* untuk *training* mundur. *Training* dilakukan dengan *least square* yang dilanjutkan dengan *back propagation* kemudian dilakukan lagi dengan *least square* secara berulang. Banyaknya pengulangan proses training tersebut disebut *Epoch*, banyaknya *epoch* digunakan dalam simulasi adalah 100. Setelah melakukan training data akan diperoleh grafik seperti berikut

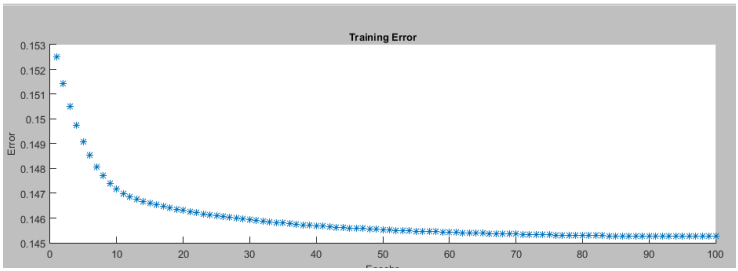

Gambar 8. Hasil grafik setelah training data

Grafik akan cenderung menurun sesuai dengan nilai *error* dengan RMSE yang akan mendekati nilai 0. Nilai *error* akan terus menurun seiiring dengan banyaknya *epoch* sampai mendekati nilai yang terus melandai pada grafik atau stabil.

d. *Testing* data

Testing data dapat dilakukan dengan cara yang sama dengan *training* data perbedaan ada pada pemasukan data

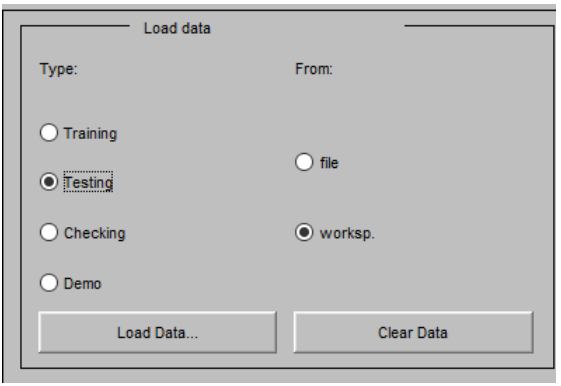

Gambar 9. Mengubah setting dari training ke testing

e. Evaluasi dengan RMSE

Setelah dilakuakan *train*, nilai RMSE dapat diperoleh seperti pada gambar yang akan ditampilkan dibawah grafik.

Gambar 10. Banyaknya *epoch* dan nilai *error*

f. Prediksi dan visualisasi

Data dapat divisualisasikan dengan grafik yang dapat dihasilkan dengan *Neuro-fuzzy designer*:

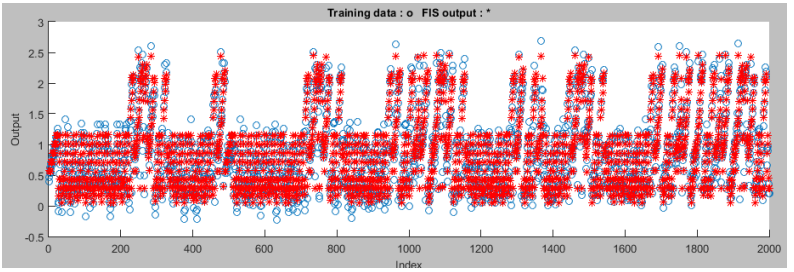

Gambar 11. Visualisasi pada *neuro fuzzy designer*

Atau dengan plot pada matlab

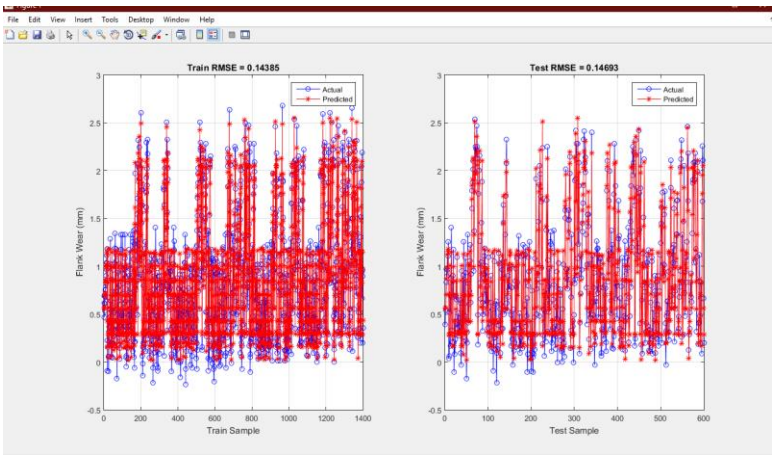

Gambar 12. Visualisasi dengan *plotting* matlab

g. Validasi data

Data hasil dibandingkan antara data *training* dan data *testing* untuk mengukur performa model berdasarkan nilai RMSE.

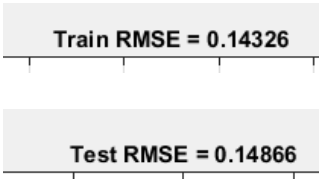

Simulasi MLR

MLR menggunakan konsep sederhana untuk meneliti hubungan fungsi antara output dan input berdasarkan variable untuk pemilihan keputusan. Dengan menggunakan referensi dataset cutting speed, feeding rate, dan flank wear, dilakukan pembagian data untuk training 70 % dan testing 30%. Pada simulasi digunakan parameter sebagai berikut: Input: cutting speed dan feeding rate, Output : Flank Wear, Training :Least Square, Epoch : 100, Validasi : RMSE.

Pada model MLR yang digunakan, data input berupa nilai cutting speed dan feeding rate untuk mendapatkan data output berupa nilai flank wear. Dengan menggunakan dua variable

untuk input, model regresi dapat dibuat persamaan sebagai berikut:

$$\boldsymbol{y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \varepsilon}$$

Dengan y: variabel output, x1, x2: variabel input, β0: (konstanta), β1,β2: koefisien regresi yang mempengaruh variabel input terhadap output, dan ε: error.

a) Analisis masalah

Masalah utama yang dibahas dalam penelitian ini adalah tentang *flank wear* yang dimonitor untuk dikontrol menggunakan model ANFIS, dalam hal ini input menggunakan nilai *cutting speed* dan *feeding rate*, output berupa nilai *flank wear*.

b) Desain Model MLR

Model MLR digunakan untuk memodelkan hubungan linear antara input dan output. Pada penelitian diguankan dua input *cutting speed* dan *feeding rate*, dengan output *Flank wear*.

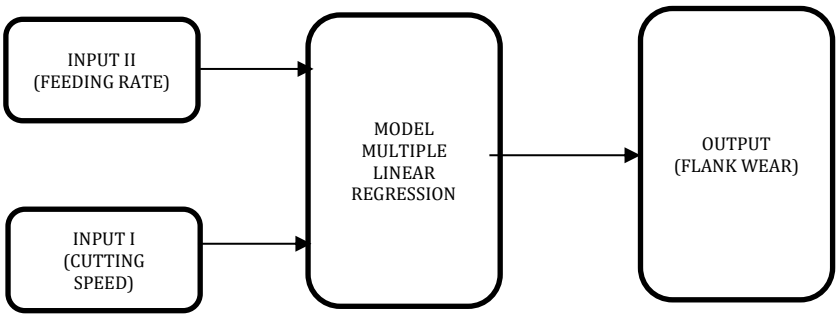

Gambar 13. Struktur model MLR

c) Pengumpulan Data

Data diperoleh melalui referensi data set dengan jumlah data sebanyak total 6000 data yang masing-masing *Cutting Speed*, Data *Feeding Rate*, dan data *Flank Wear* memiliki 2000 nilai.. Matriks data *training* berisi tiga kolom data sebanyak 70 % data (4200 data)yang dibagi menjadi 3 kolom. Dan 30 % (1800) data sisanya digunakan untuk *testing*/pengujian.

d) Simulasi MATLAB untuk *Multiple Linear Regresion* (MLR)

a. Memasukan data ke MATLAB

```
%% === LOAD DATA FROM EXCEL ===
filename = 'flank_wear_dataset_2000.xlsx';
data = xlsread(filename);

Vc = data(:,1); % Cutting speed
f  = data(:,2); % Feed rate
VB = data(:,3); % Flank wear

% Combine predictors
X = [Vc f];
```

Data set dimasukkan ke dalam MATLAB dengan menggunakan fungsi 'xlsread'. Data dibagi menjadi 3 kolom table untuk masing masing; *cutting speed*, *feed rate*, dan *Flank wear*

b. Inisiasi MLR

Dataset diubah menjadi format table dapat dilakukan *train* dengan model MLR menggunakan fungsi 'fitlm (tlb_train)' atau menggunakan fit linear model untuk melakukan train pada table dataset.

```
%% === KONVERSI KE FORMAT TABEL UNTUK fitlm ===
tbl_train = array2table([X_train Y_train], 'VariableNames', {'Vc','f','VB'});
tbl_test  = array2table([X_test  Y_test], 'VariableNames', {'Vc','f','VB'});

%% === TRAINING MODEL MLR ===
mdl = fitlm(tbl_train, 'VB ~ Vc + f');
B = mdl.Coefficients.Estimate;  % Koefisien regresi
```

c. *Training* dan *Testing* data

Data *train* dan data *test* dilakukan prediksi berdasarkan input data referensi.

```
%% === TRAINING MODEL MLR ===
mdl = fitlm(tbl_train, 'VB ~ Vc + f');
B = mdl.Coefficients.Estimate;  % Koefisien regresi

%% === PREDIKSI TRAINING DAN TESTING ===
Y_train_pred = predict(mdl, tbl_train);
Y_test_pred  = predict(mdl, tbl_test);
```

d. Evaluasi

Evaluasi digunakan untuk menghitung nilai *error* menggunakan RMSE.

```
%% === EVALUASI TRAINING ===
rmse_train = sqrt(mean((Y_train - Y_train_pred).^2));

%% === EVALUASI TESTING ===
rmse_test = sqrt(mean((Y_test - Y_test_pred).^2));
```

e. Visualisasi

Data disajikan dalam bentuk grafik untuk perbandingan antara dataset dan data prediksi berdasarkan training dan testing.

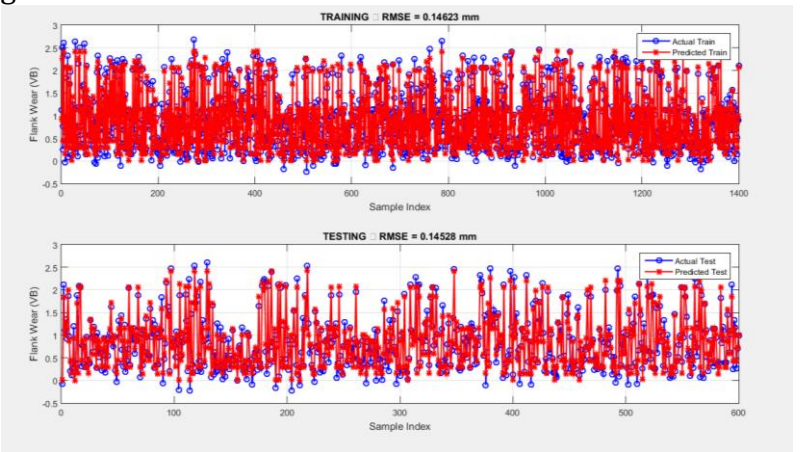

Gambar 14. Grafik *training* dan *testing* dengan *plotting* matlab

Dan disajikan dengan grafik *scatter*.

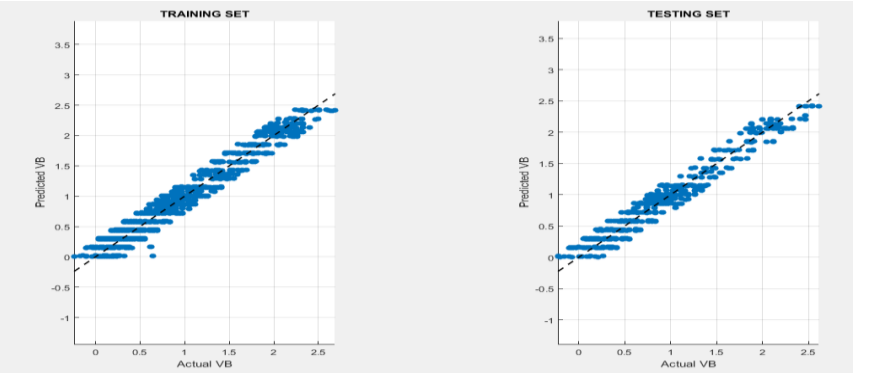

Gambar 15. Grafik *scatter* dengan plotting matlab

PEMBAHASAN

Berdasarkan peletian diatas peneliti ingin mengetahui solusi untuk mengetahui tingkat keausan menggunakan parameter umum sehingga ketika alat mencapai tingkat keausan tertemtu dapat dilakukan penggantian ataupun perbaikan. Penulis juga ingin mengetahui perbandingan antara model ANFIS dan model MLR untuk memprediksi keausan dari data hasil pengukuran. Berdasarkan penelitian yang telah dilakukan didapatkan hasil berupa grafik dan nilai *error* yang dihitung dengan RMSE.

Hasil Data Perbandingan

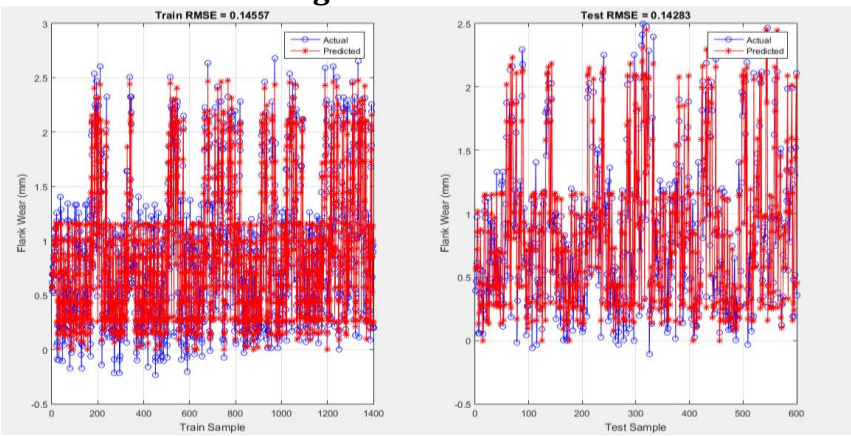

Gambar 16. Grafik model anfis dengan 6000 data

Hasil dari simulasi yang dilakukan dengan menggunakan ANFIS dengan 6000 data memiliki RMSE 0,14557 untuk *train* dan RMSE 0,14283 untuk *test*

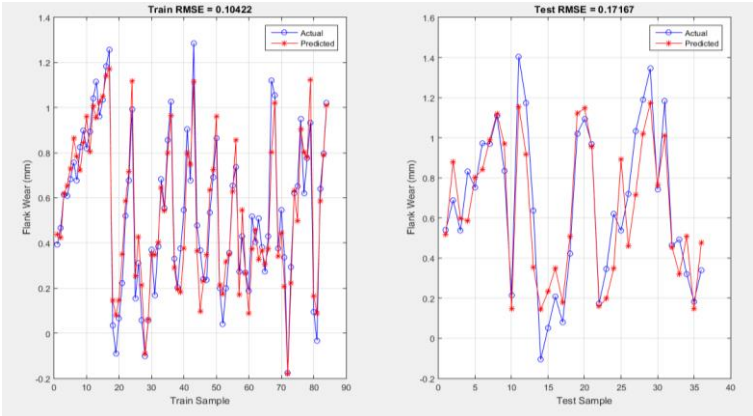

Gambar 17. Grafik model anfis dengan 360 data

Hasil dari simulasi yang dilakukan dengan menggunakan ANFIS dengan 360 data memiliki RMSE 0,10422 untuk *train* dan RMSE 0,17167 untuk *test.*

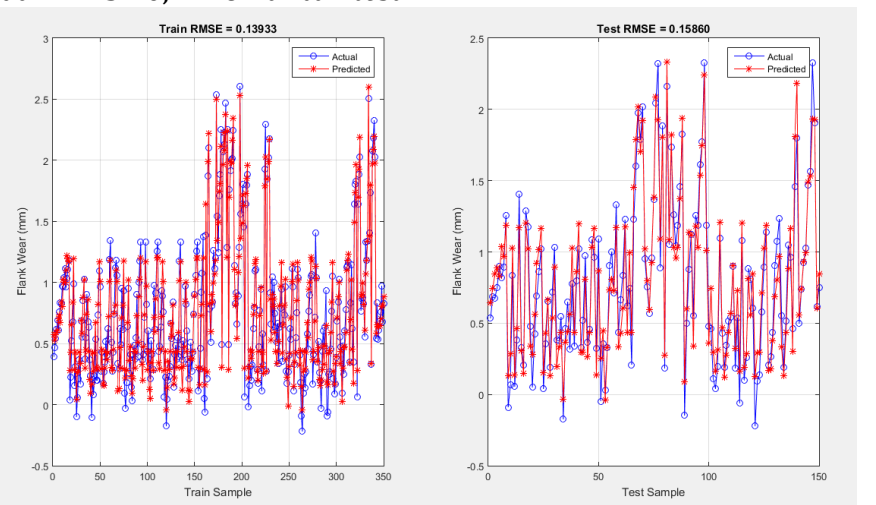

Gambar 18. Grafik model anfis dengan 1500 data

Hasil dari simulasi yang dilakukan dengan menggunakan ANFIS dengan 1500data memiliki RMSE 0,13933 untuk *train* dan RMSE 0,15860 untuk *test.*

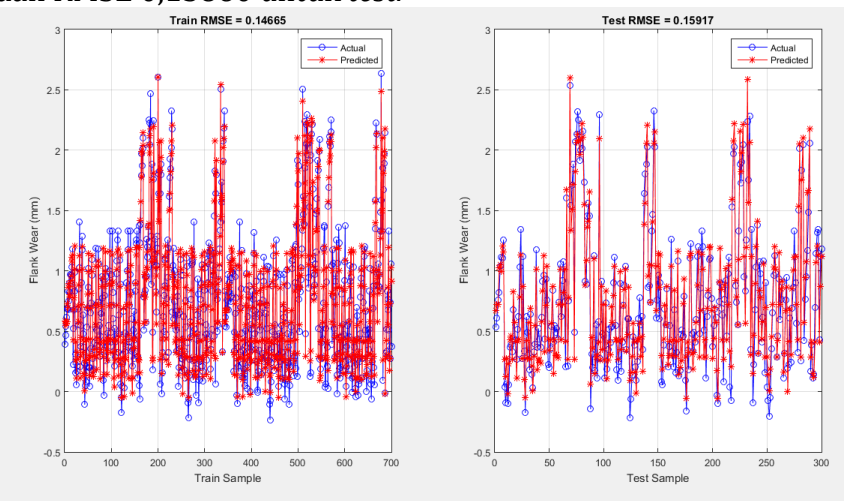

Gambar 19. Grafik model anfis dengan 3000 data

Hasil dari simulasi yang dilakukan dengan menggunakan ANFIS dengan 3000 data memiliki RMSE 0,14665 untuk *train* dan RMSE 0,15917 untuk *test*.

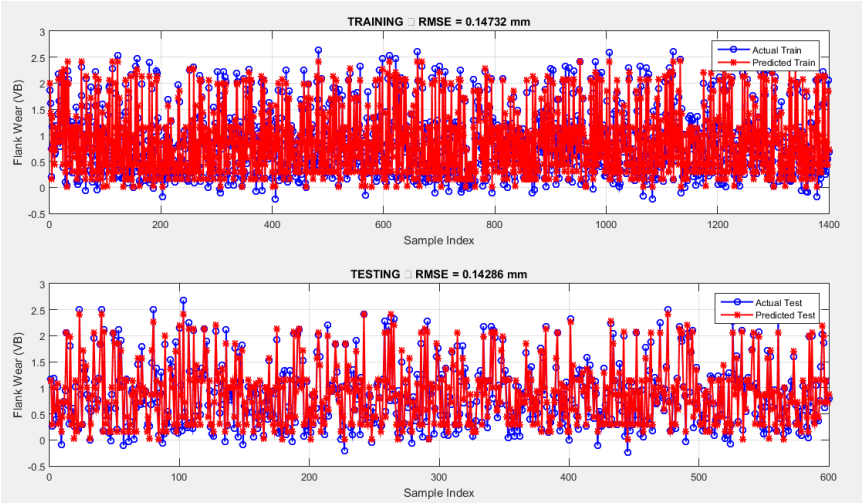

Gambar 20. Grafik model MLR dengan 6000 data

Hasil dari simulasi yang dilakukan dengan menggunakan *Linear Regression* dengan 6000data menunjukan RMSE 0, 14732 untuk *train* dan RMSE 0, 14286 untuk *test*.

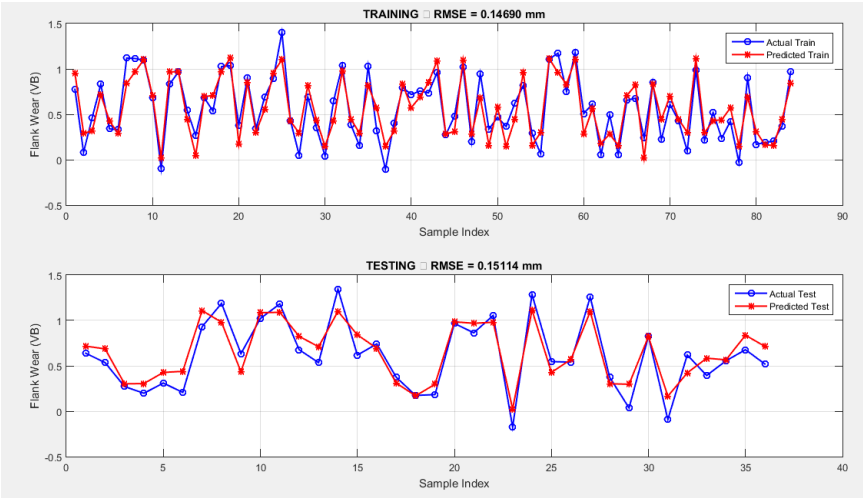

Gambar 21. Grafik model MLR dengan 360 data

Hasil dari simulasi yang dilakukan dengan menggunakan *Linear Regression* dengan 360 data menunjukan RMSE 0, 14690 untuk *train* dan RMSE 0, 15114 untuk *test*.

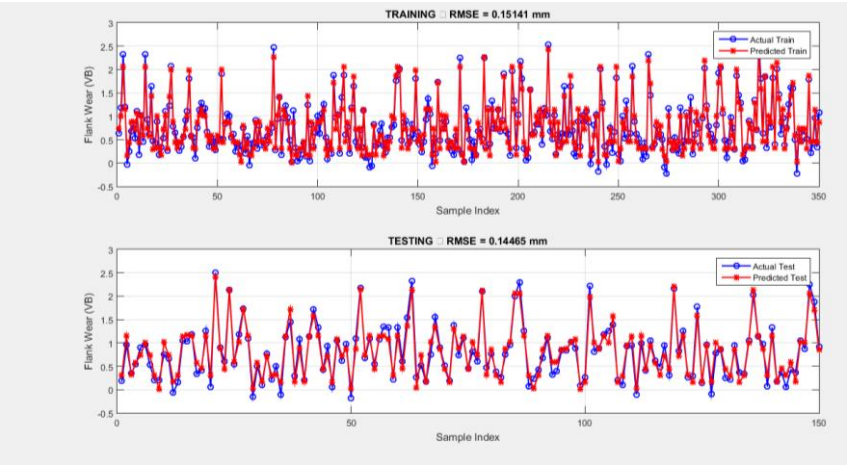

Gambar 22. Grafik model MLR dengan 1500 data

Hasil dari simulasi yang dilakukan dengan menggunakan *Linear Regression* dengan 1500 data menunjukan RMSE 0,15141 untuk *train* dan RMSE 0, 14465 untuk *test*.

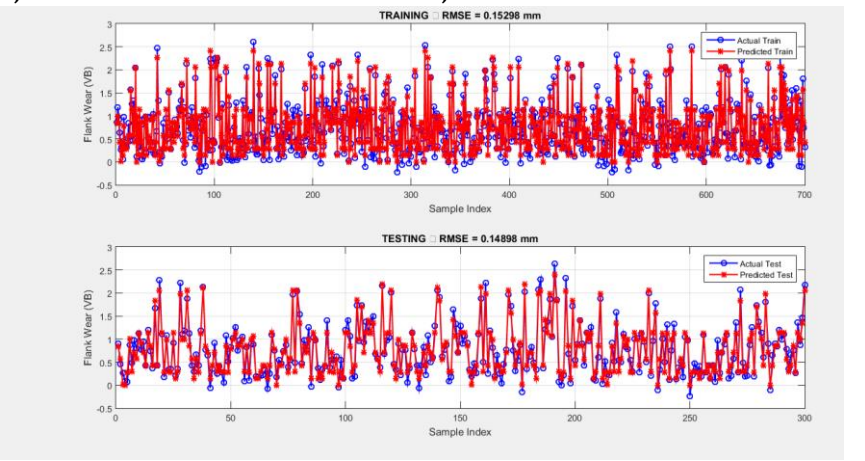

Gambar 23. Grafik model MLR dengan 3000 data

Hasil dari simulasi yang dilakukan dengan menggunakan *Linear Regression* dengan 3000 data menunjukan RMSE 0,15298 untuk *train* dan RMSE 0, 14898 untuk *test*.

Berdasarkan simulasi yang telah dilakukan dengan dua model yaitu ANFIS dan *Multiple Linear Regression* dengan *epoch* 100, data simulasi yang telah dilakukan dapat dibuat table sebagai berikut:

MODEL	Hasil RMSE Train	Hasil RMSE Test
ANFIS (360 data)	0,10422	0,17167
ANFIS (1500 data)	0,13933	0,15860
ANFIS (3000 data)	0,14665	0,15917
ANFIS (6000 data)	0,14557	0,14283
Rata-Rata	0,133943	0,158068
Linear Regression (360 data)	0,14690	0,15114
Linear Regression (1500data)	0,15141	0, 14465
Linear Regression (3000data)	0,15298	0, 14898
Linear Regression (6000data)	0,14732	0,14286
Rata-Rata	0,149653	0,147

Tabel 2. Perbandingan nilai RMSE antara ANFIS dan MLR

Pada penelitian ini digunakan dua model untuk prediksi keausan, yaitu dengan menggunakan ANFIS dan MLR. ANFIS mampu menangani hubungan non-linear antara input dan output. Model ANFIS menghasilkan akurasi yang lebih tinggi yang di tunjukan dengan nilai RMSE lebih rendah dibandingkan dengan model MLR karena dapat mempelajari pola yang kompleks dalam data. Namun karena sifatnya yang kompleks dan melibatkan parameter tersembunyi, hasil sulit untuk diinterpretasikan secara langsung. Di lain sisi, MLR dapat dipahami dan dijelaskan dengan bentuk persamaan linear. Model MLR mampu menjelaskan pengaruh masing-masing variable secara eksplisit melalui koefisien regresi.

Dengan menggunakan 2 parameter input, selisih RMSE pada kedua model tidak terlalu jauh. Selisih antara kedua model dan antara training dan testing yang dihasilkan kemungkinan dipengaruhi oleh nilai variable yang digunakan.

Model MLR cenderung lebih mudah diinterpretasikan

karena menggunakan persamaan linier dan setiap koefisien menunjukan pengaruh terhadap masing masing variable. Model ANFIS cenderung sulit di interpretasikan, ANFIS menggunakan aturan *fuzzy* dan juga *neuro network* yang tidak dapat diinterpretasikan secara langsung.

Kedua model memiliki pola hubungan antara input dan output yang berbeda, struktur, kompleksitas dan cara pembelajaran dari tiap model memiliki karakteristik tertentu. *Flank wear* tidak hanya dipengaruhi oleh parameter *cutting speed* dan *feeding rate*, berbagai parameter dalam proses permesinan dapat mempengaruhi baik dari parameter mesin maupun dari bahan yang diproses. Keausan yang terjadi dapat dibengaruhi oleh berbagai faktor tidak hanya *cutting speed* dan *feeding rate.* Factor lainya diantaranya adalah: suhu, waktu kerja/proses, dan getaran. Hubungan antara factor ini tidak linier, misal kenaikan *cutting speed* dapat mempengaruhi *flank wear* namun pada titik tertentu pengaruhnya akan berkurang bahkan hilang. Contoh lain adalah parameter *cutting speed* dan *feeding rate* tidak memiliki sinergi, kedua parameter menghasilkan nilai keausan yang tidak sebanding satu sama lain atau keausan yang dihasikan adalah dampak masing masing parameter yang tidak mempengaruhi satu sama lain. Model ANFIS lebih cocok untuk diterapkan dalam proses permesinan *drilling* karena dapat digunakan untuk memprediksi dengan akurasi yang lebih tinggi dibandingkan dengan model MLR. ANFIS dapat mengangkap pola hubungan dari data yang diberikan secara dua arah dengan menggunakan *back propagation*, dibandingkan dengan MLR yang hanya bisa memberikan hubungan satu arah.

Dalam memprediksi *flank wear* akurasi yang tinggi lebih diutamankan dibandingakn dengan interpretasi model. Nilai *flank wear* dapat menentukan hasil proses *drilling*, dan efisiensi dari proses manufaktur.

Dalam penelitian ini, model MLR memiliki nilai akurasi yabg lebih rendah dari model ANFIS yang dapat dilihat dari nilai RMSE yang lebih tinggi. Dalam penelitian ini perbandingan kedua nilai RMSE antara kedua model tidak jauh berbeda yaitu di antara rentan nilai 0,10 dan 0,17. Dengan selisih antar nilai yang kecil model MLR masih relevan untuk digunakan sebagai model prediksi *flank wear* berdasarkan

input nilai *cutting speed* dan *feeding rate*.

PENUTUP

ANFIS memiliki keunggulan dalam menangkap hubungan non-linear antara nilai variabel *cutting speed*, *feed rate*, dan *flank wear*, dibanding MLR yang menggunakan hubungan linier. Kemampuan model ANFIS dalam penyesuaian parameter yang fleksibel terhadap data kompleks dengan *fuzzy* yang dapat membagi menjadi rentan nilai tertentu dan *neuro network* yang dapat memproses data dengan parameter nilai yang kompleks dan tersembunyi untuk data *non-linear*. Nilai RMSE dari ANFIS lebih rendah ketika menggunakan data yang berbeda. Selisih antar kedua model masih terlihat meskipun menggunakan jumlah data yang berbeda. Nilai ANFIS berkisar antara 0,01 – 0,17, dengan rata rata 0,133943 untuk *training* dan 0,158068 untuk *testing* ; sedangkan MLR stabil pada 0,14 - 0,150, dengan rata rata 149653 untuk *training* dan 0,147untuk *testing*. Hal tersebut mengindikasikan bahwa ANFIS dapat memprediksi dengan baik dalam parameter dan jumlah data tertentu. Dan model MLR memberikan nilai akurasi yang stabil. Meskipun model MLR memiliki nilai akurasi yang lebih rendah, namun model masih relevan digunakan. Dengan 2 parameter input pada penelitian, perbedaan nilai RMSE tidak terlalu jauh terhadap nilai RMSE model ANFIS. Dengan keunggulan dan kemudahan dalam interpretasi, prediksi yang cepat dan stabil dapat dilakukan menggunakan model MLR. Prediksi *Flank Wear* berbasis dua input parameter menunjukan tingkat keakuratan model ANFIS dan MLR yang mampu memprediksi nilai keausan dengan parameter input sederhana yaitu *cutting speed* dan *feeding rate* yang dapat diukur secara langsung saat proses permesinan terjadi.

DAFTAR PUSTAKA

Abbas, A. T., Alata, M., Ragab, A. E., El Rayes, M. M., & El Danaf, E. A. (2017). Prediction model of cutting parameters for turning high-strength steel grade-H: Comparative study of regression model versus ANFIS. *Advances in Materials*

Science and Engineering, 2759020.

Aru, O. (2016). Exploration of the adaptive neuro-fuzzy inference system architecture and its applications. *American Journal of Engineering Research*, 5(10), 181–188.

Basari, A. S. H. (2011). Application of ANFIS in prediction TiAlN coating flank wear. *Third International Conference on Computational Intelligence, Modelling & Simulation. 57-62.*

Çakan A., Evrendilek F, & Ozkaner, V. (2016). Data-driven simulations of flank wear coated cutting tools in hard turning. *Mechanics*, 21(6).

Çelik, Y. H., & Fidan, Ş. (2022). Analysis of cutting parameters on tool wear in turning of Ti-6Al-4V alloy by multiple linear regression and genetic expression programming methods. *Measurement*, 200, Article 111638.

Dutta, S., Pal, S. K., & Sen, R. (2016). On-machine tool prediction of flank wear from machined surface images using texture analyses and support vector regression. *Precision Engineering*, 43, 34–42.

Feng, K., Ji, J. C., Ni, Q., & Beer, M. (2023). A review of vibration-based gear wear monitoring and prediction techniques. *Mechanical Systems and Signal Processing*, 182, Article 109605.

Ganeshkumars. (2021). Flank wear of CNC lathe tool insert dataset [Data set]. *Kaggle*. https://www.kaggle.com/datasets/ganeshkumars/flank-wear-of-cnc-lathe-tool-insert.

Imhade P. O & Jude E. S. (2023). Overview study of ANN-GA, ANN-PSO, ANFIS-GA, and ANFIS-PCM prediction analysis on tool wear. *Journal Européen des Systèmes Automatisés* Vol. 56, No. 2, pp. 269-280.

Jang, J. S. R. (1993). ANFIS: Adaptive-network-based fuzzy inference system*. IEEE Transactions on Systems, Man, and Cybernetics*, 23(3), 665–685. https://doi.org/10.1109/21.256541

Jeong, M. J., Lee, S. W., Jang, W. K., Kim, H. J., Seo, Y. H., & Kim, B. H. (2021). Prediction of drill bit breakage using an infrared sensor. *Sensors*, 21(8), 2808.

Khaled Z, Mondher B A, &Mourad T. (2018). Modeling of Flank

Wear Using ANFIS. *ICEMIS '18*.47, 1 – 5.

Kong, D., Chen, Y., & Li, N. (2018). Gaussian process regression for tool wear prediction. *Mechanical Systems and Signal Processing*, 104, 556–574.

Lin, C.-J., Jhang, J.-Y., Chen, S.-H., & Young, K.-Y. (2020). Using an interval type-2 fuzzy neural network and tool chips for flank wear prediction. *IEEE*, 8, 122626–122640.

Mushtaq, Z., Hanief, M., & Manroo, S. A. (2021). Prediction of friction and wear during ball-on-flat sliding using multiple regression and ANN: *Modeling and experimental validation. Jurnal Tribologi*, 28, 117–128.

Sarhan, Ahmed. (2015). Adaptive neuro-fuzzy approach to predict tool wear accurately in turning operations for maximum cutting tool utilization. *IFAC-PapersOnLine*. 48. 93-98. 10.1016/j.ifacol.2015.05.029.

Senthilkumar, N. & Tamizharasan, T. (2015). Flank Wear and Surface Roughness prediction in Hard Turning via Artificial Neural Network and Multiple Regressions. *Australian Journal of Mechanical Engineering*. 13. 31-45. 10.7158/M13-045.2015.13.1.

Srivastava, A. K., & Islam, M. M. (2024). Prediction of tool wear and surface finish using ANFIS modelling during turning of carbon fiber reinforced plastic (CFRP) composites. *Manufacturing Letters, 41*, 658–669.

Thangarasu S. K., Mohanraj T., Devendran K., Rajalakshmi M., Subrata C., 5 & Saravanakumar G. (2023). Prediction of Flank Wear during Turning of EN8 Steel with CuttingForce Signals Using a Deep Learning Approach. *Hindawi Mathematical Problems in Engineering*, 5401372.

Vuong, N. D. Y. Xue, S. Liu, Y. Zhou and M. Wu. (2020). Predicting Surface Roughness and Flank Wear in Turning Processes, *International Conference on Prognostics and Health Management (ICPHM),* Detroit, MI, USA, pp. 1-6,

Xu, L., Huang, C., Li, C., Wang, J., Liu, H., & Wang, X. (2021). Estimation of tool wear and optimization of cutting parameters based on novel ANFIS-PSO method toward intelligent machining. *Journal of Intelligent Manufacturing*, 32(1), 77–90.

Zhang, J., Starly, B., Cai, Y., Cohen, P., & Lee, Y.-S. (2017). Particle

learning in online tool wear diagnosis and prognosis. *Journal of ManufacturingProcesses*, 28,322–330.