

MONITORING KEAUSAN PAHAT MENGGUNAKAN ARTIFICIAL NEURAL NETWORKS PADA PROSES TURNING

Heri Widiantoro^{1*}, Ahmad Atif Fikri^{1}, Muslim Mahardika^{1***}**

¹Jurusan Teknik Mesin dan Industri, Fakultas Teknik Universitas Gadjah Mada.

Jalan Grafika No.2 55281, Yogyakarta, Indonesia.

*E-mail: h.widiantoroazka@gmail.com

**E-mail: ahmadatifkri@gmail.com

***E-mail: muslim_mahardika@yahoo.com

Abstrak

Dalam penelitian ini dikembangkan sebuah sistem monitoring dengan menggunakan Artificial Neural Networks (ANN) Backpropagation untuk memprediksi keausan cutting tool (pahat) sehingga diharapkan dapat meningkatkan produktifitas dan mencegah lebih dini kerugian akibat keausan pahat seperti permukaan komponen tidak rata, pahat rusak (chipping) dan perawatan mesin tidak terjadwal yang dapat berdampak pada membengkaknya biaya produksi. Sinyal suara selama proses pemotongan akan ditangkap oleh microphone dan diproses menggunakan software LabVIEW berupa time domain dan frequency domain. Sinyal yang diterima oleh LabVIEW kemudian difilter sehingga nilai yang muncul merupakan sinyal dari proses pemotongan dan bukan noise dari luar. Sinyal tersebut digunakan sebagai informasi untuk menentukan pola atau karakteristik ketika pahat aus dan digunakan untuk membangun jaringan ANN Backpropagation. Arsitektur ANN Backpropagation dengan menggunakan fungsi aktivasi sigmoid biner (logsig), 2 neuron pada input layer, 500 neuron pada hidden layer dan 2 neuron pada output layer ($2 \times 500 \times 2$) mampu mengenali kondisi pahat selama proses pemotongan dengan memberikan hasil kinerja sebesar 92%.

Kata kunci: ANN, backpropagation, online monitoring, turning

1. PENDAHULUAN

Kemajuan teknologi yang berkembang seperti *online monitoring* akan memberikan kontribusi terhadap proses permesinan dan optimasi proses produksi. Perlunya *monitoring* pada proses pemotongan logam meliputi *monitoring* mesin, dinamika proses pemotongan, alat potong dan benda kerja untuk mengoptimalkan kinerja dari sistem. Sebuah *monitoring* kondisi alat potong bertujuan (Dimla, 1999) mendeteksi kesalahan pada pemotongan dan pahat pada mesin, memeriksa dan menjaga stabilitas proses *permesinan*, menjaga toleransi permesinan sehingga produk yang dihasilkan dapat memenuhi standar yang ditetapkan dengan memperhitungkan keausan pahat serta menghindari kerusakan mesin akibat kegagalan sistem.

Online monitoring digunakan untuk memprediksi keausan pahat secara dini sehingga kontrol kualitas dari produk dapat tetap terjaga dan proses permesinan menjadi optimal. Kerugian akibat keausan pahat seperti permukaan komponen tidak rata, *chipping* dan perawatan mesin tidak terjadwal dapat berdampak pada membengkaknya biaya produksi. Dengan adanya *online monitoring* ini diharapkan kondisi pahat segera dideteksi tingkat keausannya karena pahat merupakan faktor penting dalam proses pemotongan logam. *Flank wear* dipilih sebagai dasar untuk kriteria kegagalan pahat serta paling mudah untuk diukur tingkat keausannya.

Kemampuan *monitoring* keausan pahat sangat penting untuk mencapai kemungkinan pemanfaatan pahat secara maksimum. Tingkat keausan pahat sulit ditentukan mengingat fakta bahwa keausan pahat menyebabkan perubahan material kecil dalam prosesnya sehingga diperlukan pemilihan sensor yang tepat baik secara fungsi, ekonomis, pengidentifikasi kondisi alat, dan penggunaan informasi. Salah satunya pada penelitian ini akan menggunakan mikrofon sebagai sensor suara dalam membangun ANN *Backpropagation* menggunakan *software Matlab*.

1.1 Mekanisme Keausan Pahat

Secara umum kegagalan pahat dapat mengakibatkan keausan, deformasi plastik, atau *fracture*. Terjadinya keausan tergantung pada material yang digunakan dan kondisi pemotongan,

terutama kecepatan potong. Keausan pahat dapat diklasifikasikan menjadi beberapa jenis seperti keausan *adhesive*, keausan *abrasive*, keausan *diffusion* dan keausan *fracture*.

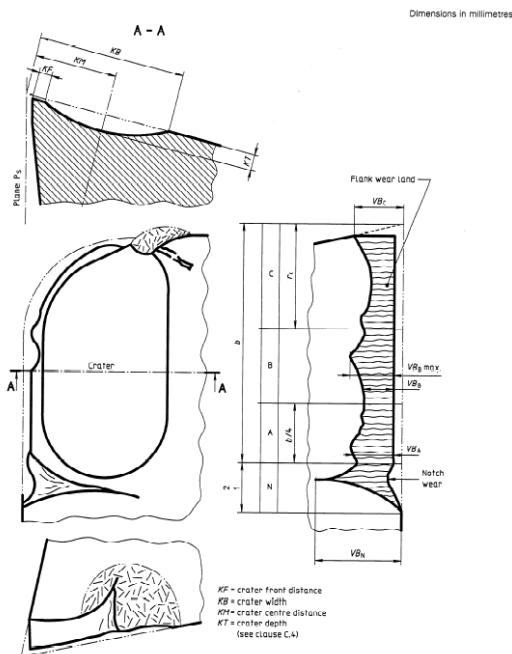
Proses keausan pahat tergantung pada kondisi pemotongan, material benda kerja, material pahat, dan geometri *insert*. Untuk kombinasi material pahat dan benda kerja. Bentuk keausan pahat tergantung pada kondisi pemotongan, terutama kecepatan potong (*cutting speed*), kedalaman pemotongan (*depth of cut*) dan laju pemakanan (*feed rate*). Bentuk keausan yang terjadi pada pahat secara umum diidentifikasi seperti *nose wear*, *flank wear*, *notch wear* dan *crater wear*.

Nose wear terjadi karena mekanisme abrasi di ujung pahat yang mengakibatkan berkurangnya *rake angle*. Ketajaman dari pahat akan berkurang dengan adanya deformasi plastis atau elastis. *Flank wear* terjadi karena mekanisme keausan *adhesive* dan *abrasive* dari gesekan kedua permukaan. *Flank wear* berpengaruh pada kualitas permukaan benda kerja, semakin luas kontak *flank wear* dengan benda kerja akan meningkatkan temperatur permesinan. *Crater wear* terbentuk dari kombinasi temperatur tinggi pada permesinan dan tegangan geser tinggi yang membentuk kawah pada *rake face* dengan jarak tertentu dari ujung pahat. Kedalaman tertentu dari *crater wear* akan menyebabkan kegagalan permesinan. *Notch wear* terbentuk ketika pahat bersentuhan dengan lapisan permukaan bagian atas dari benda kerja. Abrasi pada lapisan permukaan pahat dipercepat dengan adanya oksidasi atau reaksi kimia. *Notch wear* dapat menyebabkan cacat atau kegagalan pada pahat.

1.2 Pengukuran Keausan Pahat

Kriteria untuk menentukan umur pahat seperti nilai keausan VB, diukur menggunakan standar ISO 3685 seperti terlihat pada Gambar 1. dimana merekomendasikan beberapa nilai batas untuk keausan pahat dari material Cemented carbide, HSS dan keramik, seperti yang dijelaskan di bawah ini:

1. Cemented carbide :
 - a. $VB_B = 0,3 \text{ mm}$, jika *flank wear* regular atau
 - b. $VB_{B\max} = 0,6\text{mm}$, jika *flank wear* tidak teratur , atau
 - c. $KT = 0,06 + 0,3 f$
dimana f adalah *feed*.
2. HSS dan keramik
 - a. *Catastrophic failure*
 - b. $VB_B = 0,3 \text{ mm}$, jika *flank wear* regular atau
 - c. $VB_{B\max} = 0,6\text{mm}$, jika *flank wear* tidak teratur.



Gambar 1. Tool wear menurut ISO 3685

1.3 Tool Wear Monitoring

Byrne (1995) dalam penelitiannya menyimpulkan bahwa sistem *monitoring* itu harus memiliki kehandalan, diterima dan tersedia di pasar (komersial) dan digunakan secara luas dalam industri, bagaimanapun sistem ini masih memiliki lingkup kinerja yang sempit atau memerlukan latihan intensif dan *setup time* untuk berfungsi dengan benar.

Perkembangan terkini dalam menentukan metode *monitoring* yang sesuai yaitu menggunakan beberapa teknik canggih dalam pemrosesan *signal* kemudian menghubungkan dengan metoda kecerdasan buatan (*Artificial Intelligent, AI*) dalam pengambilan keputusan sistem *monitoring*. Salah satu pendekatan yang paling populer adalah dengan menggunakan jaringan saraf tiruan (*Artificial neural networks, ANN*), sistem dibangun pada konsep yang berasal dari pemahaman dalam sistem saraf. Struktur mereka dapat dianggap sebagai otak (*black-box*) yang menampilkan hubungan non-linear antara respon multi-input-output. Penekanannya adalah pada membangun jaringan saraf dengan akurasi yang tinggi, *fast learning* dan *low connectivity*.

1.4 Backpropagation

Backpropagation adalah jenis dari ANN dimana algoritma pembelajarannya terawasi dan biasanya digunakan oleh *perceptron* dengan banyak lapisan (*multi layer*) untuk mengubah bobot-bobot yang terhubung dengan neuron-neuron yang ada pada lapisan tersembunyinya. Algoritma *Backpropagation* menggunakan *error output* untuk mengubah nilai bobot-bobotnya dalam arah mundur (*backward*). Untuk mendapatkan *error* ini, tahap perambatan maju (*forward propagation*) harus dikerjakan terlebih dahulu. Pada saat permabatan maju, neuron-neuron diaktifkan dengan menggunakan fungsi aktivasi yang dapat didefernsialkan. Algoritma pelatihan untuk jaringan dengan satu latar tersembunyi adalah sebagai berikut (Siang, 2005) :

1. Fase propagasi maju
 - a) setiap unit input menerima sinyal dan meneruskannya ke unit hidden layer di atasnya.
 - b) hitung semua keluaran di unit hidden layer z_j ($j = 1, 2, \dots, p$)

$$z_{net_j} = v_{j0} + \sum_{i=1}^n x_i v_{ji} \quad (2)$$

$$z_j = f(z_{net_j}) = \frac{1}{1 + e^{-z_{net_j}}} \quad (3)$$

- c) hitung semua keluaran jaringan di unit hidden layer

$$y_{net_k} = w_{k0} + \sum_{j=1}^p z_j w_{kj} \quad (4)$$

$$y_k = f(y_{net_k}) = \frac{1}{1 + e^{-y_{net_k}}} \quad (5)$$

2. Fase propagasi mundur

- a) hitung faktor δ unit output berdasarkan error disetiap unit output y_k ($k = 1, 2, \dots, m$)

$$\delta_k = (t_k - y_k)f'(y_{net_k}) = (t_k - y_k)y_k(1 - y_k) \quad (6)$$

- b) hitung perubahan bobot w_{kj} dengan laju percepatan α

$$\Delta w_{kj} = \alpha \delta_k z_j \quad (7)$$

$$k = 1, 2, \dots, m ; j = 0, 1, \dots, p$$

- c) hitung faktor δ unit hidden layer berdasarkan error di setiap unit hidden layer z_j ($j = 1, 2, \dots, p$)

$$\delta_{net_j} = \sum_{k=1}^m \delta_k w_{kj} \quad (8)$$

$$\delta_j = \delta_{net_j} f'(z_{net_j}) = \delta_{net_j} z_j(1 - z_j) \quad (9)$$

- d) hitung perubahan bobot v_{ji}

$$\Delta v_{ji} = \alpha \delta_j x_i \quad (10)$$

$j = 1, 2, \dots, p ; i = 0, 1, \dots, n$

3. Fase perubahan bobot

- a) hitung perubahan bobot yang menuju ke unit output

$$w_{kj}(baru) = w_{kj}(lama) + \Delta w_{kj} \quad (11)$$

$k = 1, 2, \dots, m ; j = 0, 1, \dots, p$

- b) hitung perubahan bobot yang menuju unit hidden layer

$$v_{kj}(baru) = v_{kj}(lama) + \Delta v_{kj} \quad (12)$$

$j = 1, 2, \dots, p ; j = 0, 1, \dots, n$

2. METODE PENELITIAN

2.1 Alat dan Bahan

Peneletian ini dilakukan pada mesin EMCO Turn 242 dengan beberapa parameter pemotongan, pahat insert DCGT 070204EN dan benda kerja yang digunakan adalah *mild steel* $\emptyset 50 \times 150 mm$. seperti pada Tabel 1. *Microphone* digunakan untuk menangkap sinyal suara selama proses pemotongan.

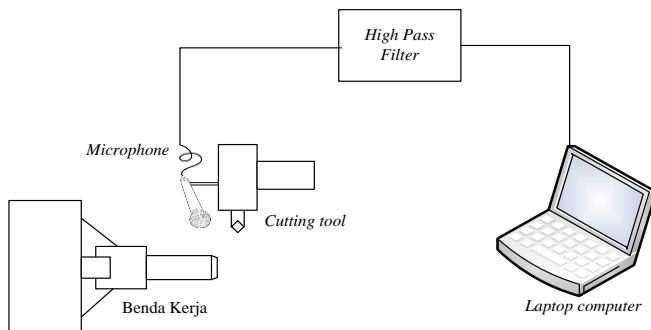
Tabel 1. Parameter pemotongan

Parameter	V_c (m/min)	f (mm/rev)	Depth of cut (mm)
Level 1	180	0,08	0,125
Level 2	200	0,1	0,25
Level 3	220	0,12	0,375

2.2 Prosedur Penelitian

Proses monitoring dilakukan selama proses pemotongan yang dilakukan pada mesin EMCO Turn 242 dengan menggunakan pahat insert seperti pada Gambar 4. Sebelum proses pemotongan dilakukan beberapa persiapan seperti pemasangan benda kerja, pemasangan pahat, setting parameter pemotongan, pemasangan mikrofon, mikrofon dengan jarak sekitar 10 sampai 40 mm terhadap pahat maupun benda kerja (Nair, dkk. 2010) dan menghubungkan mikrofon dengan PC.

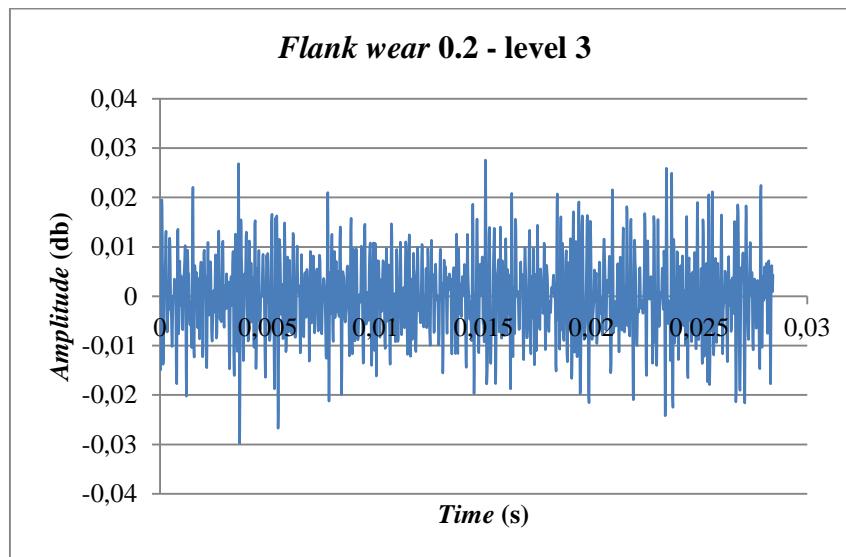
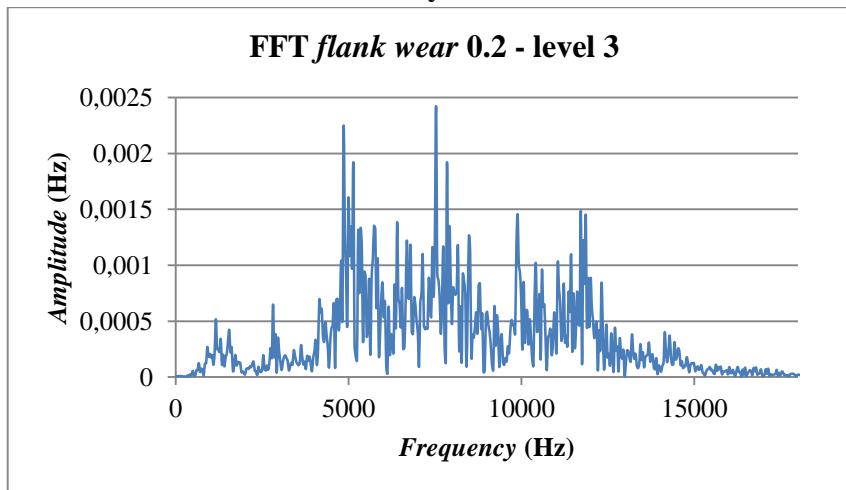
Pada penelitian ini hanya digunakan signal dari proses pemotongan untuk diproses lebih lanjut menggunakan LabVIEW. Sementara *noise* yang diterima mikrofon baik suara dari mesin, peralatan lain dan suara sekitar tidak digunakan sehingga perlu dihilangkan (*filtering*). Informasi data yang diperoleh dari LabVIEW untuk setiap kondisi pemotongan serta tingkat keausan dari pahat yaitu berupa *audio signal* dan FFT terfilter serta *audio signal* dan FFT tidak terfilter. Sinyal tersebut digunakan untuk dianalisa dalam menentukan karakteristik tingkat keausan dari pahat. Lebih lanjut sinyal tersebut dapat digunakan untuk membangun sistem monitoring dalam memprediksi keausan dari pahat dengan menggunakan *software* Matlab.



Gambar 2. *Experiment setup*

3. HASIL DAN PEMBAHASAN

Pada level 1 untuk kondisi pahat baru amplitudo yang diterima sekitar 0,0021 db. Pada *frequency domain* terdapat beberapa sinyal frekuensi yang menonjol diantaranya adalah frekuensi 4891,438 Hz dengan magnitude 6,79E-04 db dan frekuensi 7706,654 Hz (8,26E-04 db). Sementara pada level 3 dan *flank wear* 0,2 mm terjadi perbedaan yang cukup besar dengan kondisi level 3 *flank wear* 0,1 seperti pada Gambar 3 dan 4. Amplitude yang diterima lebih besar yaitu 0,0066 db dan pada *frequency domain* terdapat frekuensi yang menonjol yaitu frekuensi 4856,248 Hz dengan magnitude 2,23E-03 db dan frekuensi 7530,703 Hz (2,42E-03 db). Kedua frekuensi yang paling menonjol tersebut merupakan frekuensi yang berada pada range frekuensi natural dari benda kerja dan pahat. Kondisi pada level 1 dengan pahat baru dapat digunakan sebagai acuan dari kondisi normal pemotongan.

Gambar 3. Sinyal *time domain*Gambar 4. Sinyal *frequency domain*

Terjadi kecenderungan kenaikan amplitudo seperti yang terlihat pada Tabel 2. dikarenakan meluasnya bidang kontak pahat dengan benda kerja sehingga menghasilkan gesekan dan getaran yang lebih besar. Dengan keausan yang lebih tinggi pahat akan bergetar lebih tinggi amplitudo-nya karena pahat akan menerima beban lebih besar daripada pahat lebih tajam (kondisi baru). Namun terdapat fenomena penurunan amplitudo pada flank wear 0,3 level 2 dan level 3.

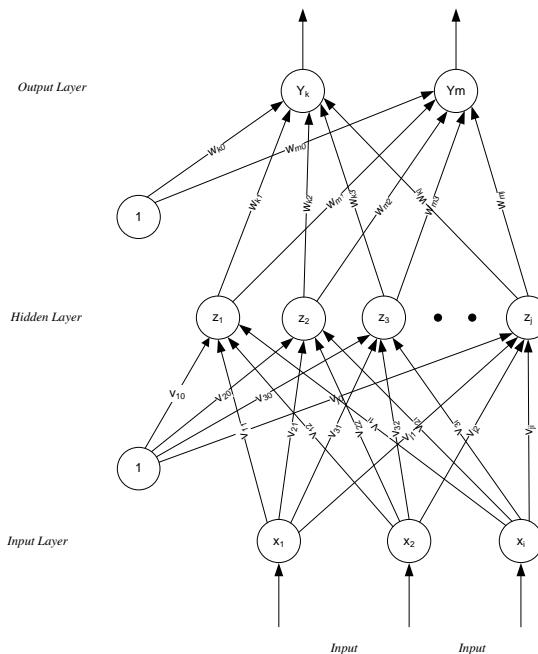
Tabel 2. Hasil proses sensing

No.	Parameter	Wear	Frequency domain				Time domain*
			Frequency (Hz)	Magnitude (db)	Frequency (Hz)	Magnitude (db)	
1	Level 1	Pahat baru	4891,438	6,79E-04	7706,654	8,26E-04	0,0021
2		flank wear 0,1	4926,628	8,72E-04	7777,035	9,82E-04	0,0025
3		flank wear 0,2	4997,009	9,76E-04	7847,415	1,49E-03	0,0026
4		flank	4856,248	1,20E-03	6510,188	1,71E-03	0,0031

		<i>wear 0,3</i>				
5	Level 2	Pahat baru	4891,438	1,24E-03	7847,415	1,61E-03
6		<i>flank wear 0,1</i>	4821,058	1,18E-03	7460,323	1,64E-03
7		<i>flank wear 0,2</i>	5032,199	1,53E-03	7847,415	2,35E-03
8		<i>flank wear 0,3</i>	4856,248	3,04E-03	6580,568	2,44E-03
9	Level 3	Pahat baru	4961,819	1,73E-03	6897,280	1,69E-03
10		<i>flank wear 0,1</i>	4997,009	2,02E-03	6826,899	1,72E-03
11		<i>flank wear 0,2</i>	4856,248	2,23E-03	7530,703	2,42E-03
12		<i>flank wear 0,3</i>	4891,426	4,66E-03	6580,552	2,91E-03

keterangan: *time domain diambil nilai rata-rata

Arsitektur ANN *Backpropagation* sangat menentukan tingkat *performance*, seperti pada gambar 5. Salah satu karakteristik utama membangun ANN adalah waktu pelatihan. Waktu pelatihan biasanya lebih lama ketika keputusan yang diinginkan kompleks dan ketika jaringan memiliki beberapa *hidden layer*. Waktu pelatihan akan berkurang dan kinerja meningkat jika ukuran jaringan disesuaikan secara optimal.



Gambar 5. Arsitektur ANN *Backpropagation*

Fase-fase (maju, mundur dan perbaikan bobot) pada ANN *Backpropagation* diulang-ulang terus hingga kondisi penghentian dipenuhi. Umumnya kondisi penghentian yang sering dipakai adalah jumlah iterasi atau *error*. Iterasi akan dihentikan jika jumlah iterasi yang dilakukan sudah melebihi jumlah maksimum iterasi yang ditetapkan, atau jika *error* yang terjadi sudah lebih kecil dari batas toleransi yang diijinkan.

Arsitektur ANN *Backpropagation* pada penelitian ini menggunakan fungsi aktivasi sigmoid biner (*logsig*), 2 neuron pada *input layer*, 500 neuron pada *hidden layer* dan 2 neuron pada *output layer* [$2 \times 500 \times 2$]. *Performance* dari sistem ini memberikan nilai sekitar 92%, seperti yang

terlihat pada Tabel 3. Sebanyak 25 unit *input* mampu mengenali kondisi pahat aus selama proses pemotongan dengan baik, terdapat 2 *input* yang tidak sesuai dengan target [1 0].

Tabel 3. Pengujian keausan

Frekuensi (Hz)	Magnitude (db)	ANN Backpropagation		Tool condition	
		Pengujian	Target		
6510,171536	7,16,E-04	0,9961	0,0000	1	0
6545,361652	8,52,E-04	0,9952	0,0003	1	0
6580,551769	2,91,E-03	0,9893	0,0418	1	0
6615,741885	4,83,E-04	1,0000	0,0000	1	0
6650,932001	1,54,E-03	0,5155	0,2463	1	0
6686,122118	3,28,E-04	0,9974	0,0000	1	0
6721,312234	1,37,E-03	0,0244	0,9983	0	1
6756,502351	4,62,E-04	0,9999	0,0000	1	0
6791,692467	1,22,E-03	0,9868	0,0751	1	0
6826,882584	8,59,E-04	0,9994	0,0002	1	0
6862,072700	1,01,E-03	1,0000	0,0008	1	0
6897,262816	1,02,E-03	1,0000	0,0017	1	0
6932,452933	4,96,E-04	1,0000	0,0000	1	0
6967,643049	2,83,E-04	0,9997	0,0000	1	0
7002,833166	2,00,E-04	0,9998	0,0000	1	0
7038,023282	4,13,E-04	1,0000	0,0000	1	0
7073,213398	9,30,E-04	1,0000	0,0001	1	0
7108,403515	6,70,E-05	0,9999	0,0000	1	0
7143,593631	6,65,E-05	1,0000	0,0000	1	0
7178,783748	4,65,E-04	1,0000	0,0000	1	0
7213,973864	1,42,E-03	1,0000	0,9861	1	1
7249,163980	4,22,E-04	1,0000	0,0000	1	0
7284,354097	2,16,E-03	0,9845	0,2089	1	0
7319,544213	3,76,E-05	1,0000	0,0000	1	0
7354,734330	7,82,E-04	0,9687	0,0001	1	0

keterangan: 1:pahat aus, 0:pahat tidak aus

4. KESIMPULAN

Komponen arsitektur ANN *Backpropagation* seperti bobot awal, jumlah *hidden layer*, neuron, fungsi aktivasi dan parameter pelatihan sangat berpengaruh terhadap waktu pelatihan dalam mengenali setiap kondisi pahat semua level parameter pemotongan. Semua faktor tersebut dapat dipilih kombinasi yang tepat hingga menghasilkan kinerja yang optimal dalam pembangunan ANN.

Bobot awal sangat mempengaruhi ANN *Backpropagation* dalam mencapai minimum global terhadap nilai *error*, serta cepat tidaknya proses pelatihan menuju kekonvergenan. Apabila nilai bobot awal terlalu besar, maka *input* ke setiap lapisan tersembunyi atau lapisan *output* akan jatuh pada daerah dimana turunan fungsi sigmoidnya akan kecil. sebaliknya, apabila nilai bobot awal terlalu kecil, maka input ke setiap lapisan tersembunyi atau lapisan *output* akan sangat kecil, yang akan menyebabkan proses pelatihan akan berjalan sangat lambat. Biasanya bobot awal diinisialisasi secara acak dengan nilai antara -0,5 sampai 0,5 (atau -1 sampai 1, atau interval yang lainnya).

DAFTAR PUSTAKA

- A. Siddhpura & R. Paurobally, *A review of flank wear prediction methods for tool condition monitoring in a turning process, International Journal Advance Manufacture Technology* 65:371–393, 2013.

- Dimla Snr. D.E., *Multivariate tool condition monitoring in a metal cutting operation using neural networks*. Ph.D. thesis, School of Engineering and the Built Environment, The University of Wolverhampton, UK, 1998.
- Dimla E. Dimla Snr., *Sensor signals for tool-wear monitoring in metal cutting operations—a review of methods*, International Journal of Machine Tools & Manufacture Vol 40. pp 1073–1098, 2000.
- Dimla Snr D.E., *Tool wear monitoring using cutting force measurements*, in: 15th NCMR: Advances in Manufacturing Technology XIII, University of Bath, 6–8 September, 1999, pp. 33–37.
- Dimla Snr D.E., P.M. Lister, *On-line metal cutting tool condition monitoring—I: Force and vibration analyses*, International Journal of Machine Tools and Manufacture, Vol 40 (5) 739–768, 2000.
- D.R. Salgado, F.J. Alonso, *An approach based on current and sound signals for n-process tool wear monitoring*, International Journal of Machine Tools & Manufacture 47 (2007) 2140–2152
- F.J. Alonso, D.R. Salgado, *Application of singular spectrum analysis to tool wear detection using sound signals*, Proceedings of the IMechE Journal of Engineering Manufacture 219 (9) (2005) 703–710
- Hongli Gao, Mingheng Xu, *Intelligent Tool Condition Monitoring System for Turning Operations*, School Of Mechanical Engineering, Southwest Jiaotong University Chengdu, Sichuan 610031, China, 2005.
- ISO 3685, International standard second edition, 1993.
- Jong Jek Siang, *Jaringan syaraf tiruan*, Andi, 2005.
- Matlab, 2010. Help File
- Muslim Mahardika, *Neural Networks Prediction of Cutting Tool Wear During Turning Operation. Master Thesis*, University of malaya, 2005.
- Puhar J., *1st Seminar on Manufacturing Technologies*, University of Ljubljana, Slovenia, pp. 1–19, 1999.
- Rao P. N. 2000. *Manufacturing Technology, Metal Cutting and Machine Tools*, Singapore : McGraw Hill Higher Education.,
- Taylor F.W., *Trans. ASME*, 28:31-279, 1907.
- Tien-I Liu, Shin-Da Song, George Liu, Zhang Wu, *Online monitoring and measurements of tool wear for precision turning of stainless steel parts*, International journal advance manufacture technology, vol.65 pp.1397-1407, 2013.
- Tizit Maxiflex Universal Tooling System Catalogue, 2002
- Usha Nair, Bindu M. Krishna, V. N. N. Namboothiri and V. P. N. Nampoori, *Permutation entropy based real-time chatter detection using audio signal in turning process*, International Journal Advance Manufacture Technology vol 46, pp 61–68. 2010.