

PEMILIHAN FITUR UNTUK *MONITORING* DAN KLASIFIKASI KONDISI PAHAT

Syaiful¹⁾ dan Herianto²⁾

¹⁾ Departemen Teknik Mesin dan Industri, Universitas Gadjah Mada, Yogyakarta, Indonesia
(Tel: 081-878-1266-9407; E-mail: syaifulmansyur1986@gmail.com)

²⁾ Departemen Teknik Mesin dan Industri, Universitas Gadjah Mada, Yogyakarta, Indonesia
(Tel: 081-858-4275-2865; E-mail: herianto@ugm.ac.id)

Abstract

Tool Condition Monitoring system (TCM) is an application for monitoring condition of tool where mounted on a CNC machining system. A good of TCM application is that which is capable of features mapping the signals obtained from the sensor system to appropriate class (tool condition). This study aimed to optimizing the dataset from the sensor signal in the previous study, with the features selection or features reduction, and with optimization parameters decision-making system to separate the two conditions, that is normal tool and breakage tool.

There are 1800x282 dimensional data, where obtained from the two transformed feature in the time domain and frequency domain. The results of the transformation are selected features by comparing three methods of feature selection that is Fishers Discriminant Ratio (FDR), Sequential Forward Selection (SFS). The result of selected method is L-SVM, and there are selected 10 best features by FDR to be input to the neural network backpropagation method. The system had accuracy test 97,8% in normal condition of tool and 98,9% in breakage condition of tool. Reduction feature by Principal component Analysis (PCA) it's using from selected feature. It takes for understanding how spindle rotate influence to classification the tool condition.

Keyword : *Optimization, Feature Selection, Feature Reduction, Tool Condition Monitoring, Neural Networks*

1. Pendahuluan

Latar Belakang

Penelitian mengenai *tool condition monitoring* telah mengalami perkembangan yang cukup pesat. Hal ini dikarenakan dibutuhkannya suatu sistem yang dapat mengetahui kondisi *tool* tersebut secara baik. Berbagai macam cara dan metode digunakan untuk melakukan monitoring terhadap kondisi *tool* tersebut, baik secara langsung maupun tidak langsung (Bassiuny & Li, 2007). Penggunaan sensor termasuk dalam monitoring *tool* secara tidak langsung, salah satunya penelitian yang dilakukan oleh Scheffer (1999) yang menggunakan *strain* dan *accelerometer* untuk memantau kondisi

pahat aus pada *turning* dengan mengukur sinyal getaran. Secara lengkapnya langkah-langkah proses *tool condition* adalah: menangkap gejala fisik permesinan dengan sensor; mengolah data sinyal sensor; ekstraksi fitur sinyal; penilaian kondisi pahat (Teti *et al.*, 2010). Penilaian kondisi pahat dapat dilakukan dengan menggunakan beberapa cara: *Artificial Neural Network* (Gao, 2006); *fuzzy logic* (Jun & Suh, 1999; Teti *et al.*, 2010), *Genetic Algorithm* (Jia *et al.*, 2011), ambang batas secara langsung; analisis *time-series*.

Berbagai macam sensor dapat digunakan dalam penilaian kondisi pahat, misalnya dengan sensor getaran, sinyal arus listrik dan sinyal audio. Namun penggunaan sensor yang

berlebihan dapat mengurangi efisiensi dari sensor tersebut. Untuk melakukan pemantauan kondisi *tool*, saat ini telah banyak digunakan sensor yang sangat sensitif dengan harga yang sangat mahal, hal itu membuat perusahaan yang menggunakan pemantauan *tool* ini harus mengeluarkan biaya untuk mengetahui kondisi *tool* tersebut dan seperti yang diketahui biaya yang dikeluarkan apabila tidak menggunakan pemantauan kondisi *tool* adalah kualitas produk yang tidak standar, produktivitas menurun, *downtime* pada mesin akan meningkat, dan lain-lain. Penggunaan sensor yang tepat, dapat menghasilkan rekaman data yang jelas dan kemudian dapat diolah untuk menilai kondisi *tool* tersebut.

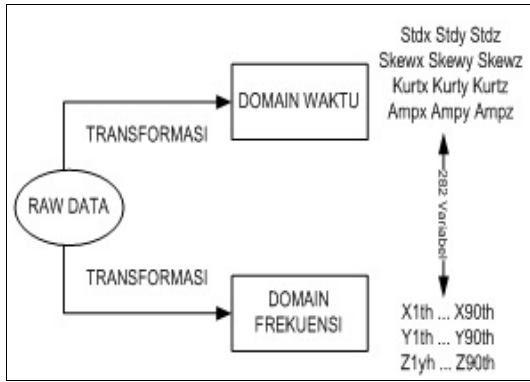
Proses pemilihan metode preprosesing data sangat mempengaruhi kinerja akhir dari sebuah klasifikator karena dimensi fitur set yang terlalu tinggi memberikan efek negatif dalam performansi sistem pengenalan pola. Semakin banyak fitur maka semakin mengurangi akurasi klasifikasi karena boleh jadi fitur tersebut memiliki data yang *redundant* sehingga tidak informatif lagi, (Oluleye *et al*, 2014). Tugas utama dalam pemilihan fitur adalah bagaimana cara memilih fitur yang paling penting diantara kandidat tersebut sehingga dapat mengurangi jumlahnya, dan pada saat yang sama memungkinkan memberikan diskriminasi kelas yang baik. Fase pemilihan fitur merupakan fase yang kritis, karena jika fitur yang dipilih memiliki kekuatan diskriminasi yang kecil akan berakibat desain klasifikator yang dibentuk mempunyai kinerja yang buruk. Sebaliknya, jika fitur kaya informasi saja yang dipilih, maka desain klasifikator yang dibentuk menjadi sangat sederhana. Ini berarti fitur harus mempunyai nilai perbedaan yang jauh dalam kelas yang berbeda dan nilainya dekat dalam kelas yang sama.

Penelitian yang dilakukan sebelumnya oleh Arendra (2014) yaitu memisahkan atau mengklasifikasikan kondisi pahat normal dan rusak. Pahat normal diidentifikasi secara visual dengan pahat baru, sedangkan pahat rusak diidentifikasi dengan *chipping* pada mata potongnya atau V_{bmax} sebesar 0,6 mm. Penelitian sebelumnya dilakukan dengan

mengabaikan bahwa ada tiga mode kecepatan atau putaran *spindel* (RPM), padahal putaran *spindel* sangat berpengaruh terhadap kondisi pahat. Dimana, semakin cepat putaran *spindel*, maka proses menuju kerusakan pahat juga semakin cepat, sehingga putaran *spindel* dapat digunakan sebagai salah satu faktor pendeteksian kondisi pahat. Selain putaran *spindel* ada tiga mode jangkauan pemakanan mata pahat per milimeter (*Feed per Tooth/mm*) dan total pengamatan yang dilakukan adalah sebanyak 1800 kali percobaan. Pada penelitian sebelumnya, pemilihan fitur dilakukan dengan menggunakan teknik/metode analisis korelasi dengan cara memilih fitur yang paling berpengaruh terhadap kondisi pahat normal dan rusak. Penelitian saat ini dilakukan dengan menggunakan *dataset* yang telah diteliti (Arendra, 2014), *dataset* terdiri dari hasil transformasi fitur pada domain waktu dan domain frekuensi, dengan dimensi 1800x282 data. Tujuan dari penelitian yang dilakukan saat ini adalah untuk melihat sejauh mana kecepatan putaran *spindel* berpengaruh terhadap kondisi pahat, yaitu dengan memisahkan atau mengklasifikasikan *dataset* tersebut sesuai dengan *treatment* percobaannya (putaran *spindel*) pada Tabel 1. Sehingga, hasil yang diperoleh nantinya dapat digunakan sebagai panduan untuk penelitian selanjutnya yaitu dengan menambah jumlah percobaan pada setiap putaran *spindle* sehingga memperoleh set data yang lebih banyak.

2. Metodologi


Sebuah sensor *accelerometer* dipasang pada *fixture* benda kerja yang akan menghasilkan sinyal getaran kontinyu pada saat proses permesinan berlangsung. Sinyal getaran ini akan dikonversi menjadi sinyal diskrit oleh data *acquisition* sehingga memudahkan pengolahannya. Berbagai macam metode transformasi fitur yang ditawarkan. Pada penelitian ini ekstraksi fitur sinyal dilakukan dengan menggunakan data *descriptive statistics* (domain waktu) dan tranformasi *fourier* (domain frekuensi).



Gambar 1. Ilustrasi 282 data variabel per sampel

Strategi pemilihan fitur


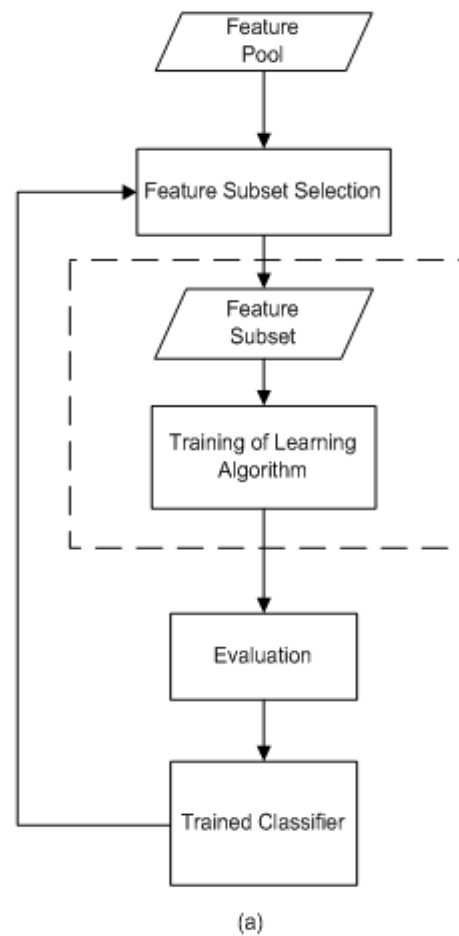
Terdapat dua pendekatan dalam proses pemilihan fitur, yaitu pendekatan *filter* dan pendekatan *wrapper*. Pendekatan *filter* dapat didefinisikan, dimana metrik digunakan pada kriteria lokal atau secara independen dan berbeda dengan model target. Sedangkan pendekatan *wrapper* didefinisikan, dimana metrik ditentukan oleh performa atau akurasi dari model target (Gambar 2).



Gambar 2. Pendekatan dalam pemilihan fitur

Penggunaan metode dalam pemilihan fitur sangat berpengaruh terhadap akurasi klasifikasi pada bagian akhir proses penelitian. Metode *wrapper* secara sistem sangat mahal dari segi komputasi karena metode ini menggunakan *learning algorithm* didalam melakukan pencarian fitur yang paling memenuhi kriteria (fungsi objektif) terhadap target. Pendekatan *filter* tidak memerlukan waktu dan biaya yang lama dalam komputasinya, sehingga pada penelitian ini sangat efisien jika menggunakan pendekatan filter. Gambar 3

menunjukkan *flowchart* dari kedua pendekatan tersebut.



Gambar 3. (a). *Flowchart* pendekatan *wrapper*
(b). *Flowchart* pendekatan *filter*

Pendekatan *wrapper* (3a) akan melakukan *feedback* dalam proses pemilihan fitur, ini terjadi karena algoritma pembelajaran yang digunakan harus mengevaluasi kembali subset fitur yang terpilih, apakah sudah fit atau belum. Sedangkan dalam pendekatan *filter* (3b), fitur subset akan dipilih langsung secara sekuensial, korelasi ataupun dengan metode lain tanpa ada proses evaluasi fitur yang dipilih. Pada penelitian ini akan dievaluasi kombinasi fitur terpilih dari dua metode pendekatan pemilihan fitur.

Penelitian dilakukan berdasarkan *treatment* putaran *spindel* yang diikuti dengan *Feed per Tooth* dari proses pemotongan oleh pahat *end-mill*.

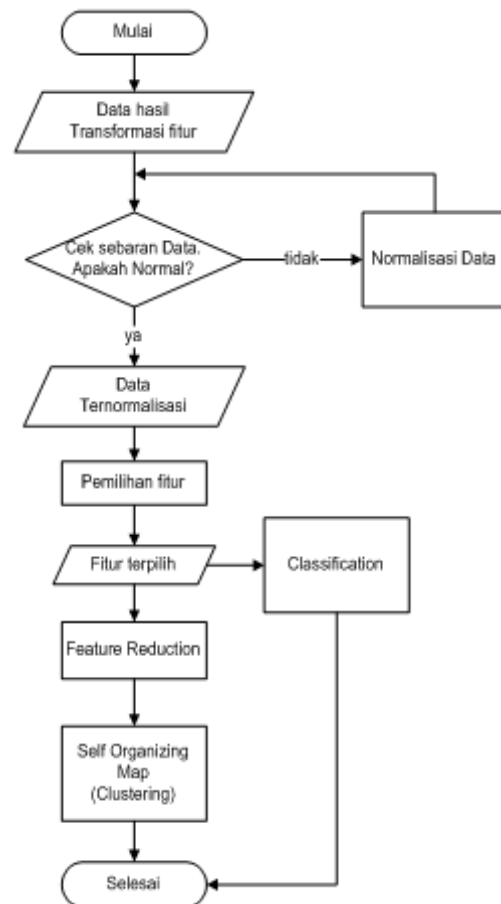
Tabel 1. Daftar *treatment* percobaan

| No. Treatment | Kondisi Pahat | Putaran Spindel (RPM) | Feed per Tooth (mm) |
|---------------|--------------------|-----------------------|---------------------|
| 1 | Normal (Kondisi 1) | 750 | 0.08 |
| 2 | | | 0.05 |
| 3 | | | 0.02 |
| 4 | | 650 | 0.08 |
| 5 | | | 0.05 |
| 6 | | | 0.02 |
| 7 | | 550 | 0.08 |
| 8 | | | 0.05 |
| 9 | | | 0.02 |
| 10 | Rusak (Kondisi 2) | 750 | 0.08 |
| 11 | | | 0.05 |
| 12 | | | 0.02 |
| 13 | | 650 | 0.08 |
| 14 | | | 0.05 |
| 15 | | | 0.02 |
| 16 | | 550 | 0.08 |
| 17 | | | 0.05 |
| 18 | | | 0.02 |

Berdasarkan Tabel 1, diketahui bahwa ada tiga kondisi kecepatan putaran *spindel* dan parameter pemotongan. Dari kondisi tersebut akan dilakukan pemisahan sebanyak 3 kelas dari tiap kondisi pahat yaitu, kondisi pahat normal atau kondisi 1, dan kondisi pahat rusak atau kondisi 2. Pemisahan ini sangat penting dilakukan dengan tujuan utamanya dapat memudahkan pembacaan dan monitoring yang nantinya akan dilakukan

pada *display* mesin *CNC milling* pada tiap kondisi pahat. Selain itu, sensor-sensor yang digunakan harganya sangat terjangkau dan sangat banyak dijual dipasaran di Indonesia.

Pada proses keputusan akhir akan dilakukan optimasi parameter pada metode Jaringan Syaraf Tiruan dengan jaringan *Multi Layer Perceptron* untuk menguji akurasi klasifikasi kondisi pahat.



Gambar 4. Flowchart proses penelitian

Dataset yang digunakan merupakan hasil transformasi yang dilakukan oleh penelitian sebelumnya. Dimana data set tersebut adalah sebuah matriks berukuran 900 x 282 untuk tiap kondisi pahat. 900 merupakan banyaknya jumlah percobaan dan 282 adalah hasil transformasi fitur pada domain waktu dan frekuensi, yang terdiri dari:

Fitur&Atribut i =

| | | | | |
|--------|--------|--------|---------|-----|
| (stdxi | skewxi | kurtxi | rangexi | ... |
| stdyi | skewyi | kurtyi | rangeyi | ... |
| stdzi | skewzi | kurtzi | rangezi | ... |
| X1th | X2th | ... | X90th | ... |
| Y1th | Y2th | ... | Y90th | ... |
| Z1th | Z2th | ... | Z90th | ... |

Labeli)

Berikutnya, untuk Fitur & Label i dari $i = 1$ hingga $i = 900$ disusun dalam matrik Fitur&Label berukuran 900×282 . Sehingga jumlah untuk semua kondisi pahat adalah matrik berukuran 1800×282 .

$$\text{Fitur\&Label} = \begin{Bmatrix} \text{Fitur\&Label 1} \\ \text{Fitur\&Label 2} \\ \vdots \\ \text{Fitur\&Label 1800} \end{Bmatrix}$$

Pada fase ekstraksi fitur, masih ada diantara atribut-atribut tersebut yang diskriminasinya kecil yang akan menyebabkan klasifikator mengklasifikasikan kondisi pahat dengan tidak relevan, sehingga akan dilakukan perbandingan dua penyeleksi fitur dengan pendekatan *filter* dan *wrapper*. Untuk pendekatan *filter* digunakan *Fisher's Discriminant Ratio (FDR)* sedangkan untuk pendekatan *wrapper* digunakan *Sequential Forward Selection (SFS)*.

4. Hasil dan Pembahasan

Dari hasil transformasi data yang telah didapatkan, selanjutnya dilakukan perbandingan dua metode pemilihan fitur. Sehingga dapat diketahui, metode mana yang paling baik digunakan pada penelitian ini. Setelah terpilih metode pemilihan fiturnya, hasilnya digunakan sebagai *input* pada metode klasifikasi *Multi Layer Perceptron* dengan algoritma *backpropagation*.

Pemilihan fitur


Tabel 2. Hasil uji coba metode pemilihan fitur *FDR* untuk dua kondisi pahat dengan tiga kelas


| METODE PEMILIHAN FITUR (FDR) | | | |
|--------------------------------------------------------------------------------------|-------------------|-----------------------------------------------------------------------------------------------|-------------------|
| Kondisi Pahat Normal (Kondisi 1) | | Kondisi Pahat Rusak (Kondisi 2) | |
| FDR (WAKTU) | | FDR (WAKTU) | |
| $(skewZ - kurtZ - skewY - kurtX - stdZ - kurtY - stdY)$ | 7 Fitur Terpilih | $(stdY - stdZ - stdX - rangeZ - rangeY - rangeX - skewZ - kurtZ)$ | 8 Fitur Terpilih |
| FDR (ORDER) | | FDR (ORDER) | |
| $(X43th - X42th - X40th - X41th - X44th - Z3th - X6th - Z32th - X3th - X4th - Y7th)$ | 11 Fitur Terpilih | $(X42th - X43th - X41th - X40th - X74th - X1th - X44th - X39th - X75th - Y9th - Z3th - Y7th)$ | 12 Fitur Terpilih |
| 18 fitur terpilih | | 20 fitur terpilih | |
| Akurasi terbaik 97.8% | | Akurasi terbaik 98.9% | |

Tabel 3. Hasil uji coba metode pemilihan fitur *SFS* untuk dua kondisi pahat dengan 3 kelas

| METODE PEMILIHAN FITUR (SFS) | | | |
|-------------------------------------------------------------------|------------------|------------------------------------------------------------------|------------------|
| Kondisi Pahat Normal (Kondisi 1) | | Kondisi Pahat Normal (Kondisi 2) | |
| SFS (WAKTU) | | SFS (WAKTU) | |
| $(kurtX - stdY - skewZ - rangeZ - kurtZ - SkewY - kurtY - skewX)$ | 8 Fitur Terpilih | $(stdY - kurtY - stdZ - skewZ - rangeY - stdX - kurtZ - rangeZ)$ | 8 Fitur Terpilih |
| SFS (ORDER) | | SFS (ORDER) | |
| $(X1th)$ | 1 fitur terpilih | $(X1th)$ | 1 fitur terpilih |
| 9 fitur terpilih | | 9 fitur terpilih | |
| Akurasi terbaik 80.7% | | Akurasi terbaik 80.0% | |

Dari hasil pengujian perbandingan metode pemilihan fitur pada Tabel 2 dan Tabel 3, dapat dilihat bahwa pemilihan fitur berpengaruh besar terhadap kinerja klasifikator. Saat pemilihan fitur menggunakan metode *FDR*, banyaknya fitur terpilih terjadi karena fitur terseleksi berdasarkan pemilihan diskriminan terbesar berada pada fitur order Xth . Sementara, metode *SFS* secara otomatis hanya memilih satu fitur yang memenuhi kriteria pada fitur order Xth . Menurunnya tingkat akurasi, terjadi karena pemisahan tiga kelas membutuhkan variabel/fitur yang banyak, dimana fitur ini dapat meningkatkan tingkat akurasi yang tinggi.





(b)

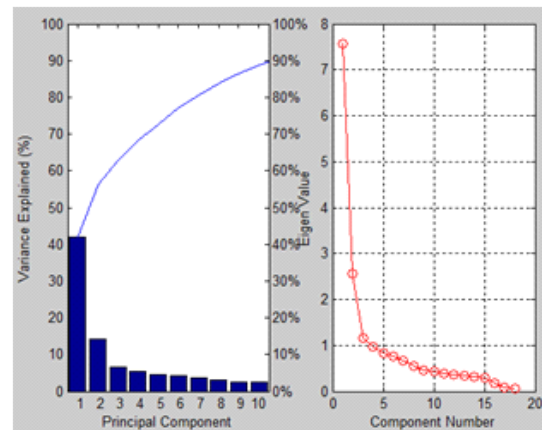
Gambar 5. Plot data normal (a) dan rusak (b) fitur terpilih yang dapat di korelasikan dengan putaran *spindel* (RPM) dan *Feed per Tooth* (mm)

Pola fitur data terpilih dari dua pendekatan yang digunakan, dapat dipisahkan dan berkorelasi dengan putaran *spindel* dan *Feed per Tooth* dari pahat. Dimana, semakin besar putaran *spindel* yang digunakan maka lebar antar data juga akan semakin besar. Gambar 5 menunjukkan putaran *spindel*, yang paling tinggi dalam kasus ini berada pada putaran 750 RPM, artinya bahwa data-data pada treatment ini teridentifikasi terdapat pada batas atas dari tiap kondisi pahat.

Reduksi Dimensi Fitur

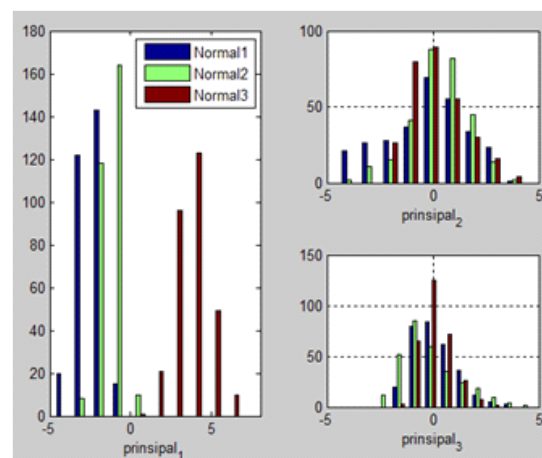
PCA atau *Principal component Analysis* adalah suatu teknik handal untuk mengekstraksi struktur dari suatu set data dengan dimensi yang cukup banyak. Seringkali hanya dengan beberapa *principal component* sudah cukup untuk menjelaskan struktur dari data. Jika dalam dimensi asli sulit direpresentasikan melalui grafik, maka dengan beberapa PC bisa digambarkan melalui grafik. Pada penelitian ini dimensi yang direduksi adalah dimensi dari fitur yang telah terpilih dari metode *FDR*.

Pahat Normal




Gambar 6. Diagram *pareto* (kiri) dan *Scree plot* *PCA* (kanan) hasil reduksi

Gambar 6 memperlihatkan hasil reduksi yang dilakukan oleh *PCA*, dimana terlihat 3 PC atau sebanyak 63% sudah cukup mewakili variansi dari dimensi aslinya, sedangkan sisanya terdistribusi dalam prinsipal berikutnya.




Gambar 7. *Histogram* perbandingan pahat Normal 1 – 3

Pahat normal 1, 2 dan 3, sangat jelas terpisah pada komponen prinsipal pertama. Pada Gambar 7, terlihat bahwa kondisi pahat normal 3 (merah), terpisah sangat jelas dari grafik pahat normal lainnya hal ini berkesesuaian dengan kondisi putaran *spindel* 750 RPM. Apabila prinsipal pertama diambil plot datanya, maka akan terlihat seperti pada Gambar 8(b)



(a)




(b)

Gambar 8. Perbandingan plot data sebelum (a) dan sesudah (b) melakukan reduksi dimensi


Pahat Rusak

Seperti pada pahat normal, pengujian/percobaan pada pahat rusak juga akan dilakukan dengan model pendekatan yang sama.




Gambar 9. Diagram pareto (kiri) dan *Scree plot* PCA (kanan) hasil reduksi


Pada grafik *scree plot* PCA (Gambar 8), terlihat PC 2 da PCA 3 mengalami kerapatan lebar data sama halnya seperti pahat normal sebelumnya, sehingga pada histogram (Gambar 10) akan terlihat pahat rusak 2 dan 3 terjadi hal yang sama.



Gambar 10. Histogram perbandingan pahat Rusak 1 – 3



(a)




(b)


Gambar 11. Perbandingan *plot* data sebelum (a) dan sesudah (b) melakukan reduksi dimensi

Klustering

Klustering digunakan untuk memisahkan data dan/vektor kedalam sejumlah kelompok (kluster) menurut karakteristik-nya masing-masing. Pada klustering, segera setelah kluster terbentuk, maka label kelas untuk setiap data dapat diberikan dengan mengamati hasil kluster. Pembelajaran tak terbimbing (*unsupervised*) seperti klustering dapat digunakan untuk mengeksplorasi dan mengkarak-teristikkan set data sebelum melakukan pembelajaran yang terbimbing (*supervised*).



(a)



(b)

Gambar 12. Hasil klustering menggunakan *k-means* terhadap pahat normal (a) dan pahat rusak (b)

Dari Gambar 12 (a,b), dapat diketahui bahwa setelah dilakukan reduksi dimensi dengan menggunakan *PCA*, data hasil reduksi dapat dikelompokkan menjadi 3 kelas. Hal ini berkesesuaian dengan data awal yang

diklasifikasikan menjadi 3 kelas.

4. Kesimpulan

Pemilihan metode seleksi fitur sangat besar pengaruhnya terhadap kinerja klasifikator secara keseluruhan. Pada kasus ini, dataset yang sebelumnya digunakan untuk memisahkan dua kelas (pahat normal dan pahat rusak), ternyata mampu diolah lagi menjadi enam kelas secara keseluruhan. Tiap kondisi diklasifikasikan menjadi tiga kelas sesuai dengan *treatment* putaran *spindle*, hal ini dilakukan agar klasifikator mampu bekerja secara optimal. Dengan menggunakan metode pemilihan fitur FDR diperoleh pada kondisi pahat normal terpilih 18 fitur yang paling baik, sedangkan untuk kondisi pahat rusak terpilih 20 fitur terbaik.

Tiap kecepatan putaran *spindel* mampu mengetahui kondisi pahat berada dikelas mana. Semakin besar putaran *spindel*, maka lebar data semakin besar. Sehingga, untuk penelitian selanjutnya diperlukan jumlah percobaan yang lebih banyak pada tiap putaran *spindle* agar dapat terlihat lebih jelas pemisahan kelas yang terjadi.

Dari hasil percobaan yang telah dilakukan, akurasi yang diperoleh dengan menggunakan metode pemilihan fitur FDR adalah sebesar 97,8% pada kondisi pahat normal dan 98,9% pada kondisi pahat rusak.

Daftar Pustaka

- Aliustaoglu, C., Ertunc, H. M., and Ocak, H., 2009, Tool Wear Condition Monitoring using a Sensor Fusion Model Based on Fuzzy Inference System, *Mechanical Systems and Signal Processing*, 23(2), 539–546
- Arendra, 2014, Deteksi on-line kondisi pahat PC-Based CNC milling menggunakan tri-axial Mems Accelerometer dengan JST, *Tesis*, Program Studi Teknik Mesin, Universitas Gadjah Mada, Yogyakarta.
- Baek, D.K., Ko, T.J., and Kim, H.S., 2000, Real Time Monitoring of Tool Breakage in a Milling Operation using a Digital Signal Processor, *Journal of Materials Processing Technology*, 100(1-3), 266–272.

- Bagci, E., 2011, Monitoring and Analysis of MRR-Based Feedrate Optimization Approach and Effects of Cutting Conditions using Acoustic Sound Pressure Level in Free-form Surface Milling, *Scientific Research and Essays*, 6(2), 256–277.
- Botsaris, P. N., and Tsanakas, J. A., 2008, State of The Art in Methods Applied to Tool Condition Monitoring (TCM) in Unmanned Machining Operations: A Review, *Proceedings of The International Conference of COMADEM*, Prague, 73–87.
- Chen, S., and Jen, Y. W., 2000, Data Fusion Neural Network for Tool Condition Monitoring in CNC Milling Machining, *International Journal of Machine Tools & Manufacture*, 40, 381–400.
- Coleman, D. E. and D. C. Montgomery., 1993, A Systematic Approach to Planning for a Designed Industrial Experiment, (with discussion), *Technometrics*, Vol.35, No.1.
- Cho, S., Binsaeid, S., and Asfour, S., 2009, Design of Multi Sensor Fusion – Based Tool Condition Monitoring System in End Milling, *International Journal Adv. Manufacture Technology*, 1–14.
- Macqueen, J., 1967, Some Methods for Classification and Analysis of Multivariate Deservation, *Proceddings of the Fall Joint Computers Conference*, 281–297.
- Navidi, W., 2009, *Statistics for Engineers and Scientists* Third ed, Mc Graw Hill, New York.
- Oluleye, B., Leisa, A., Leng, J., and Dean, D., 2014, Zernike Moments and Genetic Algorithm: Tutorial and Aplication, *British Journal of Mathematics & Computer Science*, 4(5), 2217–2236.
- Prasetyo, B., 2014, *Data Mining: Mengolah Data Menjadi Informasi Menggunakan MATLAB*, Edisi I, Andi Publisher, Yogyakarta.
- Rui,G.S., and Steven, J., 2008, Sensor Based Condition Monitoring Feature Selection using Self Organizing Map, *World Congress on Engineering*, Vol.2, 1-6
- Santosa, 2007, Pemilihan variabel dalam kasus klasifikasi multikelas dan regresi dengan support vector machines”, LPPM-ITS, Surabaya.
- Scheffer, C., 1999, Monitoring of Tool Wear In Turning Operations Using Vibration Measurements, *Master Thesis*, University of Pretoria, South Africa.
- Soltani, J., Hosseini, E., Zhang, Y., and Chen, C., 2013, Online Tool Monitoring and Estimation using Power Signals and S-Transform, *Conference on Control and Fault-Tolerant Sytem (systol)*, 234–238.
- Teti, R., Jemielniak, K., O’Donnell, G., and Dornfeld, D., 2010, Real Time Monitoring of Tool Breakage in a Milling Operation using a Digital Signal Processor, *Advanced Monitoring of Machining Operations, Manufacturing Technology*, 59(2), 717–739.