

Deteksi Dini Kavitasasi Pada Pompa Sentrifugal Menggunakan *Principal Component Analysis (PCA) – Support Vector Machine (SVM)*

Cavitation Detection of Centrifugal Pump Using Principal Component Analysis (PCA) – Support Vector Machine (SVM)

BERLI P KAMIEL, YUDHA Y PAMUNGKAS

ABSTRACT

Centrifugal pump is one of the energy conversion machines that have been widely used in industries such as power plant, petroleum, water treatment, and waste treatment. The use of pumps in the industrial world is crucial in the series of work system of the production process. Seeing the importance of its role, it is very important to maintain its optimal performance and the decrease of its performance will not occur. One of the causes of pump fault is cavitation. The cavitation phenomenon is usually characterized by the appearance of the bubbles in the suction pipe which can affects the components in pump such as impeller and bearing. Therefore, research is needed which aims to detect and develop method to centrifugal pump due to cavitation phenomena. This research was carried out by detecting the initial cavitation in a centrifugal pump. Data processing through extraction of statistical features, statistical data selection using PCA, and classification of PCA data selection results using SVM. Variations in pump operating conditions in this study were variations of valve blockage which aimed to create cavitation in the test rig design. Variations consist of 25% (720°), 50% (1440°), and 75% (2160°) blockage. The PCA process produces the first 3PC which is 90% of the variance used as input in the classification process using SVM. The results of multi class and binary SVM classification were successfully carried out with 100% accuracy. This already showed that the classification model built in the training process and the mapping process is optimal.

Keywords: Centrifugal Pump, Cavitation, Vibration, Rig Test, Statistical Parameters, PCA, SVM.

PENDAHULUAN

Pompa sentrifugal adalah salah satu jenis pompa yang umum digunakan dalam berbagai bidang industri. Pompa sentrifugal memiliki peranan penting dalam rangkaian kerja sistem proses produksi. Oleh karena itu perlu menjaga dari kerusakan dini yang akan terjadi pada komponen di dalam pompa sentrifugal.

Penyebab kerusakan pompa sentrifugal diantaranya adalah korosi, kebocoran *casing*, kebocoran *seal*, poros bengkok atau macet, dan kerusakan impeller (Kurniady,2017). Salah satu penyebab kerusakan tersebut adalah kavitasasi. Kavitasasi adalah fenomena perubahan phase uap zat cair pada fluida yang mengalir yang ditandai dengan gelembung-gelembung uap.

Gangguan kavitasasi pada pompa sentrifugal akan berpengaruh pada penurunan performa dan kerusakan komponen dalamnya. Respon vibrasi dari pompa yang beroperasi dapat dijadikan indikator yang memberikan gambaran tentang kondisi mekanis pompa tersebut (Delly,2009).

Pemantauan sinyal getaran merupakan salah satu metode yang dapat digunakan dalam mendeteksi kavitasasi yang terjadi pada pompa sentrifugal (Scheffer dan Girdhar, 2004). Secara umum, metode deteksi berbasis getaran dapat dibagi menjadi 2 yaitu berdasarkan domain waktu dan domain frekuensi. Dari kedua metode tersebut, memiliki teknik analisis yang berbeda. Kurniady (2017) melakukan penelitian berbasis domain frekuensi (spektrum) sinyal getaran menggunakan *accelerometer* untuk mengetahui kavitasasi dengan mekanisme variasi tutupan katup yang memberikan

hambatan pada aliran. Kamiel & Ramadhan (2017) mengembangkan metode deteksi kavitas berbasis parameter statistik domain waktu. Hasil dari parameter statistik dalam mendeteksi fenomena kavitas terhadap pengaruh kecepatan operasi menunjukkan bahwa, pompa sentrifugal mulai mengalami kavitas pada level lanjut.

Dari analisa domain waktu, ada beberapa langkah yang harus dilakukan diantaranya seleksi parameter statistik dan klasifikasi data/parameter. Teknik PCA merupakan solusi yang dapat digunakan untuk mendeteksi kavitas yang berbasis statistik parameter. Menurut Miranda (2008) PCA atau metode seleksi parameter merupakan teknik penyederhanaan data dengan mentransformasi secara linier sehingga terbentuk sistem koordinat baru dengan varians maksimum. Kamiel (2015) melakukan penelitian diagnosis kerusakan pompa sentrifugal berdasarkan sinyal getaran menggunakan metode PCA. Hasil penelitian menunjukkan metode ini dapat digunakan untuk diagnosis multi-kesalahan untuk pompa sentrifugal. Dengan metode PCA yang dilakukan menunjukkan keakurasi rata-rata hampir diatas 95%. Akan tetapi, metode PCA masih terdapat kelemahan dalam mengklasifikasi data hasil seleksi. Oleh karena itu, perlu metode klasifikasi data yang relevan. Salah satu teknik klasifikasi data yang sedang umum digunakan yaitu Support Vector Machine (SVM).

Menurut Santoso (2007) SVM adalah suatu teknik untuk melakukan prediksi, baik dalam kasus klasifikasi maupun regresi. Sebagai salah satu contohnya pada penelitian (Taghi dkk, 2017) melakukan penelitian menganalisa kavitas pada pompa sentrifugal berbasis sinyal getaran dengan metode multi class SVM dengan tujuan mengumpulkan data getaran eksperimental untuk lima tingkat kavitas yang berbeda. Fitur domain waktu diekstraksi berdasarkan perilaku statistik dari sinyal yang diukur. Hasil penelitian menunjukkan teknik deteksi kavitas berbasis SVM yang mengklasifikasi fitur parameter statistik memberikan perkiraan akurasi 97%.

Sakhtivel dkk. (2016) pada penelitiannya membandingkan dua parameter classifier SVM (C-SVC dan γ -SVC) dengan empat kernel function yang berbeda. Keempat kernel function yang digunakan diantaranya RBF, Linear, Polynomial, dan Sigmoid Function. Hasil klasifikasi menunjukkan semua jenis kernel

function memberikan hasil yang baik, namun pada RBF mempunyai tingkat akurasi yang lebih tinggi dari yang lain yaitu sebesar 99,93 %.

Melihat berbagai penelitian sebelumnya tentang analisa kerusakan kavitas pada pompa sentrifugal, belum ada penelitian yang menggabungkan 2 metode antara PCA dan SVM. Teknik PCA berguna untuk menyeleksi statistik data parameter yang paling baik dan teknik SVM berguna untuk mengklasifikasi data.

PARAMETER STATISTIK

Pemilihan parameter statistik domain waktu yang efektif akan dipaparkan berdasarkan beberapa tinjauan penelitian sebelumnya, khususnya pada pompa sentrifugal. Tabel 1 menunjukkan beberapa penelitian yang menggunakan parameter statistik domain waktu pada pompa sentrifugal. Parameter statistik domain waktu yang digunakan dalam penelitian ini diantaranya Root Mean Square (RMS), Standar deviasi, Peak Value, Mean, Varians, Kurtosis, Crest Factor, dan Skewness. Parameter statistik dirumuskan dalam persamaan berikut:

$$RMS = \sqrt{\frac{1}{n} \sum_{i=1}^N (x_i - \bar{x})^2} \dots \dots \dots (1)$$

$$PeakValue = \frac{\max(x) - \min(x)}{2} \dots \dots \dots (2)$$

$$Standar\ Deviasi = \sqrt{\frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N - 1}} \dots \dots \dots (3)$$

$$Variance = \frac{\sum (x_i - \bar{x})^2}{N - 1} \dots \dots \dots (4)$$

$$Kurtosis = \frac{\sum_{i=1}^N (x_i - \bar{x})^4}{(N - 1) \sigma^4} \dots \dots \dots (5)$$

$$Crest\ Factor = \frac{\max(|x(n)|)}{\sigma} \dots \dots \dots (6)$$

$$Skewness = \frac{1}{T \sigma^3} \sum_{t=1}^T (x) (r_t - \mu)^3 \dots \dots \dots (7)$$

$$Mean = \frac{1}{K} \sum_{k=1}^K x(k) \dots \dots \dots (8)$$

TABEL 1 TINJAUAN PENELITIAN

| Tahun | Author (s) | Objek | Metode | Parameter Statistik |
|-------|---------------------|-------------------|--------------------|--|
| 2013 | Al-Hasymi | Pompa Sentrifugal | Analisis Statistik | PDF, RMS, SD |
| 2015 | Kamiel | Pompa Sentrifugal | PCA | energy level, standard deviation, RMS, kurtosis, variance dan crest factor |
| 2015 | Luo, dkk. | Pompa Sentrifugal | Analisis Statistik | RMS, Crest Factor, Peak, PDF |
| 2016 | Al-Tobi & Al-Sabari | Pompa Sentrifugal | Analisis Statistik | RMS & Peak Value |
| 2017 | Ramadhan | Pompa Sentrifugal | Analisa Statistik | Peak Value, Mean RMS, SD, Crest Factor, variance, kurtosis, dan PDF |
| 2017 | Sofyan | Pompa Sentrifugal | Analisa Statistik | mean, RMS, Standar Deviasi, Varians, kurtosis, dan skewness. |

PRINCIPAL COMPONENT ANALYSIS

Teknik PCA merupakan solusi yang dapat digunakan untuk mendeteksi kavitasi yang berbasis statistik parameter. PCA atau metode seleksi parameter merupakan teknik pederhanaan data dengan mentransformasi secara linier sehingga terbentuk sistem koordinat baru dengan varians maksimum (Miranda,2008). Teknik PCA dapat mengurangi dimensi dari data tanpa menghilangkan informasi penting dari data tersebut.

Penyelesaian dengan *principal component* (PC) dapat menjelaskan struktur data asli dalam proses PCA. Apabila data dalam dimensi asli sulit untuk direpresentasikan melalui grafik, maka dua atau satu PC bisa dicitrakan melalui grafik (Santosa 2007). Misalkan terdapat data dengan susunan sebagai berikut:

$$\mathbf{X} = \begin{pmatrix} x_{11} & x_{12} & \dots & x_{1j} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2j} & \dots & x_{2n} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ x_{i1} & x_{i2} & \dots & x_{ij} & \dots & x_{in} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ x_{m1} & x_{m2} & \dots & x_{mj} & \dots & x_{mn} \end{pmatrix} \dots\dots\dots(9)$$

Hitung nilai rata-rata

$$\mu_{wj} = \frac{1}{m} \sum_{i=1}^m x_{ij}, \dots\dots\dots(10)$$

Hitung matriks covarian C dari vektor eigen

$$\mathbf{C}_x = \frac{1}{m-1} \mathbf{X}^T \mathbf{X} \dots\dots\dots(11)$$

Hitung nilai eigen λ_i dan vektor eigen v_i (1,2, ...,n) dari C

$$\mathbf{C}_x \mathbf{P} = \mathbf{P} \mathbf{\Lambda} \dots\dots\dots(12)$$

$$\mathbf{\Lambda} = (\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n \geq 0)$$

adalah matriks diagonal yang memiliki eigenvalues yang positif dari yang terbesar hingga yang terkecil. Tentukan variabel baru (*principal component*) dengan mengalikan variabel asli dengan matriks vektor eigen.

$$\mathbf{X} = \mathbf{TP}^T \dots\dots\dots(13)$$

SUPPORT VECTOR MACHINE

Metode klasifikasi yang kini banyak dikembangkan dan diterapkan salah satunya adalah *Support Vector Machine* (SVM). Metode ini berakar dari teori pembelajaran statistik yang hasilnya sangat menjanjikan untuk memberikan hasil yang lebih baik daripada metode lain. SVM juga bekerja

dengan baik pada set data berdimensi tinggi, bahkan SVM yang menggunakan teknik kernel harus memetakan data asli dari dimensi asalnya menjadi dimensi lain yang relatif lebih tinggi.

SVM merupakan metode yang digunakan untuk klasifikasi biner. Pertama kali SVM dikemukakan oleh Vapnik pada tahun 1992 dengan menggabungkan beberapa rangkaian konsep di bidang *pattern recognition*. Pada dasarnya, metode ini bekerja dengan menemukan *hyperplane* terbaik yang memisahkan kelompok data pada suatu dimensi dengan sempurna ke dalam dua kelas (Santosa, 2007). *Pattern* dari kedua kelas tersebut diasumsikan telah terpisah sempurna oleh *hyperplane* dalam suatu dimensi yang didefinisikan dengan persamaan 14.

$$\vec{w} \cdot \vec{x} + b = 0 \dots\dots\dots(14)$$

jika \vec{x}_i pada kelas -1, maka seperti yang ditunjukkan pada persamaan 15.

$$\vec{w} \cdot \vec{x}_i + b \leq -1 \dots\dots\dots(15)$$

Sedangkan nilai \vec{x}_i pada kelas +1, ditunjukkan pada persamaan 16.

$$\vec{w} \cdot \vec{x}_i + b \geq +1 \dots\dots\dots(16)$$

Quadratic Programming (QP) problem merupakan usaha dalam memaksimalkan nilai jarak antara *hyperplane* dan titik terdekatnya dengan mencari titik minimalnya seperti persamaan 17.

$$\min_{\vec{w}} \tau(\vec{w}) = \frac{1}{2} \|\vec{w}\|^2 \dots\dots\dots(17)$$

$$y_i (\vec{x}_i \cdot \vec{w} + b) - 1 \geq 0, \forall_i \dots\dots\dots(18)$$

Permasalahan pada Persamaan 17 dan 18 dapat diselesaikan dengan teknik *Lagrange Multiplier* (α_i), seperti pada Persamaan 19 berikut.

$$L(\vec{w}, b, \alpha) = \frac{1}{2} \|\vec{w}\|^2 - \sum_{i=1}^l \alpha_i (y_i ((\vec{x}_i \cdot \vec{w} + b) - 1)); (i = 1, 2, \dots, l) \dots\dots\dots(19)$$

Selanjutnya Persamaan 19 dioptimalisasi dengan memaksimalkan *problem* yang hanya mengandung nilai (α_i), seperti pada Persamaan berikut 20.

$$\sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j x_i x_j \dots\dots\dots(20)$$

Sehingga, didapat Persamaan 21 :

$$\alpha_i \geq 0 (i = 1, 2, \dots, l) \sum_{i=1}^l \alpha_i y_i = 0 \dots\dots(21)$$

Dari persamaan 21 menunjukkan bahwa nilai (α_i) kebanyakan positif, dan *support vector* berkorelasi dengan nilai (α_i) yang bernilai positif ini.

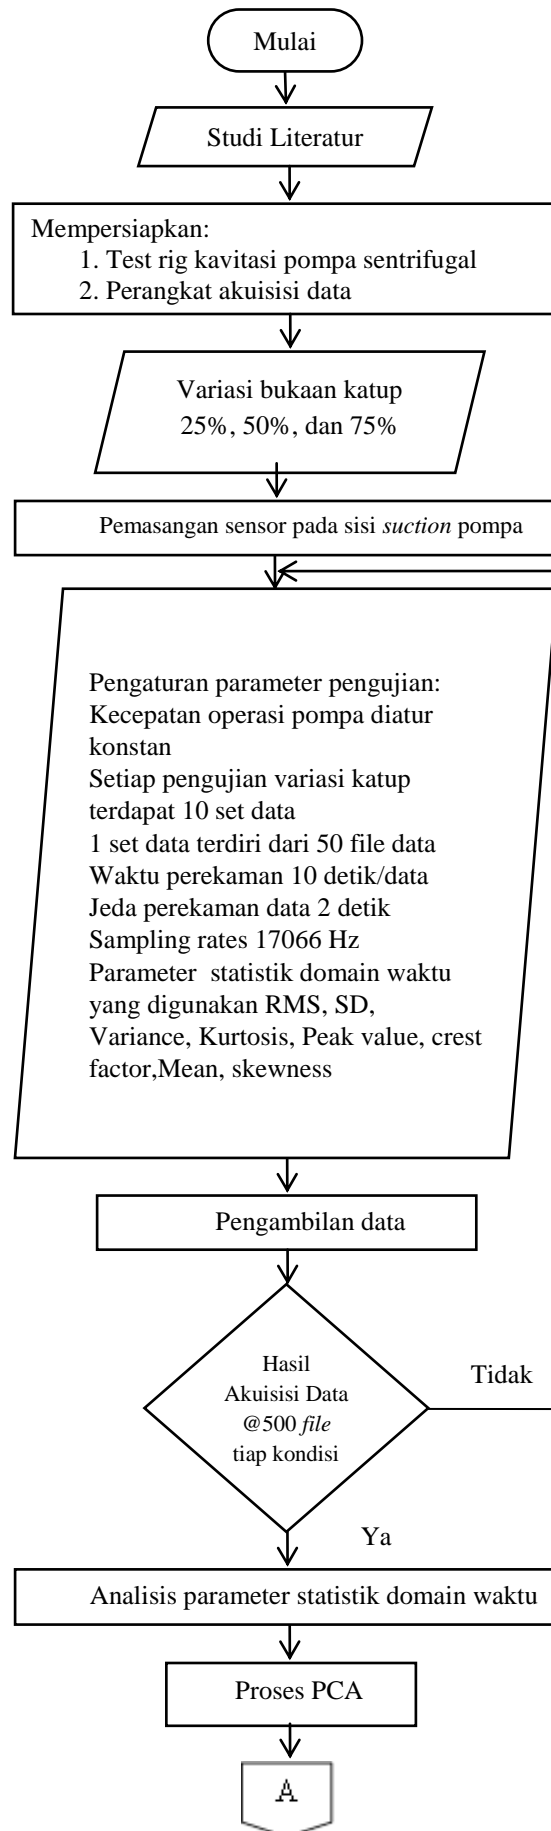
METODOLOGI PENELITIAN

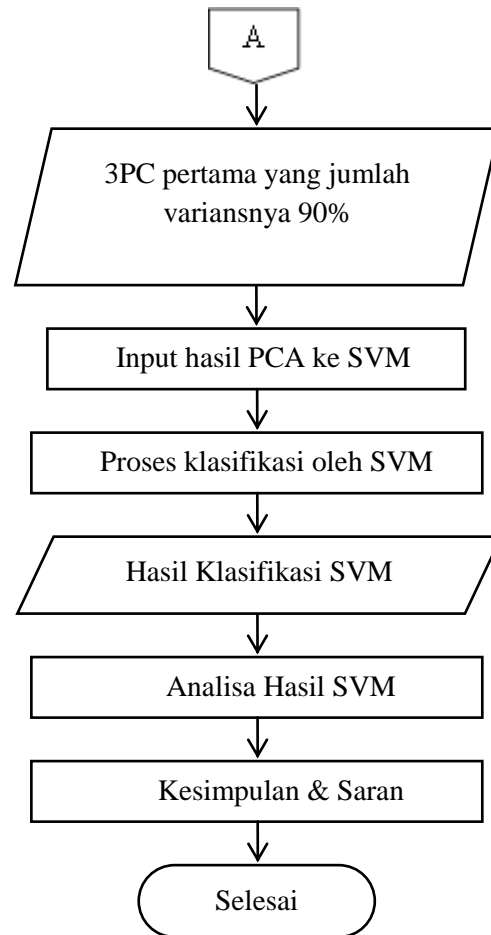
Gambar 1 menunjukkan alur dalam penelitian ini. Penelitian dimulai dengan melakukan studi literature kemudian mempersiapkan perancangan test-rig dan perangkat akuisisi data. Selanjutnya dilakukan proses perekaman data sinyal getaran menggunakan *accelometer*. Kemudian melakukan pengaturan pengujian parameternya. Variasi katup dilakukan guna menciptakan kavitasi dengan cara memvariasikan buka katup untuk kondisi normal, tutupan katup 25% untuk kavitasi level 1, 50% tutupan katup untuk kavitasi level 2, dan 75% tutupan katup untuk kavitasi level 3.

Data akuisisi yang telah direkam kemudian dilakukan proses pengolahan data. Hasil data akuisisi dianalisis ke dalam domain spektrum menggunakan metode *FFT*. Apabila data tersebut telah sesuai seperti rancangan penelitian, maka proses pengolahan data dapat dilakukan. Seluruh proses yang dilakukan pada tahap pengolahan ini menggunakan *software Matlab*. Setiap *file* data akuisisi berbasis domain waktu kemudian di kalkulasi ke dalam parameter statistik yang telah dipilih.

Hasil konversi parameter domain waktu adalah set data dengan dimensi yang banyak. Selanjutnya data akan di ekstraksi dengan menggunakan *PCA*. Proses *PCA* akan menghilangkan kelompok data yang dianggap tidak memiliki informasi penting atau yang mengandung informasi sama dengan data yang lain, sehingga menghasilkan koordinat baru yang menyimpan data yang lebih sederhana tanpa mengurangi karakteristik data tersebut secara signifikan.

Selama mendapat hasil ekstraksi parameter menggunakan *PCA* maka tahapan berikutnya mengklasifikasi menggunakan metode *SVM*. Proses *SVM* akan memilih dan memilah hasil akhir seleksi dari *PCA* untuk mendapat data unggulan yang nantinya menjadi hasil analisa data relevan.






GAMBAR 1. Diagram Alir Penelitian

Data sinyal getaran diambil melalui simulator tes rig kavitasi pada pompa sentrifugal seperti yang ditunjukkan pada Gambar 2. Simlator ini bertujuan untuk mempermudah pengamatan kavitasi yang ada pada pompa sentrifugal. Test rig kavitasi pompa sentrifugal terdiri dari beberapa komponen utama diantaranya pompa sentrifugal 1,5 HP. Sirkulasi fluida terjadi melalui *discharge* dan *suction* pompa. Tanki diletakkan diantara *discharge* dan *suction* yang bertujuan untuk menjaga *suction* mendapatkan fluida yang cukup selama proses pengoperasian pompa. Sebuah *flowmeter* dipasang di sisi *discharge* sebagai laju aliran fluida. Sebuah katup pada sisi *suction* dipasang sebagai pengatur variasi kondisi normal dengan bukaan katup 25% untuk kavitasi level 1, 50% (kavitasi level 2), dan 75% (kavitasi level 3). *Pressure gauge* dipasang pada sisi *discharge* untuk mengetahui nilai tekanan fluida dan *vaccum*


gauge dipasang pada sisi *suction* untuk mengetahui nilai tekanan *vaccum* yang terjadi

Gambar 3 merupakan skematik test rig kavitasi pada pompa sentrifugal pada penelitian ini.. Dari data akuisisi tersebut akan digunakan sebagai indikator metode untuk mendeteksi fenomena kavitasi pada pompa sentrifugal.

Sensor yang digunakan berupa *accelerometer type 4507* yang diletakkan pada sisi *suction* dan *discharge* pompa. Sensor tersebut dihubungkan ke perangkat akuisisi data *NI 9234* yang terpasang pada *chassis NI Compact DAQ 9174* dan terhubung dengan laptop yang memiliki software *Matlab* untuk menyimpan data akuisisi.



GAMBAR 2 TEST RIG KAVITASI POMPA SENTRIFUGAL



GAMBAR 3 SKEMATIK TEST RIG KAVITASI POMPA SENTRIFUGAL

HASIL DAN PEMBAHASAN

Pengujian yang dilakukan memperoleh hasil akuisisi data yang berjumlah 500 *file*, kemudian setiap *file* data tersebut diekstrak ke dalam sejumlah parameter statistik domain waktu. Metode parameter statistik telah banyak digunakan dan bisa memberikan karakteristik fisik dari data domain waktu. Analisis statistik sinyal getaran menghasilkan parameter statistik deskriptif yang berbeda. Hasil analisa karakteristik data dari setiap parameter statistik domain waktu, diantaranya :

1. Root Mean Square

Parameter statistik *RMS* dalam Gambar 4 (a) menunjukkan besar intensitas energi pada nilai

vibrasi yang dihasilkan. Dari keempat variasi kondisi, *RMS* hampir dapat menunjukkan pemisahannya dengan sempurna. Akan tetapi, pada kondisi normal dan kavitasi level 1 tidak menunjukkan perbedaan yang signifikan.

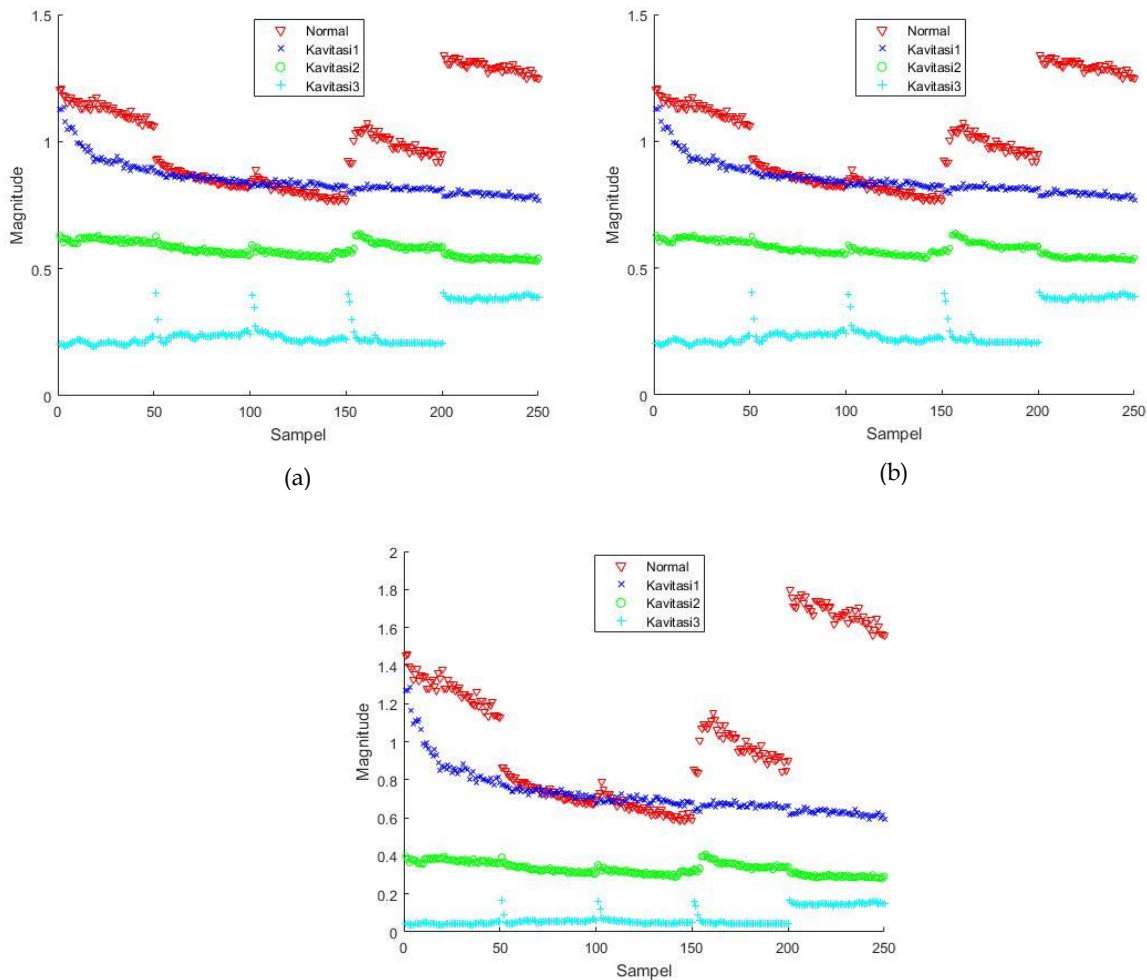
2. Standar Deviasi

Parameter *SD* seperti yang ditunjukkan dapat memperlihatkan perbedaan dari empat variasi kondisi. Namun belum cukup baik dalam memisahkan kondisi normal dan kavitasi level 1 terlihat pada Gambar 4 (b).

3. Variance

Karakteristik parameter *variance* hampir dapat memisahkan keempat variasi kondisi secara sempurna. Seperti halnya *RMS* dan *SD*, parameter ini belum dapat memisahkan

kelompok data normal dan kavitasi level 1 seperti yang ditunjukkan Gambar 4 (c).



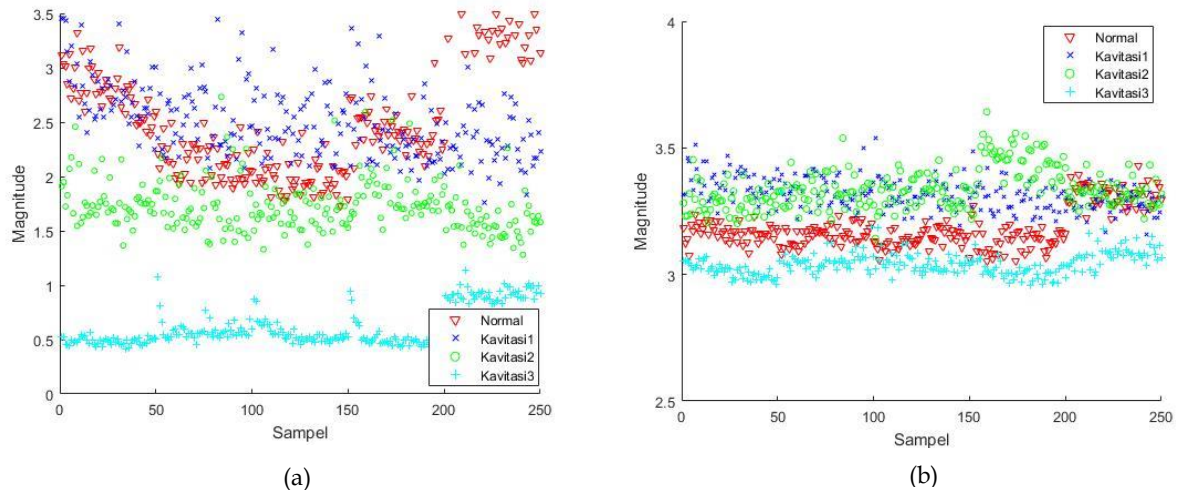
GAMBAR 4 KARAKTERISTIK PARAMETER (A) RMS, (B) STANDAR DEVIASI, (C) VARIANCE

4. Peak Value

Parameter ini sangat sensitif dalam membedakan kelompok data berdasarkan turbulensi aliran. Pada penelitian ini parameter *peak value* tidak dapat membedakan kondisi normal, kavitasi level 1, dan level 2, namun sangat jelas menunjukkan kavitasi level 3 yang ditunjukkan pada Gambar 5 (a). Karakteristik parameter *peak value* tidak dapat membedakan kondisi normal dan kavitasi apabila tidak terjadi perubahan laju aliran.

5. Kurtosis

Parameter *kurtosis* pada keempat variasi kondisi sama sekali tidak dapat terpisahkan. Baik pada kelompok data normal hingga kavitasi level 3 tidak terlihat adanya pemisahan. Hal ini dikarenakan karakteristik parameter *kurtosis* mengubah semua nilai menjadi positif. Oleh karena itu parameter ini tidak mampu memisahkan kelompok data dari kelas yang berbeda yang ditunjukkan pada Gambar 5 (b).

GAMBAR 5 KARAKTERISTIK PARAMETER (A) *PEAK VALUE*, (B) *KURTOSIS*

6. Mean

Nilai parameter *mean* menunjukkan ukuran yang mendominasi keseluruhan data. Karakteristik parameter *mean* sama sekali tidak dapat menunjukkan pemisahan pada keempat variasi kondisi yang ditunjukkan pada Gambar 6 (a).

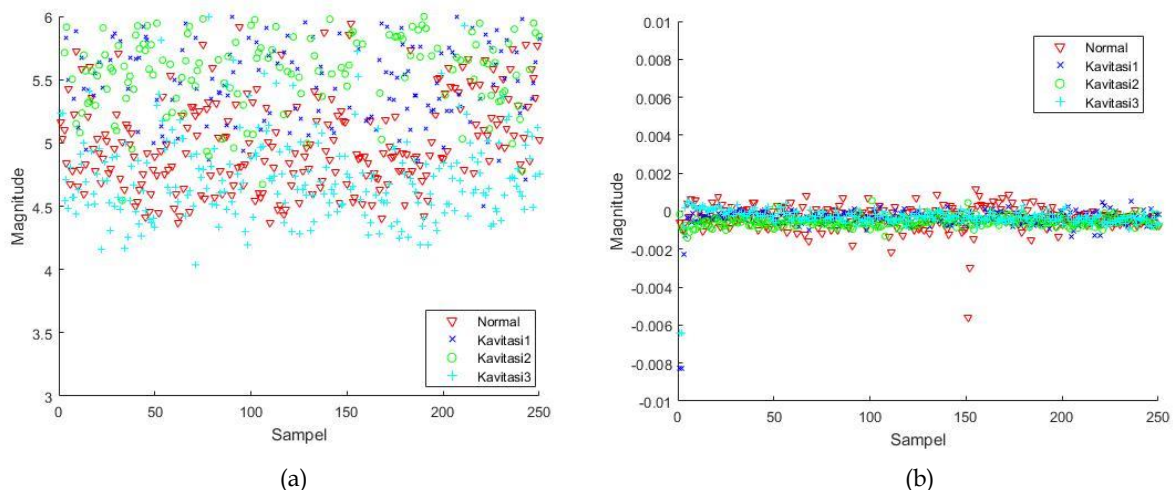
7. Crest Factor


Parameter ini merupakan ukuran ketajaman dan jumlah *peak* pada sinyal. Sehingga dapat

diketahui bahwa ukuran ketajaman suatu sinyal pada variasi kondisi yang berbeda bukan merupakan suatu faktor pembeda sinyal tersebut yang terlihat dalam Gambar 6 (b).

8. Skewness

Parameter *skewness* sama sekali tidak dapat menunjukkan perbedaan dari semua variasi kondisi. Gambar 6 (c) mempresentasikan penyebaran data hasil analisis statistik *skewness*.





GAMBAR 6 KARAKTERISTIK PARAMETER (A) MEAN, (B) CREST FACTOR, (C) SKEWNESS


Pengujian sensitifitas deteksi dini kavitasi menggunakan metode statistik domain waktu memiliki perbedaan plot data *training* yang berbeda. Tiap parameter mempunyai karakter tersendiri dalam menyimpulkan hasil ekstraksi terhadap jumlah sampe data. Hasil tersebut belum mampu mengindikasikan kondisi kavitasi dini, menengah dan lanjut, oleh karena itu perlu metode yang lebih efisien yaitu dengan melakukan kombinasi domain waktu dengan PCA.

Principal Component Analysis

Data yang telah diekstraksi ke dalam delapan parameter statistik merepresentasikan nilai dan hal yang berbeda terhadap sinyal *vibrasi* yang dihasilkan. Setiap parameter statistik yang digunakan mengandung informasi yang dibutuhkan sebagai input klasifikasi, akan tetapi terdapat banyak kesamaan informasi yang direpresentasikan oleh setiap parameter statistiknya.

Apabila input klasifikasi memiliki banyak data dengan kandungan informasi yang sama, maka hasil klasifikasi secara visual akan mengalami penumpukan. Selain itu, tingkat akurasi klasifikasi yang dihasilkan juga menjadi tidak optimal. Oleh karena itu metode seleksi parameter statistik menggunakan PCA sangat dibutuhkan dalam proses persiapan data sebelum klasifikasi.

Sampel data yang diperoleh dikelompokkan menjadi dua yaitu 250 data *training* dan 250 data *testing* tiap kondisi normal, kavitasi level 1, kavitasi level 2 dan kavitasi level 3. Data *training* dinormalisasi dan dilatih menggunakan PCA pada setiap kondisinya. Hasil tersebut akan menggambarkan nilai data *loading matriks*. Data testing yang telah diekstraksi dikalikan dengan loading matriks hasil dari *training* data. Hasil perkalian tersebut menghasilkan *score* yang diperoleh dari permodelan PCA. *Score* akan dijadikan data input klasifikasi menggunakan SVM. Hasil PCA digambarkan pada bagan pareto dari kontribusi 4 *Principal Component* (PC) yang dapat dilihat pada Gambar 7.

GAMBAR 7 GRAFIK PARETO *PRINCIPAL COMPONENTS*

PC1 menyimpan informasi sebesar 54,5%, PC2 menyimpan informasi sebesar 19,9%, PC3 menyimpan informasi sebesar 12,1%, PC4 menyimpan informasi sebesar 9%. Tiga PC

pertama yang berjumlah 90% dianggap sudah mewakili informasi dari keseluruhan informasi. Untuk memastikan kontribusi parameter di dalam Principal Component dapat diperlihatkan pada Tabel 2.

TABEL 2 KONTRIBUSI PARAMETER DALAM *PRINCIPAL COMPONENTS*

| Paramater | PC1 | PC2 | PC3 | PC4 |
|--------------|---------|---------|---------|---------|
| RMS | 0,40694 | 0,18654 | -0,1716 | -0,1843 |
| STDV | 0,40694 | 0,18654 | -0,1716 | -0,1843 |
| Peak Value | 0,41483 | -0,0306 | 0,1433 | -0,243 |
| Kurtosis | 0,34981 | -0,2221 | 0,14758 | 0,82748 |
| Varians | 0,41073 | 0,16462 | -0,1556 | -0,1264 |
| Crest Factor | 0,22059 | -0,4622 | 0,72524 | -0,3165 |
| Mean | -0,0164 | 0,79883 | 0,5719 | 0,15924 |
| Skewness | -0,3959 | 0,03531 | 0,14675 | -0,2164 |

Berdasarkan Table 1 diatas, tiap parameter mempunyai karakteristik yang berbeda untuk memberikan tingkat kontribusinya. Nilai *RMS*, *STDV*, *Peak Value*, dan *Varians* dalam PC1 memberikan kontribusi yang lebih besar dibandingkan parameter lainnya. Selanjutnya, *Mean* memberikan distribusi lebih tinggi dibandingkan parameter lainnya di PC2. *Crest Factor* dan *Mean* memberikan nilai kontribusi lebih besar di dalam PC3. PC4 hanya *Kurtosis* yang memberikan kontribusi yang besar dari

parameter lainnya. Hasil 3 PC pertama dari permodelan PCA yang variansnya berjumlah 90% akan dijadikan input dalam klasifikasi SVM.

Klasifikasi Binary SVM

Proses klasifikasi *binary SVM* bertujuan untuk mengklasifikasikan dua kelas. Ada dua tahap dalam mengklasifikasikan yang perlu dilakukan yaitu proses *training* dan *testing*. Pemisahan

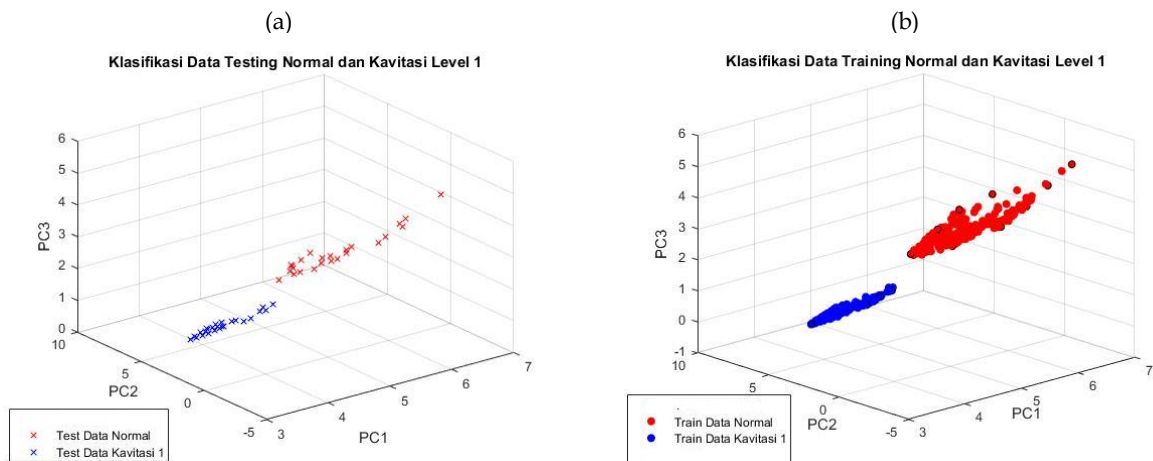
data dilakukan dengan teknik *cross-validation* yang bertujuan mengelompokkan 450 set data untuk *training* dan 50 set data untuk *testing*.

Proses *training* merupakan tahap pembentukan model klasifikasi. Model ini dibangun berdasarkan 450 set data *training* yang


Proses *testing* dilakukan sebagai tahapan evaluasi terhadap model klasifikasi yang dibangun. Sebanyak 50 set data *testing* dari 2 kelas menempati model klasifikasi dan menghitung tingkat akurasi yang diberikan dari pengelompokan data tersebut.

dikelompokkan terhadap tiap kelasnya. Pembentukan model ini memetakan *hyperplane* optimal menggunakan *kernel function RBF*. Output yang dihasilkan berupa *support vector*, yang berupa pola dengan jarak terdekat terhadap *hyperplane* optimal.

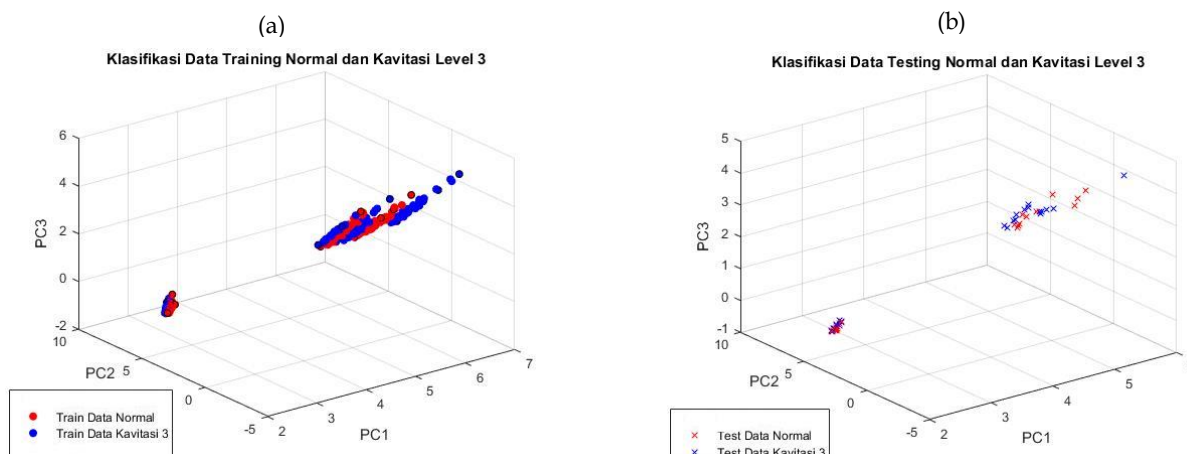
Hasil klasifikasi binary SVM tentu akan memiliki perbedaan. Normal dengan kavitas 1 akan berbeda pada kondisi normal dan kavitas 2. Begitu juga, perbandingan antara normal dengan kavitas 3. Hasilnya dapat dilihat dalam visualisasi gambar berikut:



GAMBAR 8 DATA NORMAL DAN KAVITASI 1 (A) TRAINING, (B) TESTING



GAMBAR 9 DATA NORMAL DAN KAVITASI 2 (A) TRAINING, (B) TESTING



GAMBAR 10 DATA NORMAL DAN KAVITASI 3 (A) TRAINING, (B) TESTING

Pada dasarnya pada Gambar 8 (a) dan (b) memiliki pola yang sama, karena pada proses *testing SVM* tidak membentuk model baru melainkan menempati model yang telah dibentuk pada proses *training*. Akan tetapi, sudah terlihat separasi yang jelas antara kondisi normal dan kavitas 1 pada hasil *testing*.

Hasil kedua Gambar 9 (a) dan (b) diatas terlihat bahwa data normal masih tercampur dengan data kavitas 2 dalam satu kelas. Hal ini dipengaruhi terbatasnya jumlah kelas yang kecil sehingga terjadi pengklasifikasian yang belum optimal.

Gambar 10 (a) dan (b) diatas menunjukkan masih ada penumpukkan data di sebagian kelas dalam hasil *training* dan *testing*. Akan tetapi, terlihat juga pemisahan antar kondisi normal dengan kavitas 3 pada *training* dan *testing* walaupun masih ada penumpukkan antara data normal dengan data kavitas 3.

Performa Klasifikasi Binary SVM

Pengukuran performa hasil klasifikasi *SVM* pada umumnya dapat dilihat pada visualisasi hasil klasifikasi. Namun untuk menentukan seberapa baik hasil klasifikasi dan tingkat akurasi tidak cukup hanya dilakukan melalui pengamatan secara visual. Oleh karena itu, proses *testing* berfungsi sebagai indikator keberhasilan sebuah klasifikasi yang diinginkan.

Pada proses *testing*, hal yang paling utama dilakukan adalah memberikan hasil analisa dan perhitungan tingkat akurasi. Nilai ini diukur berdasarkan bagaimana set data yang digunakan dalam proses *testing* dapat menempati posisinya sesuai pengelompokan kelas pada model klasifikasi. Tingkat akurasi ketiga hasil klasifikasi *binary SVM* dapat dilihat seperti yang ditunjukkan pada Tabel 2.

TABEL 3 HASIL KLASIFIKASI BINARY SVM

| No | Model Klasifikasi | Tingkat Akurasi (%) |
|----|----------------------------|---------------------|
| 1 | Normal dan Kavitas Level 1 | 100 |
| 2 | Normal dan Kavitas Level 2 | 100 |
| 3 | Normal dan Kavitas Level 3 | 100 |

Berdasarkan Tabel 3 dapat diketahui bahwa hasil klasifikasi *binary SVM* berhasil dilakukan dengan tingkat akurasi 100%. Hal ini lebih

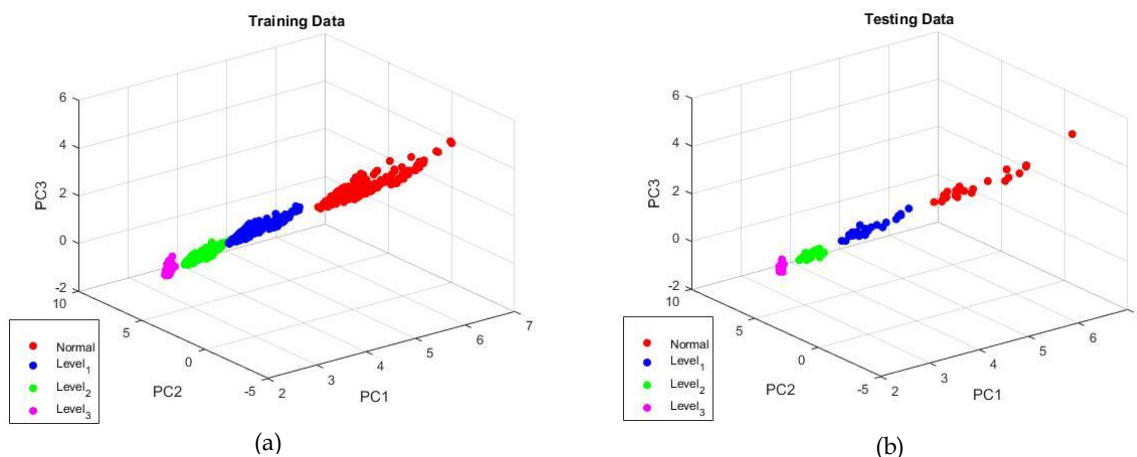
unggul jika dibandingkan dengan analisa karakteristik parameter statistik domain waktu.

Klasifikasi Multiclass SVM

Pada dasarnya *SVM* merupakan metode klasifikasi yang bersifat *binary*. Namun dengan melakukan modifikasi algoritma, klasifikasi *multi class* (banyak kelas) *SVM* dapat dilakukan. Prinsip klasifikasi *multi class SVM* dilakukan dengan menerapkan metode *one vs one* dan *one vs all*. Metode *one vs one*, dimana model *multi class SVM* dibangun berdasarkan jumlah kelas. Sehingga dari empat kelas dapat menghasilkan enam *hyperplane* optimal.

Sedangkan metode *one vs all* dilakukan dengan mencari satu *hyperplane* optimal dari empat kelas.

Jumlah kelas yang akan diklasifikasikan sejumlah empat kelas, sehingga menghasilkan input sebanyak 250 data tiap kondisinya. Hasil proses *cross-validation* menunjukkan bahwa 900 set data digunakan untuk proses *training* dan 100 set data digunakan untuk proses *testing*. Gambar 11 (a) dan (b) menunjukkan hasil model klasifikasi berdasarkan proses *training*.



GAMBAR 11 MODEL MULTICLASS SVM (A) TRAINING, (B) TESTING

Pemetaan yang dilakukan pada proses *training* ini menggunakan *kernel function RBF*. Model klasifikasi ini kemudian dievaluasi dengan menggunakan 100 set data *testing*. Gambar 10 (a) menunjukkan pembentukan pola oleh data *training*. Separasi normal, kavitas 1, kavitas 2, dan kavitas 3 terlihat optimal dalam pemisahannya. Multiclass SVM sudah mampu untuk membedakan data keempat kondisi tersebut dalam banyak kelas. Proses evaluasi ini berupaya untuk menghitung tingkat akurasi klasifikasi serta menentukan jumlah kesalahan klasifikasi pada model. Hasil *testing* model klasifikasi *multi class SVM* dapat dilihat seperti yang ditunjukkan pada Gambar 12.

Pengukuran performa klasifikasi *multi class SVM* dihitung berdasarkan tingkat akurasi klasifikasinya. Selain itu jumlah kesalahan klasifikasi yang dilakukan juga merupakan tolak ukur keberhasilan klasifikasi. Hal ini secara jelas dapat ditunjukkan pada *confusion matrix* seperti yang terdapat pada Gambar 12.

Pada model *multi class SVM* yang mengklasifikasikan kelompok data dalam empat kelas. Hal ini sudah menunjukkan model klasifikasi yang dibangun pada proses *training* serta proses pemetaannya optimal. Data *testing* mengevaluasi hasil pembentukan pola data *training*.

Confusion Matrix

| | | | | | | |
|--------------|---|--------------|--------------|--------------|--------------|--------------|
| Output Class | 1 | 25 25.0% | 0 0.0% | 0 0.0% | 0 0.0% | 100% 0.0% |
| | 2 | 0 0.0% | 25 25.0% | 0 0.0% | 0 0.0% | 100% 0.0% |
| | 3 | 0 0.0% | 0 0.0% | 25 25.0% | 0 0.0% | 100% 0.0% |
| | 4 | 0 0.0% | 0 0.0% | 0 0.0% | 25 25.0% | 100% 0.0% |
| | | 100% 0.0% | 100% 0.0% | 100% 0.0% | 100% 0.0% | 100% 0.0% |
| | 1 | 2 | 3 | 4 | Target Class | |

GAMBAR 12 CONFUSION MATRIX MULTICLASS SVM

Terlihat hasil data *testing* sudah sesuai menempati pola tiap kondisi normal, kavitasi 1, kavitasi 2, dan kavitasi 3. Kesalahan pengklasifikasiannya menunjukkan tingkat akurasi 0%. Tingkat keberhasilan klasifikasi *multiclass* SVM sudah menunjukkan 100%.

KESIMPULAN

Berdasarkan hasil analisa dan pembahasan penelitian yang telah dilakukan, maka dapat disimpulkan bahwaseleksi data menggunakan PCA menghasilkan data yang optimal dalam mengklasifikasi kondisi normal dan kavitasi. *RMS*, *STDV*, dan *variance* dapat membedakan antara kondisi normal dengan kavitasi tingkat awal. Permodelan dari PCA menghasilkan 3PC pertama yang jumlah varians 90% dijadikan input dalam proses klasifikasi menggunakan SVM. Klasifikasi data menggunakan SVM menghasilkan informasi yang sesuai untuk membedakan kondisi normal dan kavitasi. Hal ini dibuktikan dengan metode klasifikasi *binary* dan *multiclass* SVM. Terlihat dalam visualisasi grafiknya dapat membedakan kondisi normal dengan kavitasi 1, kavitasi 2, dan kavitasi 3 dengan tingkat keakurasian 100%. Optimalisasi yang dilakukan bisa memastikan bahwa kedua metode klasifikasi tersebut sudah mampu mengklasifikasi data yang optimal.

DAFTAR PUSTAKA

- A.A. Miranda, Y.A. Le Borgne, and G. Bontempi. New Routes From Minimal Approximation Error to Principal Component, Volume 27, Number 3/ june 2008, Neural Processing Letter, Springer.
- Al Hashmi, S.A. (2009). Statistical Analysis of Vibration Signals for Cavitation Detection ISIEA. 2009 IEEE Symposium on Industrial Electronics and Application, ISIEA 2009 – Proceedings 1 (ISIEA), 78 – 82.
- Al Tobi, M.A.S., Al Sabari, M.H.J. (2016). *Cavitation Detection of Centrifugal Pump Using Time – Domain Method*, 4 (5), 161 – 167.
- Delly, Jenny. (2009). Tugas Akhir “Pengaruh Temperatur Terhadap Terjadinya Kavitasi Pada Sudu Pompa Sentrifugal”. Kendari : Jurusan Teknik Mesin, Fakultas Teknik Universitas Haluoleo.
- Kamiel, Berli Paripurna. (2015). *Vibration-based multi-fault diagnosis for centrifugal pumps*. Ph.D. Curtin University, Department of Mechanical Engineering.

- Luo, Y., Sun, H., Yuan, S., Yuan, J. (2015). *Research on Statistical Characteristics of Vibration in Centrifugal Pump*, 38, 49 – 61.
- Pratama, M. Sofyan Bagus. (2017). Tugas Akhir “*Metode Deteksi Fenomena Kavitasi Pompa Sentrifugal Berbasis Domain Waktu dan Domain Frekuensi Sinyal Getaran*”. Jurusan Teknik Mesin Fakultas Teknik Universitas Muhammadiyah Yogyakarta.
- Ramadhan, Ray Setia. (2017). “*Pengaruh Kecepatan Operasi Pompa Sentrifugal Terhadap Sensitifitas Metode Deteksi Fenomena Kavitasi Berbasis Parameter Statistik Domain Waktu*”. Skripsi. Universitas Muhammadiyah Yogyakarta.
- Santosa B. (2007). *Data Mining (Teori dan Aplikasi)*, Graha Ilmu, Yogyakarta.
- Sakthivel, Sugumaran, and Nair, Binoy B. 2010. *Application of Support Vector Machine (SVM) and Proximal Support Vector Machine (PSVM) for Fault Classification of Monoblock Centrifugal Pump*. Int. J. Data Analysis Techniques and Strategies, Vol 2, No 1. India.
- Scheffer, Cornelius., and Girdhar, Paresh. (2004). “*Practical Machinery Vibration Analysis and Predictive Maintenance*”. Newnes An imprint of Elsevier Linacre 1-louse, Jordan Hill, Oxford OX2 BDP 200 Wheeler Road, Burlington, MA01 803.
- Syafutra, Kurniady. (2017). Tugas Akhir “*Metode Deteksi Fenomena Kavitasi pada Pompa Sentrifugal Berbasis Domain Frekuensi Sinyal Getaran*”. Jurusan Teknik Mesin Fakultas Teknik Universitas Muhammadiyah Yogyakarta.
- Taghi, Mohammed., Ettefagh, Mir Mohammed., Lotfan, Saeed., and Safarzadeh, Hamed. 2017. *Cavitation Intensity Monitoring in an Axial Flow Pump Based on Vibration Signals Using Multiclass Support Vector Machine*. Research Laboratory of Vibration and Modal Analysis, Department of Mechanical Engineering, University of Tabriz, Tabriz, Iran.

PENULIS:

Berli P Kamiel
Program Studi Teknik Mesin, Fakultas Teknik,
Universitas Muhammadiyah Yogyakarta, Jalan
Lingkar Selatan, Tamantirto, Kasihan, Bantul,
Yogyakarta

Email: berlikamiel@umy.ac.id

Yudha Yanuar Pamungkas
Teknik Mesin, Fakultas Teknik, Universitas
Muhammadiyah Yogyakarta, Yogyakarta.

Email: yanuaravengersfold@gmail.com