

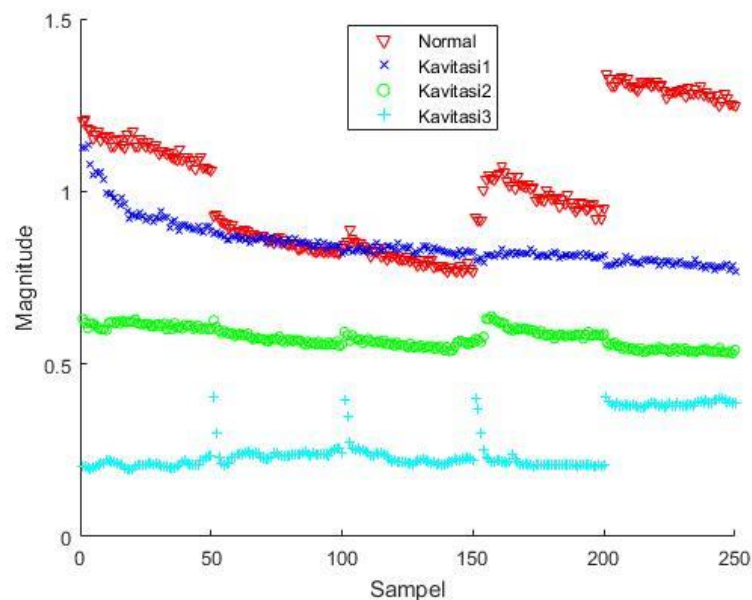
BAB IV HASIL DAN PEMBAHASAN

4.1 Analisis Parameter Statistik

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. Parameter statistik yang digunakan berdasarkan jumlah penelitian terdahulunya seperti yang dijelaskan pada Tabel 2.2. Hasil analisa karakteristik data dari setiap parameter statistik domain waktu, diantaranya :

1. *Root Mean Square*

Gambar 4.1 menunjukkan penyebaran data dari empat variasi kondisi berdasarkan karakteristik parameter *RMS*.




Gambar 4. 1 Karakteristik parameter statistik RMS

Parameter statistik *RMS* 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

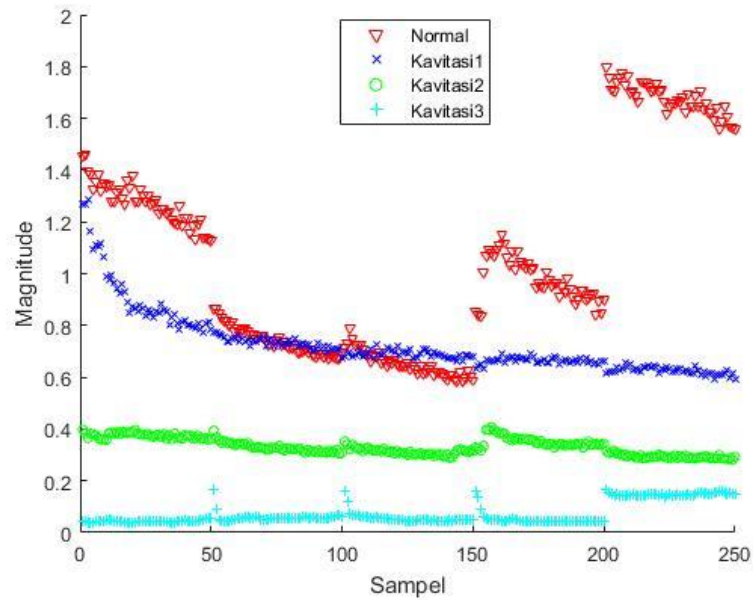
Parameter *SD* seperti yang ditunjukkan pada Gambar 4.2 dapat memperlihatkan perbedaan dari empat variasi kondisi. Namun belum cukup baik dalam memisahkan kondisi normal dan kavitasi level 1.



Gambar 4.2 Karakteristik parameter statistik *SD*

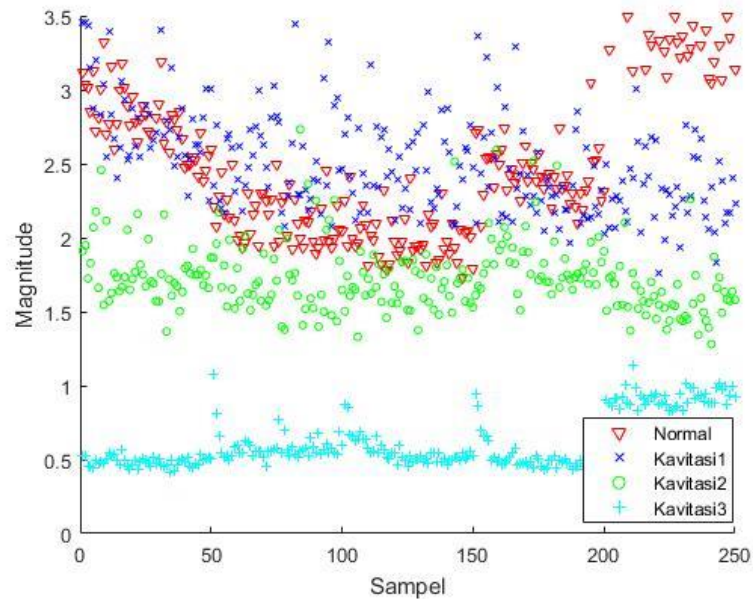
3. Variance

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. Hal ini seperti yang ditunjukkan pada Gambar 4.3.



Gambar 4.3 Karakteristik parameter statistik *variance*

4. *Peak Value*




Gambar 4.4 Karakteristik parameter statistik *peak value*

Karakteristik parameter *peak value* dapat dilihat seperti yang ditunjukkan pada Gambar 4.4. 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. Karakteristik parameter *peak value* tidak dapat membedakan kondisi normal dan kavitasi apabila tidak terjadi perubahan laju aliran yang signifikan.

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 seperti yang ditunjukkan pada Gambar 4.5.

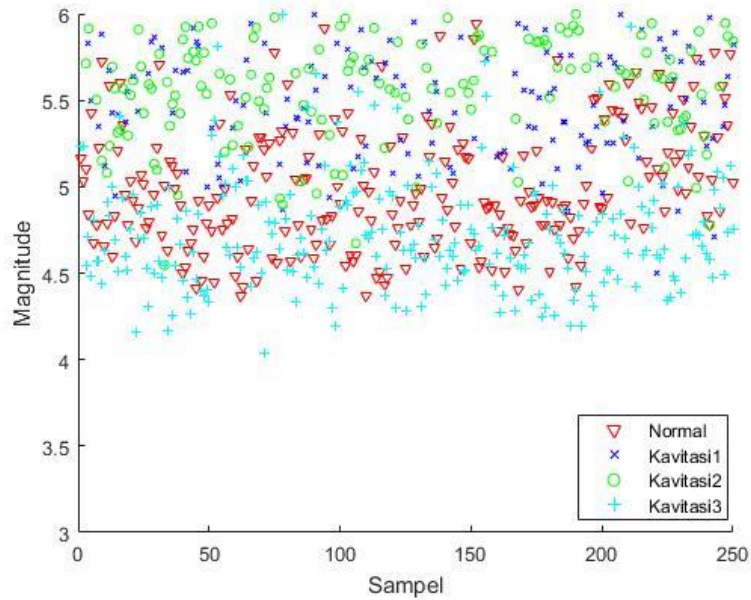


Gambar 4.5 Karakteristik parameter statistik *kurtosis*

6. Crest Factor


Gambar 4.6 terlihat bahwa parameter *crest factor* sama sekali tidak dapat menunjukkan perbedaan dari semua variasi kondisi. Pada dasarnya 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.



Gambar 4.6 Karakteristik parameter statistik *crest factor*

7. Mean

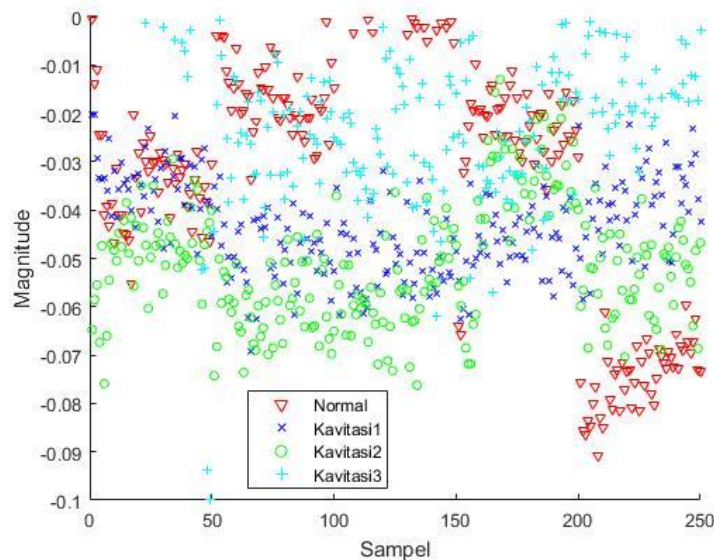


Gambar 4.7 Karakteristik parameter statistik *mean*

Nilai parameter *mean* menunjukkan ukuran yang mendominasi keseluruhan data. Seperti yang ditunjukkan pada Gambar 4.7, karakteristik parameter *mean* sama sekali tidak dapat menunjukkan pemisahan pada keempat variasi kondisi. Oleh karena itu, ukuran data dalam penelitian ini tidak dapat dijadikan sebagai faktor utama dalam memisahkan data.

8. *Skewness*

Gambar 4.8 terlihat bahwa parameter *skewness* sama sekali tidak dapat menunjukkan perbedaan dari semua variasi kondisi. Pada dasarnya 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.



Gambar 4.8 Karakteristik parameter statistik *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.

4.2 Analisis *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 4.9.



Gambar 4.9 Grafik Pareto *Principal Component*

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 4.1

Tabel 4.1 Kontribusi Paramater Pada Principal Component

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 diatas, tiap parameter mempunyai karakteristik yang berbeda untuk memberikan tingkat kontribusianya. 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

4.3 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 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.

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.


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 Gambar ini:

2.2.17 Hasil Klasifikasi Data Normal dan Kavitasi 1



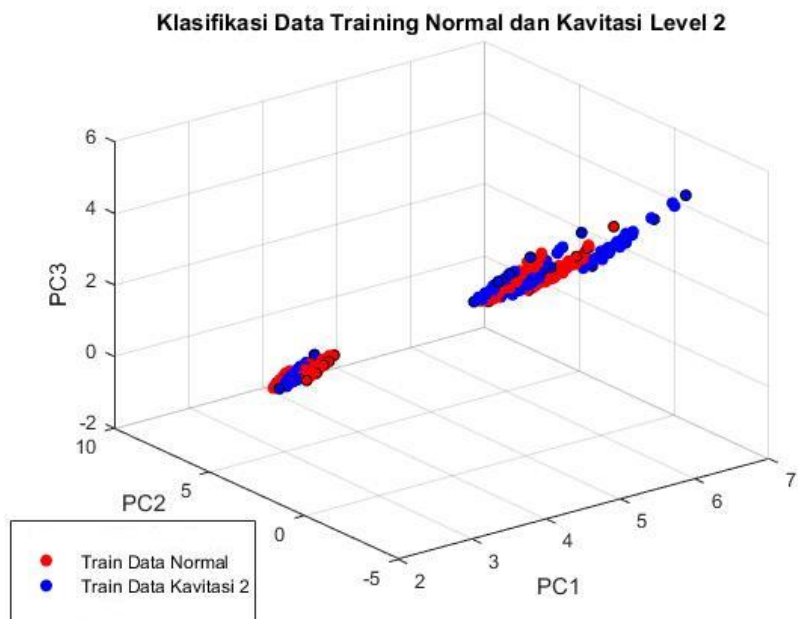
Gambar 4.10 *Training* Data Normal dan Kavitasi 1

Pada dasarnya kedua gambar ini 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 kavitasi 1 pada hasil *testing*.

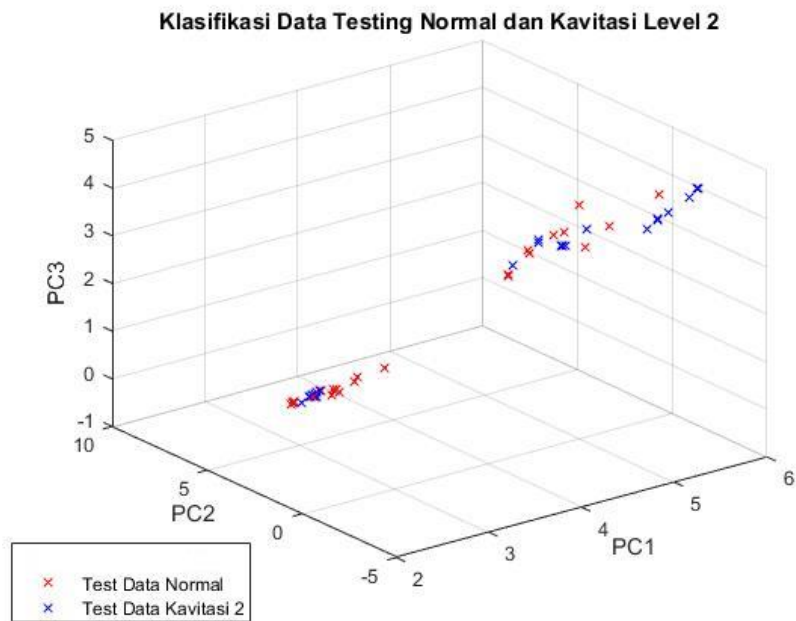


Gambar 4.11 *Testing* Data Normal dan Kavitas 1

2.2.18 Hasil Klasifikasi Data Normal dan Kavitas 2



Gambar 4.12 *Training* Data Normal dan Kavitas 2




Gambar 4.13 *Testing* Data Normal dan Kavitas 2


Hasil kedua gambar diatas memiliki kesamaan pola karena pada proses *testing SVM* tidak membentuk model baru melainkan menempati model yang telah dibentuk pada proses *training*. 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.

2.2.19 Hasil Klasifikasi Data Normal dan Kavitas 3

Model klasifikasi ini dibangun dengan menggunakan 450 set data *training* yang berasal dari data kondisi normal dan kavitas level 3. Kemudian proses *testing* juga dilakukan dengan menggunakan 50 set data dari dua kelas tersebut. Kedua Gambar 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.



Gambar 4.14 *Training Data Normal dan Kavitasi 3*



Gambar 4.15 *Testing Data Normal dan Kavitasi 3*

2.2.20 Performa Hasil 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 4.2.

Tabel 4.2 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

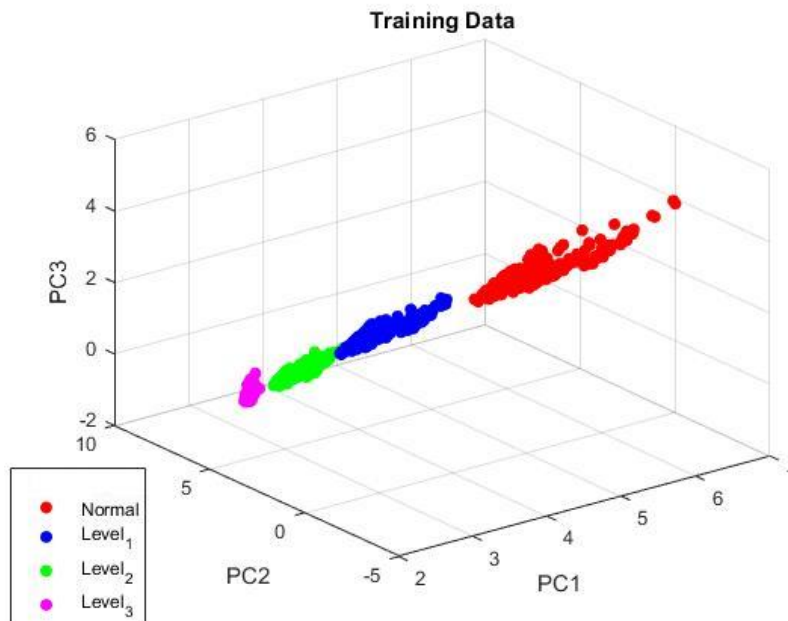
Berdasarkan Tabel 4.2 dapat diketahui bahwa hasil klasifikasi *binary SVM* berhasil dilakukan dengan tingkat akurasi 100%. Hal ini lebih unggul jika dibandingkan dengan analisa karakteristik parameter statistik domain waktu.

2.3 Klasifikasi Multi Class SVM

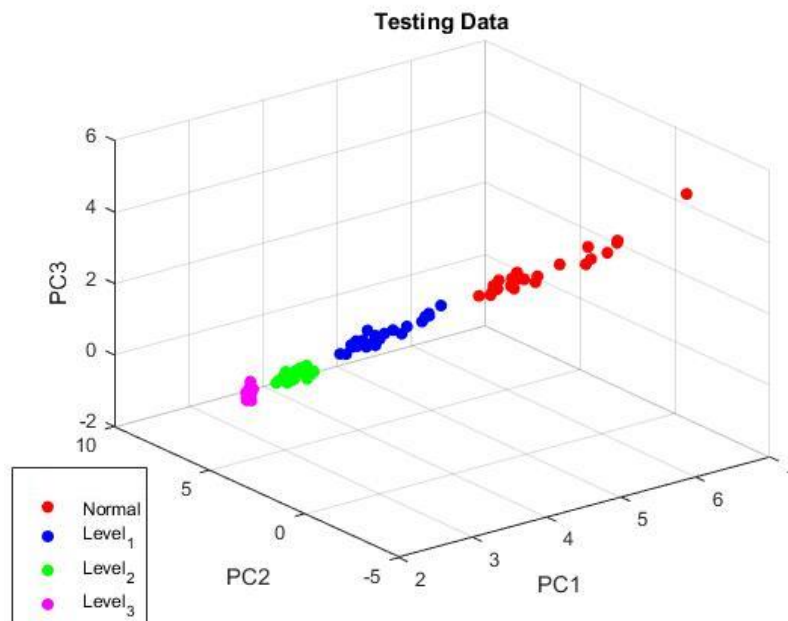
Pada dasarnya *SVM* merupakan metode klasifikasi yang bersifat *binary*. Namun dengan melakukan modifikasi algoritma, klasifikasi *multi class* (banyak kelas) *SVM* dapat dilakukan. Prinsip klasifikasi *multi class SVM* dilakukan dengan menerapkan metode *one vs one* dan *one vs all*. Metode *one vs 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*. Berikut Gambar 4.16 menunjukkan hasil model klasifikasi berdasarkan proses *training*.



Gambar 4.16 Model *Training Multiclass SVM*



Gambar 4.17 Model *Testing Multiclass SVM*

Pemetaan yang dilakukan pada proses *training* ini menggunakan *kernel function RBF*. Model klasifikasi ini kemudian dievaluasi dengan menggunakan 100 set data *testing*. Gambar 4.16 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 4.17.

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 4.18.

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 4.18 *Confusion matrix multi class SVM*

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*. 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%.