

BAB IV

HASIL DAN PEMBAHASAN

4.1 Hasil Akuisisi Data Sinyal *Vibrasi*


Akuisisi data sinyal *vibrasi* dilakukan dalam beberapa variasi kondisi, yaitu normal, kavitasi level 1, kavitasi level 2, dan kavitasi level 3. Masing – masing variasi kondisi menghasilkan 500 *file* data yang berbasis domain waktu. Kondisi operasi *test-rig* diatur dan menghasilkan beberapa *output* seperti yang ditunjukkan pada Tabel 4.1.

Tabel 4.1. Hasil akuisisi data sinyal *vibrasi*

Variasi Kondisi	Pengaturan Operasi			Output		
	Tutupan Katup (°)	Kecepatan Poros (RPM)	Sampling Rate (Hz)	Laju Aliran Air (l/m)	Tekanan Discharge (bar)	Tekanan Suction (bar)
Normal	0	2850	17066	110	0.7	0.1
Kavitasi Level 1	720	2850	17066	110	0.8	0.12
Kavitasi Level 2	1440	2850	17066	102.5	0.8	0.22
Kavitasi Level 3	2160	2850	17066	60	1.2	0.4

Setiap *output* yang dihasilkan dari masing – masing variasi kondisi memiliki perbedaan seperti laju aliran air, nilainya semakin berkurang seiring bertambahnya level kavitasi. Hal ini dikarenakan adanya hambatan pada saluran *suction* yang menyebabkan berkurangnya air yang dipompakan melalui *discharge*. Begitu pula dengan nilai tekanannya, dengan adanya hambatan maka tekanan *vacuum* pada *suction* dan tekanan *discharge* nya akan semakin besar.


Perbandingan nilai amplitudo dari setiap variasi kondisi juga dapat dilihat seperti pada Gambar 4.1. Semakin besar level kavitasi, maka semakin kecil nilai amplitudonya. Hal ini dikarenakan level kavitasi ditimbulkan oleh adanya hambatan, hambatan pada aliran kemudian mengakibatkan berkurangnya aliran yang masuk pada pompa.



Gambar 4.1 Perbandingan plot domain waktu tiap variasi kondisi

Plot domain waktu seperti pada Gambar 4.1 menunjukkan perbedaan yang mendasar dari setiap variasi kondisi. Plot domain waktu kondisi normal memiliki nilai amplitudo yang tinggi, sehingga ketajaman puncak yang ditampilkan lebih besar dibandingkan kondisi variasi lainnya. Hasil plot domain waktu dari setiap variasi kondisi berbanding lurus terhadap nilai laju aliran fluidanya. Semakin besar nilai aliran fluida, maka semakin besar nilai amplitudo yang dihasilkan dan begitu pula sebaliknya. Pada kondisi normal dan kavitasi level 1 memiliki nilai laju aliran yang sama, namun plot domain waktu yang dihasilkan memiliki perbedaan. Oleh karena itu, analisa terhadap plot domain waktu menunjukkan hasil yang lebih sensitif terhadap perbedaan dari setiap variasi kondisi.

Secara visual, fenomena kavitasi berupa pembentukan *bubble* yang terjadi pada saluran *suction* pompa. Setiap level kavitasi tentunya menghasilkan visualisasi yang berbeda, hal ini dapat dilihat seperti yang ditunjukkan pada Gambar 4.2. Perbedaan mendasar yang dapat dilihat dengan membandingkan Gambar 4.2 (a) dan gambar lainnya. Pada Gambar 4.2 (a) terlihat bahwa tidak ada pembentukan *bubble* yang terjadi di bagian *suction* pompa. Pada Gambar 4.2 (b), (c), dan (d) telah dilakukanutupan katup, dan *bubble* mulai terbentuk pada *suction* pompa.



Gambar 4.2 Visualisasi kavitasi (a) kondisi normal, (b) kavitasi level 1, (c) kavitasi level 2, (d) kavitasi level 3

Setiap variasi kondisi tentunya memberikan hasil yang berbeda, seperti halnya *output* pada kondisi operasi, nilai amplitudo, serta visualisasi. Namun untuk dapat mengetahui perbedaannya secara jelas, maka tahapan analisa lebih lanjut harus dilakukan.

4.2 Hasil Ekstraksi Parameter Statistik Domain Waktu

Setelah memperoleh data hasil akuisisi yang berjumlah 500 *file*, kemudian setiap *file* data tersebut diekstrak ke dalam sejumlah parameter statistik domain waktu. Mengacu pada Tabel 2.1, parameter statistik domain waktu yang

digunakan diantaranya *Root Mean Square (RMS)*, *Standard Deviation (SD)*, *Probability Density Function (PDF)*, *Peak Value*, *Kurtosis*, *Variance*, *Crest Factor*, *Mean*, *Entropy*, *Minimum Value*, dan *Standard Error (SE)*. Namun parameter *PDF* tidak digunakan pada penelitian ini karena belum ada tinjauan penelitian yang menggunakannya pada *SVM*. Sehingga sejumlah parameter statistik yang digunakan berdasarkan jumlah penelitian terdahulunya seperti yang ditunjukkan pada Tabel 4.2.

Ekstraksi parameter statistik domain waktu bertujuan untuk mengetahui berbagai macam karakteristik data yang dihasilkan terhadap kondisi normal, kavitasi level 1, kavitasi level 2, dan kavitasi level 3.

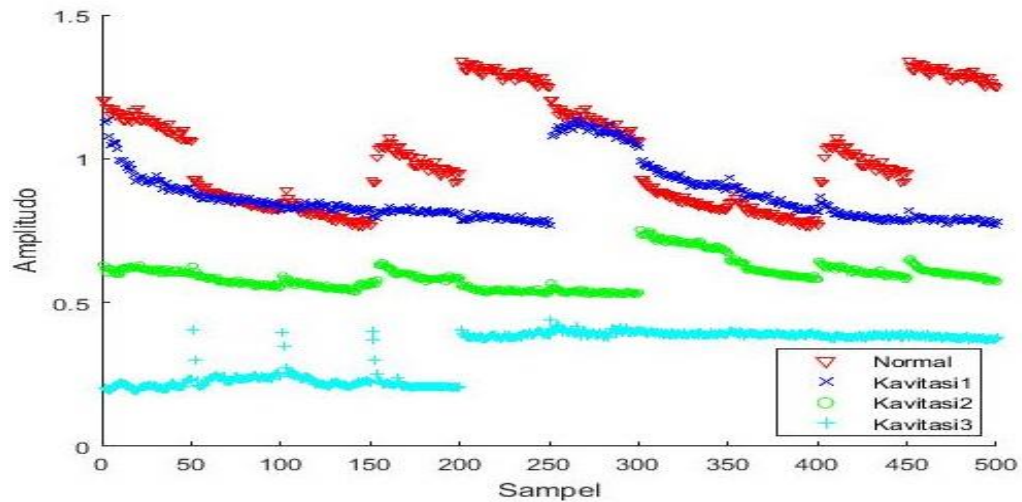
Tabel 4.2 Penggunaan parameter statistik domain waktu

Urutan	Nama Parameter Statistik	Jumlah Penelitian
1	RMS	6
2	SD	5
3	Peak Value	2
4	Kurtosis	2
5	Variance	2
6	Crest Factor	1
7	Mean	1
8	Entropy	1
9	Minimum Value	1
10	Standard Error	1

Hasil analisa karakteristik data dari setiap parameter statistik domain waktu, diantaranya :

1. *RMS*

Gambar 4.3 menunjukkan penyebaran data dari empat variasi kondisi berdasarkan karakteristik parameter *RMS*.

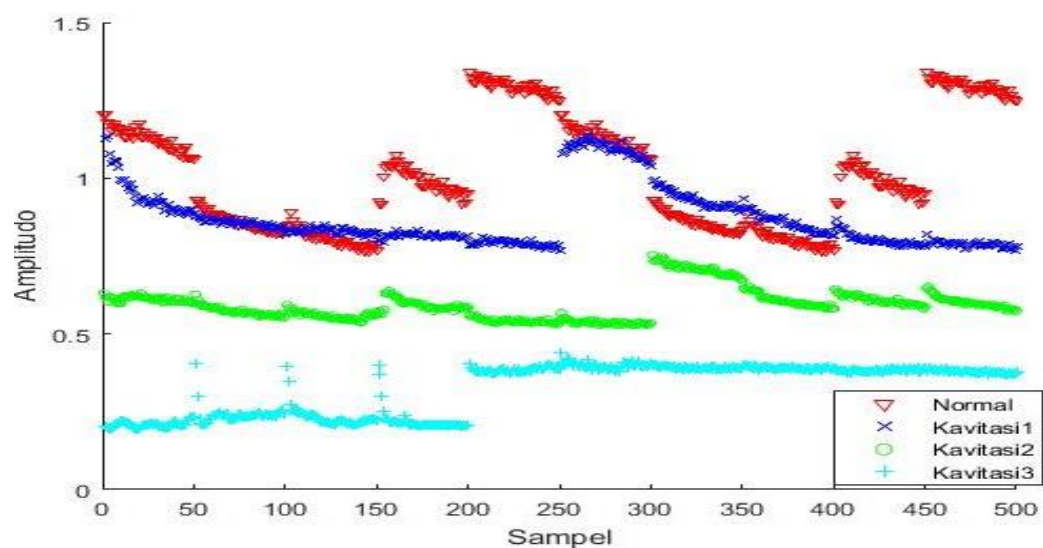


Gambar 4.3 Karakteristik parameter statistik *RMS*

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. *SD*


Hampir serupa dengan *RMS*, parameter *SD* seperti yang ditunjukkan pada Gambar 4.4 dapat memperlihatkan perbedaan dari empat variasi kondisi. Namun belum cukup baik dalam memisahkan kondisi normal dan kavitasi level 1.



Gambar 4.4 Karakteristik parameter statistik *SD*

3. *Peak Value*

Karakteristik parameter *peak value* dapat dilihat seperti yang ditunjukkan pada Gambar 4.5.

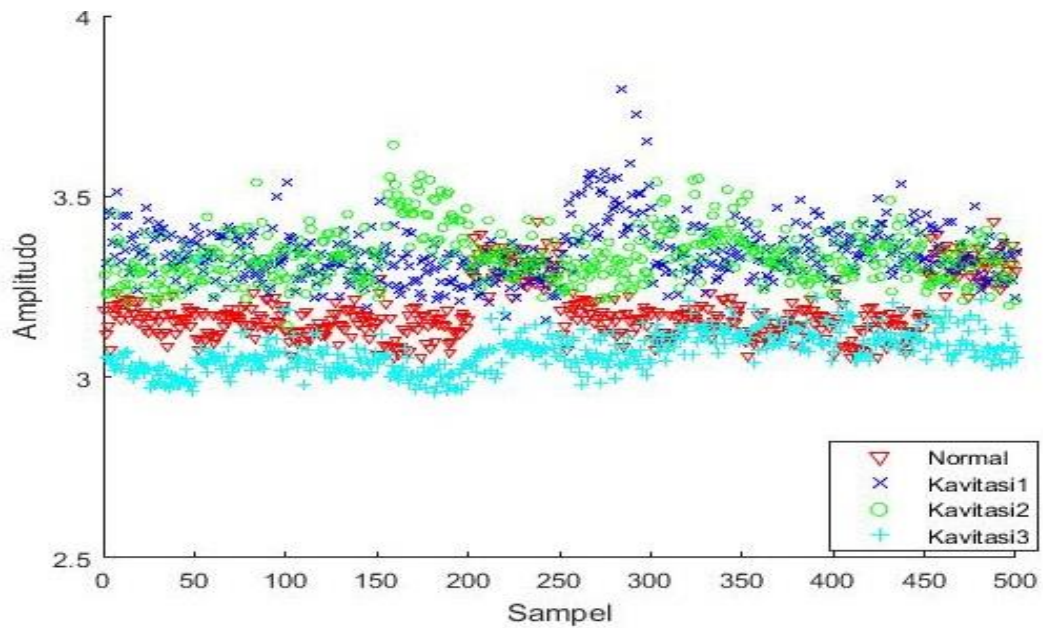


Gambar 4.5 Karakteristik parameter statistik *peak value*

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. Karakteristik parameter *peak value* tidak dapat membedakan kondisi normal dan kavitasi apabila tidak terjadi perubahan laju aliran yang signifikan.

4. *Kurtosis*

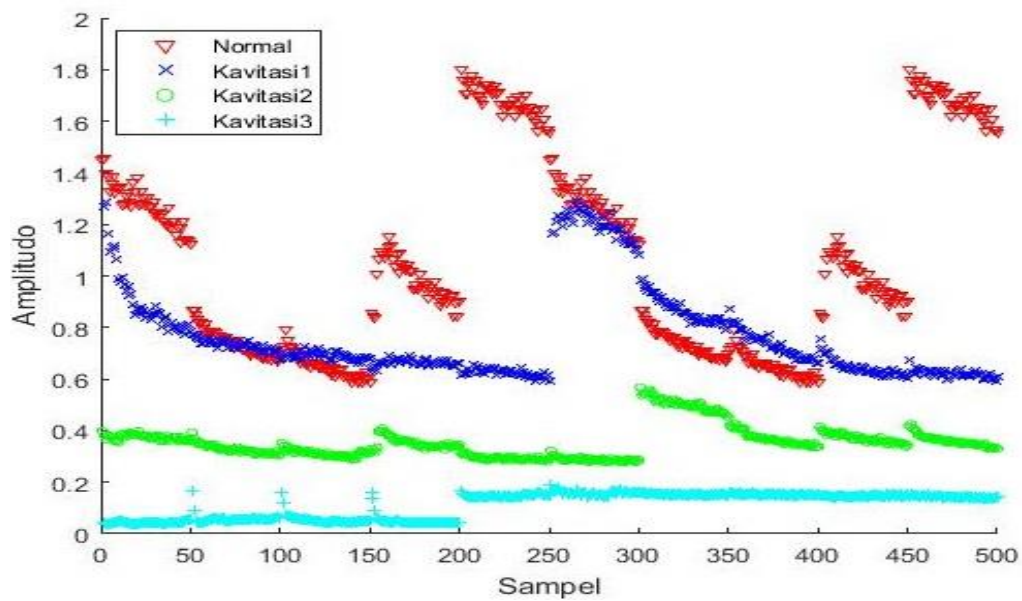
Pada parameter *kurtosis*, keempat variasi kondisi sama sekali tidak dapat terpisahkan. Baik pada kelompok data normal hingga kavitasi level 3 tidak terlihat adanya pemisahan. Hal ini dikarenakan karakteristik parameter *kurtosis* mengubah semua nilai menjadi positif. Oleh karena itu parameter ini tidak mampu memisahkan kelompok data dari kelas yang berbeda seperti yang ditunjukkan pada Gambar 4.6.



Gambar 4.6 Karakteristik parameter statistik *kurtosis*

5. *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 4.7.



Gambar 4.7 Karakteristik parameter statistik *variance*

6. *Crest Factor*

Berikut Gambar 4.8 menunjukkan karakteristik parameter *crest factor* terhadap keempat variasi kondisi.




Gambar 4.8 Karakteristik parameter statistik *crest factor*

Pada Gambar 4.8 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.

7. *Mean*


Nilai parameter *mean* menunjukkan ukuran yang mendominasi keseluruhan data. Seperti yang ditunjukkan pada Gambar 4.9, 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.



Gambar 4.9 Karakteristik parameter statistik *mean*

8. *Entropy*

Parameter statistik *entropy* dapat menunjukkan adanya perbedaan dalam sinyal *vibrasi* berdasarkan ketidak stabilan aliran serta tingkat kerusakan mesin. Gambar 4.10 menunjukkan karakteristik parameter statistik *entropy* terhadap keempat variasi kondisi.

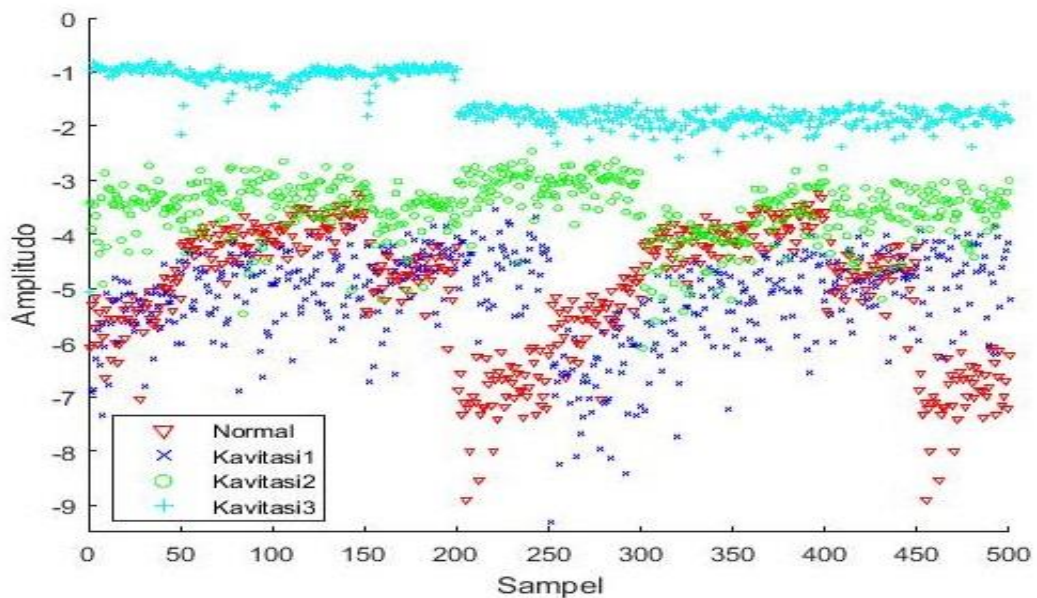


Gambar 4.10 Karakteristik parameter statistik *entropy*

Hampir sama seperti parameter *RMS*, *SD*, dan *variance*, parameter ini hampir dapat meisahkan keempat variasi kondisi dengan sempurna. Akan tetapi, belum cukup baik dalam mengklasifikasikan kondisi normal dan kavitasi level 1.

9. *Minimum Value*

Karakteristik parameter *minimum value* terhadap keempat variasi kondisi dapat dilihat seperti yang ditunjukkan pada Gambar 4.11.

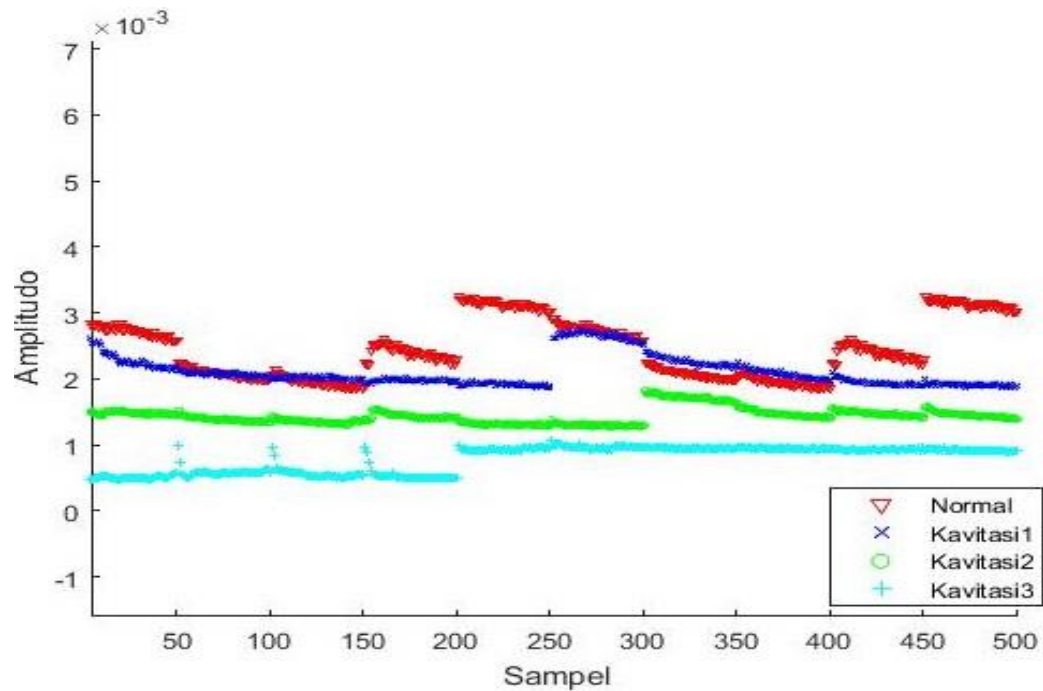


Gambar 4.11 Karakteristik parameter statistik *minimum value*

Parameter *minimum value* menunjukkan titik minimum dari sinyal *vibrasi* yang direkam. Berdasarkan Gambar 4.11 terlihat bahwa titik minimum dari nilai *vibrasi* tidak dapat menggolongkan kelompok data sinyal *vibrasi* ke dalam masing-masing variasi kondisi.

10. *SE*

Parameter *SE* memiliki karakteristik yang hampir sama dengan *RMS*, *SD*, *variance*, dan *entropy*. Karakteristik parameter ini menunjukkan prediksi *error* terhadap nilai *mean* sampel dan panjang sampel, seperti yang ditunjukkan pada Gambar 4.12. Dapat diketahui bahwa parameter *SE* menunjukkan perbedaan yang signifikan terhadap pemisahan data, akan tetapi tidak terlihat pada pemisahan data normal dan kavitasi level 1.



Gambar 4.12 Karakteristik parameter statistik *SE*

Setiap hasil yang diperoleh dari semua parameter statistik menunjukkan karakteristik yang berbeda – beda. Pada Tabel 4.3 dapat dilihat rangkuman hasil analisa setiap parameter statistik berdasarkan empat variasi kondisi.

Tabel 4.3 Hasil analisa karakteristik parameter statistik domain waktu

Nama Parameter Statistik Domain Waktu	Hasil Analisa Karakteristik Parameter
RMS, SD, Variance, Entropy, & SE	Dapat menunjukkan perbedaan kelas dengan baik, namun tidak dapat menunjukkan perbedaan yang signifikan pada kondisi normal dan kavitasi level 1
Peak Value & Kurtosis	Hampir tidak dapat memisahkan kelompok data dari tiap variasi kondisi dengan baik. Hanya data kavitasi level 3 yang dapat dipisahkan dengan baik.
Crest Factor, Mean, & Minimum Value	Sama sekali tidak mampu memisahkan kelompok data dalam empat variasi kondisi

Berdasarkan hasil analisa karakteristik parameter statistik domain waktu, dapat diketahui bahwa setiap parameter statistik memberikan informasi yang spesifik terhadap distribusi data sinyal *vibrasi*. Beberapa parameter statistik seperti *RMS*, *SD*, *variance*, *SE*, dan *entropy* menunjukkan hasil yang baik dalam membedakan beberapa level kavitasi. Namun hasil analisa belum dapat menunjukkan perbedaan variasi kondisi secara signifikan, khususnya pada kondisi normal dan kavitasi level 1.


4.3 Hasil Seleksi Parameter Statistik Domain Waktu

Data yang telah diekstraksi ke dalam sepuluh parameter statistik masing – masing 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 sangat dibutuhkan dalam proses persiapan data sebelum klasifikasi.

Proses seleksi data dilakukan dengan menggunakan algoritma *Relief Feature Selection*. Algoritma *Relief Feature Selection* memberikan urutan *ranked* (peringkat) dan *weight* (bobot) dari parameter statistik. Sistem urutan *ranked* pada *Relief Feature Selection* didasarkan pada pemilihan parameter statistik yang memiliki informasi penting untuk proses klasifikasi. Nilai *weight* merupakan hal penting pada proses ini karena semakin besar nilai ini maka semakin penting parameter tersebut. Grafik hubungan antara *ranked* dan *weight* dari setiap parameter statistik dapat dilihat pada Gambar 4.13.

Gambar 4.13 menunjukkan bahwa urutan *ranked* tertinggi berada pada parameter *variance*. Dengan kata lain parameter *variance* merupakan parameter terpenting, sedangkan parameter *crest factor* merupakan parameter yang memiliki kandungan informasi paling tidak penting sebagai input klasifikasi.



Gambar 4.13 Grafik hubungan *ranked* dan *weight*

Keseluruhan hasil seleksi parameter statistik beserta nilai *weight* dapat dilihat pada Tabel 4.4.

Tabel 4.4 Hasil Seleksi Parameter Statistik Domain Waktu

Ranked	Parameter Statistik	Weight
1	Variance	0,006974609
2	RMS	0,005680424
3	SD	0,005646849
4	SE	0,005646849
5	Entropy	0,004460221
6	Mean	0,004190307
7	Kurtosis	0,003894734
8	Peak Value	0,00356323
9	Minimum Value	0,002523585
10	Crest Factor	-0,000132408

Berdasarkan hasil seleksi, maka parameter yang dijadikan sebagai input klasifikasi *SVM* adalah *variance*, *RMS*, dan *SD*. Hal ini dikarenakan ketiga parameter ini merupakan tiga *ranked* teratas dengan nilai *weight* masing – masing diatas 0,0050. Selain itu pemilihan ketiga parameter ini dilakukan agar tidak terjadinya penumpukan data saat klasifikasi dan memperjelas visualisasi hasilnya.

4.4 Klasifikasi *Binary SVM*


Proses klasifikasi *binary SVM* dilakukan dengan mengklasifikasikan dua kelas, dimana setiap kelasnya memiliki 500 set data. Sehingga total *input* data sejumlah 1000 data x 3 parameter statistik. Terdapat dua tahapan yang dilakukan, diantaranya proses *training* dan *testing*. Total data *input* yang dimiliki kemudian dipisahkan dengan menggunakan metode *cross-validation*, sehingga menghasilkan 800 set data untuk proses *training* dan 200 set data untuk proses *testing*.

Proses *training* merupakan tahap pembentukan model klasifikasi. Model ini dibangun berdasarkan 800 set data *training* yang digolongkan terhadap kelasnya masing – masing. Proses pembentukan ini memetakan *hyperplane* optimal menggunakan *kernel function RBF*. Keluaran yang dihasilkan dari model ini berupa *support vector*, yang berupa pola dengan jarak terdekat terhadap *hyperplane* optimal.

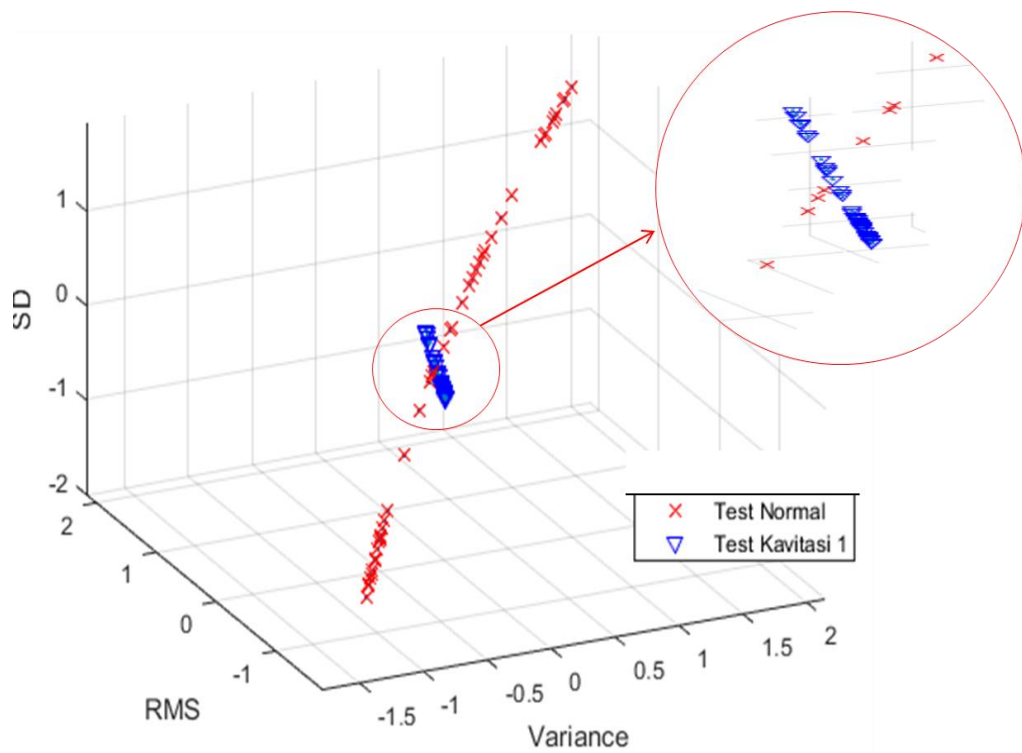
Proses *testing* dilakukan sebagai tahapan evaluasi terhadap model klasifikasi yang dibangun. Sebanyak 200 set data *testing* dari 2 kelas menempati model klasifikasi dan menghitung tingkat akurasi yang diberikan dari pengelompokan data tersebut.

4.4.1 Hasil Klasifikasi Data Normal dan Kavitas Level 1

Hasil klasifikasi data normal dan kavitas level 1 dapat dilihat seperti yang ditunjukkan pada Gambar 4.14. Model *training* yang ditunjukkan pada Gambar 4.14 (a) dan hasil *testing* pada Gambar 4.14 (b). 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*.



(a)

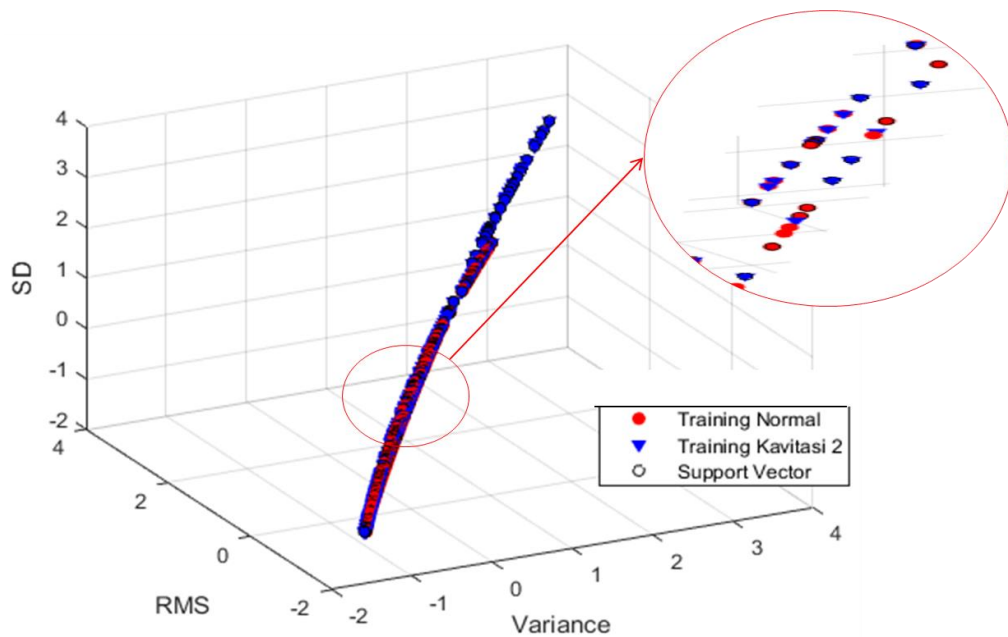


(b)

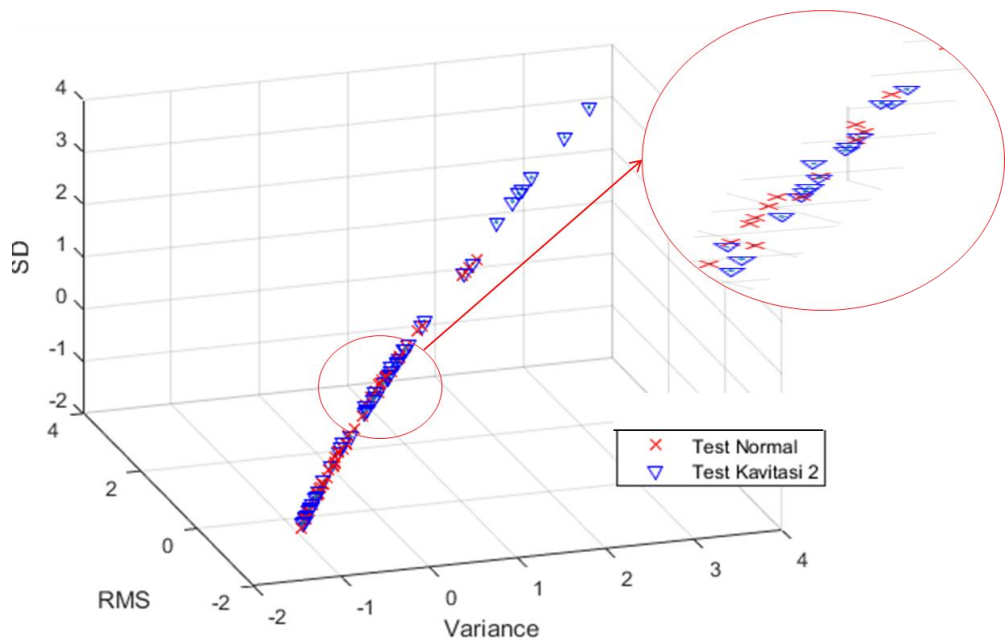
Gambar 4.14 (a) *Training* data normal dan kavitasi level 1, (b) Hasil *testing* data

4.4.2 Hasil Klasifikasi Data Normal dan Kavitas Level 2

Hasil klasifikasi berikut merupakan klasifikasi data normal terhadap kavitas level 2. Susunan pola model klasifikasi dan hasil *testing* dapat dilihat pada Gambar 4.15.



(a)



(b)

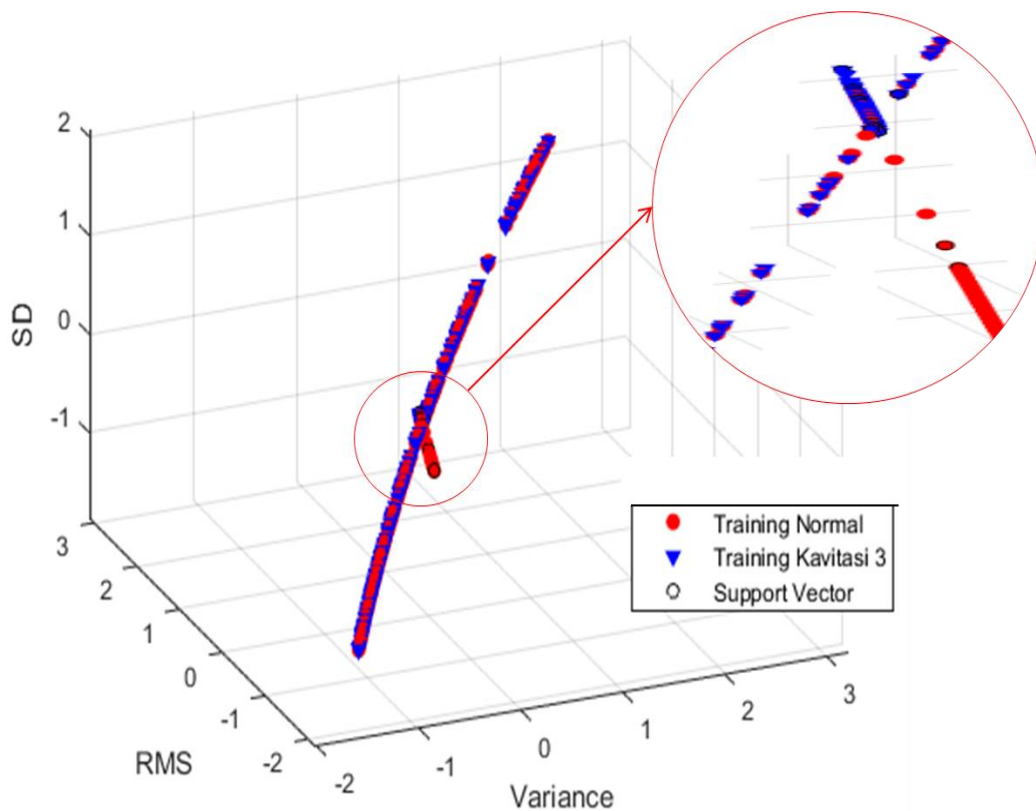
Gambar 4.15 (a) *Training* data normal dan kavitas level 2, (b) Hasil *testing* data

Dapat diketahui bahwa terdapat perbedaan antara susunan pola Gambar 4.14 dan Gambar 4.15. Hal ini dikarenakan kedua hasil klasifikasi ini dibentuk oleh proses *training* yang menggunakan set data berbeda. Pada Gambar 4.15(a) menunjukkan model klasifikasi data normal dan kavitasi level 2, dan Gambar 4.15(b) menunjukkan hasil *testing* terhadap model klasifikasi.


4.4.3 Hasil Klasifikasi Data Normal dan Kavitasi Level 3

Melalui tahapan yang sama seperti proses klasifikasi sebelumnya, model klasifikasi ini dibangun dengan menggunakan 800 set data *training* yang berasal dari data kondisi normal dan kavitasi level 3. Kemudian proses *testing* juga dilakukan dengan menggunakan 200 set data dari dua kelas tersebut.

Pada Gambar 4.15 menunjukkan klasifikasi antara normal dan kavitasi level 3 berhasil dilakukan. Gambar 4.16(a) menunjukkan model klasifikasi yang dibangun berdasarkan proses *training* dan Gambar 4.16(b) menunjukkan hasil *testing* terhadap model klasifikasi.



(a)



(b)

Gambar 4.16 (a) *Training* data normal dan kavitasi level 3, (b) Hasil *testing* data

4.4.4 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 serta tingkat akurasi tidak dapat dilakukan dengan pengamatan secara visual saja. Untuk itu proses *testing* berfungsi sebagai indikator kesuksesan sebuah klasifikasi.

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 penggolongan kelas yang ada pada model klasifikasi. Artinya semakin banyak data yang berada di dalam kelasnya maka tingkat akurasi klasifikasi semakin besar. Tingkat akurasi ketiga hasil klasifikasi *binary SVM* dapat dilihat seperti yang ditunjukkan pada Tabel 4.5.

Tabel 4.5 Hasil Klasifikasi *Binary SVM*

No	Model Klasifikasi	Tingkat Akurasi (%)
1	Normal dan Kavitasi Level 1	99
2	Normal dan Kavitasi Level 2	97
3	Normal dan Kavitasi Level 3	100

Berdasarkan Tabel 4.5 dapat diketahui bahwa hasil klasifikasi *binary SVM* berhasil dilakukan dengan tingkat akurasi diatas 97%. Hal ini lebih unggul jika dibandingkan dengan analisa karakteristik parameter statistik domain waktu, khususnya pada hasil klasifikasi data normal dan kavitasi level 1.

4.5 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 keempat kelas dapat menghasilkan enam *hyperplane* optimal. Sedangkan metode *one vs all* dilakukan dengan mencari satu *hyperplane* optimal dari keempat kelas.

Jumlah kelas yang akan diklasifikasikan sejumlah empat kelas, sehingga menghasilkan input sebanyak 2000 data x 3 parameter statistik. Hasil proses *cross-validation* menunjukkan bahwa 1800 set data digunakan untuk proses *training* dan 200 set data digunakan untuk proses *testing*. Pemetaan yang dilakukan pada proses *training* ini menggunakan *kernel function RBF*. Model klasifikasi ini kemudian dievaluasi dengan menggunakan 200 set data *testing*. Proses evaluasi ini berupaya untuk menghitung tingkat akurasi klasifikasi serta menentukan jumlah kesalahan klasifikasi pada model.

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 4.17.

Confusion Matrix

Output Class	1	27 13.5%	13 6.5%	2 1.0%	11 5.5%	50.9% 49.1%
	2	23 11.5%	37 18.5%	6 3.0%	2 1.0%	54.4% 45.6%
	3	0 0.0%	0 0.0%	35 17.5%	20 10.0%	63.6% 36.4%
	4	0 0.0%	0 0.0%	7 3.5%	17 8.5%	70.8% 29.2%
		54.0% 46.0%	74.0% 26.0%	70.0% 30.0%	34.0% 66.0%	58.0% 42.0%
	Target Class					
	1	2	3	4		

Gambar 4.17 *Confusion matrix multi class SVM*

Pada model *multi class SVM* yang mengklasifikasikan kelompok data dalam empat kelas memiliki tingkat akurasi sebesar 58% atau tingkat kesalahan klasifikasi sebesar 42%. Hal ini menunjukkan model klasifikasi yang dibangun pada proses *training* serta proses pemetaannya kurang optimal, sehingga dibutuhkan proses optimalisasi untuk meningkatkan akurasi klasifikasi.

4.6 Optimalisasi Hasil Klasifikasi *Multi Class SVM*

Metode *multi class SVM* yang mengklasifikasikan kelompok data dalam beberapa kelas merupakan metode yang diadaptasi berdasarkan modifikasi algoritma *binary SVM*. Hal ini mengakibatkan pemetaan dalam membangun model klasifikasi menjadi sulit dan rentan terhadap kesalahan. Seperti yang telah dipaparkan pada bagian sebelumnya, hasil klasifikasi *multi class SVM* pada

penelitian ini menjadi tidak optimal. Sehingga metode optimalisasi diterapkan untuk memaksimalkan hasil klasifikasi *multi class SVM*.

Metode yang digunakan dalam mengoptimalkan hasil *multi class* pada penelitian ini adalah *Grid Search Method (GSM)* dan *Bayesian Optimization (BO)*. Kedua algoritma optimalisasi ini berupaya untuk mengevaluasi kegagalan fungsi pemetaan yang dilakukan oleh *RBF*, kemudian mengembalikan hasil berupa parameter klasifikasi yang optimal untuk kembali dilakukan proses *training* hingga menghasilkan model klasifikasi terbaik.

4.6.1 Algoritma Optimalisasi *Grid Search Method (GSM)*

Tahap awal pada proses ini sama seperti proses *multi class* secara umum. Sejumlah 2000 data x 3 parameter statistik sebagai input dipisahkan dengan metode *cross validation*. Sebanyak 1800 data digolongkan ke dalam data *training* dan 200 data sebagai data *testing*. Pemisahan menggunakan metode ini dilakukan dengan mengambil sampel data berdasarkan kemungkinan terbaik terhadap masing – masing set data.

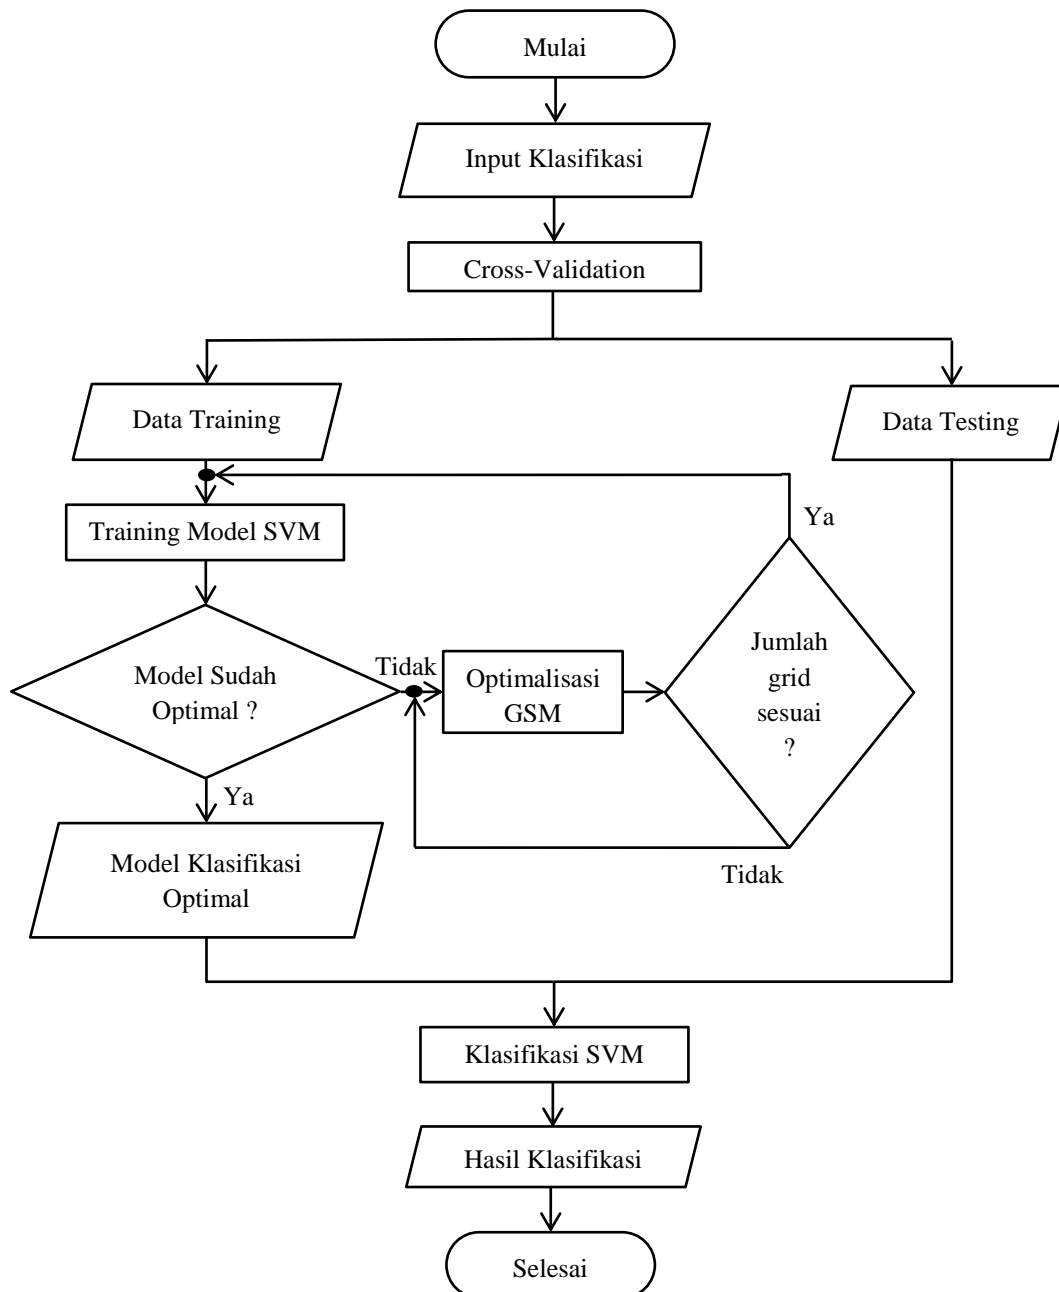
Pembentukan model klasifikasi dilakukan seperti sebelumnya. Pada setiap proses pemetaan, algoritma *GSM* berupaya melakukan evaluasi fungsi tersebut. Evaluasi dilakukan dengan menentukan posisi *grid* pada setiap satu tahapan pemetaan pada model. Jumlah pemetaan yang dilakukan oleh *RBF* sejumlah data *input* pada proses *training*, maka skala *grid* yang dihasilkan juga sejumlah 1800.

Proses optimalisasi *GSM* selesai dilakukan setelah mengevaluasi seluruh fungsi pemetaan. Kemudian dari seluruh fungsi yang dioptimalisasikan tersebut diurutkan berdasarkan fungsi yang memiliki nilai parameter klasifikasi terbaik. Urutan pertama dalam hasil optimalisasi ini seperti yang ditunjukkan pada Tabel 4.6, menjadi parameter *input* dalam model klasifikasi.

Tabel 4.6 Parameter hasil optimalisasi algoritma *GSM*

Metode	Box Constrain	Kernel Scale	Objective
One vs One	1000e + 3	0,1	0,020555556

Penggunaan algoritma *GSM* berbasis pada pencarian *grid* (kisi – kisi) pada fungsi pemetaan yang digunakan pada proses *training*. Skala *grid* ditentukan secara logaritmik terhadap hasil *cross validation*. Proses kerja optimalisasi menggunakan algoritma *GSM* dapat dilihat pada diagram alir seperti yang ditunjukkan pada Gambar 4.18.



Gambar 4.18 Diagram alir proses optimalisasi menggunakan *GSM*

Input parameter baru yang telah dioptimalisasikan kemudian di *training* untuk membangun sebuah model klasifikasi yang optimal. Untuk menentukan tingkat keberhasilan model klasifikasi yang optimal dilakukan dengan proses *testing*. Proses *testing* model klasifikasi terhadap data *testing* menentukan tingkat akurasi dan kesalahan klasifikasi. Unjuk kerja model klasifikasi dapat dilihat berdasarkan *confusion matrix* seperti yang ditunjukkan pada Gambar 4.19.

Confusion Matrix

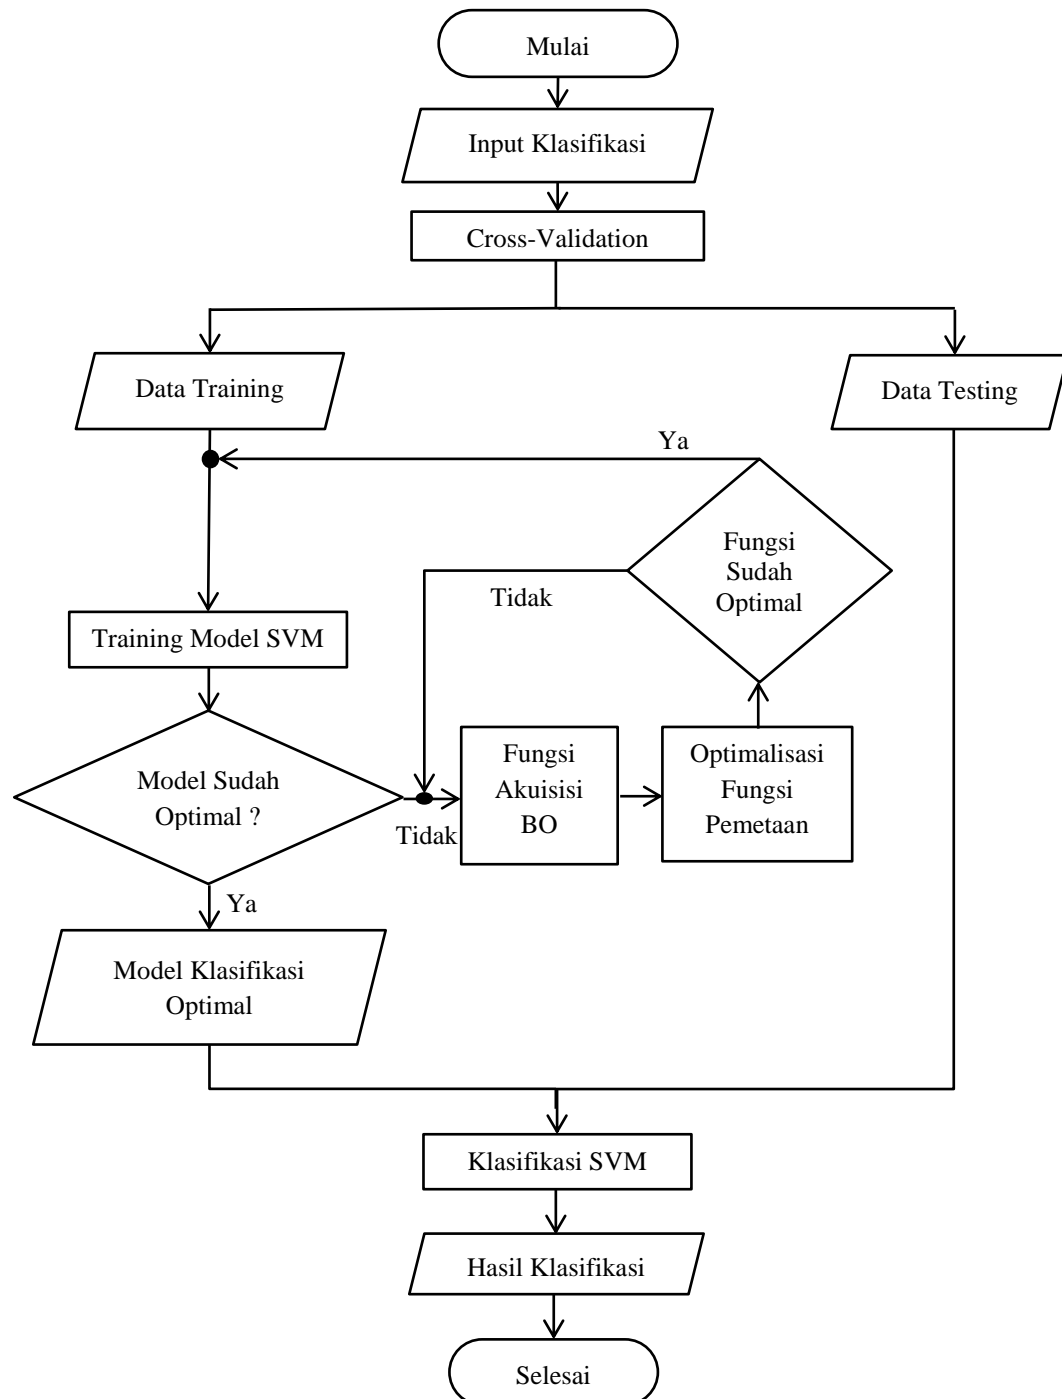
Output Class	1	50 25.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	50 25.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	0 0.0%	49 24.5%	0 0.0%	100% 0.0%
	4	0 0.0%	0 0.0%	1 0.5%	50 25.0%	98.0% 2.0%
		100% 0.0%	100% 0.0%	98.0% 2.0%	100% 0.0%	99.5% 0.5%
	1	2	3	4		Target Class

Gambar 4.19 *Confusion matrix* hasil optimalisasi algoritma *GSM*

Dapat diketahui bahwa peningkatan akurasi pada hasil klasifikasi *multi class SVM* mencapai 99,5% . Hal ini menunjukkan bahwa *GSM* berhasil meningkatkan akurasi hasil klasifikasi *multi class SVM*.

4.6.2 Algoritma Optimalisasi *Bayesian Optimization* (BO)

Proses kerja *BO* dapat dilihat pada diagram alir seperti yang ditunjukkan pada Gambar 4.20.



Gambar 4.20 Diagram alir optimalisasi menggunakan *BO*

Algoritma *BO* merupakan metode optimalisasi yang bekerja dengan meminimalisir kesalahan pemetaan dalam pembentukan model klasifikasi. Penggunaan metode ini bertujuan untuk mempertahankan fungsi *RBF* dengan menyeimbangkan *sampling* pada bagian-bagian yang rentan terhadap kesalahan pemetaan. Penyeimbangan tersebut dilakukan dengan mengevaluasi parameter klasifikasi dan mengembalikan hasil parameter yang telah dioptimalisasi.

Proses serupa dilakukan dalam *input* data klasifikasi hingga pemisahan kelompok data *training* dan *testing*. Pada metode ini algoritma *BO* memiliki dua tahapan utama, yaitu tahapan yang menggunakan fungsi akuisisi dan evaluasi terhadap fungsi pemetaan. Model klasifikasi yang dihasilkan oleh proses *training* kemudian diidentifikasi berdasarkan fungsi akuisisi *BO*. Fungsi ini bekerja dengan mencari bagian dari fungsi pemetaan yang tidak optimal. Kemudian dioptimalisasikan dengan menggunakan algoritma *BO*.

Berbeda dengan algoritma *GSM*, *BO* tidak mengevaluasi seluruh fungsi pemetaan. Akan tetapi hanya terhadap fungsi pemetaan yang masih belum optimal. Oleh sebab itu, jumlah fungsi pemetaan yang dievaluasi bergantung pada hasil tahapan fungsi akuisisi *BO*. Hal ini mengakibatkan total waktu pengoptimalisasian menggunakan algoritma *BO* lebih cepat dibanding *GSM*. Parameter yang telah dioptimalisasikan menggunakan algoritma *BO* dapat dilihat seperti yang ditunjukkan pada Table 4.7.

Tabel 4.7 Parameter hasil optimalisasi algoritma *BO*

Metode	Box Constrain	Kernel Scale	Jumlah Fungsi	Total Waktu
One vs One	128,8594	0,0292	30	508,8995
One vs All	949,436	0,0141		

Hasil optimalisasi seperti pada Tabel 4.7 kemudian dikembalikan ke proses *training* sebagai parameter klasifikasi optimal. Model klasifikasi yang dibangun kemudian dievaluasi terhadap data *testing* untuk mengetahui tingkat keberhasilannya. Performa algoritma optimalisasi *BO* dapat dilihat seperti yang ditunjukkan pada *confusion matrix* pada Gambar 4.21.


Confusion Matrix

Output Class	1	50 25.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	50 25.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	0 0.0%	50 25.0%	0 0.0%	100% 0.0%
	4	0 0.0%	0 0.0%	0 0.0%	50 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 4.21 *Confusion matrix* optimalisasi algoritma *BO*

Dapat diketahui bahwa tingkat akurasi hasil klasifikasi sebesar 100%, artinya fungsi pemetaan yang dihasilkan sempurna tanpa adanya kesalahan klasifikasi. Optimalisasi menggunakan algoritma *BO* terbukti dapat meningkatkan akurasi klasifikasi *multi class SVM*. Berikut Gambar 4.22 menunjukkan hasil *training* model klasifikasi dan hasil testing terhadap model dengan menggunakan algoritma *BO*.

Secara visual hasil klasifikasi menunjukkan pemisahan kelas dengan baik tanpa adanya kesalahan klasifikasi. Pada Gambar 4.22 (a) dapat dilihat susunan pola pada model klasifikasi dan *support vector* yang dihasilkan, dan pada Gambar 4.22(b) dimana setiap susunan pola menempati kelasnya sesuai dengan model klasifikasi.



(a)



(b)

Gambar 4.22 (a) *Training optimal multi class SVM*, (b) *Hasil test optimal multi class SVM*

4.7 Perbandingan Performa Hasil Klasifikasi *Multi Class SVM*

Seperti yang telah disebutkan bahwa tingkat keberhasilan klasifikasi ditentukan berdasarkan nilai akurasi dan jumlah kesalahan klasifikasi nya. Pada Tabel 4.8 berikut menunjukkan tingkat akurasi dan jumlah kesalahan klasifikasi dari setiap hasil *multi class SVM*.

Tabel 4.8 Performa hasil klasifikasi *multi class SVM*

Metode	Variasi Kondisi	Kesalahan Klasifikasi	Akurasi	Total Akurasi
Multi Class SVM (tanpa optimalisasi)	Normal	23	13,50%	58%
	Kavitasi Level 1	13	18,50%	
	Kavitasi Level 2	15	17,50%	
	Kavitasi Level 3	33	8,50%	
Multi Class SVM (GSM Optimization)	Normal	0	25%	99,50%
	Kavitasi Level 1	0	25%	
	Kavitasi Level 2	1	24,50%	
	Kavitasi Level 3	0	25%	
Multi Class SVM (Bayesian Optimization)	Normal	0	25%	100%
	Kavitasi Level 1	0	25%	
	Kavitasi Level 2	0	25%	
	Kavitasi Level 3	0	25%	

Hasil penelitian ini menunjukkan bahwa *multi class SVM* menggunakan metode optimalisasi *Bayesian Optimization* merupakan metode terbaik yang dapat digunakan dalam mengklasifikasikan data sinyal *vibrasi* dalam kondisi normal, kavitasi level 1, kavitasi level 2, dan kavitasi level 3 dengan perolehan tingkat akurasi sebesar 100%.