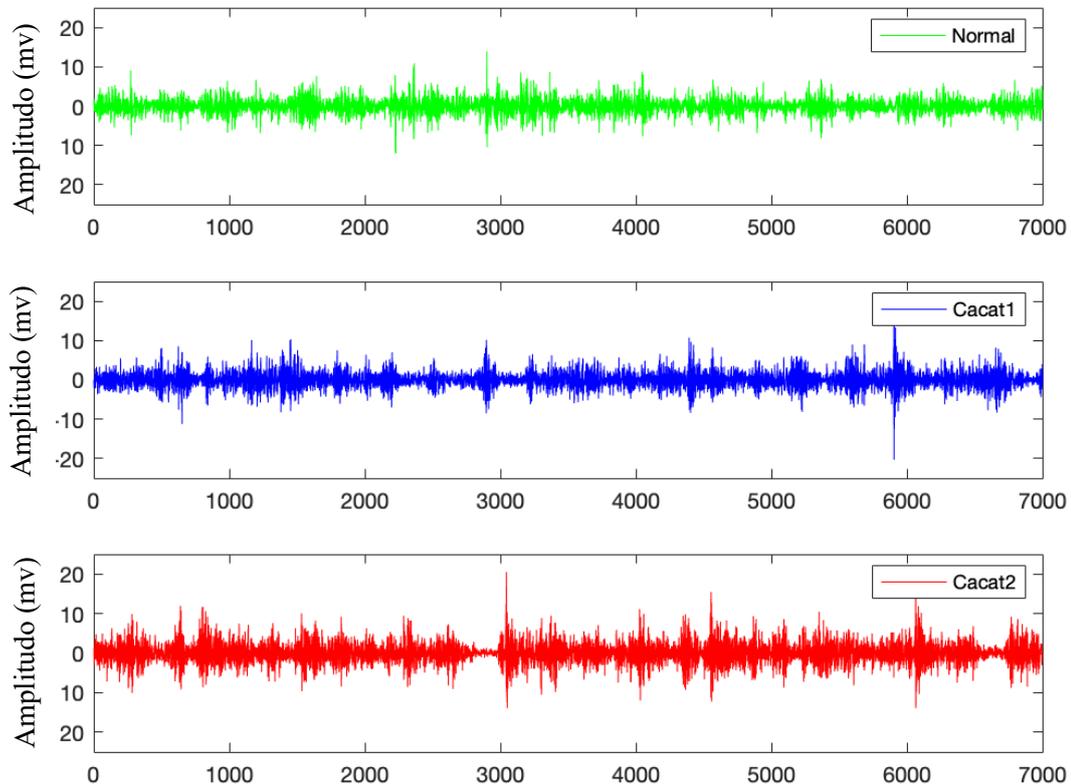


## BAB IV

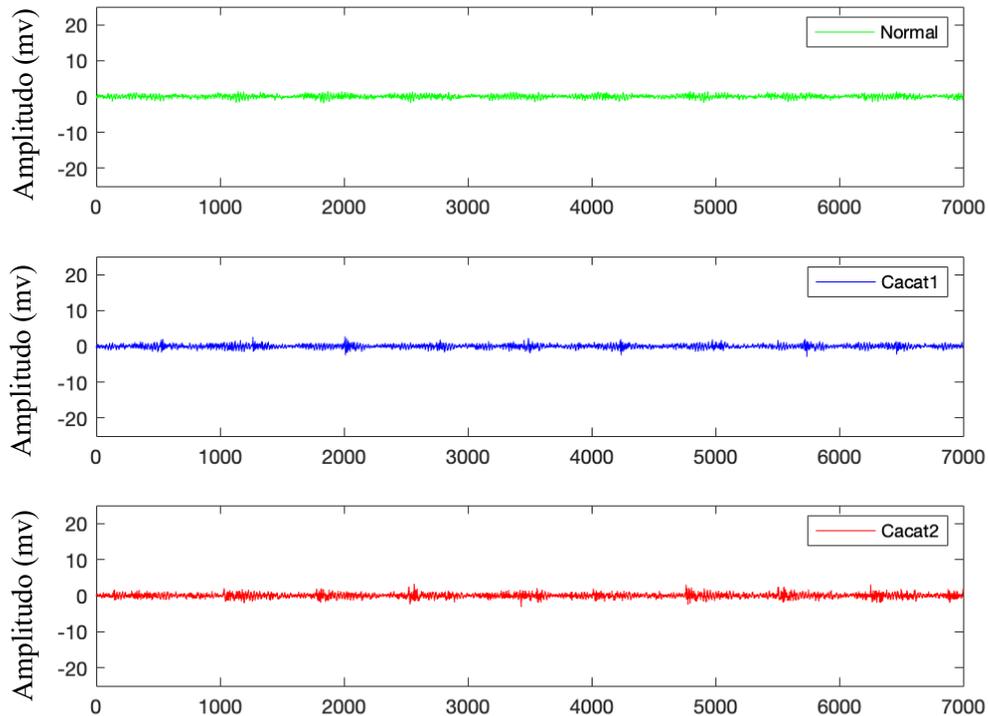
### HASIL DAN PEMBAHASAN

#### 4.1 Hasil Akuisisi Data Sinyal *Vibrasi*

Akuisisi data sinyal *vibrasi* dilakukan dengan tiga variasi kondisi, yakni roda gigi normal (Normal), roda gigi rusak satu buah gigi sebagian (Cacat 1), dan roda gigi rusak satu buah gigi keseluruhan (Cacat 2). Masing-masing dari variasi tersebut menghasilkan 500 *file* data berbasis domain waktu. Gambar 4.1 menunjukkan *plot* domain waktu kondisi roda gigi tanpa *TSA* dan Gambar 4.2 menunjukkan *plot* domain waktu kondisi roda gigi setelah *TSA*. Berdasarkan gambar tersebut terlihat bahwa amplitudo yang ditimbulkan dari variasi roda gigi yang rusak dapat terlihat dari tingginya amplitudo, begitu juga pada gambar grafik *TSA* amplitudo dari cacat roda gigi dapat terlihat.



Gambar 4.1 Roda Gigi tanpa *TSA*



Gambar 4.2 Roda Gigi setelah *TSA*

Plot domain waktu seperti pada Gambar 4.1 dan Gambar 4.2 menunjukkan perbedaan yang mendasar dari setiap variasi kondisi. Plot domain waktu kondisi normal memiliki nilai amplitudo yang rendah, sehingga ketajaman puncak yang ditampilkan lebih besar dibandingkan kondisi variasi lainnya. Hasil plot domain waktu dari setiap variasi kondisi berbanding lurus terhadap tingkat kerusakan yang terjadi pada roda gigi. Semakin besar kerusakan, maka semakin besar nilai amplitudo yang dihasilkan, dan begitu pula sebaliknya.

#### 4.2 Hasil Ekstaksi Parameter Statistik Domain Waktu

Untuk melakukan suatu klasifikasi *SVM* diperlukan beberapa parameter statistik untuk membantu dalam pengelompokan berdasarkan karakteristik dari data yang direkam. Dari 500 data normal, 500 data rusak satu buah gigi sebagian (cacat 1), dan 500 data roda gigi rusak satu buah gigi keseluruhan (cacat 2) yang direkam dan dilakukan klasifikasi dengan menggunakan beberapa parameter statistik.

Ekstraksi parameter statistik domain waktu bertujuan untuk mengetahui berbagai macam karakteristik data yang dihasilkan terhadap kondisi normal, cacat 1, dan cacat 2. Berikut tabel 4.1 penggunaan parameter statistik domain waktu.

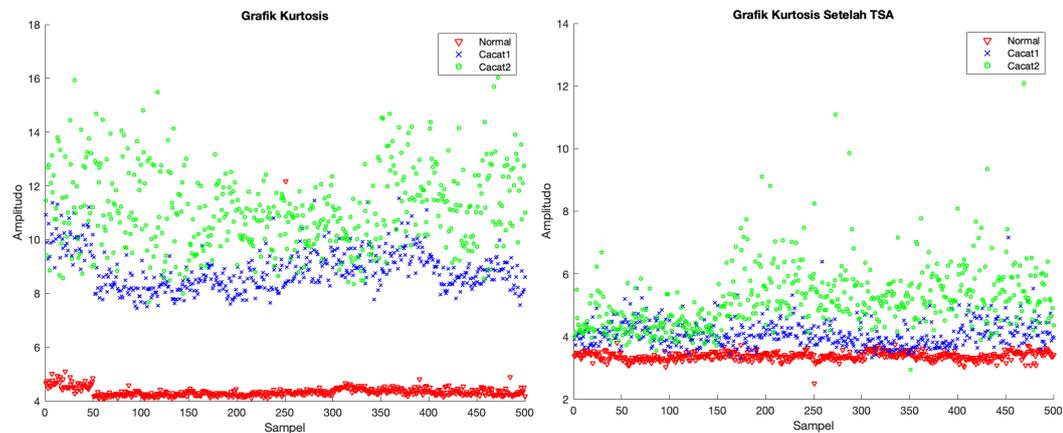
Tabel 4.1 Penggunaan parameter statistik domain waktu

No	Parameter Statistik	Jumlah Penelitian
1	Kurtosis	7
2	Skewness	6
3	Variance	6
4	Mean	5
5	RMS	4
6	Crest Factor	3
7	Peak Value	3
8	Standard Deviation	2
9	Maximum	2
10	Median	2
11	Entropy	1
12	Minimum	1

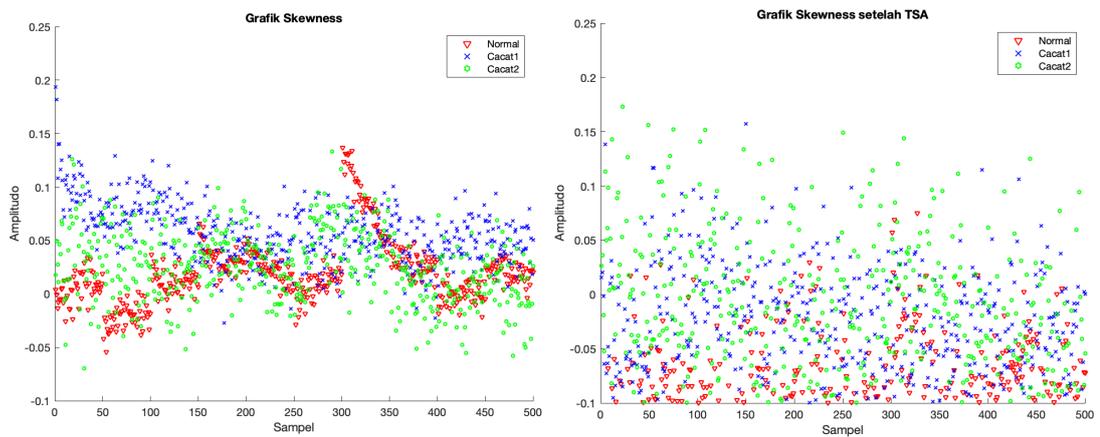
Dari tabel 4.1 dapat dilihat ada dua belas parameter statistik domain waktu yang pernah digunakan oleh peneliti sebelumnya dengan hasil cukup baik. Oleh karena itu, dalam penelitian ini akan menggunakan parameter *Kurtosis*, *Skewness*, *Variance*, *Mean*, *Root Mean Square (RMS)*, *Crest Factor*, *Peak Value*, *Standard Deviation*, *Maximum*, *Median*, *Entropy*, dan *Minimum*.

Pada gambar 4.3 dan gambar 4.4, bagian kiri adalah grafik data tanpa *TSA* dan grafik bagian kanan adalah data setelah *TSA*. Pada gambar 4.3 menunjukkan plot parameter statistik *Kurtosis*, *Skewness*, *Variance*, *Mean*, *Root Mean Square (RMS)*, *Crest Factor*, *Peak Value*. Pada plot parameter tersebut dapat dilihat bahwa parameter *Kurtosis*, *Variance*, *RMS*, dapat memisahkan variasi kondisi cukup baik pada data tanpa *TSA*, namun pada data *TSA* kurang optimal dalam memisahkan variasi kondisi. Hal ini terlihat masih banyak data yang tercampur antar variasi kondisi. Sedangkan pada parameter *Skewness*, *Mean*, *Crest Factor* tidak dapat

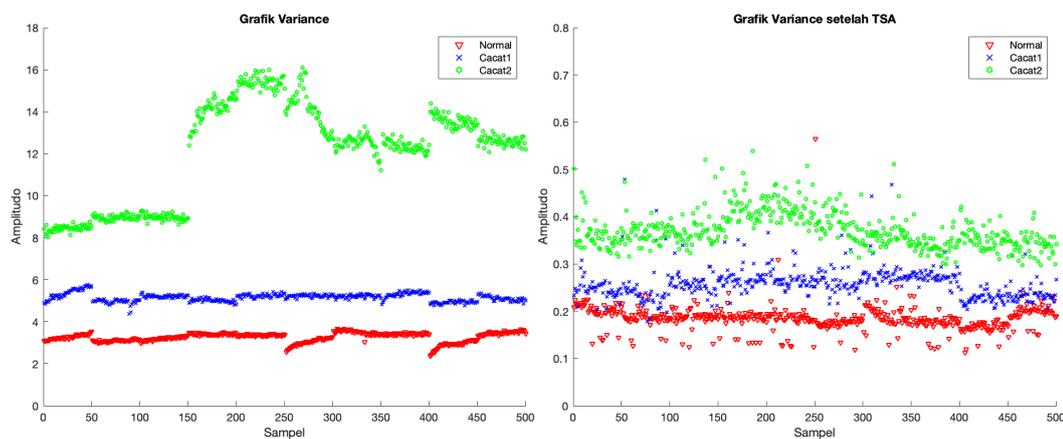
memisahkan variasi kondisi baik pada data tanpa *TSA* maupun data setelah *TSA*, sehingga parameter ini tidak dapat dijadikan rujukan sebagai input klasifikasi. Hasil plot parameter bisa dilihat pada gambar 4.3.

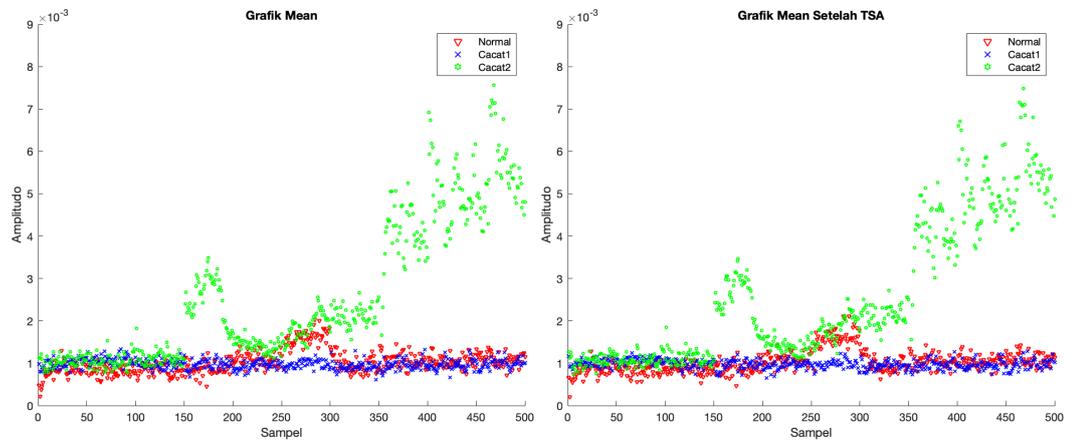
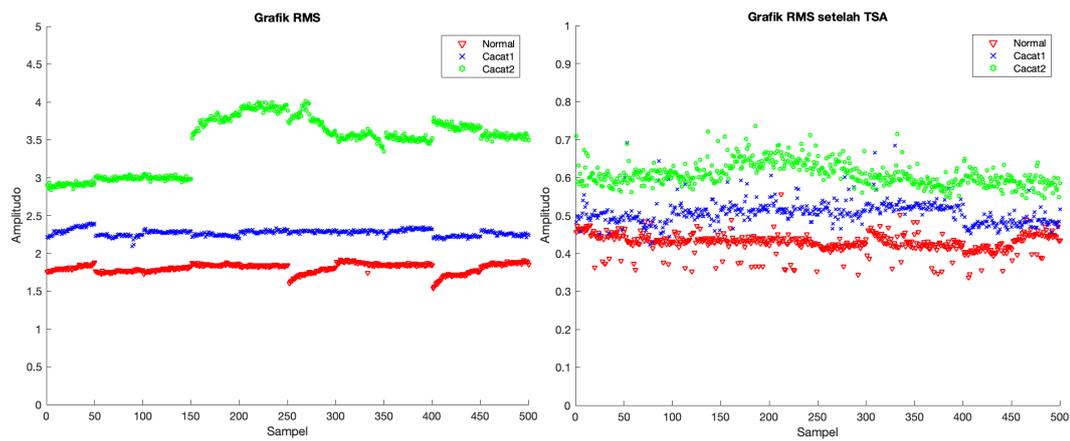
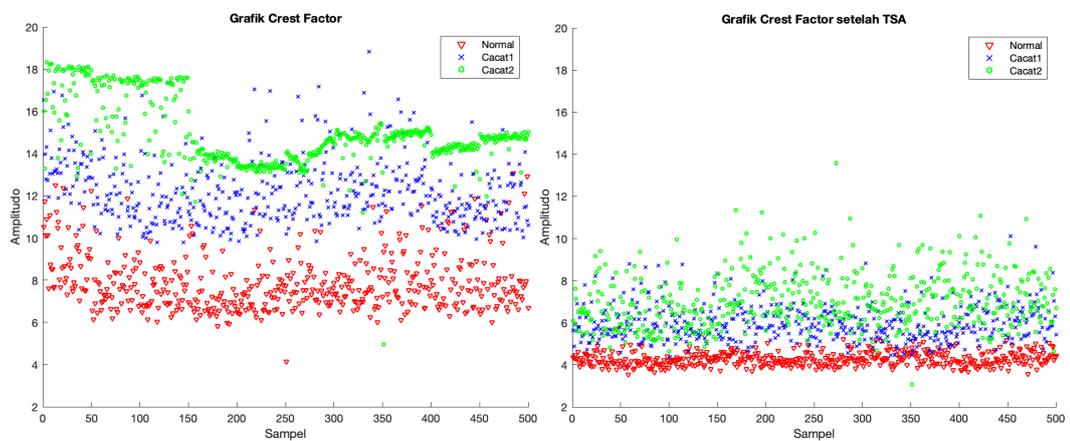


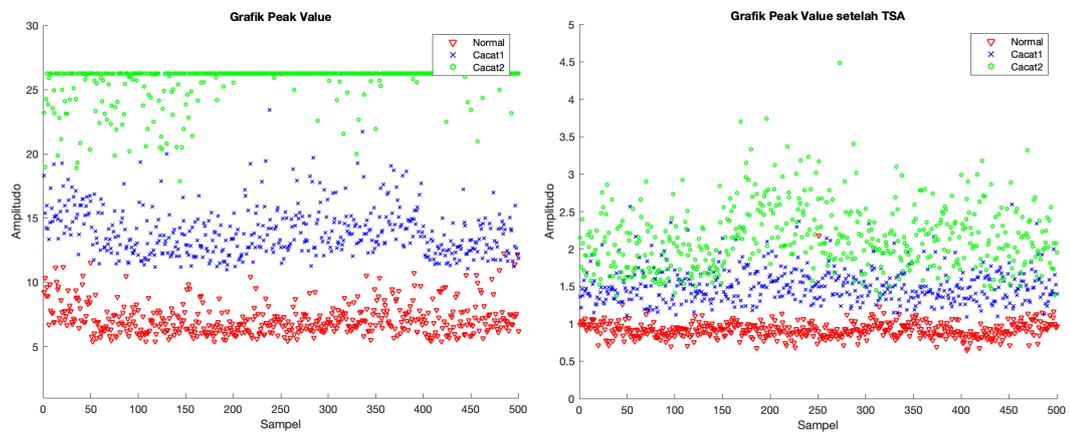
(a) Grafik parameter statistik *Kurtosis*



(b) Grafik parameter statistik *Skewness*



(c) Grafik parameter statistik *Variance*(d) Grafik parameter statistik *Mean*(e) Grafik parameter statistik *RMS*(f) Grafik parameter statistik *Crest Factor*

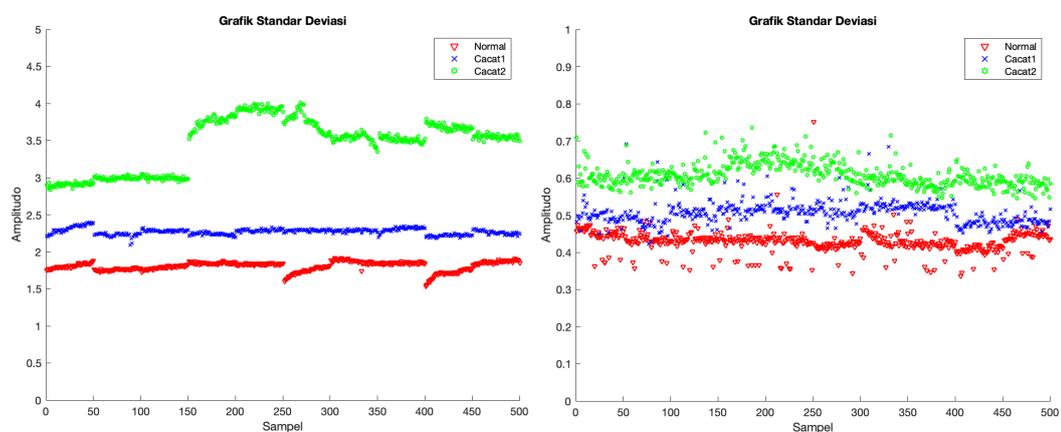


(g) Grafik parameter statistik *Peak Value*

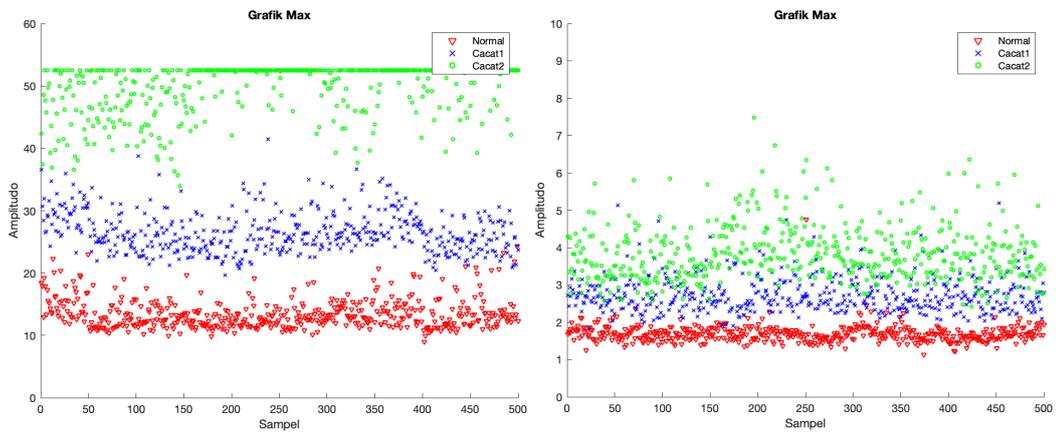
Gambar 4.3 Karakteristik parameter statistik, (a) *Kurtosis*, (b) *Skewness*, (c) *Variance*, (d) *Mean*, (e) *RMS*, (f) *Crest Factor*, (g) *Peak Value*

Pada data hasil plot tersebut dapat dilihat bahwa parameter yang cukup optimal dalam memisahkan variasi kondisi yaitu parameter *Variance* dan *RMS*. Hal ini sesuai dengan penelitian yang pernah dilakukan oleh Ramahandran, dkk pada tahun 2009 yang membuktikan bahwa parameter tersebut cukup baik.

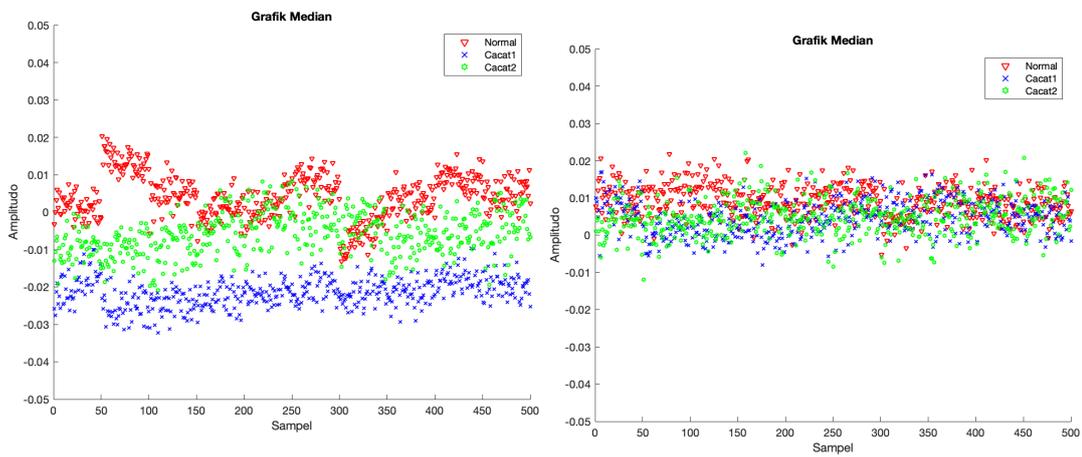
Berikut gambar 4.4 menunjukkan plot parameter statistik *Standard Deviation*, *Maximum*, *Minimum*, *Median*, *Entropy*, dan *Minimum*. Pada gambar grafik tersebut terlihat data sebaran masing-masing kondisi variasi cacat roda gigi.



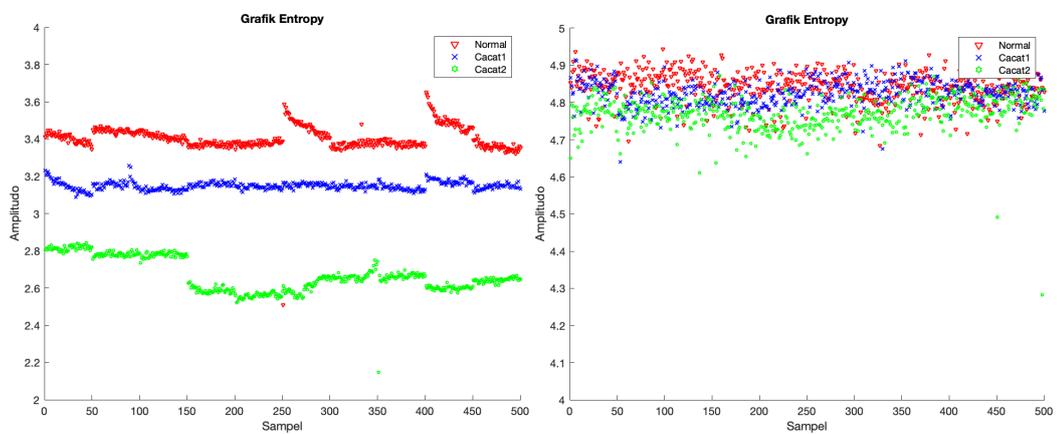
(a) Grafik parameter statistik *Standard Deviation (SD)*



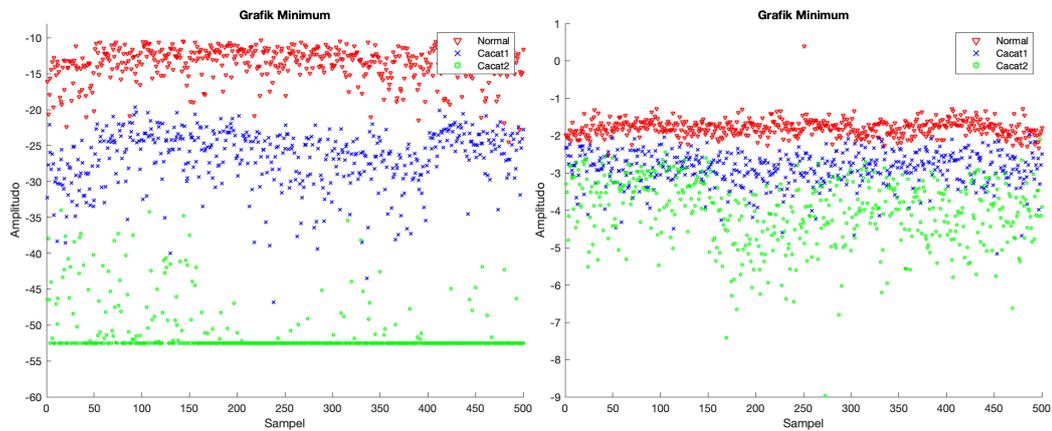
(b) Grafik parameter statistik *Maximum*



(c) Grafik parameter statistik *Median*



(d) Grafik parameter statistik *Entropy*

(e) Grafik parameter statistik *Minimum*Gambar 4.4 Karakteristik parameter statistik, (a) *Standard Deviation*, (b) *Maximum*, (c) *Median*, (d) *Entropy*, (e) *Minimum*

Pada gambar 4.4 secara visual dapat dilihat parameter yang dapat memisahkan sebaran data adalah *Standard Deviation (SD)*, *Maximum*, *Minimum*, dan *Entropy*. Namun pada parameter tersebut tidak dapat memisahkan sebaran data setelah *TSA*, karena masih banyak yang bercampur dan bersinggungan antar variasi kondisi.

Sedangkan pada parameter *Median* tidak dapat memisahkan variasi kondisi, baik itu data tanpa *TSA* dan setelah *TSA*. Hal ini bertentangan dengan penelitian yang telah dilakukan oleh Praveenkumar (2014) yang menyebutkan bahwa parameter *Median* dapat memisahkan variasi kondisi. Perbedaan ini wajar terjadi, karena objek dan variasi kondisi pada penelitian ini berbeda dengan penelitian yang pernah dilakukan oleh Praveenkumar.

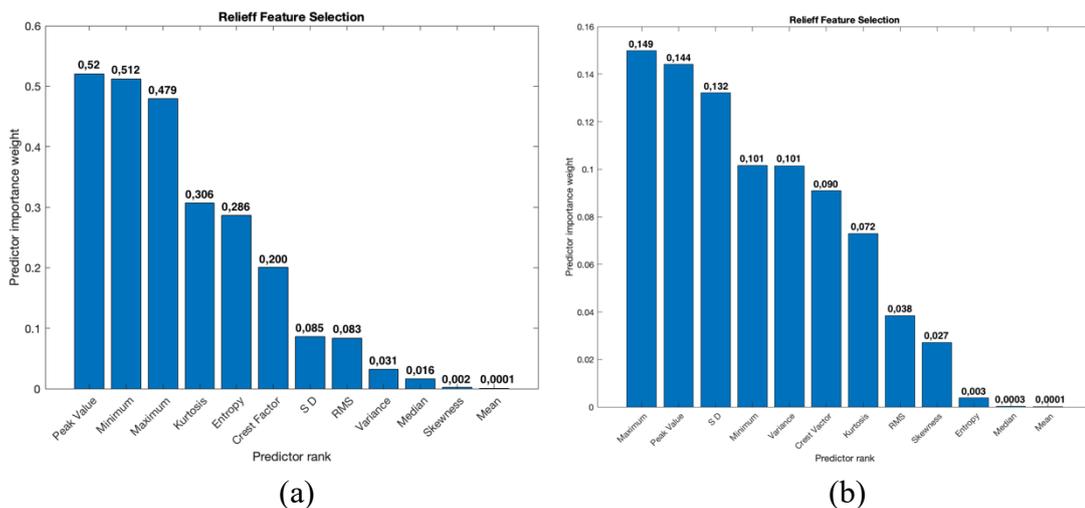
### 4.3 Hasil Seleksi Parameter Statistik Domain Waktu

Data yang telah diekstraksi ke dalam 12 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. Apabila input klasifikasi memiliki banyak data dengan kandungan informasi yang sama, maka hasil klasifikasi secara visual akan mengalami penumpukan dan 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 4.5.

Gambar 4.5 menunjukkan perbandingan grafik data tanpa *TSA* dan data yang menggunakan *TSA*. Dari grafik tersebut dapat dilihat bahwa urutan *ranked* tertinggi pada data tanpa *TSA* yaitu parameter *Peak Value* dan data setelah *TSA* yaitu *Maximum*.



Gambar 4.5 Grafik *Ranked* (a) Data tanpa *TSA* dan (b) Data setelah *TSA*

Hasil keseluruhan dari seleksi parameter statistik beserta nilai *weight* dapat dilihat pada tabel 4.2 dan tabel 4.3.

Tabel 4.2 Hasil seleksi parameter statistik tanpa *TSA*

<b>Ranked</b>	<b>Parameter Statistik</b>	<b>Weight</b>
1	Peak Value	0,52000
2	Minimum	0,51220
3	Maximum	0,47940
4	Kurtosis	0,30660
5	Entropy	0,28680
6	Crest Factor	0,20070
7	Standard Deviation	0,08572
8	RMS	0,08367
9	Variance	0,03187
10	Median	0,01652
11	Skewness	0,00250
12	Mean	0,00015

Tabel 4.3 Hasil seleksi parameter statistik setelah *TSA*

<b>Ranked</b>	<b>Parameter Statistik</b>	<b>Weight</b>
1	Maximum	0,14990
2	Peak Value	0,14420
3	Standard Deviation	0,13230
4	Minimum	0,10160
5	Variance	0,10130
6	Crest Factor	0,09099
7	Kurtosis	0,07295
8	RMS	0,03845
9	Skewness	0,02719
10	Entropy	0,00387
11	Median	0,00030
12	Mean	0,00015

Dari tabel hasil seleksi parameter statistik baik itu pada data tanpa *TSA* dan data setelah *TSA*, dipilih parameter statistik *Peak Value* dan *Kurtosis* sebagai parameter klasifikasi *SVM*. Parameter tersebut dipilih karena tingkat skor *weight* tinggi dan secara visual pada gambar 4.3(a), merupakan parameter yang dapat memisahkan data antar variasi kondisi, sehingga dijadikan *input* dalam proses klasifikasi.

#### 4.4 Klasifikasi *Binary SVM*

Proses klasifikasi *binary SVM* dilakukan dengan mengklasifikasikan dua kelas, dimana setiap kelasnya memiliki 500 set data. Ada tiga variasi kondisi, jadi total *input* data sejumlah 1500 data x 2 parameter statistik. Terdapat dua tahapan yang dilakukan, diantaranya proses *training* dan *testing*.

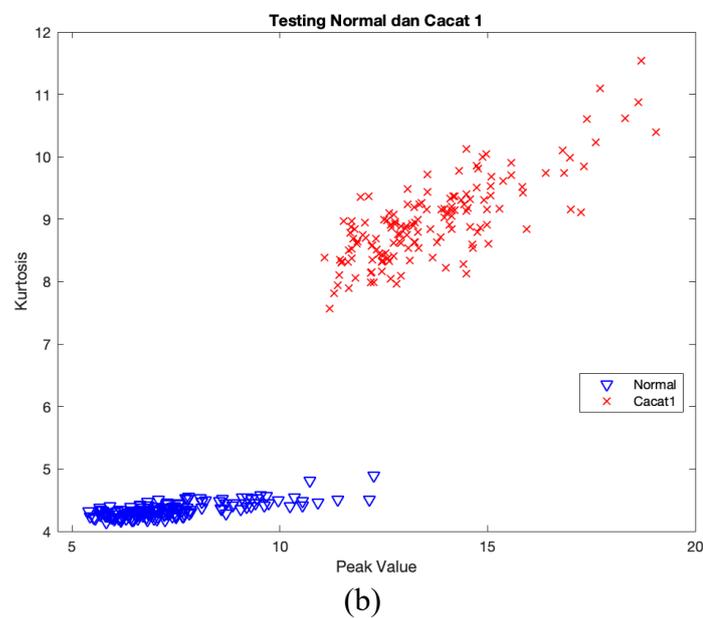
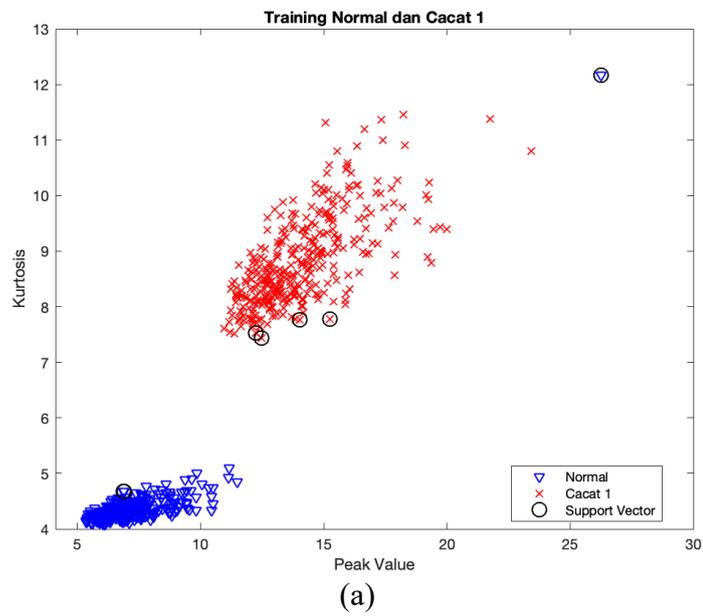
Proses *training* adalah proses pembuatan model yang digunakan sebagai acuan dalam melakukan klasifikasi. Model ini dibuat dengan menggunakan 1500 data gabungan. Kemudian dilakukan pemisahan, data *training* terdiri dari 1050 data dari ketiga variasi yang dikelompokkan 350 data tiap variasi menjadi satu set data *testing*. 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* adalah proses pengujian terhadap data *training* yang telah dibuat untuk menjamin generalisasi suatu model, dilakukan sebagai tahapan evaluasi terhadap model klasifikasi yang dibangun. Sebanyak 350 data *testing* yang terdiri dari 150 data dari ketiga kondisi variasi cacat roda gigi. Hasil dari proses ini adalah menghitung tingkat akurasi yang diberikan dari pengelompokkan data tersebut.

##### 4.4.1 Hasil Klasifikasi Kondisi Normal dan Kondisi Cacat 1

Hasil klasifikasi data normal dan kavitasi cacat 1 dapat dilihat seperti yang ditunjukkan pada Gambar 4.6. Model *training* yang ditunjukkan pada Gambar 4.6 (a) dan hasil *testing* pada Gambar 4.6 (b). Pada dasarnya kedua gambar ini memiliki

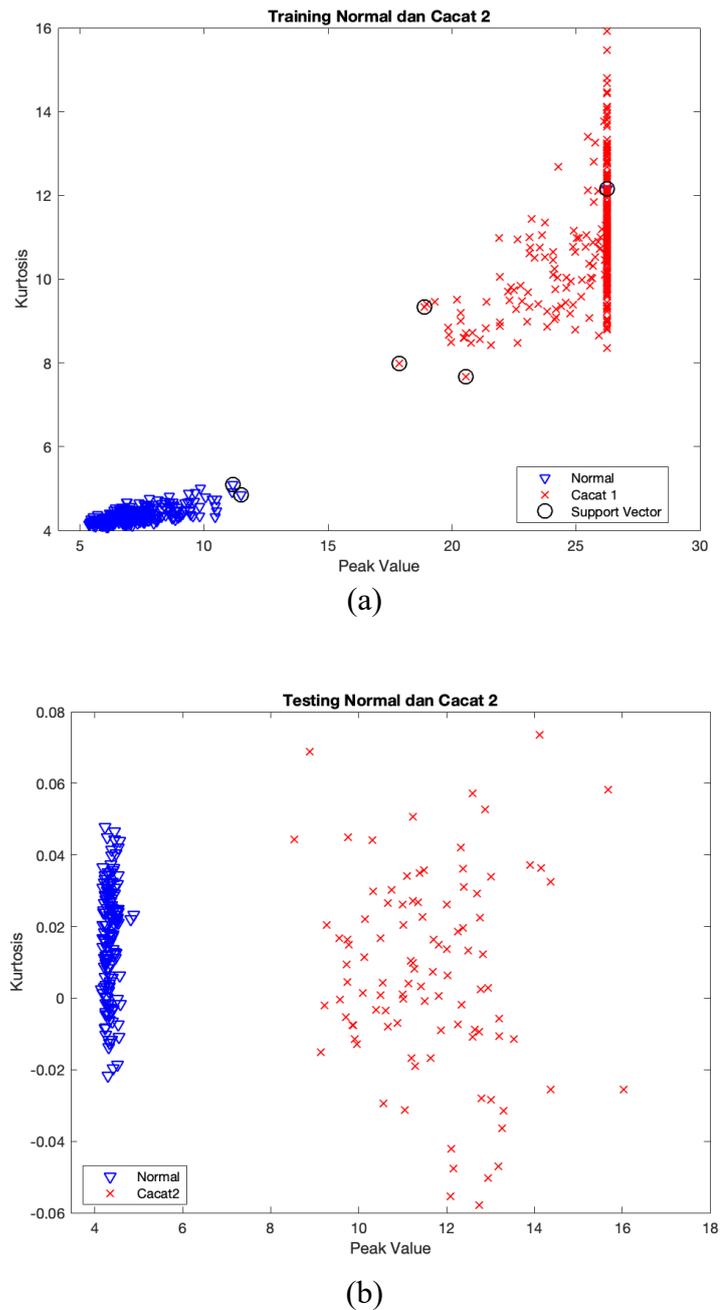
pola yang sama, karena pada proses *testing SVM* tidak membentuk model baru melainkan menempati model yang telah dibentuk pada proses *training*.



Gambar 4.6 (a) *Training* data Normal dan Cacat 1, (b) *Testing* data

#### 4.4.2 Hasil Klasifikasi Kondisi Normal dan Kondisi Cacat 2

Hasil klasifikasi berikut merupakan klasifikasi data normal terhadap kavitasi cacat 2. Susunan pola model klasifikasi dan hasil *testing* dapat dilihat pada Gambar 4.7.



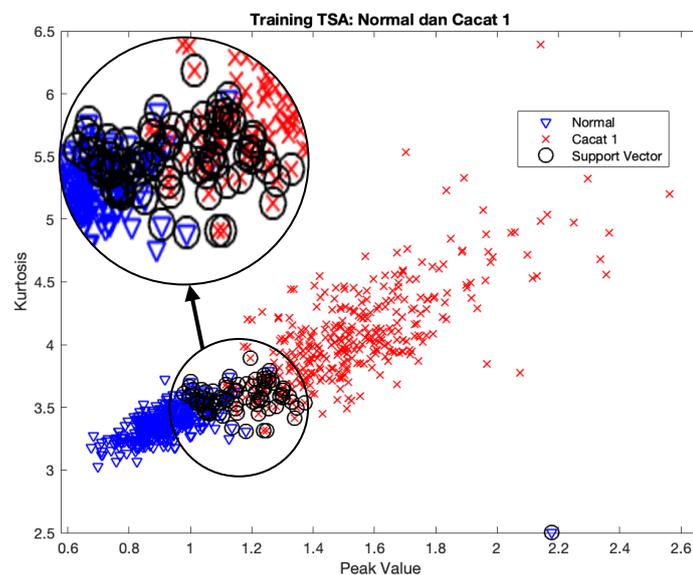
Gambar 4.7 (a) *Training* data Normal dan Cacat 2, (b) *Testing* data

Dari grafik diatas dapat diketahui bahwa terdapat perbedaan antara susunan pola Gambar 4.6 dan Gambar 4.7. Hal ini dikarenakan kedua hasil klasifikasi ini dibentuk oleh proses *training* yang menggunakan set data berbeda. Pada Gambar 4.6 menunjukkan klasifikasi menggunakan data Normal dan Cacat 1. Pada Gambar 4.7(a) menunjukkan model klasifikasi data normal dan cacat 2, dan Gambar 4.7(b) menunjukkan hasil *testing* terhadap model klasifikasi.

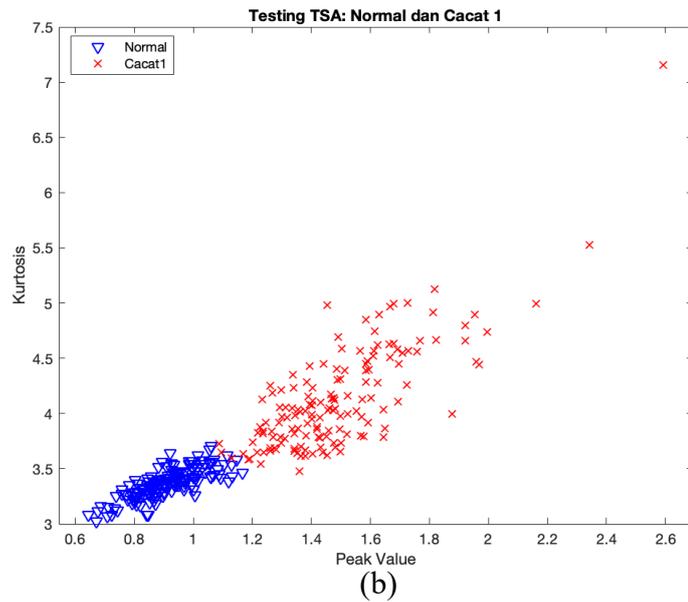
#### 4.4.3 Hasil Klasifikasi Kondisi Normal dan Kondisi Cacat 1 setelah TSA

Pada proses ini menggunakan data hasil dari pengurangan *noise* menggunakan metode *TSA*. Melalui tahapan yang sama seperti sebelumnya, data *testing* terdiri dari 1050 data dan proses *training* terdiri dari 350 data yang terdiri dari ketiga variasi kondisi.

Gambar 4.8 (a) menunjukkan hasil *testing* data normal dan cacat 1 yang sudah melalui tahapan pengurangan *noise*. Gambar 4.8 (b) menunjukkan hasil *testing* terhadap model klasifikasi.



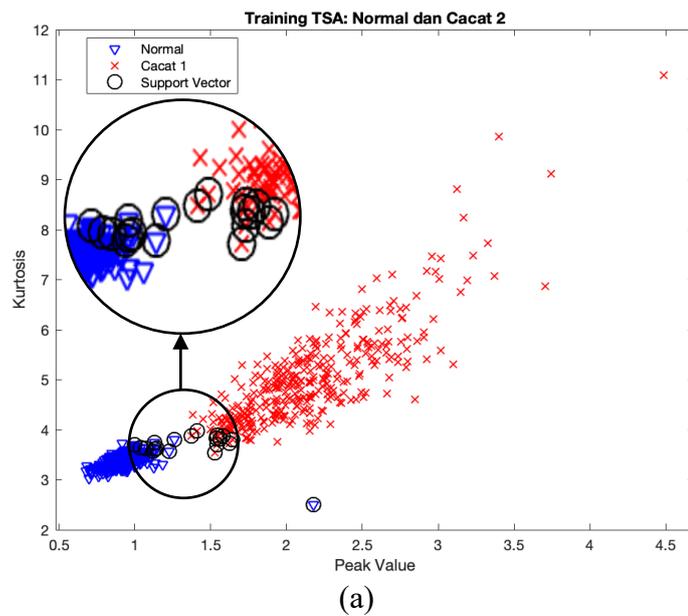
(a)

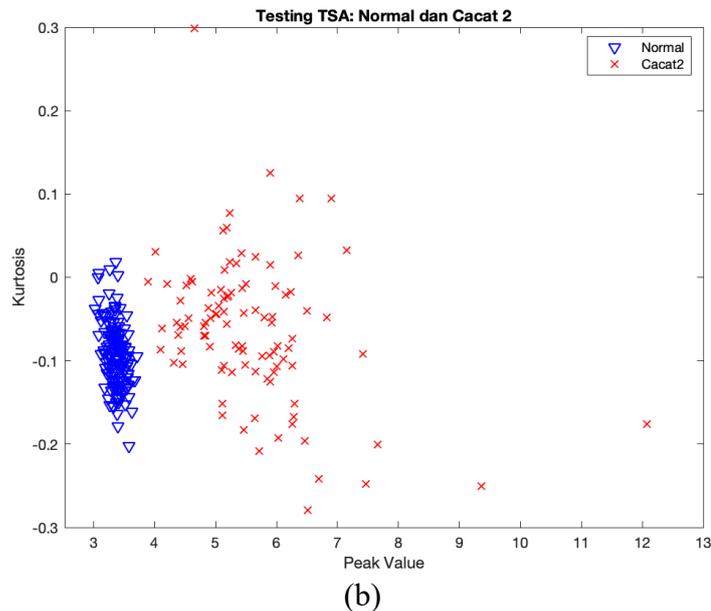


Gambar 4.8 (a) *Training* data Normal dan Cacat 1, (b) *Testing* Data

#### 4.4.4 Hasil Klasifikasi Kondisi Normal dan Kondisi Cacat 2 setelah TSA

Hasil klasifikasi normal dan cacat 2 dapat dilihat pada Gambar 4.9. Model *training* dapat dilihat pada Gambar 4.9 (a) dan hasil *testing* ditunjukkan pada Gambar 4.9 (b).





Gambar 4.9 (a) *Training* data Normal dan Cacat 2, (b) *Testing* Data

Hasil Gambar 4.9 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 berhimpitan dengan data cacat 2 dalam satu variasi. Hal ini dipengaruhi parameter statistik yang belum optimal dalam pengklasifikasian data.

#### 4.4.5 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 pengelompokkan kelas pada model klasifikasi. Tingkat akurasi kedua hasil klasifikasi *binary SVM* dapat dilihat seperti yang ditunjukkan pada Tabel 4.4.

Tabel 4.4 Hasil Klasifikasi Binary SVM

No	Model Klasifikasi	Tingkat Akurasi	Tingkat Akurasi (TSA)
1	Normal dan Cacat 1	100%	99%
2	Normal dan Cacat 2	100%	100%

Berdasarkan tabel 4.4 dapat diketahui bahwa hasil klasifikasi *binary SVM* berhasil dilakukan dengan tingkat akurasi diatas 99%. Hal ini lebih unggul jika dibandingkan dengan analisa karakteristik parameter statistik domain waktu.

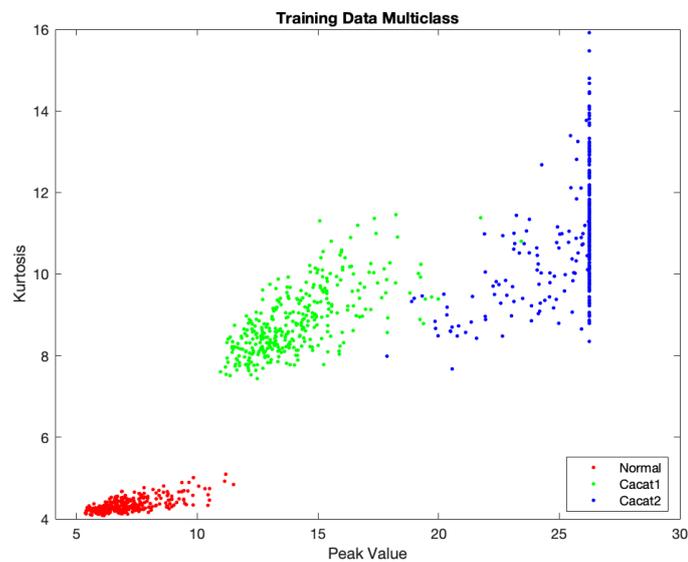
#### 4.5 Klasifikasi *Multi Class SVM*

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 ketiga kelas dapat menghasilkan empat hyperplane optimal. Sedangkan metode one vs all dilakukan dengan mencari satu hyperplane optimal dari tiga kelas.

Jumlah kelas yang akan diklasifikasikan sejumlah tiga kelas, sehingga menghasilkan input sebanyak 500 data tiap kondisinya. Dari 500 x 3 kondisi variasi, dikelompokkan untuk data *training* 1050 data dan 450 data untuk *testing*. Pemetaan yang dilakukan pada proses *training* ini menggunakan *kernel function RBF*. Model klasifikasi ini kemudian dievaluasi dengan menggunakan 450 data *testing*. Proses evaluasi ini berupaya untuk menghitung tingkat akurasi klasifikasi serta menentukan jumlah kesalahan klasifikasi pada model.

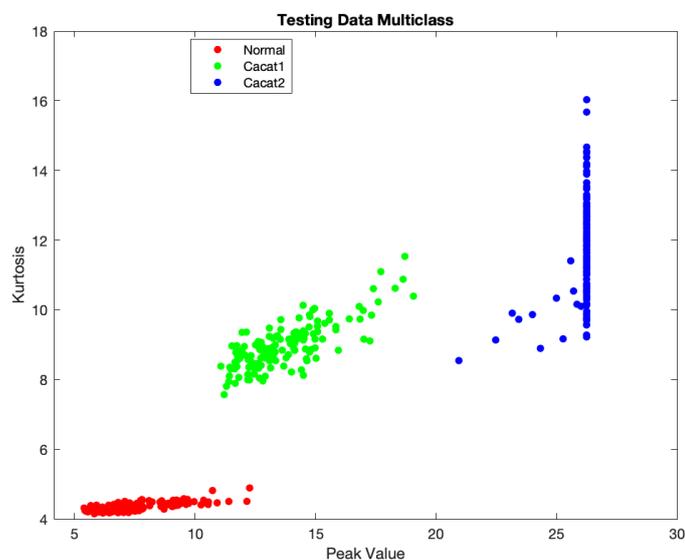
##### 4.5.1 Klasifikasi *Multi Class SVM* data tanpa TSA

Pada gambar 4.10 menunjukkan proses *training* data. Pada gambar tersebut dapat dilihat bahwa plot parameter yang digunakan masih ada data yang saling bersinggungan antar kondisi Cacat1 dan Cacat2, hal ini maklum terjadi karena hasil plot adalah dari gabungan dua parameter.



Gambar 4.10 Model *Training Multiclass SVM*

Pemetaan yang dilakukan pada proses *training* ini menggunakan *kernel function RBF*. Model klasifikasi ini kemudian dievaluasi dengan menggunakan 450 set data *testing*. Gambar 4.10 menunjukkan pembentukan pola oleh data *training*. Separasi normal dan cacat 1 terlihat optimal dalam pemisahannya, namun pada normal dan cacat 2 terlihat kurang optimal karena masih ada data yang bercampur. 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 4.11.



Gambar 4.11 Model *Testing Multiclass SVM*

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 4.12.

**Confusion Matrix**

Output Class	1	150 33.3%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	150 33.3%	0 0.0%	100% 0.0%
	3	0 0.0%	0 0.0%	150 33.3%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
		1	2	3	
		Target Class			

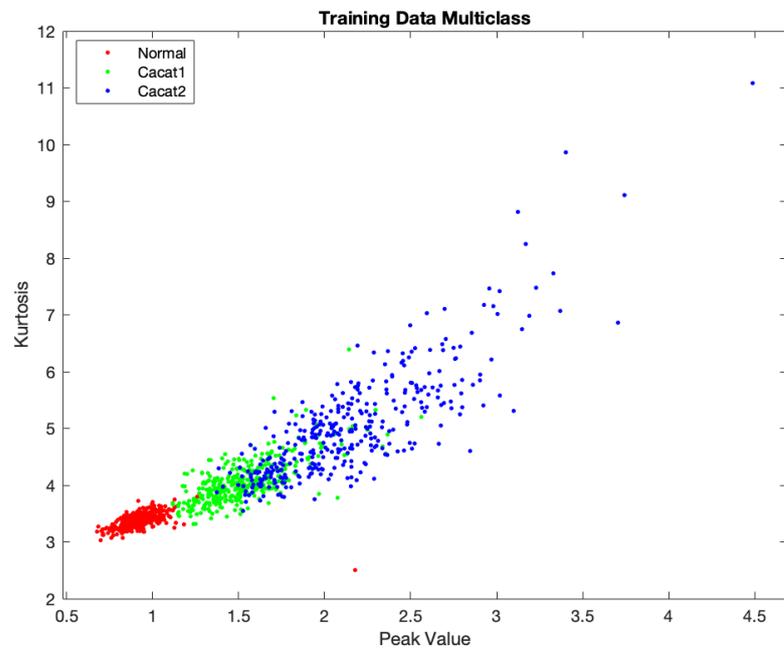
Gambar 4.12 *Confusion Matrix Multiclass SVM*

Pada model *multi class SVM* yang mengklasifikasikan kelompok data dalam tiga kelas memiliki tingkat akurasi sebesar 100%. Hal ini menunjukkan model klasifikasi yang dibangun pada proses *training* serta proses pemetaannya optimal. Terlihat hasil data *testing* sudah sesuai menempati pola tiap kondisi normal, cacat 1, dan cacat 2.

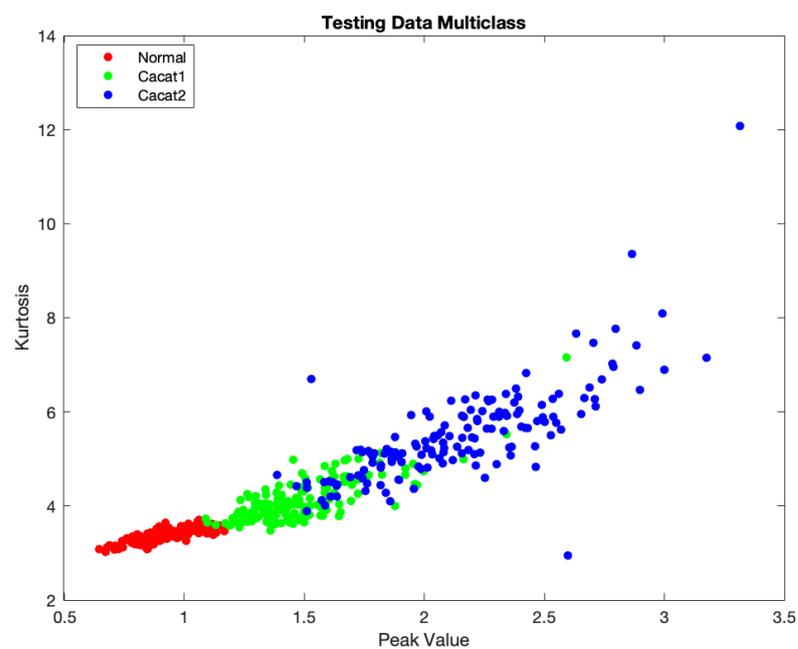
#### 4.5.2 Klasifikasi *Multi Class SVM* data setelah *TSA*

Gambar 4.13 menunjukkan sebaran data *multiclass SVM*, data yang digunakan pada plot ini adalah data yang sudah melalui *TSA*. Dapat dilihat bahwa data antara kondisi normal dan cacat 1 cukup bersinggungan, tetapi tidak banyak yang bercampur. Namun, pada kondisi kumpulan data cacat 1 dan cacat 2 banyak data yang bersinggungan bahkan bercampur. Hal ini terjadi karena pada proses *TSA* banyak data yang telah berkurang dan berubah.

Pada gambar 4.14 menunjukkan data *testing*. Dapat dilihat, data yang bercampur paling banyak yaitu pada kondisi cacat 1 dan cacat 2.



Gambar 4.13 Model *Training Multiclass SVM*



Gambar 4.14 Model *Testing Multiclass SVM*

**Confusion Matrix**

Output Class	1	127 28.2%	15 3.3%	2 0.4%	88.2% 11.8%
	2	20 4.4%	134 29.8%	0 0.0%	87.0% 13.0%
	3	3 0.7%	1 0.2%	148 32.9%	97.4% 2.6%
		84.7% 15.3%	89.3% 10.7%	98.7% 1.3%	90.9% 9.1%
	1	2	3		
	Target Class				

Gambar 4.15 *Confusion Matrix Multiclass SVM*

Pada gambar 4.15 *Confusion Matrix Multi Class SVM* data setelah *TSA* terdapat penurunan performa tingkat akurasi, karena masih ada data yang salah menempati klasifikasi. Data kondisi normal, ada 15 data menempati kondisi cacat 1 dan ada 2 data menempati cacat 2. Data kondisi cacat 1, ada 20 data menempati kondisi normal. Data kondisi cacat 2, ada 3 data yang menempati klasifikasi kondisi normal dan 1 data menempati kondisi cacat 1. Hal ini disebabkan saat penggunaan *TSA* sinyal-sinyal yang tidak sinkron akan dihilangkan, sehingga berpengaruh terhadap klasifikasi. Tingkat keberhasilan klasifikasi multiclass *SVM* untuk data setelah *TSA* menunjukkan tingkat akurasi sebesar 90,9%.