

DIAGNOSIS KETIDAKLURUSAN (*MISALIGNMENT*) POROS MENGGUNAKAN METODE *MULTICLASS SUPPORT VECTOR MACHINE* (SVM)

Wanto¹, R. Lulus Lambang, G. H. ¹, Didik Djoko Susilo ¹

¹Jurusan Teknik Mesin – Universitas Sebelas Maret

Keywords:

Misalignment
Vibration
Feature extraction
PCA
SVM

Abstract :

Misalignment is a condition where the centerlines of two coupled shafts do not coincide. Misalignment is the commonly fault in rotating machinery. Detection and diagnosis of shaft misalignment is crucial to achieve its optimal performance. The purpose of research is to diagnose shaft misalignment using multiclass support vector machine (SVM). The time-domain vibration signals of a shaft alignment rig with normal, parallel misalignment and angular misalignment of shaft conditions were obtained from vibration measurement signals. The accelerometer was used to measure vibration with a sampling frequency of 20 kHz at the constant speed operation of 1000 rpm. The features of median, RMS, crest factor, variance, kurtosis, shape factor, impulse factor, skewness, range, standard deviation and maximum were extracted from the vibration signal. The Principal Component Analysis (PCA) was applied for reduce the number of variables for data input to principal components with lower dimension. The multiclass SVM with One Against One (OAO) method and linear kernel were used for classification. The results show that SVM for diagnosis of shaft misalignment show a good performance with an accuracy of 100%.

PENDAHULUAN

Sebuah mesin rotasi dapat mengalami suatu perawatan yang tidak terjadwal (*unscheduled maintenance*) antara lain dikarenakan kegagalan suatu komponen, hal tersebut dapat diakibatkan oleh ketidakseimbangan (*unbalance*), poros bengkok (*bent shaft*) maupun ketidaklurusan (*misalignment*) pada poros putar. *misalignment* pada poros akan menyebabkan bantalan-bantalan poros menerima gaya sentrifugal tambahan yang disebabkan putaran yang tidak seimbang. Kondisi tersebut akan mengakibatkan getaran berlebihan yang akan menimbulkan kebisingan, dan selanjutnya akan menurunkan efisiensi mesin serta mengganggu pengoperasian mesin tersebut.

Kondisi *misalignment* pada mesin rotasi jika tidak segera dilakukan perbaikan proses *alignment* dapat meyebabkan kerusakan yang lebih parah. *Misalignment* menyebabkan penambahan beban pada mesin yang dapat mengakibatkan berkurangnya umur *bearing*. Hal tersebut juga dapat mengakibat -kan kendornya baut pada pondasi mesin. Selain itu *misalignment* menyebabkan temperatur tinggi pada kopling, sehingga komponen tersebut dapat cepat rusak.

Hariharan dan Srinivasan (2010), melakukan penelitian *misalignment* pada sebuah poros transmisi yang dihubungkan dengan kopling. *Misalignment* sebesar 0,2 mm dibuat dan diatur dengan kopling kaku. Kopling kaku diganti dengan kopling fleksibel dan pengujian dilakukan untuk mendapat spektrum frekuensi. Pengujian ini disimulasikan dalam ANSYS dan hasil dibandingkan. Dapat disimpulkan bahwa

dengan menggunakan kopling fleksibel getaran dapat dikurangi 85-89%.

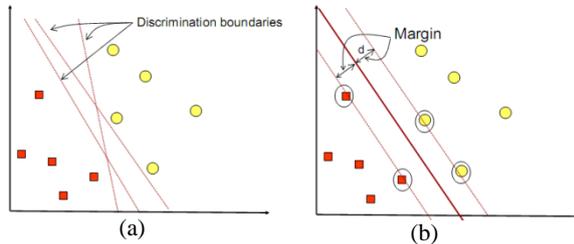
Khot dan Khaire (2015), melakukan penelitian eksperimental mengenai kegagalan akibat *parallel misalignment* dan *angular misalignment* dengan analisis frekuensi menggunakan FFT. Penelitian simulasi dari dampak *misalignment* pada sistem rotasi juga dilakukan dengan ANSYS. Kesimpulan penelitian adalah perbandingan antara simulasi dan eksperimental menunjukkan hasil yang hampir sama. Karakteristik getaran *misalignment* dapat dilihat pada 2X kecepatan putar untuk *parallel misalignment* dan 1X kecepatan putar untuk *angular misalignment*.

Ahmadi dkk (2012), mempelajari diagnosis kegagalan pada kompresor akibat *misalignment* dengan metode *Least Square Support Vector Machine* (LSSVM). Pada penelitian tersebut digunakan 30 fitur statistik, kemudian dengan seleksi fitur *backward stepwise* dipilih 2 dan 8 fitur terbaik. Hasil akurasi klasifikasi menggunakan 8 fitur lebih baik daripada menggunakan 2 fitur. Tetapi waktu komputasi dengan 2 fitur lebih cepat daripada 8 fitur.

Support Vector Machine (SVM)

Konsep SVM dapat dijelaskan secara sederhana sebagai usaha mencari *hyperplane* terbaik yang berfungsi sebagai pemisah dua buah kelas pada *input space*. Gambar 1 memperlihatkan sebaran data yang terdiri dari dua buah kelas, positif (dinotasikan dengan +1) dan negatif (dinotasikan dengan -1). Data yang tergabung pada kelas negatif disimbolkan dengan kotak, sedangkan data pada kelas positif, disimbolkan dengan lingkaran. Proses pembelajaran dalam

problem klasifikasi diterjemahkan sebagai upaya menemukan garis (*hyperplane*) yang memisahkan antara kedua kelompok tersebut. Berbagai alternative garis pemisah (*discrimination lineses*) ditunjukkan pada Gambar 1 (a).



Gambar 1. Menentukan *hyperplane* terbaik dengan SVM (Nugroho,2008)

Pada Gambar 1. (b) dua kelas dipisahkan oleh dua garis sejajar. Bidang pembatas pertama membatasi kelas pertama sedangkan bidang kedua membatasi kelas kedua, sehingga diperoleh rumus batas.

$$x_i \cdot w + b \geq +1 \quad \text{untuk} \quad x_i = +1$$

$$x_i \cdot w + b \leq -1 \quad \text{untuk} \quad x_i = -1 \quad (1)$$

dengan w adalah normal bidang dan b adalah posisi bidang relatif terhadap pusat koordinat. Nilai *margin* (jarak) antara bidang pembatas (berdasarkan rumus jarak ke garis pusat) adalah:

$$\frac{1 - b - (-1 - b)}{w} = \frac{2}{w} \quad (2)$$

Nilai ini dimaksimalkan dengan tetap memenuhi persamaan (1). Perkalian b dan w dengan sebuah konstanta, akan dihasilkan nilai margin yang dikalikan dengan konstanta yang sama. Oleh karena itu, batas (*constraint*) pada persamaan (1) merupakan *scaling constant* yang dapat dipenuhi dengan *rescaling* b dan w . Selain itu, karena memaksimalkan $1/|w|$ sama dengan meminimumkan $|w|^2$ dan jika kedua bidang pembatas persamaan (1) dinyatakan sebagai:

$$y_i(x_i \cdot w + b) - 1 \geq 0 \quad (3)$$

Maka pencarian bidang pemisah terbaik dengan nilai margin terbesar dapat dirumuskan menjadi masalah *constraint optimization*, yaitu

$$\min \frac{1}{2} |w|^2 \quad (4)$$

$$\text{s.t } y_i(x_i \cdot w + b) - 1 \geq 0$$

Persoalan ini akan lebih mudah diselesaikan jika diubah ke dalam formula *lagrangian* yang menggunakan *lagrange multiplier*. Dengan demikian permasalahan optimasi konstrain dapat diubah menjadi:

$$\min_{w,b} L_p(w,b,a) = \frac{1}{2} |w|^2 - \sum_{i=1}^n a_i y_i (x_i \cdot w + b) + \sum_{i=1}^n a_i \quad (5)$$

dengan tambahan konstrain, $a_i \geq 0$ (nilai dari koefisien lagrange). Dengan meminimumkan L_p terhadap w dan b , maka diperoleh persamaan (6) dan (7).

$$\frac{\partial}{\partial b} L_p(w,b,a) = 0$$

$$\sum_{i=1}^n a_i y_i = 0 \quad (6)$$

$$\frac{\partial}{\partial w} L_p(w,b,a) = 0$$

$$w = \sum_{i=1}^n a_i y_i x_i \quad (7)$$

Vektor w seringkali bernilai besar (mungkin tak terhingga), tetapi nilai a_i terhingga. Untuk itu, formula lagrangian L_p (*primal problem*) diubah ke dalam *dual problem* L_D . Dengan mensubstitusikan persamaan (7) ke L_p diperoleh *dual problem* L_D dengan batas berbeda.

$$L_D(\alpha) = \sum_{i=0}^n \alpha_i - \frac{1}{2} \sum_{i=1, j=1}^n \alpha_i \alpha_j y_i y_j x_i x_j \quad (8)$$

$$\text{s.t. } \sum_{i=1}^n a_i y_i = 0, \alpha_i \geq 0$$

Dengan demikian, dapat diperoleh nilai a_i yang nantinya digunakan untuk menemukan w . Terdapat nilai a_i dari setiap data pelatihan. Data pelatihan yang memiliki nilai $a_i > 0$ adalah *support vector* sedangkan sisanya memiliki nilai $a_i = 0$. Dengan demikian fungsi keputusan yang dihasilkan hanya dipengaruhi oleh *support vector*.

Formula pencarian bidang pemisah terbaik ini adalah permasalahan *quadratic programming* sehingga nilai maksimum global dari a_i selalu dapat ditemukan. Setelah solusi permasalahan *quadratic programming* ditemukan (nilai a_i diperoleh), maka kelas dari data pengujian x dapat ditentukan berdasarkan nilai dari fungsi keputusan:

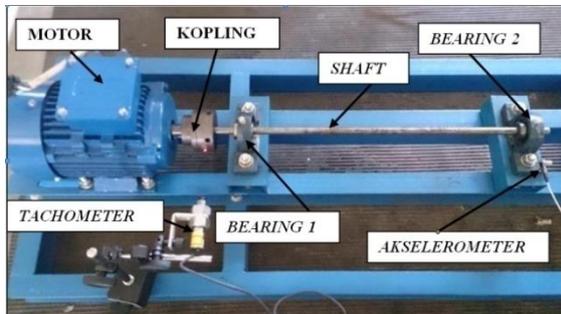
$$f(x_d) = \sum_{i=0}^{ns} \alpha_i y_i x_i x_d + b \quad (9)$$

x_i adalah *support vector*, ns = jumlah *support vector* dan x_d adalah data yang akan diklasifikasi.

METODE PENELITIAN

Pada penelitian yang telah dilakukan menggunakan *rig alignment shaft* dengan penggerak motor listrik berdaya 1 hp dengan putaran kerja 1000 rpm. *Rig* yang digunakan ditunjukkan pada Gambar 1. Sinyal getaran pada poros dengan kondisi normal, *parallel misalignment* dan *angular misalignment*

diukur menggunakan sensor PCB *Piezotronics Single Axis Accelerometer* model 352C33. Sensor akselerometer dipasang dengan arah aksial pada kedudukan *bearing* dengan metode *adhesive mounting*. *Sampling rate* yang digunakan adalah 20 kHz.



Gambar 2. *Rig alignment shaft*

Filter

Filter sinyal yang digunakan adalah filter *low pass Finite Impulse Response (FIR)* dengan *window blackman* dan frekuensi *cut-off* 200 Hz. Frekuensi getaran yang diamati adalah frekuensi harmonik dari kecepatan putar komponen yang berada pada frekuensi 0 sampai 200 Hz. Filter digunakan untuk menghilangkan sinyal *noise* dan interferensi yang tidak diinginkan agar menghasilkan kualitas sinyal yang lebih baik.

Ekstraksi Fitur

Hasil dari filter terhadap sinyal getaran kemudian diekstrak menggunakan parameter fitur statistik. Fitur statistik yang digunakan berjumlah 11 fitur, yaitu:

1. Standar Deviasi

Standar deviasi dari sebuah himpunan data adalah ukuran seberapa tersebar nya nilai data-data tersebut. Hal tersebut ditunjukkan oleh rumus standar deviasi sebagai berikut.

$$s = \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n}} \quad (10)$$

2. Maksimum

Maksimum adalah nilai tertinggi dari suatu *array* (deret angka). Maka nilai maksimum ditunjukkan oleh rumus berikut.

$$\text{Max} = \max(x_i) \quad (11)$$

3. Root Mean Square (RMS)

RMS adalah akar rata-rata kuadrat yang dirumuskan sebagai berikut.

$$\text{RMS} = \sqrt{\frac{\sum_{i=1}^n (X_i)^2}{n}} \quad (12)$$

4. Varian

Varian merupakan cara lain untuk mengukur tersebar nya data-data yang ada dalam sebuah himpunan. Varian (s^2) adalah kuadrat dari standar deviasi. Rumus dari varian adalah sebagai berikut.

$$s^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n} \quad (13)$$

5. Skewness

Skewness adalah pengukuran data asimetri di sekitar rata-rata sampel. *Skewness* dirumuskan dengan persamaan sebagai berikut:

$$sk = \frac{\frac{1}{n} \sum_{i=1}^n ((X_i - \bar{X})^3)}{(\frac{1}{n} \sum_{i=1}^n ((X_i - \bar{X})^2)^{3/2}} \quad (14)$$

6. Kurtosis

Kurtosis adalah derajat keruncingan dari suatu distribusi. Kurtosis dapat dirumuskan dengan persamaan berikut:

$$k = \frac{\frac{1}{n} \sum_{i=1}^n ((X_i - \bar{X})^4)}{(\frac{1}{n} \sum_{i=1}^n ((X_i - \bar{X})^2)^2} \quad (15)$$

7. Faktor Puncak (*crest factor*)

Faktor puncak adalah perbandingan nilai puncak terhadap nilai RMS dari gelombang.

$$Cf = \frac{X_{peak}}{X_{rms}} \quad (16)$$

8. Faktor Bentuk (*shape factor*)

Faktor bentuk adalah perbandingan antara nilai RMS dengan nilai rata-rata dari gelombang.

$$Sf = \frac{X_{rms}}{\text{Mean}(|X_i|)} \quad (17)$$

9. Median

Median adalah nilai tengah dari nilai-nilai pengamatan setelah disusun secara teratur menurut besarnya data.

$$M = \frac{n+1}{2} \quad (18)$$

10. Impulse Factor

Impulse Factor adalah perbandingan antara nilai maksimum dengan nilai rata-rata dari gelombang.

$$If = \frac{\text{Max}(X_i)}{\text{Mean}(|X_i|)} \quad (19)$$

11. Jangkauan (*range*)

Range adalah ukuran variasi yang dihitung dari selisih antara nilai yang terbesar dengan nilai terkecil.

$$\text{Range} = \text{Max}(X_i) - \text{Min}(X_i) \quad (20)$$

Principal Component Analysis (PCA)

Tujuan dari analisis PCA adalah untuk mereduksi variabel yang ada menjadi lebih sedikit tanpa harus kehilangan informasi yang termuat dalam data asli/awal. Dengan menggunakan PCA, variabel yang tadinya sebanyak n variabel akan direduksi menjadi k , $k \leq n-1$ variabel baru (*principal component*). Dengan hanya menggunakan k *principal component* akan menghasilkan nilai yang sama dengan menggunakan n variabel (Johnson dan Wichem, 2007). Sifat dari variabel baru yang terbentuk dengan analisis PCA selain memiliki jumlah variabel yang lebih sedikit tetapi juga

menghilangkan korelasi antar variabel yang terbentuk. Algoritma PCA adalah sebagai berikut :

1. Hitung matriks kovarian dengan menggunakan persamaan.

$$cov(X, Y) = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{(n-1)} \quad (21)$$

2. Hitung nilai eigen dengan menyelesaikan persamaan.

$$(A - \lambda I) = 0 \quad (22)$$

3. Hitung vektor eigen dengan menyelesaikan persamaan.

$$(A - \lambda I)[X] = [0] \quad (23)$$

4. Tentukan variabel baru (*principal component*) dengan mengalikan variabel asli dengan matriks vektor eigen.

Sedangkan varian yang dapat dijelaskan oleh variabel baru ke-i tergantung kontribusi pi, dari masing-masing nilai eigen yang dihitung dengan persamaan.

$$pi = \frac{\lambda_i}{\sum_{j=1}^n (\lambda_j)} \quad (24)$$

Ada tiga cara yang digunakan untuk menentukan jumlah komponen utama (*principal component*) yang akan digunakan untuk analisis selanjutnya (Johnson dan Wichem, 2007). Pertama, dengan melihat total variansi yang dapat dijelaskan lebih dari 80%. Cara kedua adalah dengan melihat nilai eigen tiap-tiap komponen yang memiliki nilai lebih dari satu. Cara ketiga adalah dengan mengamati *scree plot* yaitu dengan melihat patahan siku dari *scree plot*.

Data yang mempunyai dimensi 11 hasil dari ekstraksi fitur akan direduksi menjadi data berdimensi lebih kecil dengan metode PCA. Pemilihan jumlah dimensi data (variabel data) dilakukan dengan melihat total variansi yang dapat dijelaskan lebih dari 80%. Setelah dimensi data direduksi, selanjutnya akan digunakan sebagai data *input* pengklasifikasian metode SVM.

Klasifikasi SVM

Proses pembelajaran pada SVM bertujuan untuk mendapatkan hipotesis berupa bidang pemisah terbaik yang tidak hanya meminimalkan *empirical risk* yaitu rata-rata *error* pada data pelatihan, tetapi juga memiliki generalisasi yang baik. Generalisasi adalah kemampuan sebuah hipotesis untuk mengklasifikasikan data yang tidak terdapat dalam data pelatihan dengan benar.

Akurasi model yang akan dihasilkan dari proses pelatihan dengan SVM sangat bergantung pada fungsi kernel serta parameter yang digunakan. Oleh karena itu performansinya dapat dioptimasi dengan mencari atau mengestimasi parameter terbaik. Cara yang dapat dilakukan adalah *cross validation* untuk menentukan nilai parameter C dan parameter

kernel yang tidak menyebabkan kondisi *overfit* pada data pelatihan (Hsu, 2004).

Parameter C disebut juga dengan *error penalty*, karena berhubungan *trade-off* antara batas maksimum dan kesalahan klasifikasi selama proses *training*. Pemilihan nilai *error penalty* yang tepat akan membuat *training SVM* dapat mencegah terjadinya kesalahan klasifikasi. Dengan nilai *error penalty* yang tinggi dapat menghasilkan batas yang mengklasifikasikan semua data *training* secara tepat (Poyhonen, 2004).

HASIL DAN PEMBAHASAN

Dari hasil model *training SVM* diperoleh akurasi 100 % untuk parameter C = 1, C = 10 dan C = 100. Pada C = 0,1 akurasi model SVM adalah 99,7%, data pada *training* tidak terklasifikasikan secara sempurna seperti ditunjukkan pada Gambar 3.(a). Penurunan akurasi tersebut terjadi karena dengan nilai C yang semakin kecil maka akan menyebabkan margin pada model SVM semakin luas dan jumlah data yang melewati batas margin lebih banyak. Luas margin pada model SVM ditunjukkan dengan *decision boundary* ditunjukkan Gambar 3. Semakin luas margin maka data yang melewati batas margin akan semakin banyak, hal tersebut dapat ditunjukkan dengan bertambahnya jumlah *bounded support vector* jika nilai parameter C semakin kecil yang ditunjukkan pada Tabel 1.

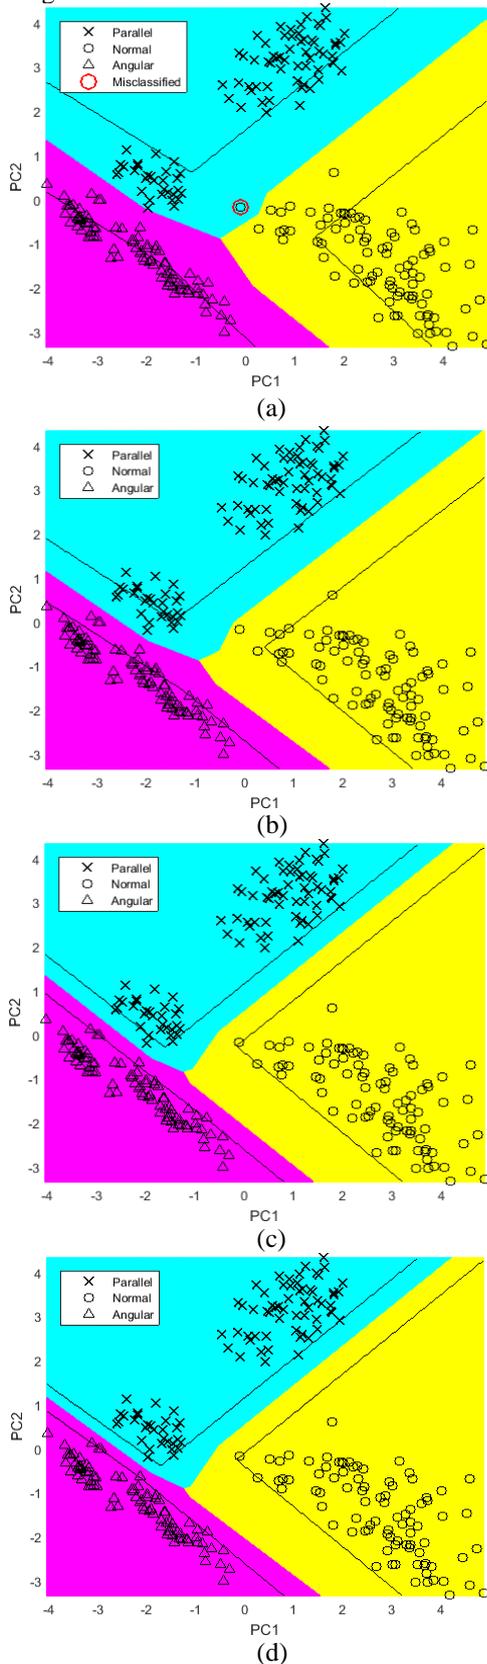
Tabel 1. Hasil klasifikasi SVM

NO	C	Free SV	Bounded SV	Total SV	Akurasi Training	Akurasi Testing
1	0,1	8	114	122	99,6 %	92,2 %
2	1	8	26	34	100 %	97,8 %
3	10	9	3	12	100 %	100 %
4	100	9	0	9	100 %	100 %

Hasil pengklasifikasian kondisi poros normal, *angular misalignment* dan *parallel misalignment* menggunakan metode SVM diperoleh bahwa data dapat terpisah secara linier (*linearly separable*). Hal tersebut ditandai dengan nilai akurasi *training* yang dapat mencapai 100 %. Sehingga nilai parameter C yang tepat digunakan untuk pengklasifikasian adalah C = 100. Nilai C yang besar akan dapat membuat kondisi *soft margin* mendekati kondisi *hard margin*. *Hard margin* adalah kondisi dimana *hyperplane* terbentuk dari data terdekat yang memiliki jarak terbesar. Pada nilai C = 100 kondisi sama dengan *hard margin* dikarenakan tidak terdapatnya *bounded support vector*. Sedangkan pemilihan nilai C yang lebih kecil digunakan untuk mengatasi data yang tidak terpisah sempurna atau nonlinier (*non-linear separable*).

Dari hasil klasifikasi *data testing* diperoleh akurasi 100 % pada parameter C dengan nilai 10 dan 100. Parameter C = 1 akurasi klasifikasi sebesar 97,8 %. Sedangkan parameter C = 0,1 menghasilkan akurasi klasifikasi 92,2 %. Pada nilai parameter C = 0,1 dan

C = 1 terdapat data yang tidak terklasifikasi -kan dengan baik.



Gambar 3. Model *training* SVM
 (a) parameter C = 0.1; (b) parameter C = 1;
 (c) parameter C = 10; (d) parameter C = 100

KESIMPULAN

Metode *Support Vector Machine* (SVM) yang digunakan untuk mendiagnosis ketidaklurusan poros menunjukkan hasil yang baik dengan tingkat akurasi mencapai 100 %. Pengaturan parameter C pada kernel linier SVM dapat mempengaruhi hasil akurasi *training* dan *testing*. Pada pengklasifikasian data yang terpisah secara linear, dengan menggunakan nilai parameter C yang besar (*hard margin*) akan menghasilkan akurasi yang paling baik.

DAFTAR PUSTAKA

- [1] H. Ahmadi, A. Moosavian, dan M. Khazaee, "An Appropriate Approach for Misalignment Fault Diagnosis Based on Feature Selection and Least Square Support Vector Machine," *Int. J. of Mechanics*, vol. 6, no. 2, 2012.
- [2] V. Hariharan dan P. S. S. Srinivasan, "Vibration Analysis of Flexible Coupling by Considering Unbalance," *World Applied Sciences Journal*, Vol. 8, 2010.
- [3] C. Hsu, "A Practical Guide to Support Vector Classification." *Department of Computer Science and Information Engineering, National Taiwan University*. 2004.
- [4] I. T. Jolliffe, "Principal Component Analysis Edisi kedua," *Springer-Verlag*, New York, 2002.
- [5] Johnson dan Wichern, "Applied Multivariate Statistical Analysis Edisi keenam," *Pearson Prentice Hall*, 2007.
- [6] Khot dan P. Khaire, "Simulation and Experimental Study for Diagnosis of Misalignment Effect in Rotating System." *Journal of Vibration Analysis, Measurement, and Control*. vol. 3, no 2, pp.165-173, 2015.
- [7] A. S. Nugroho, "Support Vector Machine: Paradigma Baru dalam Softcomputing," *PTIK-BPPT*, 2008.
- [8] S. Poyhonen, "Support Vector Machine Based Classification in Condition Monitoring of Induction Motors," *Helsinki University of Technology*, Finlandia, 2004.