

Deteksi kavitasi menggunakan *linear discriminant analysis* pada pompa sentrifugal

Berli Paripurna Kamiel^{1*}, Yusuf Ahmad², Krisdiyanto³

^{1,3}Jurusan Teknik Mesin, Fakultas Teknik, Universitas Muhammadiyah Yogyakarta

²Prodi Sarjana Teknik Mesin, Fakultas Teknik, Universitas Muhammadiyah Yogyakarta
Kampus Terpadu UMY, Jl. Brawijaya, Kasihan, Bantul, Yogyakarta, Indonesia 55183

*Corresponding author: berlikamiel@umy.ac.id,

Abstract

Cavitation is a phenomenon that often occurs in the centrifugal pumps. The impact of cavitation is a decrease in pump performance which will affect the ongoing production process in the industries. It is important to have a method to detect the phenomenon of cavitation early. The vibration signal is a parameter that is often used in detecting cavitation or other faulty components. One of the methods is based on the pattern recognition i.e. machine learning. Linear Discriminant Analysis (LDA) is a machine learning algorithm that has the advantage of reducing the parameters used into low dimensions without reducing the accuracy of their classification. The study proposes LDA to classify normal conditions, initial cavitation, intermediate cavitation and severe cavitation. The recording of the vibration signal is taken using the an accelerometer mounted on the inlet of the centrifugal pump. The vibration signal is then extracted using 10 statistic parameters of time domain as the LDA feature selection, namely mean, RMS, standard deviation, kurtosis, skewness, crest factor, clearance factor, shape factor, variance and peak value. The results shows that the LDA classifier can detect and classify cavitation conditions with an accuracy rate of 98.8% on training and 99.6% on testing. The shape factor, kurtosis, skewness and RMS parameters are a combination of parameters that have a large contribution to the classifier to detect and classify cavitation conditions.

Keywords: *Linear Discriminant Analysis (LDA), cavitation, centrifugal pump, statistical parameter*

Abstrak

Kavitasi merupakan fenomena yang sering terjadi pada pompa sentrifugal. Dampak yang ditimbulkan dari kavitasi yaitu turunnya performa pompa yang akan mempengaruhi proses produksi yang sedang berlangsung pada suatu pabrik. Maka, dibutuhkan suatu metode untuk mendeteksi dini fenomena kavitasi. Sinyal getaran merupakan parameter yang sering digunakan dalam melakukan deteksi kavitasi ataupun kerusakan mesin lainnya. Salah satu metode yang digunakan dalam menganalisis suatu sinyal getaran adalah metode pengenalan pola (*machine learning*) dengan menggunakan algoritma tertentu. *Linear Discriminant Analysis* (LDA) merupakan salah satu algoritma *machine learning* yang memiliki keunggulan mereduksi parameter yang digunakan kedalam dimensi yang rendah tanpa mengurangi akurasi klasifikasinya. Penelitian ini menggunakan LDA untuk mengklasifikasi kondisi normal, kavitasi awal, kavitasi menengah dan kavitasi lanjut. Perekaman sinyal getaran dilakukan dengan menggunakan sebuah *accelerometer* yang diletakkan pada sisi inlet pompa. Selanjutnya data sinyal getaran diekstraksi dengan menggunakan 10 parameter statistik domain waktu sebagai *feature selection* LDA yaitu *mean*, *RMS*, standar deviasi, *kurtosis*, *skewness*, *crest factor*, *clearance factor*, *shape factor*, *variance* dan *peak value*. Hasil yang didapatkan bahwa *classifier* LDA dapat mendeteksi dan mengklasifikasi kondisi kavitasi dengan tingkat akurasi 98,8% pada *training* dan 99,6% pada *testing*. Parameter *shape factor*, *kurtosis*,

skewness dan RMS merupakan kombinasi parameter yang memiliki kontribusi besar dalam *classifier* untuk mendeteksi dan mengklasifikasi kondisi kavitasi.

Kata kunci: *Linear Discriminant Analysis* (LDA), kavitasi, pompa sentrifugal, parameter statistik

Pendahuluan

Pompa sentrifugal merupakan jenis pompa yang sering digunakan dalam dunia industri. Permasalahan yang sering terjadi pada pompa sentrifugal adalah kavitasi [1]. Dampak dari kavitasi pada pompa sentrifugal adalah penurunan kinerja dan bahkan kegagalan sehingga dapat menyebabkan terganggunya proses produksi.

Penelitian yang telah dilakukan banyak menggunakan sinyal getaran untuk mendeteksi kerusakan komponen mesin ataupun kavitasi pada pompa sentrifugal. Kotb & Abdulaziz [2] melakukan penelitian tentang deteksi kavitasi menggunakan analisis akustik dan spektrum getaran dengan variabel kecepatan pompa. Luo *et al.* [3] menyelidiki karakteristik parameter statistik getaran pada pompa sentrifugal. Tobi & Sabari [4] menerapkan deteksi kavitasi menggunakan metode domain waktu pada pompa sentrifugal. Kamiel & Ramadhan [5] menyimpulkan pengaruh kecepatan pompa terhadap sensitifitas parameter statistik domain waktu untuk mendeteksi kavitasi. Tobi *et al.* [6] melakukan diagnosis lima kerusakan (*misalignment, looseness, imbalance, cacat bearing, dan cacat impeller*) dan kavitasi pada pompa sentrifugal menggunakan spektrum getaran.

Penelitian-penelitian tersebut pada umumnya menggunakan analisis getaran berbasis domain waktu atau spektrum. Akurasi deteksi kavitasi berbasis domain waktu sangat tergantung pada jumlah dan jenis parameter statistik yang diekstrak. Jumlah dan jenis parameter tersebut sangat bervariasi tergantung pada obyek yang dideteksi dan tidak tersedia aturan baku dalam proses memilihnya [7]. Hal ini berpotensi menimbulkan kesulitan dalam aplikasi di lapangan. Sedangkan analisis berbasis spektrum kurang efektif dalam

mendeteksi kavitasi karena *fast fourier transform* (FFT) mengasumsikan bahwa konten frekuensi sebuah sinyal adalah konstan. Sedangkan kavitasi menghasilkan konten frekuensi yang bervariasi terhadap waktu [6]. Akibatnya spektrum yang dihasilkan sulit dibaca dan dianalisis. Kesulitan lainnya adalah pembacaan spektrum membutuhkan seorang ahli yang berpengalaman untuk memutuskan apakah kavitasi terjadi atau tidak. Dibutuhkan pendekatan baru untuk mendeteksi kavitasi pompa dengan mudah dan efektif. Penelitian ini mengusulkan metode pengenalan pola yang dapat mengklasifikasi kondisi pompa secara langsung.

Metode pengenalan pola (*machine learning*) merupakan salah satu cabang *artificial intelligent* yang bertujuan untuk klasifikasi ataupun *clustering* [8]. Salah satunya adalah *Linear Discriminant Analysis* (LDA). *Classifier* ini mempunyai keunggulan yaitu dapat mereduksi parameter kedalam dimensi yang rendah sekaligus melakukan klasifikasi tanpa mengurangi hasil akurasi [9]. Metode ini sudah banyak digunakan oleh peneliti sebelumnya untuk mendeteksi suatu kerusakan pada mesin dan akurat dalam mengklasifikasi kerusakan tersebut. Jakovljevic *et al.* [9] menggunakan LDA untuk mendeteksi kerusakan rotor bar pada motor induksi. Haddad & Strangas [10] menggunakan LDA untuk mendeteksi kerusakan pada *Permanent Magnet Synchronous Machine* (PMSM). Mbo'o & Hameyer [11] menggunakan LDA untuk mendeteksi kerusakan pada *cylindrical bearing*.

Namun demikian tidak ditemukan aplikasi LDA untuk mendeteksi terjadinya kavitasi. Oleh karena itu, penelitian ini mengusulkan LDA untuk mendeteksi kavitasi pada pompa sentrifugal. LDA dalam melakukan klasifikasi menggunakan

input berupa parameter statistik yang jumlah dan jenisnya sangat bervariasi dan tergantung pada obyek yang dideteksi. Penelitian ini juga menyelidiki dan menyeleksi parameter statistik menggunakan metode *binomial coefficient* untuk menentukan parameter yang berkontribusi besar terhadap akurasi *classifier* dalam mendeteksi dan mengklasifikasi kondisi pompa.

Tinjauan Pustaka

Linear Discriminant Analysis

LDA merupakan salah satu *supervised learning* yang dikembangkan oleh R. A. Fisher pada tahun 1936. *Classifier* ini menentukan kombinasi karakteristik *linear* yang menggambarkan dua kelas atau lebih. LDA dikembangkan untuk mentransformasikan suatu parameter ke ruang dimensi rendah dengan memaksimalkan rasio varian antar kelas dan meminimalkan rasio varian dalam kelas, sehingga menjamin pemisahan kelas yang dilakukan secara maksimum [12]. Proses transformasi yang dilakukan oleh LDA sebagai berikut,

Langkah awal, menghitung separabilitas antar beda kelas (varian antar kelas) menggunakan Pers. 1.

$$S_B = \sum_{i=1}^c n_i (\mu_i - \mu)(\mu_i - \mu)^T \quad (1)$$

Dimana c adalah kelas, n_i adalah jumlah sampel dari kelas i , μ_i adalah rata-rata kelas i , dan μ adalah rata-rata keseluruhan kelas.

Selanjutnya, menghitung jarak antara rata-rata dengan sampel dari tiap kelas (varian dalam kelas) menggunakan Pers. 2.

$$S_W = \sum_{i=1}^c \sum_{j=1}^{n_i} (x_j^i - \mu_i)(x_j^i - \mu_i)^T \quad (2)$$

Dimana x_j^i adalah sampel j yang berada dikelas i .

Merekonstruksi ruang dimensi rendah dengan menggunakan Pers. 3 yang disebut juga sebagai *Fisher's criterion*.

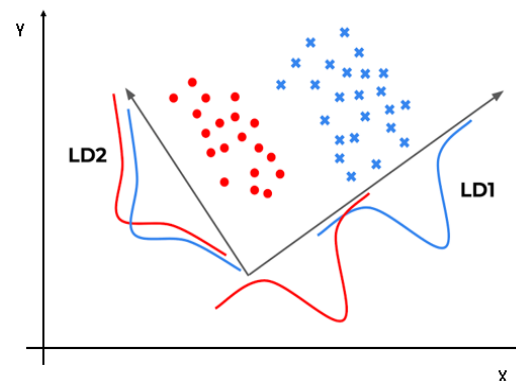
$$J(W) = \arg \max \frac{W^T S_B W}{W^T S_W W} \quad (3)$$

Pers. 3 bisa diformulasikan ulang jika S_W adalah matriks non-singular dengan menghitung nilai eigen dan eigen vektornya. Hasil formulasi tersebut bisa dilihat pada Pers. 4.

$$S_W W = \lambda S_B W \quad (4)$$

Dengan W adalah transformasi matriks dan λ adalah nilai eigen dari transformasi matriks.

Nilai eigen merupakan kekuatan dari vektor eigen. Kekuatan vektor eigen tersebut mencerminkan kemampuan transformasi LDA untuk membedakan antar kelas. Dengan demikian, vektor eigen dengan nilai eigen tertinggi yang digunakan untuk membangun ruang dimensi rendah, sedangkan vektor eigen lainnya bisa diabaikan. Gambar 1 merupakan ilustrasi LDA dalam mengklasifikasi suatu kelas.




Gambar 1. Ilustrasi LDA

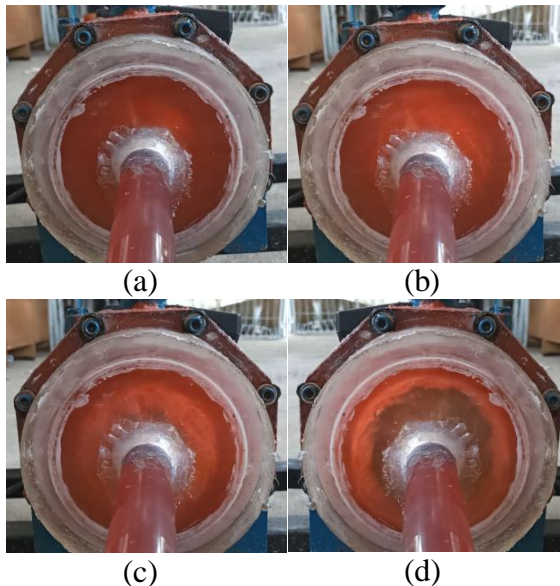
Metode Penelitian

Penelitian ini menggunakan alat uji simulasi kavitas yang tersusun berdasarkan skema yang ditunjukkan pada Gambar 2. Alat uji tersebut terdiri dari pompa sentrifugal, tangki vakum, kompresor vakum, sistem perpipaan, alat ukur tekanan, *flowmeter* dan katup. Penelitian ini menggunakan 4 macam variasi kondisi yaitu kondisi normal, kavitas awal, kavitas menengah dan kavitas lanjut. Pengaturan kondisi tersebut dengan cara mengatur tekanan udara pada tangki vakum menggunakan kompresor vakum dan

mengamati pembentukan gelembung kavitasi yang terjadi pada bagian *inlet* pompa yang transparan. Kondisi normal didapatkan pada tekanan 0 cmHg, kavitasi awal -10 cmHg, kavitasi menengah -20 cmHg dan kavitasi lanjut -28 cmHg. Visualisasi pembentukan gelembung kavitasi dapat dilihat pada Gambar 3.



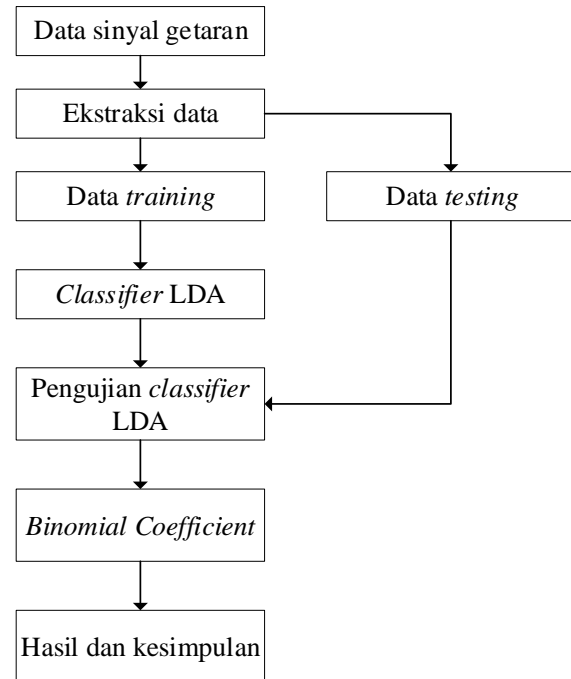
Gambar 2. Alat uji simulasi kavitasi dan arah alirannya



Gambar 3. Visualisasi kondisi pompa (a) normal, (b) kavitasi awal, (c) kavitasi menengah, dan (d) kavitasi lanjut

Perekaman sinyal getaran menggunakan sensor *accelerometer* dari Bruel & Kjaer tipe 4507 B yang diletakkan pada rumah volute pompa pada yang merekam arah aksial. Sedangkan, modul data akuisisi yang digunakan yaitu National Instrument NI 9234 dengan kecepatan *sampling rate* 25600 Hz dan waktu perekaman yaitu 8 detik. Hasil perekaman adalah sebanyak 500 set dari tiap variasi kondisi sehingga total berjumlah 2000 set data. Selanjutnya data set diekstraksi

menggunakan parameter statistik. Hasil ekstraksi tersebut dibagi menjadi 2 bagian yaitu 1500 data *training* untuk membentuk dan melatih *classifier* dan 500 data *testing* untuk menguji tingkat akurasi *classifier* tersebut. Selanjutnya, penelitian ini mencari parameter yang berpengaruh dalam *classifier* LDA dengan metode *binomial coefficient*. Gambar 4 merupakan alur pengolahan sinyal getaran.



Gambar 4. Skema pengolahan sinyal getaran

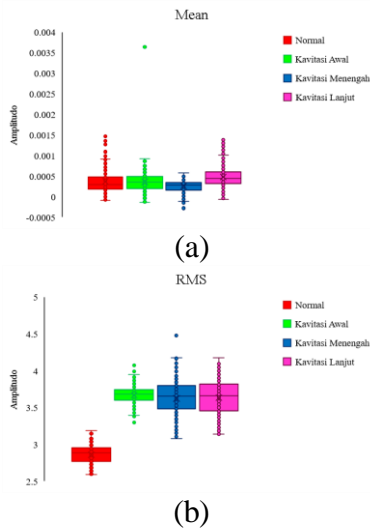
Classifier LDA

Penelitian ini menggunakan parameter statistik domain waktu dalam mengekstraksi sinyal getaran. Parameter statistik tersebut dipilih berdasarkan gabungan parameter yang pernah digunakan oleh Luo et al. [3], Tobi & Sabari [4], Kamiel & Ramadhan [5], Jakovjevic et al. [9], dan Mbo'o & Hameyer [11]. Parameter yang digunakan pada penelitian ini adalah *mean*, standar deviasi, *Root Mean Square (RMS)*, *kurtosis*, *skewness*, *crest factor*, *clearance factor*, *shape factor*, *variance* dan *peak value*.

Hasil dan Pembahasan

Gambar 5 merupakan contoh hasil distribusi nilai ekstraksi parameter *mean* dan RMS. Jika dilihat secara visual parameter

mean tidak dapat membedakan 4 variasi kondisi pompa. Hal ini dikarenakan 50% data hasil ekstraksi parameter tersebut dari masing-masing variasi kondisi, terletak pada posisi yang cenderung sejajar pada grafik *boxplot*. Sedangkan parameter RMS dapat membedakan kondisi normal karena terlihat pada kondisi normal 50% data hasil ekstraksi parameter tersebut tidak sejajar dengan kondisi manapun.



Gambar 5. *Boxplot* parameter (a) *mean* dan (b) RMS

Tabel 1. Analisis visual parameter statistik

Parameter Statistik	Hasil Analisis Visual
<i>Mean</i>	Tidak dapat membedakan 4 variasi kondisi
Standar deviasi	Dapat membedakan kondisi normal saja
RMS	Dapat membedakan kondisi normal saja
<i>Kurtosis</i>	Dapat membedakan kondisi normal dan kavitasi menengah
<i>Skewness</i>	Tidak dapat membedakan 4 variasi kondisi
<i>Crest factor</i>	Tidak dapat membedakan 4 variasi kondisi
<i>Clearance factor</i>	Tidak dapat membedakan 4 variasi kondisi
<i>Shape factor</i>	Dapat membedakan kondisi kavitasi awal dan kavitasi lanjut
<i>Variance</i>	Dapat membedakan kondisi normal dan kavitasi menengah
<i>Peak value</i>	Dapat membedakan kondisi kavitasi awal saja

Tabel 1 merupakan rangkuman hasil analisis secara visual dari distribusi nilai ekstraksi 10 parameter statistik. Hasil tersebut menunjukkan bahwa tidak ada parameter yang dapat membedakan 4 variasi secara keseluruhan.

Classifier LDA dilatih menggunakan 10 parameter statistik yang telah dibagi kedalam data *training*. Hasil dari pelatihan ini menghasilkan akurasi sebesar 98.8%. Selanjutnya *classifier* LDA diuji akurasi menggunakan data baru berupa data *testing*. Hasil pengujian ini menghasilkan akurasi sebesar 99,6%. Gambar 6 merupakan *confusion matrix* dari hasil pelatihan dan pengujian.

T r u n g	Normal	372	2		
	Kavitasi Awal		364	7	
	Kavitasi Menengah		1	386	
	Kavitasi Lanjut		3	5	374
		Normal	Kavitasi Awal	Kavitasi Menengah	Kavitasi Lanjut
		Predicted Class			

(a)

T e s t	Normal	126			
	Kavitasi Awal		128	1	
	Kavitasi Menengah			113	
	Kavitasi Lanjut			1	131
		Normal	Kavitasi Awal	Kavitasi Menengah	Kavitasi Lanjut
		Predicted Class			

(b)

Gambar 6. *Confusion matrix* (a) data *training* dan (b) data *testing*

Hasil akurasi *classifier* LDA untuk mengklasifikasi kondisi pompa sangat baik dengan menggunakan 10 input parameter statistik. Namun demikian terdapat potensi parameter-parameter tersebut ada yang berkorelasi sehingga membawa informasi yang identik ataupun berkontribusi kecil dalam pembentukan *classifier* LDA. Maka,

metode *binomial coefficient* digunakan pada penelitian ini untuk menemukan kombinasi parameter yang berkontribusi besar dalam *classifier*.

Kombinasi yang dibentuk yaitu mulai dari kombinasi 9 sampai dengan kombinasi 4 dari 10 parameter yang tersedia. Hasil kombinasi tersebut dapat dilihat pada Tabel 2 yang merupakan kombinasi yang menghasilkan akurasi tertinggi.

Tabel 2. Hasil tertinggi kombinasi 9 sampai 4 parameter dari 10 parameter

Kombinasi	Parameter Statistik	Akurasi (%)	
		Training	Testing
9	mean, RMS, standar deviasi, kurtosis, skewness, crest factor, clearance factor, shape factor, dan variance	99,1	99,8
8	mean, RMS, standar deviasi, kurtosis, skewness, crest factor, clearance factor, dan shape factor	99,3	99,4
7	mean, RMS/standar deviasi, kurtosis, skewness, crest factor, clearance factor, dan shape factor	99,4	99,4
6	mean, RMS/standar deviasi, kurtosis, skewness, crest factor, dan shape factor	99,3	99,3
5	mean, RMS/standar deviasi, kurtosis, skewness, dan shape factor	99	99,4
4	RMS/standar deviasi, kurtosis, skewness, dan shape factor	98,3	99

Hasil tersebut dapat dilihat bahwa hasil tertinggi kombinasi 4 parameter merupakan parameter yang berkontribusi besar dalam *classifier* LDA. Hal ini

dikarenakan hasil akurasi *training* yang didapat hanya selisih 0,5% dengan hasil akurasi *training* 10 input parameter.

Parameter RMS dan standar deviasi merupakan parameter yang membawa informasi yang sama besar kontribusinya karena dapat saling bertukar posisi dan menghasilkan akurasi *training* maupun *testing* yang sama besarnya. Hal ini dapat dilihat pada Tabel 2 dimulai dari kombinasi 7 hingga kombinasi 4 parameter.

Kesimpulan

LDA dengan input 10 parameter statistik terbukti dapat digunakan untuk mendeteksi dan mengklasifikasi terjadinya kavitasi pada berbagai variasi kondisi dengan akurasi *training* sebesar 98,8% dan akurasi *testing* sebesar 99,6%. Empat dari 10 parameter yang digunakan pada penelitian ini merupakan parameter yang paling berpengaruh pada akurasi *classifier* dalam mendeteksi kavitasi. Parameter tersebut yaitu RMS, kurtosis, skewness, dan shape factor. Hasil dari akurasi 4 parameter tersebut sebesar 98,3% untuk *training*, sebesar 99% untuk *testing*. Standar deviasi merupakan parameter yang dapat bertukar posisi dengan RMS. Hal ini karena informasi yang terkandung dalam kedua parameter tersebut adalah informasi yang sama besar kontribusinya.

Referensi

- [1] Tan, C.Z. and Leong, M.S., 2008. An Experimental Study of Cavitation Detection in a Centrifugal Pump Using Envelope Analysis. *Journal of System Design and Dynamics*, 274–285.
- [2] Kotb, A. and Abdulaziz, A. M., 2015. Cavitation Detection in Variable Speed Pump by Analyzing the Acoustic and Vibration Spectrums. *Engineering*, 706–716.
- [3] Luo, Y., Sun, H., Yuan, S. and Yuan, J., 2015. Research on Statistical Characteristics of Vibration in Centrifugal Pump. *Revista Tecnica de*

- la Facultad de Ingenieria Universidad del Zulia*, 49–61.
- [4] Tobi, M. A. S. AL., and Sabari, M. H. J. Al., 2016. Cavitation Detection of Centrifugal Pump Using Time – Domain Method. *International Journal of Engineering Research and General Science*, 161–167.
- [5] Kamiel, B. P. and Ramadhan, R. S., 2017. Pengaruh Kecepatan Operasi Pompa Sentrifugal Terhadap Sensitifitas Metode Deteksi Fenomena Kavitasi Berbasis Parameter Statistik Domain Waktu,” *Semesta Teknika*, 51–66.
- [6] Tobi, M. A. S. AL., Bevan, G., Wallace, P., Harrison, D. and Ramachandran, K. P., 2019. Centrifugal Pump Condition Monitoring and Diagnosis Using Frequency Domain Analysis. *Int. Conf. Cond. Monit. Mach. Non-Stationary Oper.*, 122–131.
- [7] Kamiel, B. P., Wiranto, A. J., Riyanta, B. and Yulianto, S., 2019. Klasifikasi Cacat Lintasan Dalam Bantalan Bola Berbasis Support Vector Machine (SVM) pada Fan Industri. *Turbo*, 143–152.
- [8] Sharma, P. and Kaur, M., 2013. Classification in Pattern Recognition: A Review. *Int. J. Adv. Res. Comput. Sci. Softw. Eng.*, 298–306.
- [9] Jakovljevic, B. B., Kanovic, Z. S. and Jelicic, Z. D., 2012. Induction Motor Broken Bar Detection Using Vibration Signal Analysis, Principal Component Analysis and Linear Discriminant Analysis. *Proc. IEEE Int. Conf. Control Appl.*, 1686–1690.
- [10] Haddad, R. Z., and Strangas, E. G., 2016. On the Accuracy of Fault Detection and Separation in Permanent Magnet Synchronous Machines Using MCSA/MVSA and LDA. *IEEE Trans. Energy Convers.*, 924–934.
- [11] Mbo’o, C. P. and Hameyer, K., 2016. Fault Diagnosis of Bearing Damage by Means of the Linear Discriminant Analysis of Stator Current Features from the Frequency Selection. *IEEE Trans. Ind. Appl.*, 3861–3868.
- [12] Nandi, A. and Ahmed, H., 2019. *Condition Monitoring with Vibration Signals*. Brunel University London, UK.