

Pemodelan Menggunakan *Autoregressive Integrated Moving Average* (ARIMA) dan *Support Vector Regression* (SVR) pada *Vibrasi Bearing*

Isna Maya Fitria*, Sutawanir Darwis

Prodi Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam,
Universitas Islam Bandung, Indonesia.

*isnamaya97@gmail.com

Abstract. Machines are tools to facilitate human work. One proof that machines are needed for society is that many large machines are used in industry. There is one component of the machine that is very important, namely the bearing. The function of the bearing is to support a shaft so that the shaft can rotate without experiencing excessive friction. Excessive friction causes vibration and harms machine users who are unable to properly supervise. So that forecasting is needed because it has an influence on performance for performance to help companies in machine conditions. The most popular forecasting model is the Autoregressive Integrated Moving Average (ARIMA), where ARIMA is a time series-based model developed by Box and Jenkins (1976) and the Support Vector Regression (SVR) Model. SVR is a generalization of the Support Vector Machine Model in the regression case where the output is a continuous number. This thesis discusses how to model and find the accuracy value on the vibration bearing data of the FEMTO-ST Institute with selected feature extraction, namely root mean square (RMS) and produce accurate forecasts.

Keywords: Support Vector Regression, ARIMA, Bearing Vibration.

Abstrak. Mesin merupakan alat bantu untuk mempermudah pekerjaan manusia. Salah satu bukti mesin sangat dibutuhkan bagi masyarakat adalah banyak mesin besar digunakan dalam industri. Terdapat salah satu komponen dari mesin yang sangat penting yaitu *bearing*. Fungsi dari *bearing* adalah menumpu sebuah poros agar poros dapat berputar tanpa mengalami gesekan yang berlebihan. Gesekan yang berlebihan inilah mengakibatkan vibrasi dan merugikan pengguna mesin apabila tidak ditangani dengan baik. Sehingga peramalan sangat dibutuhkan karena memiliki pengaruh terhadap proses kinerja bagi praktisi untuk membantu perusahaan dalam memantau kondisi mesin. Terdapat model peramalan yang paling populer yaitu *Autoregressive Integrated Moving Average* (ARIMA), dimana ARIMA merupakan model berbasis *time series* yang dikembangkan oleh Box dan Jenkins (1976) serta Model *Support Vector Regression* (SVR). SVR merupakan generalisasi Model *Support Vector Machine* pada kasus regresi yang *outputnya* bilangan kontinu. Skripsi ini membahas cara memodelkan dan mencari nilai akurasi pada data vibrasi *bearing* FEMTO-ST Institut dengan ekstraksi fitur terpilih yaitu *root mean square* (RMS) serta menghasilkan peramalan yang akurat.

Kata Kunci: Support Vector Regression, ARIMA, Vibrasi Bearing.

1. Pendahuluan

Mesin merupakan peralatan yang digerakan oleh suatu kekuatan atau tenaga yang dipergunakan untuk membantu manusia dalam mengerjakan produk (Assauri, 1999). Salah satu bukti mesin sangat dibutuhkan bagi masyarakat adalah mesin digunakan dalam industri. Kendala yang dihadapi yaitu sistem peramalan kondisi mesin yang bersifat deskriptif. Proses peramalan tersebut tentu berpengaruh besar terhadap proses kinerja praktisi. Salah satu komponen terpenting pada mesin yaitu *bearing*. *Bearing* (bantalan) berfungsi menumpu sebuah poros agar dapat berputar tanpa mengalami gesekan yang berlebihan. Gesekan yang berlebihan mengakibatkan vibrasi yang akan mengakibatkan kerugian bagi pengguna mesin apabila tidak ditangani dengan baik.

Salah satu model peramalan yang paling populer yaitu *Autoregressive Integrated Moving Average* (ARIMA), model berbasis *time series* dikembangkan oleh Box dan Jenkins (1976). Metode ini diakui memiliki kemampuan ramalan yang cukup memuaskan untuk peramalan jangka Panjang (Tapliy dalam Bey, A. 1988) dan dikatakan sebagai model yang kompleks, karena selain model ini merupakan gabungan dari *Autoregressive* (AR) dan *Moving Average* (MA), model tersebut dapat dipergunakan untuk pola *time series seasonal* (musiman) dan *non-seasonal* (bukan musiman) secara bersamaan. Selain metode ARIMA, terdapat juga metode yang serupa namun berbeda pada asumsinya yaitu Model berbasis regresi *Support Vector Regression* (SVR).

Model *Support Vector Regression* (SVR) merupakan generalisasi dari model *Support Vector Machine* (SVM) pada peramalan dalam menangani kasus regresi yang *outputnya* berupa bilangan kontinu. Model SVR dapat menindak kasus nonlinier dengan menambahkan fungsi kernel dimana didalam fungsi kernel tersebut diperlukan parameter-parameter kernel yang digunakan untuk mengoptimasikan hasil peramalan serta berguna dalam mengatasi masalah *overfitting*. Metode SVR juga dapat memberikan hasil yang baik walaupun menggunakan sampel relatif kecil. Berdasarkan uraian diatas, skripsi ini bertujuan memahami metode SVR dan menerapkan metode ARIMA pada data vibrasi *bearing* FEMTO-ST Institut, mendapatkan koefisien model dan diharapkan menghasilkan peramalan sehingga memberi masukan bagi praktisi dalam mengembangkan metodologi pemantauan kondisi mesin.

2. Landasan Teori

Model Autoregressive Integrated Moving Average (ARIMA(1,1,1))

Model ARIMA dibagi menjadi 3 kelompok, yaitu:

Model Autoregressive (AR)

$$Z_t = \mu + \phi_1 Z_{t-1} + \alpha_t \quad (1)$$

Model Moving Average (MA)

$$Z_t = \mu - \theta_1 \alpha_{t-1} - \theta_2 \alpha_{t-2} - \dots - \theta_q \alpha_{t-q} + \alpha_t \quad (2)$$

Karena kata *integrated* mengacu pada pembedaan maka apabila data tidak stasioner perlu dilakukan differencing (pembedaan). Rumus ARIMA (1,1,1) yaitu:

$$Z_t = \mu + (1 + \phi_1)Z_{t-1} - (\phi_1)Z_{t-2} - \theta_1 \alpha_{t-1} + \alpha_t \quad (3)$$

Sebelum menggunakan ARIMA terdapat asumsi yang harus dipenuhi yaitu data harus stasioner terhadap mean dan varians. Setelah data dapat memenuhi asumsi tersebut maka dilakukan identifikasi model ARIMA dilakukan dengan melihat plot ACF dan PACF. Tahapan selanjutnya adalah melakukan estimasi parameter. Kemudian di-lakukan uji signifikansi parameter, jika parameter tidak signifikan maka dilakukan identifikasi model ARIMA kembali. Setelah didapatkan parameter yang signifikan, kemudian dilakukan pengujian asumsi residual yaitu *white noise* dan distribusi normal. Pemenuhan asumsi residual yang *white noise* menggunakan uji *Ljung Box* dan pemenuhan asumsi normalitas residual dilihat dari plot residual.

Support Vector Regression (SVR)

Support Vector Regression (SVR) merupakan teknik untuk melakukan prediksi, SVR bertujuan untuk menemukan sebuah fungsi $f(x)$ yang mempunyai deviasi ϵ paling besar dari target yang

diobservasi untuk semua data training, sehingga ketika $\epsilon=0$ maka akan dihasilkan fungsi regresi yang sempurna. SVR dapat digeneralisasi untuk melakukan pendekatan fungsi regresi dengan menggunakan konsep ϵ -insensitive loss function. Konsep ϵ -insensitive loss function digunakan untuk mengevaluasi seberapa baik fungsi regresi yang digunakan. Dengan model SVR didapat fungsi regresi sebagai berikut:

$$f(\mathbf{x}) = \mathbf{w}^T \varphi(\mathbf{x}) + b \tag{4}$$

Dengan \mathbf{w}^T merupakan vector pembobot, $\varphi(\mathbf{x})$ merupakan fungsi yang memetakan \mathbf{x} dalam suatu dimensi dan b merupakan bias. Untuk mengevaluasi seberapa baik fungsi regresi, maka digunakan fungsi ϵ -insensitive loss sebagai berikut.


Mencari hyperplane terbaik ekuivalen dengan memaksimalkan margin atau jarak antara dua set objek dari kelas yang berbeda. Memaksimalkan nilai margin berarti meminimalkan nilai dari $\|\mathbf{w}\|$ sebagai penyebut. Meminimalkan $\|\mathbf{w}\|^2$ akan membuat fungsi setipis mungkin, sehingga bisa mengontrol kapasitas fungsi. Parameter model diperoleh melalui proses optimasi sebagai berikut:

$$\min \left\{ \frac{1}{2} \|\mathbf{w}\|^2 \right\} \tag{5}$$

dengan kendala:

$$\begin{aligned} y_i - \mathbf{w}^T \varphi(\mathbf{x}_i) - b &\leq \epsilon \\ \mathbf{w}^T \varphi(\mathbf{x}_i) - y_i + b &\leq \epsilon, i = 1, 2, \dots, n \end{aligned} \tag{6}$$

Berikut Gambar 1. merupakan penjabaran ilustrasi untuk mempermudah dalam memahami model SVR.



Gambar 1. Ilustrasi model SVR (a) Original input space (b) Feature space (c) ϵ -intensive loss function

Asumsikan bahwa ada suatu fungsi $f(\mathbf{x})$ yang dapat mengaproksimasi semua titik (x_i, y_i) dengan presisi ϵ . Asumsikan semua titik ada dalam rentang $f(\mathbf{x}) \pm \epsilon$ atau disebut *feasible*. Sedangkan *infeasible* merupakan kondisi dimana terdapat titik yang keluar dari rentang $f(\mathbf{x}) \pm \epsilon$, titik yang *infeasible* atau titik yang diluar margin akan dikenai pinalti sehingga ditambahkan dengan variabel *slack* ξ, ξ^* untuk mengatasi masalah pembatas yang tidak layak dalam masalah optimasi. Selanjutnya masalah optimasi diatas dapat diformulasikan:

$$\min \left\{ \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \right\} \tag{7}$$

dengan kendala:

$$\begin{aligned} y_i - \mathbf{w}^T \varphi(\mathbf{x}_i) - b &\leq \epsilon + \xi_i, i = 1, 2, \dots, n \\ \mathbf{w}^T \varphi(\mathbf{x}_i) - y_i + b &\leq \epsilon + \xi_i^*, i = 1, 2, \dots, n \\ \xi_i, \xi_i^* &\geq 0 \end{aligned} \tag{8}$$

Solusi permasalahan optimasi untuk Persamaan (7) dengan pembatas yang tertera pada Persamaan (8) dapat lebih mudah diselesaikan menggunakan fungsi Lagrange, Sehingga solusi optimal fungsi *Lagrange* adalah sebagai berikut:

Sehingga solusi optimal fungsi *Lagrange* adalah sebagai berikut:

$$\begin{aligned} L(\mathbf{w}, b, \xi, \xi^*, \alpha, \alpha^*, \beta, \beta^*) &= \frac{1}{2} \|\mathbf{w}^T\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) - \sum_{i=1}^n \alpha_i (\epsilon + \xi_i - y_i \\ &+ \mathbf{w}^T \varphi(\mathbf{x}_i) + b) - \sum_{i=1}^n \alpha_i^* (\epsilon + \xi_i^* + y_i - \mathbf{w}^T \varphi(\mathbf{x}_i) - b) - \sum_{i=1}^l (\eta_i \xi_i + \eta_i^* \xi_i^*) \end{aligned} \tag{9}$$


Scholkopf dan Smola (2003) solusi optimal untuk bias (b) dapat dihitung menggunakan KKT(Karus-Kuhn-Tucker). Faktor pengali Lagrange beserta KKT menghasilkan fungsi regresi secara eksplisit sebagai berikut:

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*)K(x_i, x) + b \tag{10}$$

Ditemukan selisih antara α_i dan α_i^* yang menghasilkan nilai beta dan b. Dimana $K(x_i, x)$ merupakan fungsi kernel yang memiliki nilai *inner product* dari dua vektor x_i dan x_j . Fungsi kernel yang digunakan adalah kernel *linear* sebagai berikut.

$$\varphi(x) = K(x_i, x_j) = x_i^T x_j \tag{11}$$

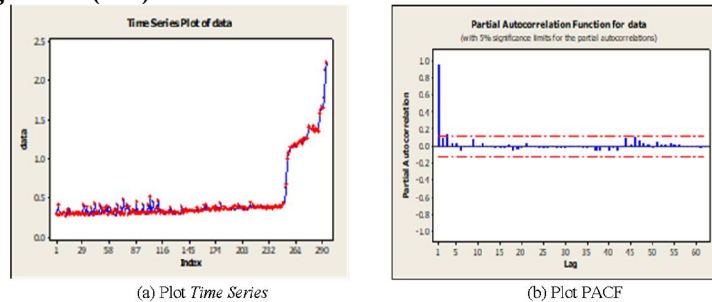
3. Hasil Penelitian dan Pembahasan
Data Vibrasi RMS Bearing1_2



Gambar 2. Plot Ekstraksi Fitur RMS Vibrasi bearing1_2 pada Arah Horizontal

Dapat dilihat pada Gambar 2 bahwa jumlah data fitur RMS bearing1_2 memiliki data sebanyak 871, kemudian dari data tersebut dilakukan pembagian data menjadi dua kelompok, bagian pertama sebanyak 577 data awal diasumsikan bearing normal disebut data1 dan bagian kedua sebanyak 294 data akhir diasumsikan rusak disebut data2.

Model Autoregressive (AR)



Gambar 3. Plot Time Series dan Plot PACF RMS vibrasi bearing1_2 Arah Horizontal

Berdasarkan Gambar 3 (a) Menunjukkan bahwa pola data vibrasi rms bearing1_2 memiliki trend meningkat dan pada Gambar 3 (b) terlihat bahwa nilai PACF signifikan pada lag ke-1 dan lag ke-3. Maka model tentatif AR yang mungkin terbentuk adalah AR(1), AR(2), AR(3).

Tabel 1. Dugaan Model AR

| Model | Parameter | Coef | t_{hitung} | p-value | Keputusan | Res. white noise | Normalitas Res |
|-------|-----------|-----------|--------------|---------|------------|------------------|----------------|
| AR(2) | ϕ_1 | -0.012291 | 3.08 | 0.002 | Signifikan | Terpenuhi | Normal |
| | ϕ_2 | 0.7085 | 12.80 | 0.000 | Signifikan | | |
| AR(3) | ϕ_1 | -0.014757 | 3.73 | 0.000 | Signifikan | Terpenuhi | Normal |
| | ϕ_2 | 0.6294 | 10.63 | 0.000 | Signifikan | | |
| | ϕ_3 | 0.2826 | 4.06 | 0.000 | Signifikan | | |
| | | 0.1371 | 2.15 | 0.032 | Signifikan | | |

Untuk model AR(2) diperoleh hasil bahwa koefisien ϕ_1 dan ϕ_2 signifikan terhadap model, sehingga model AR(2) layak digunakan dimana persamaan model AR(2) adalah $Z_t = -0.012291 + 0.7085Z_{t-1} + 0.3334Z_{t-2} + \alpha_t$ dengan terpenuhinya asumsi residual *white noise* dan asumsi normalitas residual.

Untuk model AR(3) diperoleh hasil bahwa koefisien ϕ_1 , ϕ_2 , dan ϕ_3 signifikan terhadap model dimana persamaan model AR(3) adalah $Z_t = -0.014757 + 0.6294Z_{t-1} + 0.2826Z_{t-2} + 0.1371Z_{t-3} + \alpha_t$, sehingga model AR(3) layak digunakan dengan terpenuhinya asumsi residual *white noise* dan asumsi normalitas residual.

Kemudian dilanjutkan dengan menghitung akurasi model, pada model AR(2) menghasilkan nilai RMSE = 0.05955 dan R-Square = 0.974157 atau 97.4157% sedangkan pada model AR(3) menghasilkan nilai RMSE = 0.05938 dan R-Square = 0.974304 atau 97.4304%.

Model Support Vector Regression (SVR)

Pada peramalan dengan SVR akan menggunakan lag-lag input yang didapat dari penguraian model AR pada analisis sebelumnya yang sudah memiliki parameter yang signifikan yang berjumlah 2 model. Lag input tersebut digunakan sebagai input (X) pada peramalan dengan menggunakan metode SVR.

Tahap awal sebelum masuk pada metode SVR yakni dilakukan pengujian nonlinieritas. Pengujian nonlinieritas tersebut dapat dipecahkan dengan fungsi kernel, kernel yang digunakan pada penelitian ini yaitu kernel *linear*.

Terdapat parameter C & ϵ pada metode SVR namun untuk mendapatkan hasil yang optimal perlu dilakukan beberapa percobaan. Dari percobaan tersebut didapatkan hasil yakni parameter C 0.1 & ϵ 0.05 yang optimal.

Berikut merupakan hasil perhitungan kebaikan model dengan menggunakan metode SVR dimana nilai $\sum_{i=1}^n (\alpha_i - \alpha_i^*)$ yang berupa permasalahan *quadratic programming* dapat diselesaikan dengan mengubahnya ke bentuk fungsi *Lagrange* dan perhitungan KKT (*Karush-Kuhn-Tucker*) menghasilkan nilai bias. Berikut merupakan hasil perhitungan kebaikan model dengan menggunakan metode SVR.

Tabel 2. Model dan Akurasi SVR


| Model | Parameter | Coef | RMSE | R-Square |
|-----------------|----------------|-------------|----------|----------------------------|
| SVR dua lag | $Z_{t-1}(x_1)$ | -0.00019775 | 0.063554 | 0.9708 atau 97.08% |
| | $Z_{t-2}(x_2)$ | 0.58582 | | |
| SVR tiga lag | | -0.0025105 | 0.0626 | 0.97167 atau 97.167% |
| | $Z_{t-1}(x_1)$ | 0.4376 | | |
| | $Z_{t-2}(x_2)$ | 0.39737 | | |
| | $Z_{t-3}(x_3)$ | 0.32792 | | |
| | | 0.30266 | | |

Setelah didapatkan nilai-nilai parameter tersebut, maka model persamaan SVR dua lag yang dibuat dapat digunakan untuk peramalan *bearing* mulai rusak pada vibrasi *bearing1_2*, yaitu $f_{(Z_{t-1}, Z_{t-2})} = 0.58582(Z_{t-1}) + 0.4376(Z_{t-2}) - 0.00019775$ yang menghasilkan nilai akurasi sangat baik. Serta model persamaan SVR tiga lag yang dibuat dapat digunakan untuk peramalan, yaitu $f_{(Z_{t-1}, Z_{t-2}, Z_{t-3})} = 0.39737(Z_{t-1}) + 0.32792(Z_{t-2}) + 0.30266(Z_{t-3}) - 0.0025105$.

Koefisien serta Akurasi Model AR dan Model SVR

Dihasilkan dari keempat model memiliki nilai koefisien yang hampir sama antara model AR dan SVR. Kemudian dengan nilai parameter C dan ϵ yang sama pada model SVR, didapatkan nilai RMSE dan R-square pada model SVR tiga lag yang memberikan hasil akurasi lebih baik dari pada SVR dua lag dibuktikan dengan nilai RMSE yang lebih kecil serta nilai R-square yang lebih besar begitu pula dengan model AR(3), oleh karena itu dapat disimpulkan bahwa AR(3) dan SVR tiga lag menjadi model yang paling cocok digunakan untuk meramalkan kondisi mesin *bearing1_2*.


Data Vibrasi RMS Bearing1_4



Gambar 4. Plot Ekstraksi Fitur RMS Vibrasi bearing1_4 pada Arah Horizontal

Dapat dilihat pada Gambar 4. bahwa jumlah data fitur RMS *bearing1_4* memiliki data sebanyak 1140, kemudian dari data tersebut dilakukan pembagian data menjadi dua kelompok, bagian pertama sebanyak 1069 data awal diasumsikan bearing normal disebut data1 dan bagian kedua sebanyak 70 data akhir diasumsikan mulai rusak disebut data2.


Model Autoregressive Integrated Moving Average (ARIMA)



Gambar 5. Plot *Time Series* dan Plot ACF RMS vibrasi *bearing1_4* Arah Horizontal


Gambar 5 (a) Menunjukkan bahwa rms vibrasi bearing1_4 belum stasioner terhadap varians dan rata-rata karena fluktuasi antara titik satu dengan titik lainnya bervariasi serta memiliki trend meningkat, dan pada Gambar 5 (b) Menunjukkan bahwa data tidak memiliki pola musiman (*seasonal*).

Langkah selanjutnya dilakukan analisis Gambar 4.15 dengan memperlihatkan plot *Box-Cox* untuk melihat apakah data sudah stasioner dalam varians.



Gambar 6. *Box-Cox* RMS vibrasi *bearing1_4* Arah Horizontal


Gambar 4.15 memperlihatkan bahwa data rms vibrasi *bearing1_4* belum stasioner terhadap varians. Hal ini dapat ditunjukkan dengan nilai rounded value yang belum bernilai atau melewati 1, maka data vibrasi rms *bearing1_4* ditransformasikan $\frac{1}{\sqrt{V_t}}$ untuk menstabilkan varians. Selanjutnya dilakukan pengujian stasioneritas terhadap rata-rata dengan menggunakan diferensiasi (d) sebanyak satu kali (d=1).



Gambar 7. Plot Diferensi 1 RMS vibrasi bearing1_4 Arah Horizontal

Plot diferensi RMS vibrasi bearing1_4 pada Gambar 7 menunjukkan bahwa data tersebut telah stasioner terhadap rata-rata, karena data pengamatan tidak mengalami fluktuasi yang terlalu besar dari waktu ke waktu.

Untuk identifikasi model dari data dilakukan dengan memplot data rms vibrasi bearing1_4 yang telah didiferensiasi ke dalam plot ACF dan PACF.



Gambar 8. Plot ACF dan PACF RMS vibrasi bearing1_4 Arah Horizontal

Plot ACF dan PACF pada Gambar 8. menunjukkan terdapat satu lag yang keluar dari batas *significance limit*. Berdasarkan plot ACF dan PACF tersebut maka model ARIMA yang terbentuk dan dapat digunakan sebagai peramalan adalah ARIMA (1,1,1).

Tabel 3. Model ARIMA (1,1,1)

| Model | Parameter | Coef | t_{hitung} | $p-value$ | Keputusan | Res. white noise | Normalitas Res |
|-------|------------|----------|--------------|-----------|------------|------------------|----------------|
| AR(2) | | 0.024379 | 3.17 | 0.002 | Signifikan | Terpenuhi | Normal |
| | ϕ_1 | -0.4796 | -3.50 | 0.001 | Signifikan | | |
| | θ_1 | -0.9358 | -15.71 | 0.000 | Signifikan | | |

Diperoleh hasil bahwa koefisien ϕ_1 dan θ_1 signifikan terhadap model sehingga ARIMA (1,1,1) layak digunakan dimana persamaan model ARIMA(1,1,1) adalah sebagai berikut:

$$Z_t = \mu' + (1 + \phi_1)Z_{t-1} - \phi_1 Z_{t-2} - \theta_1 \alpha_{t-1} + \alpha_t$$

$$Z_t = 0.024379 + (1 - 0.4796)Z_{t-1} - (-0.4796)Z_{t-2} - (-0.9358)\alpha_{t-1} + \alpha_t$$

$$Z_t = 0.024379 + 0.5204Z_{t-1} + 0.4796Z_{t-2} + 0.9358\alpha_{t-1} + \alpha_t$$

Selanjutnya pemeriksaan diagnostik untuk memeriksa kecukupan model menghasilkan terpenuhinya asumsi residual *white noise* dan residual berdistribusi normal.

Model Support Vector Regression (SVR)

Pada peramalan dengan SVR akan menggunakan lag-lag input yang didapat dari penguraian model ARIMA pada analisis sebelumnya yang sudah memiliki parameter yang signifikan. Lag input tersebut digunakan sebagai input (X) pada peramalan dengan menggunakan metode SVR.

Tahap awal sebelum masuk pada metode SVR yakni dilakukan pengujian nonlinieritas. Pengujian nonlinieritas tersebut dapat dipecahkan dengan fungsi kernel, kernel yang digunakan pada penelitian ini yaitu kernel *linear*.

Terdapat parameter C & ϵ pada metode SVR namun untuk mendapatkan hasil yang optimal perlu dilakukan beberapa percobaan. Dari percobaan tersebut didapatkan hasil yakni parameter C 0.1 & ϵ 0.01 yang optimal.

Berikut merupakan hasil perhitungan kebaikan model dengan menggunakan metode SVR dimana nilai $\sum_{i=1}^n (\alpha_i - \alpha_i^*)$ yang berupa permasalahan *quadratic programming* dapat diselesaikan dengan mengubahnya ke bentuk fungsi *Lagrange* dan perhitungan KKT (*Karush-Kuhn-Tucker*) menghasilkan nilai bias. Berikut merupakan hasil perhitungan kebaikan model dengan menggunakan metode SVR.

Tabel 4. Model dan Akurasi SVR

| Model | Parameter | Coef | RMSE | R-Square |
|-------|----------------|----------|----------|----------|
| SVR | | 0.036601 | 0.050851 | 0.980993 |
| | $Z_{t-1}(x_1)$ | 0.4057 | | atau |
| | $Z_{t-2}(x_2)$ | 0.31911 | | 98.0993% |
| | $Z_{t-3}(x_3)$ | 0.26202 | | |

Setelah didapatkan nilai-nilai parameter tersebut, maka model persamaan SVR yang dibuat dapat digunakan untuk peramalan, yaitu:

$$f_{(Z_{t-1}, Z_{t-2}, Z_{t-3})} = 0.4057(Z_{t-1}) + 0.31911(Z_{t-2}) + 0.26202(Z_{t-3}) + 0.036601$$

4. Kesimpulan

Pada Analisis dengan menggunakan data vibrasi rms bearing1_2 didapatkan model terbaik yaitu model AR dan SVR untuk AR(2) dan SVR dua lag, dimana koefisien antara model AR dan SVR memiliki nilai yang sama ketika koefisien ϕ_1 lebih besar dari koefisien lain pada model AR dan begitu pula pada koefisien Z_{t-1} . Kemudian kedua model tersebut memberikan akurasi yang sangat baik, dilihat dari RMSE mendekati 0 dan R-Square mendekati 100% sehingga model cocok digunakan untuk meramalkan kondisi mesin bearing1_2. Sedangkan pada data vibrasi rms bearing1_4, nilai koefisien dari model ARIMA(1,1,1) dan model SVR menghasilkan nilai koefisien yang hampir sama pada nilai konstan, koefisien pertama dan koefisien kedua, namun pada koefisien ketiga nilainya sangat jauh berbeda antara ARIMA dengan SVR, hal itu disebabkan karena keikutsertaan Moving Average (MA) sebagai parameter ketiga yang tidak efektif untuk peramalan pada model SVR.

5. Saran

Saran untuk penelitian selanjutnya dapat digunakan metode yang bisa memperhatikan adanya pengaruh dari variabel lain. Dalam metode SVR dapat dicoba dengan menggunakan variabel input dari data asli tanpa melalui metode AR maupun ARIMA, serta dapat digunakan parameter C dan ϵ lain agar didapatkan peramalan yang lebih baik.

Daftar Pustaka

- [1] Agung Prihantoro. 2012. Peningkatan Kinerja Sumber Daya Manusia melalui Motivasi, Disiplin, Lingkungan Kerja, dan Komitmen (Studi Kasus Madrasah di Lingkungan Yayasan Salafiyah, Kajen, Margoyoso, Pati), STIE Agama Islam Mathali'ul Falah.
- [2] Assauri, Sofyan. 1999. Manajemen Produksi dan Operasi: Edisi Revisi. Jakarta: Fakultas. Ekonomi Universitas Indonesia.
- [3] Bey, A. 1988. Pemodelan ARIMA untuk Meramal Curah Hujan Palembang Sebagai Studi Kasus. Prosiding Simposium II PERHIMPI. Bogor 27-28 Juli 1988.
- [3] Box, G.E.P. and G.M. Jenkins, 1976. Time Series Analysis: Forecasting and Control. 1st Edn., Holden-Day, San Fransisco.
- [4] Caraka, R.E., H. Yasin, dan A.W. Basyiruddin. 2017. Peramalan Crude Palm Oil (CPO) Menggunakan Support Vector Regression Kernel Radial Basis. Matematika, 7:43-57.
- [5] Christianini, Nello. 2001. Support Vector and Kernel Machines. ICML tutorial.
- [6] Cryer, J.D., dan Chan, K.S. (2008). Time Series Analysis: With Aplication in R: Second Edition. USA: Spinger Science dan Businiess Media, LLC.
- [7] Gunn, S.1998. Support Vector Machines for Classification. Technical Report.Southampton: University of Southampton.
- [8] James et al., 2013. An Introduction to Statistical Learning with Applications in R. Verlag New York: Springer International Publishing.
- [9] P. Nectoux et al., 2012. An Experimental Platform for Bearings Accelerated Life Test IEEE Int. Conf. on Progn. and Health Manang. Denver: United States.
- [10] Putra, Jan Wira Gotama. 2018. Pengenalan Konsep Pembelajaran Mesin dan Deep Learning. 1.0. Tokyo: Tokyo Institute of Technology.

- [11] Santosa, Budi. 2007. Data Mining Teknik Pemanfaatan Data untuk Keperluan Bisnis. Yogyakarta: Graha Ilmu.
- [12] Santosa, Budi. Tutorial Support Vector Machine. Teknik Industri, ITS. Surabaya.
- [13] Scholkopf, B. dan Smola, A. 2003. A Tutorial on Support Vector Regression.
- [14] Taha, Hamdy A. 1976. Operation Research an Introduction. New York: Macmilan.
- [15] Walpole, R. E. (1992). Pengantar Statistika: Edisi Kedua. (Alih bahasa: Bambang Sumantri). Jakarta: PT Gramedia Pustaka Utama.