

Perbandingan Prediksi Harga Logam Mulia Antam Menggunakan Model ARIMA dan Support Vector Regression

Tugas Akhir

diajukan untuk memenuhi salah satu syarat

memperoleh gelar sarjana

dari Program Studi Informatika

Fakultas Informatika

Universitas Telkom

1301173718

Tyarani Puspa Puspitasari



Program Studi Sarjana Informatika

Fakultas Informatika

Universitas Telkom

Bandung

2021

LEMBAR PENGESAHAN**PERBANDINGAN PREDIKSI HARGA LOGAM MULIA ANTAM MENGGUNAKAN
MODEL ARIMA DAN SUPPORT VECTOR REGRESSION****Antam's Precious Metals Gold Price Comparison Using ARIMA and Support Vector
Regression Model****NIM : 1301173718****Tyarani Puspa Puspitasari**

Tugas akhir ini telah diterima dan disahkan untuk memenuhi sebagian syarat memperoleh gelar pada Program Studi Sarjana Informatika

Fakultas Informatika

Universitas Telkom

Bandung, 09 September 2021

Menyetujui

Pembimbing I,

Aniq Atiqi Rohmawati, S.Si., M.Si.

NIP: 15880028

Pembimbing II,

Dra. Indwarti M.Si

NIP:98690022

Ketua Program Studi
Sarjana Informatika,Dr. Erwin Budi Setiawan, S.Si., M.T.

NIP: 00760045

LEMBAR PERNYATAAN

Dengan ini saya, Tyarani Puspa Puspitasari, menyatakan sesungguhnya bahwa Tugas Akhir saya dengan judul Perbandingan Prediksi Harga Logam Mulia Antam Menggunakan Model ARIMA dan Support Vector Regression beserta dengan seluruh isinya adalah merupakan hasil karya sendiri, dan saya tidak melakukan penjiplakan yang tidak sesuai dengan etika keilmuan yang belaku dalam masyarakat keilmuan. Saya siap menanggung resiko/sanksi yang diberikan jika di kemudian hari ditemukan pelanggaran terhadap etika keilmuan dalam buku TA atau jika ada klaim dari pihak lain terhadap keaslian karya,

Bandung, 24 Agustus 2021

Yang Menyatakan



Tyarani Puspa Puspitasari

Perbandingan Prediksi Harga Logam Mulia Antam Menggunakan Model ARIMA dan Support Vector Regression

Tyarani Puspa Puspitasari¹, Aniq Atiqi Rohmawati², Indwiarti³

^{1,2,3}Fakultas Informatika, Universitas Telkom, Bandung

¹tyaranipuspa@students.telkomuniversity.ac.id, ²aniqatiqi@telkomuniversity.ac.id,

³indwiarti@telkomuniversity.ac.id

Abstrak

Pandemi COVID-19 telah menyebabkan penurunan pertumbuhan ekonomi di seluruh dunia. Tidak sedikit masyarakat yang terpaksa di PHK dan UMKM yang tidak bisa bertahan. Di satu sisi, masyarakat yang masih mempunyai uang tabungan atau uang *cash*, sementara tidak akan menginvestasikan uangnya ke sektor-sektor yang belum ada kepastian akan bertahan. Oleh karena itu, banyak masyarakat yang menginvestasikan uangnya ke dalam bentuk emas logam mulia. Karena adanya kecenderungan untuk memiliki logam mulia sebagai investasi maka diperlukan suatu peramalan. Dengan menggunakan peramalan dapat membantu masyarakat dalam membuat rencana keuangan yang tepat. Dalam penelitian ini dilakukan peramalan harga logam mulia Antam menggunakan dua model yang berbeda, yaitu model ARIMA dan model Support Vector Regression (SVR). Data yang digunakan adalah data harian emas logam mulia Antam. Model ARIMA (0,1,2) terbukti merupakan model terbaik karena memiliki nilai AIC terkecil, yaitu 4039. Selain itu, model ARIMA memiliki hasil MAE yang lebih kecil dibandingkan hasil MAE yang dimiliki oleh model SVR.

Kata kunci : arima, emas logam mulia Antam, deret waktu, SVR.

Abstract

The COVID-19 pandemic has caused a decline in economic growth worldwide. Not a few people who were forced to laid off and UMKMs who could not survive. On the other hand, people who still have savings or cash, will temporarily not invest their money in sectors where there is no certainty that they will survive. Therefore, many people invest their money in the form of precious metal gold. Due to the tendency to have precious metals as an investment, a forecast is needed. By using forecasting, it can help people in making the right financial plans. In this study, Antam's precious metal prices were forecasted using two different models, which are ARIMA time series model and Support Vector Regression (SVR) regression model. The data used is Antam's daily gold precious metal data. The ARIMA model (0,1,2) is proven to be the best model because it has the smallest AIC value, which is 4039. Furthermore, the ARIMA model has a smaller MAE result than the SVR model of the MAE result.

Keywords: arima, Antam's precious metal gold, time series, SVR.

1. Pendahuluan

Latar Belakang

Pandemi Covid-19 telah menyebabkan penurunan pertumbuhan ekonomi di seluruh dunia. Banyak perusahaan yang mengalami kesulitan dalam menutupi biaya operasional perusahaan, sehingga tidak sedikit masyarakat yang terpaksa di pengakhiran hubungan kerja (PHK). Tidak hanya itu, banyak usaha mikro kecil menengah (UMKM) yang tidak bisa bertahan. Di satu sisi, masyarakat yang masih mempunyai uang tabungan atau uang *cash*, sementara belum berani untuk menginvestasikan uangnya untuk pengembangan usaha di sektor-sektor yang belum ada kepastian akan bisa bertahan. Oleh karena itu, banyak masyarakat yang mengambil keputusan untuk mengahlikan atau menginvestasikan uangnya ke dalam bentuk yang aman. Salah satu bentuk yang aman adalah dengan mengubah ke dalam bentuk emas, terutama logam mulia.

Dalam beberapa tahun terakhir, ada kecenderungan trend untuk berinvestasi di logam mulia. Hal ini dikarenakan logam mulia memiliki banyak variasi ukuran dari terkecil sampai terbesar. Selain itu, kadar logam mulia lebih tinggi dibandingkan kadar emas perhiasan. Logam mulia memiliki kadar emas sebesar 99,99% atau 24 karat. Seiring berjalannya waktu, kecenderungan permintaan logam mulia semakin meningkat. Sehingga banyak perusahaan yang memproduksi logam mulia, seperti PT. Antam Tbk., Galeri24, PT. UBS, dan lain-lain. Diantara semua perusahaan tersebut, produk PT. Antam Tbk. paling banyak dinikmati. Hal ini dikarenakan 65% sahamnya dimiliki oleh pemerintah Indonesia dan 35% sahamnya dimiliki oleh masyarakat umum serta sudah lama memproduksi logam mulia. Karena adanya kecenderungan untuk memiliki logam mulia sebagai investasi jangka pendek maupun jangka panjang maka diperlukan suatu peramalan untuk mencoba menganalisa kemungkinan adanya kenaikan atau penurunan harga logam mulia di masa yang akan datang.

Beberapa penelitian terhadap permasalahan ini telah dilakukan, seperti [1] meneliti menggunakan model ARIMA dalam meramalkan harga emas dunia pada masa pandemi covid 19, dan menunjukkan adanya rata-rata kenaikan US\$15.859/troy ons dan mendapatkan nilai MAPE 3,70%. [2] meneliti dan meramalkan harga emas dunia periode 2005-2015 menggunakan model ARIMA dan mendapatkan nilai MSE sebesar 1866,73. [3] meneliti menggunakan model *hybrid* ARIMA-SVR dalam memprediksi harga emas pada masa pandemi covid-19 dan mendapatkan nilai MAPE pada *training* yaitu 0.3555% dan nilai MAPE pada *testing* yaitu 4.001% serta model ARIMA dan mendapatkan nilai *training* MAPE sebesar 0.903% dan nilai *testing* MAPE sebesar 4.076%. [4] meneliti dan meramalkan harga emas menggunakan model SVR, Linear Regression dan Neural Network serta model Decision Tree sebagai pemilihan fitur. Penelitian ini mendapatkan nilai MAPE 1,763% untuk model SVR, 1,882% untuk model Linear Regression dan 2,395% untuk model Neural Network. [5] meneliti dan meramalkan *financial assets* yaitu emas dengan menggunakan model SVR dan BP Neural Network dan mendapatkan nilai prediksi error sebesar 6,586,788 untuk model SVR dan 1,183,275 untuk model BP Neural Network. [6] meneliti dan memprediksi harga saham emas menggunakan metode SVR mendapatkan nilai MAPE 0.2407%.

Penelitian ini berfokus pada peramalan harga logam mulia yang berasal dari PT. Antam Tbk. dengan membandingkan dua model yang berbeda, yaitu model ARIMA dan model SVR. Kedua model tersebut bertujuan untuk memberikan hasil peramalan dengan tingkat akurasi tertinggi.

Topik dan Batasannya.

Perumusan masalah berdasarkan tema penelitian ini adalah bagaimana merancang sebuah sistem peramalan menggunakan model ARIMA? Bagaimana merancang sebuah sistem menggunakan model SVR? Bagaimana hasil akurasi yang dibuktikan oleh model ARIMA dan SVR?

Batasan masalah pada penelitian ini yaitu dataset yang digunakan merupakan data harian logam mulia Antam yang memiliki rentang waktu pada periode 1 Juli 2020 – 31 Desember 2020. Selain itu, fungsi kernel yang digunakan untuk model SVR adalah Polynomial dan RBF.

Tujuan

Tujuan penelitian ini adalah memberikan peramalan harga logam mulia Antam dengan membandingkan dua model yang berbeda, yaitu model ARIMA dan SVR. Untuk menganalisis performansi kedua model tersebut, digunakan Mean Absolute Error (MAE).

2. Studi Terkait

2.1. Investasi Logam Mulia Antam

Investasi merupakan sebuah kegiatan yang mengeluarkan sejumlah modal sebagai landasan suatu bisnis yang nantinya akan menghasilkan keuntungan dari jumlah modal yang dikeluarkan. Emas merupakan sebuah logam yang terkenal memiliki nilai tinggi yang diakui dari jaman dahulu. Emas mempunyai harga yang relatif stabil, tetapi harga emas dapat mengalami kenaikan – penurunan drastis akibat krisis dunia, kurs dollar-rupiah, dan lain-lain. Logam mulia Antam merupakan emas batangan logam mulia yang diproduksi oleh PT. Antam (Aneka Tambang) Tbk. yang didirikan pada tahun 1968. Perusahaan ini merupakan perusahaan BUMN gabungan yang berfokus untuk mengeksplorasi, menambangkan sumber daya mineral serta mengelola dan memurnikan logam mulia untuk diperdagangkan [7]. Sehingga investasi logam mulia Antam merupakan sebuah kegiatan dengan mengeluarkan sejumlah modal dalam bentuk emas logam mulia produksi Antam dengan harapan akan menghasilkan keuntungan dari jumlah modal yang dikeluarkan.

2.2. Model Autoregressive Integrated Moving Average (ARIMA)

Model ARIMA adalah model yang mempelajari data di masa lalu berdasarkan urutan waktu untuk meramalkan masa depan. Model ARIMA merupakan model yang menjadikan data stasioner sebagai data *input*. Dimana data stasioner merupakan data yang tidak memiliki pengaruh terhadap trend maupun musim berdasarkan waktu tertentu. Oleh karena itu, pengujian stasioner perlu dilakukan untuk melihat kestasioneritas data. Ada berbagai cara untuk melakukan uji stasioner, salah satunya adalah dengan melakukan uji *Augmented Dickey Fuller* (ADF). Misalkan δ adalah parameter dan $\hat{\delta}$ adalah nilai perkiraan dari δ serta $SE(\hat{\delta})$ adalah *standard error* dari $\hat{\delta}$. Sehingga statistika uji ADF adalah sebagai berikut:

$$\tau = \frac{\hat{\delta}}{SE(\hat{\delta})} \quad (1)$$

Dengan menggunakan hipotesis:

- $H_0: \hat{\delta} = 0$ (data tidak stasioner)

- $H_1 : \delta \neq 0$ (data stasioner)

Serta standar uji yang ditetapkan adalah tolak H_0 jika $\tau > \tau$ tabel atau $p\text{-value} < \alpha$ dimana $\alpha = 0.05$ (taraf signifikan 5%) yang berarti data merupakan data stasioner [13]. Jika data terbukti tidak stasioner, maka perlu dilakukan proses *differencing*. Proses *differencing* merupakan suatu proses untuk menstasionerkan data. Adapun persamaan *differencing* sebagai berikut:

$$A_t = P_t - P_{t-1} \quad (2)$$

A_t adalah hasil *differencing* harga logam mulia Antam pada saat t dan P_t adalah harga logam mulia Antam pada saat t . Model ARIMA memiliki tiga unsur yang membentuk persamaan model ARIMA, yaitu *Autoregressive* (AR), *Moving Average* (MA), dan *Integrated*. Model ARIMA dapat ditulis sebagai berikut:

$$ARIMA(p, d, q)$$

p adalah order *Autoregressive*, q adalah order *Moving Average*, dan d adalah derajat *differencing*. Persamaan model ARIMA dapat ditulis sebagai berikut:

$$A_t = s + \varphi_1 A_{t-1} + \dots + \varphi_p A_{t-p} + e_t - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q} \quad (3)$$

Dimana s adalah konstanta, φ_p adalah parameter *Autoregressive* ke- p , θ_q adalah parameter *Moving Average* ke- q , e_t adalah nilai error pada saat t [11,12]. Berikut ini merupakan contoh persamaan model ARIMA:

ARIMA (1,0,2)

$$P_t = s + \varphi_1 P_{t-1} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} \quad (4)$$

ARIMA (1,1,2)

$$\begin{aligned} A_t &= s + \varphi_1 A_{t-1} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} \\ P_t - P_{t-1} &= s + \varphi_1 (P_{t-1} - P_{t-2}) + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} \\ P_t &= s + \varphi_1 (P_{t-1} - P_{t-2}) + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} + P_{t-1} \\ P_t &= s + (\varphi_1 + 1)P_{t-1} - \varphi_1 P_{t-2} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} \end{aligned} \quad (5)$$

Model ARIMA (1,0,2) menggunakan data harga logam mulia Antam yang dinotasikan sebagai P_t dikarenakan pada model ini tidak memiliki proses *differencing*. Sedangkan pada model ARIMA (1,1,2) menggunakan data hasil *differencing* dikarenakan pada model ini memiliki proses *differencing*. Model ARIMA mempunyai empat tahapan, yaitu identifikasi (p,d,q), menentukan parameter model ARIMA, cek diagnosa terhadap independensi residu, dan *forecasting*. Pada tahap pertama, perlu dilakukan identifikasi untuk penentuan order (p), (d), dan (q) dengan menggunakan ACF (fungsi autokorelasi) dan PACF (fungsi autokorelasi parsial). ACF untuk menentukan order (q). Adapun persamaan ACF dapat ditulis sebagai berikut:

$$P_k = r_k = \frac{\sum_{t=1}^{n-k} (R_t - \bar{R})(R_{t+k} - \bar{R})}{\sum_{t=1}^n (R_t - \bar{R})^2} \quad (6)$$

\bar{R} adalah rata-rata nilai data dan R_t adalah data pada saat t . Sedangkan PACF digunakan untuk menentukan order (p) dengan persamaan yang dapat ditulis sebagai berikut:

$$P_{kk} = \frac{r_k - \sum_{j=1}^{k-1} P_{k-1,j} r_{k-j}}{1 - \sum_{j=1}^{k-1} P_{k-1,j} r_j} \quad (7)$$

Dimana $P_{kj} = P_{k-1,j} - P_{kk}P_{k-1,k-j}$ untuk nilai $j=1,2,\dots,k-1$. Order (d) dapat diketahui melalui jumlah derajat *differencing*. Setelah mendapatkan model ARIMA sementara, selanjutnya dapat dilakukan perhitungan untuk mendapatkan model ARIMA terbaik. Ada berbagai cara untuk menentukan model terbaik, salah satunya adalah perhitungan menggunakan *Akaike's Information Criterion* (AIC). Adapun persamaan AIC, yaitu:

$$AIC = -2 \log(L) + 2k \quad (8)$$

L adalah *maximum likelihood* dari data, k adalah jumlah dari parameter [7]. Model terbaik merupakan model yang memiliki nilai AIC terkecil. Tahap selanjutnya adalah menentukan parameter dari model ARIMA tersebut dengan cara melakukan uji signifikansi pada setiap parameter. Hal ini bertujuan untuk melihat

kelayakan suatu parameter di dalam model [14]. Misalkan β adalah parameter dalam model ARIMA dan $\hat{\beta}$ adalah nilai perkiraan dari β serta $SE(\hat{\beta})$ adalah *standard error* dari $\hat{\beta}$. Maka statistika uji untuk uji signifikansi dapat ditulis sebagai berikut:

$$t = \frac{\hat{\beta}}{SE(\hat{\beta})} \quad (9)$$

Dengan menggunakan hipotesis:

- $H_0 : \hat{\beta} = 0$ (parameter non-signifikan)
- $H_1 : \hat{\beta} \neq 0$ (parameter signifikan)

Standar uji yang ditetapkan adalah tolak H_0 jika $|t| > t_{\alpha,df}$ dimana $df = n - n_p$ dengan n_p adalah banyaknya parameter dan n adalah banyaknya data. Atau $p\text{-value} < \alpha$ dimana $\alpha = 0.05$ (taraf signifikan 5%) [13]. Tahap selanjutnya adalah cek diagnosa terhadap independensi residual, dimana pada tahap ini uji independensi residual menggunakan uji *Ljung-Box* dengan rumus persamaan, yaitu:

$$Q = n(n+2) \sum_{k=1}^m \frac{\widehat{P}_k}{n-k} \quad (10)$$

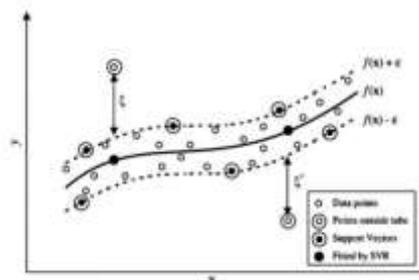
\widehat{P}_k adalah autokorelasi residual pada lag ke- k , n adalah jumlah data, m adalah jumlah lag yang diuji serta k adalah lag. Standar uji yang ditetapkan adalah tolak H_0 jika $Q > X^2_{\alpha,db}$ dimana $db = m - n_p$ atau $p\text{-value} < \alpha$ dimana $\alpha = 0.05$ (taraf signifikan 5%) [13,14]. Dengan menggunakan hipotesis:

- $H_0 : \widehat{P}_k = 0$ (residu *independent*)
- $H_1 : \text{minimal } \widehat{P}_k \neq 0$ (residu tidak *independent*)

Jika model ARIMA telah memenuhi kedua uji tersebut maka model ARIMA dapat digunakan untuk peramalan.

2.3. Model Support Vector Regression (SVR)

Model SVR adalah model tipe *supervised learning* yang berfokus pada kasus regresi dan merupakan model lanjutan dari model Support Vector Machine (SVM). Model SVR berbeda dengan model SVM yang dimana model SVM akan mengembalikan nilai diskrit atau bulat, model SVR akan mengembalikan nilai kontinu. Tujuan model SVR adalah mencari fungsi $f(x)$ serata mungkin dengan nilai simpangan ϵ yang paling besar. Oleh karena itu, model SVR merupakan model yang fleksibel dalam mendefinisikan seberapa besar error yang bisa diterima berdasarkan rentang tertentu (zona toleransi). Berikut adalah ilustrasi yang menggambarkan model SVR:



Gambar 1. Ilustrasi model SVR [14]

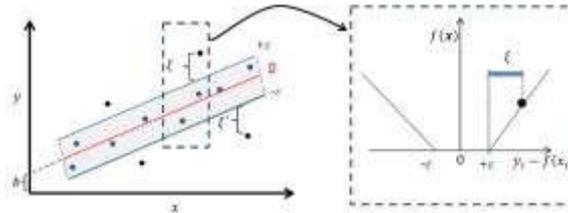
Berdasarkan Gambar 1, garis putus-putus dinamakan *boundary line*, garis ditengah dinamakan *hyperplane* serta ruang diantara kedua garis tersebut dinamakan zona toleransi, jarak antara garis *hyperplane* dengan *boundary line* bisa dinotasikan sebagai ϵ (epsilon). *Data points* terdiri dari (x_i, y_i) dimana x_i merupakan data *input* ke- i dan y_i merupakan hasil *output* atau peramalan berdasarkan x_i . *Data points* yang berada di *boundary line* disebut *support vector*. Adapun persamaan model SVR sebagai berikut:

$$f(x_i) = w \cdot x_i + b \quad (11)$$

$f(x_i)$ adalah fungsi regresi, w adalah bobot koefisien, x_i adalah data *input* ke- i dan b adalah bias atau *intercept*. Asumsikan bahwa semua *data points* berada dalam zona toleransi (*feasible*) maka dengan mencari nilai w yang minimum dapat meratakan fungsi regresi, dibutuhkan persamaan sebagai berikut:

$$\text{Min } \frac{1}{2} \|w\|^2 \tag{12}$$

Tetapi ada kemungkinan kita masih bisa mentolelir *data points* yang berada di luar *boundary line* (*infeasible*) seperti ilustrasi pada Gambar 1. Untuk mengatasi hal tersebut maka dibutuhkan variabel slack ξ dan ξ^* untuk mendefinis seberapa banyak *data points* diluar zona toleransi yang masih bisa ditolelir [9]. Berikut adalah ilustrasi penambahan variabel slack:



Gambar 2. Ilustrasi penambahan variabel slack [18]

Sehingga untuk meminimalisir nilai error berdasarkan permasalahan tersebut, maka dibutuhkan persamaan dengan konstanta C yang merupakan salah satu komponen *hyperparameter* yang ditentukan oleh user. Serta merupakan besarnya pinalti yang diberikan kepada *data points* yang berada diluar zona toleransi. Persamaan tersebut dapat ditulis sebagai berikut:

$$\text{Min } \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \tag{13}$$

Subject to:

$$\begin{aligned} y_i - f(x_i) &\leq \epsilon + \xi_i \\ f(x_i) - y_i &\leq \epsilon + \xi_i^* \\ \xi_i + \xi_i^* &\geq 0 \end{aligned}$$

Trade-off antara kerataan sebuah fungsi dan simpangan nilai error mana yang melebihi zona toleransi yang masih bisa ditolelir ditentukan oleh konstanta C. Hal ini dapat menjadi permasalahan optimasi yang diilustrasikan pada Gambar 2. Menurut [16] masalah optimasi pada Persamaan 13 dapat diatasi oleh Lagrangian. Adapun persamaan Lagrangian sebagai berikut:

$$\begin{aligned} L = \text{Min } &\frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) - \sum_{i=1}^l (\eta_i \xi_i + \eta_i^* \xi_i^*) \\ &- \sum_{i=1}^l \alpha_i (\epsilon + \xi_i - y_i + f(x_i)) - \sum_{i=1}^l \alpha_i^* (\epsilon + \xi_i^* + y_i - f(x_i)) \end{aligned} \tag{14}$$

$\alpha, \alpha^*, \eta, \eta^*$ merupakan koefisien lagrange yang harus memiliki nilai lebih besar dari 0. Persamaan 14 mengubah masalah optimasi dengan kendala menjadi masalah optimasi non-kendala. Penurunan parsial terhadap w, b, ξ, ξ^* pada Persamaan 14 menghasilkan nilai optimum untuk w , yaitu:

$$w = \sum_{i=1}^l (\alpha_i - \alpha_i^*) x_i \tag{15}$$

Sedangkan nilai optimum untuk b adalah

$$b = \begin{cases} y_i - w \cdot x_i - \epsilon, & 0 \leq \alpha_i \leq C \\ y_i + w \cdot x_i + \epsilon, & 0 \leq \alpha_i^* \leq C \end{cases} \tag{16}$$

Sehingga optimalisasi dari fungsi regresi sebagai berikut:

$$f(x_i) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) K(x_i, x) + b \tag{17}$$

$K(x_i, x)$ adalah fungsi kernel. Fungsi kernel merupakan salah satu komponen *hyperparameter* dalam model SVR yang ditentukan oleh user. Dengan adanya fungsi kernel maka data bisa dipetakan dari ruang *input* ke *feature space* dengan ruang dimensi yang lebih tinggi. Ada berbagai jenis fungsi kernel, yaitu

- Polynomial

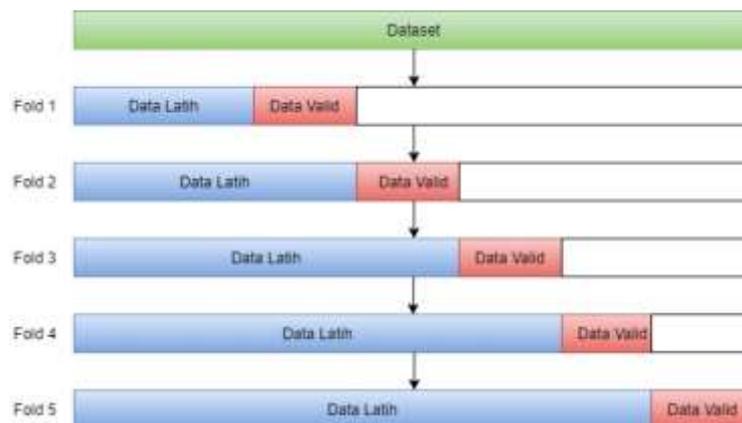
$$K(x_i, x) = ((x_i \cdot x) + 1)^d \quad (18)$$

- Radial Basis Function (RBF)

$$K(x_i, x) = \exp(-\gamma|x_i - x|^2) \quad (19)$$

γ adalah kemiringan dan d adalah derajat polynomial [18]. Terdapat tiga komponen *hyperparameter* yang ditentukan oleh user, yaitu C , fungsi kernel, dan ϵ (epsilon). Karena penelitian ini menggunakan kernel RBF, maka perlu ditambahkan satu komponen *hyperparameter* yang ditentukan oleh user, yaitu γ atau gamma. Komponen tersebut membentuk *hyperparameter* yang digunakan oleh model SVR. Salah satu metode untuk menentukan *hyperparameter* terbaik pada model SVR adalah dengan menggunakan metode *Grid Search Cross Validation*.

Metode *Grid Search Cross Validation* merupakan salah satu metode dalam *machine learning* untuk mencari *hyperparameter* terbaik agar bisa digunakan pada suatu model sehingga model tersebut bisa bekerja dengan optimal. Dengan cara menjadikan data sebagai data *input* lalu membagi data *input* tersebut menjadi data latih dan data *valid* ke dalam masing-masing *fold* sehingga pelatihan model SVR bisa dilakukan pada setiap *fold* lalu masing-masing *fold* menghitung nilai error. Setelah itu di hitung rata-rata nilai errornya sehingga bisa mendapatkan nilai error untuk kombinasi *hyperparameter* pada model tersebut. *Hyperparameter* dalam pelatihan model dengan nilai error terkecil menjadi *hyperparameter* terbaik sehingga bisa digunakan pada model peramalan [17]. Ada berbagai teknik *cross validation* untuk bisa digunakan pada metode ini, salah satunya adalah *Time Series Cross Validation*. Adapun contoh visualisasi kinerja 5 fold-*Time Series Cross Validation* sebagai berikut:



Gambar 3. Visualisasi Kinerja 5 Fold-Time Series CV

Adapun perhitungan sampel data latih dan data valid yang dilakukan pada teknik *Time Series Cross Validation* sebagai berikut:

$$\text{ukuran sampel data latih} = \frac{i * n_{sample}}{n_{fold} + 1} n_{sample} \% (n_{fold} + 1) \quad (20)$$

$$\text{ukuran sampel data valid} = \frac{n_{sample}}{n_{fold} + 1} \quad (21)$$

Tujuan Persamaan 20 adalah untuk menentukan ukuran data latih dari masing-masing *fold* yang nanti di gunakan untuk pelatihan model SVR. Dimana i adalah indeks pada *fold* ke- i , n_{sample} adalah jumlah dataset, n_{fold} adalah jumlah *fold* yang digunakan. Sedangkan tujuan pada Persamaan 21 adalah untuk menentukan ukuran data valid dari masing-masing *fold*.

Untuk meminimalisir nilai error maka perlu dilakukan normalisasi untuk variabel *independent* pada tahap *pre-processing*. Normalisasi bertujuan untuk membuat model dapat mempelajari dengan baik variabel *independent* dengan membuat nilai variabel berada pada rentang yang sama sehingga bisa meminimalisir nilai error. Teknik normalisasi yang dilakukan pada penelitian adalah teknik *MinMax Normalization*. Adapun persamaan *MinMax Normalization* dapat ditulis sebagai berikut:

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \tag{22}$$

Diketahui x' adalah hasil normalisasi, x adalah data, x_{min} adalah nilai terkecil dari keseluruhan data, x_{max} adalah nilai terbesar dari keseluruhan data.

2.4. Mean Absolute Error (MAE)

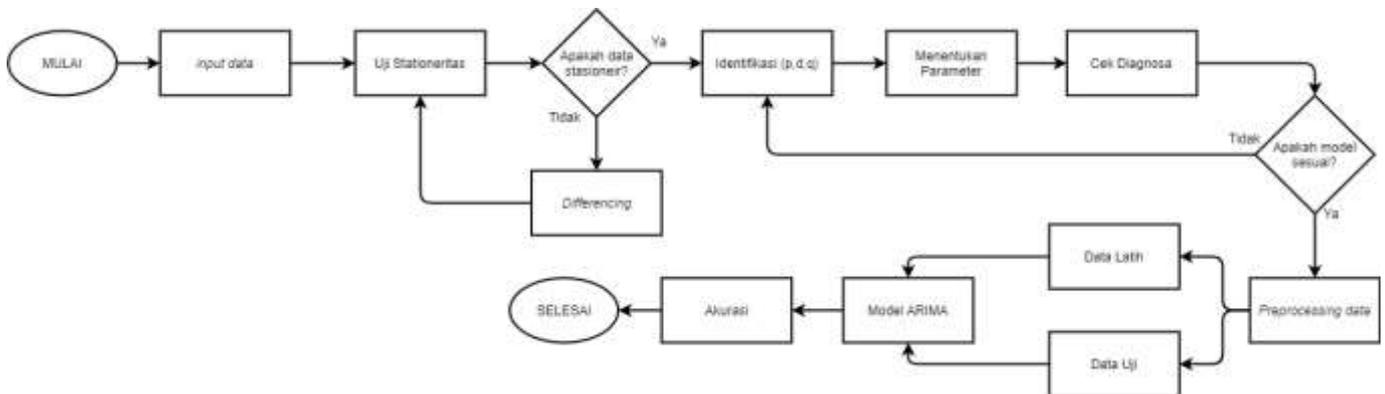
Untuk menghitung nilai error pada penelitian ini maka diperlukan rumus MAE yang merupakan salah satu metode untuk mengukur akurasi dari suatu peramalan, adapun rumus MAE sebagai berikut [15]:

$$MAE = \frac{\sum_{i=1}^n |h_i^* - h_i|}{n} \tag{23}$$

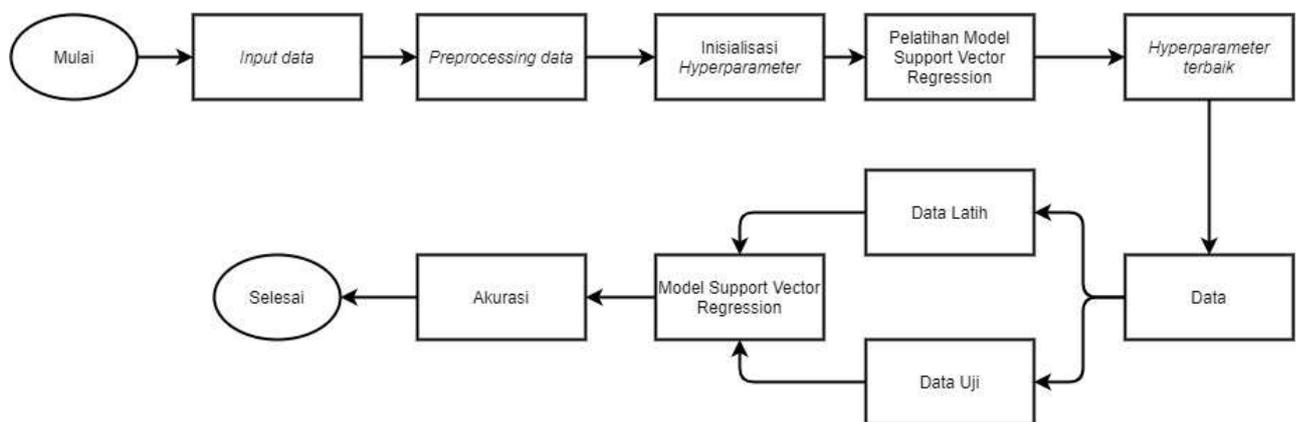
Dimana h_i adalah nilai peramalan, h_i^{*} adalah nilai aktual, n adalah banyaknya data dan i adalah urutan data.

3. Sistem yang dibangun

Adapun alur sistem yang dibangun pada penelitian ini dari masing-masing model sebagai berikut:



Gambar 4. Alur Sistem Model ARIMA

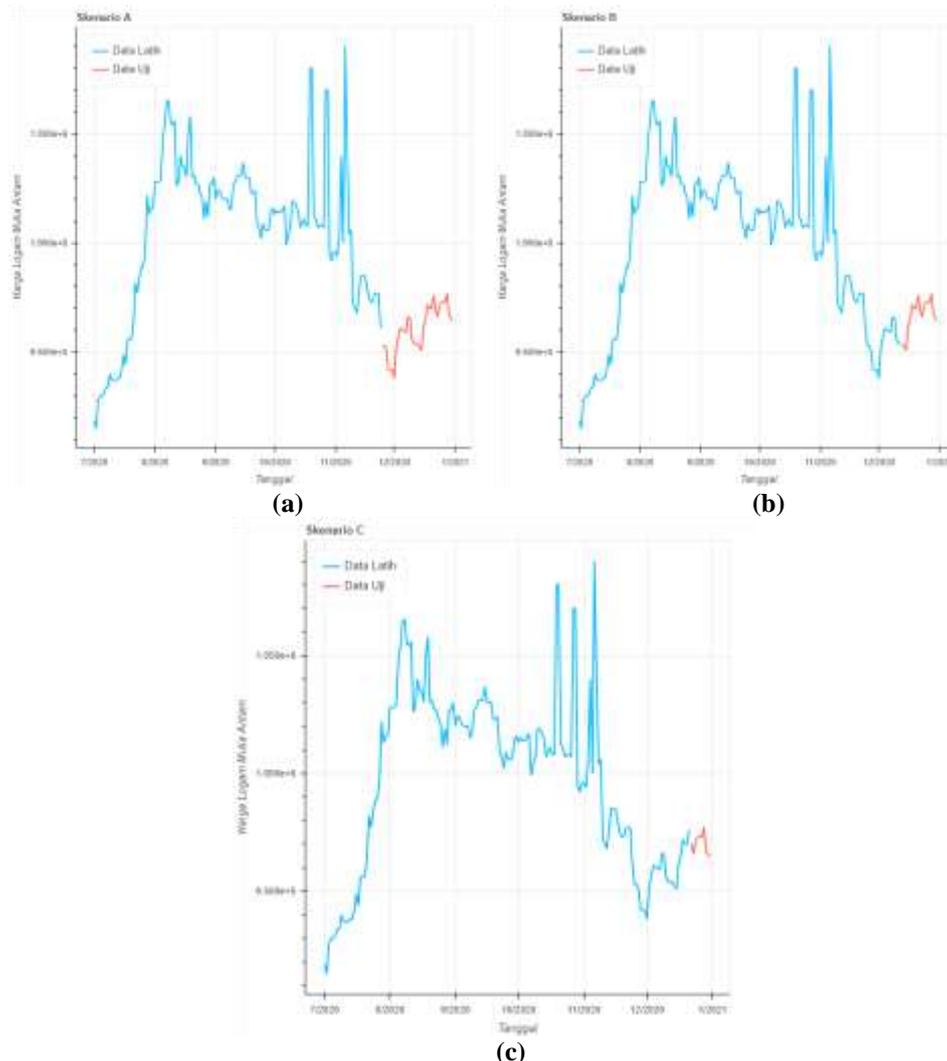


Gambar 5. Alur Sistem Model SVR

3.1.1. Dataset

Penelitian ini menggunakan data harian logam mulia Antam yang diambil dari www.logammulia.com. Serta memiliki rentang waktu pada periode 1 Juli 2020 - 31 Desember 2020. Sehingga dataset yang diperoleh terdiri dari 184 baris. Penelitian ini menggunakan tiga skenario dengan perbandingan *split* data latih dan data uji yang sudah dikelompokkan. Adapun perbandingan *split* data adalah pada skenario A dibagi menjadi 80% untuk data latih dengan jumlah 147 data dan 20% untuk data uji dengan jumlah 37 data. Skenario B dibagi menjadi 90% untuk data latih dengan jumlah 165 data dan 10% untuk data uji dengan

jumlah 19 data. Serta skenario C dibagi menjadi 95% untuk data latih dengan jumlah 174 data dan 5% untuk data uji dengan jumlah 10 data. Adapun visualisasi data latih dan uji dari masing-masing skenario sebagai berikut:



Gambar 6. (a) Skenario A (b) Skenario B (c) Skenario C

3.1.2. Model ARIMA

Alur sistem yang digunakan pada penelitian ini berdasarkan tahapan-tahapan pada model ARIMA, adapun tahapan-tahapan alur sistem sebagai berikut:

1. Uji Stasioneritas

Pada proses ini, data di uji kestasioneran data menggunakan metode *Augmented Dickey-Fuller (ADF)*, jika data terbukti tidak stasioner maka data dilakukan proses *differencing* lalu di uji kembali sampai data terbukti stasioner.

2. Identifikasi (p,d,q)

Pada proses ini dilakukan identifikasi model ARIMA menggunakan ACF untuk menentukan order (q) dan PACF untuk menentukan order (p) serta jumlah *differencing* untuk menentukan order (d). Lalu melakukan perhitungan AIC untuk menentukan model ARIMA terbaik.

3. Menentukan Parameter

Pada tahap ini dilakukan analisis parameter model ARIMA. Dalam menentukan nilai parameter pada model ARIMA, dapat dibantu oleh bantuan fungsi `.summary()` pada Python. Lalu dilakukan uji signifikansi untuk melihat kelayakan model.

4. Cek Diagnosa Terhadap Independensi Residual

Proses ini melakukan pengecekan independensi pada nilai residual yang dihasilkan oleh model dengan menggunakan Uji Ljung-Box.

5. Model ARIMA

Pada tahap ini, model yang terbukti layak dan baik dapat digunakan untuk melakukan peramalan menggunakan data uji. Jika tidak, maka akan kembali ke Tahap 2

6. Akurasi

Pada tahap ini dilakukan perhitungan antara nilai aktual dengan nilai peramalan menggunakan rumus MAE pada Persamaan 23 untuk melihat nilai error yang dihasilkan oleh model ARIMA

3.1.3. Model Support Vector Regression (SVR)

Alur sistem yang digunakan pada penelitian ini berdasarkan tahapan-tahapan pada model SVR, adapun tahapan-tahapan alur sistem sebagai berikut:

1. *Preprocessing* data

Pada tahap ini, grafik PACF dibuat berdasarkan data harga emas Antam untuk menentukan variabel *independent* yang berfungsi sebagai data input SVR. Setelah itu variabel independen tersebut di normalisasikan dengan metode *MinMaxNormalization* dan akhirnya membagi data variabel *independent* dan *dependent* menjadi data latih dan uji.

2. Inisialisasi *Hyperparameter*

3. Pelatihan Model SVR

Pada tahap ini, *hyperparameter* yang sudah di inisialisasi dimasukkan ke dalam persamaan model SVR untuk melatih model pada data latih dengan menggunakan metode *Grid Search-10 Fold Time Series Cross Validation*

4. *Hyperparameter* Terbaik

Setelah dilakukan pelatihan model maka dilakukan penilaian pada model latihan melalui hasil MAE. Model dengan nilai MAE terkecil dipilih sebagai model latih terbaik sehingga *hyperparameter* yang digunakan pada model tersebut dijadikan *hyperparameter* untuk model pengujian.

5. Model SVR

Pada tahap ini, *hyperparameter* terbaik dimasukkan ke dalam persamaan model SVR, lalu menggunakan data latih untuk membangun model SVR dalam penentuan nilai Lagrangian dan b. Lalu nilai Lagrangian dan b yang sudah didapatkan dari model SVR yang sudah dilatih, dimasukkan ke dalam model SV melakukan peramalan menggunakan data uji.

6. Akurasi

Pada tahap ini dilakukan perhitungan antara nilai aktual dengan nilai peramalan menggunakan rumus MAE pada Persamaan 23 untuk melihat nilai error yang dihasilkan oleh model SVR

4. Evaluasi

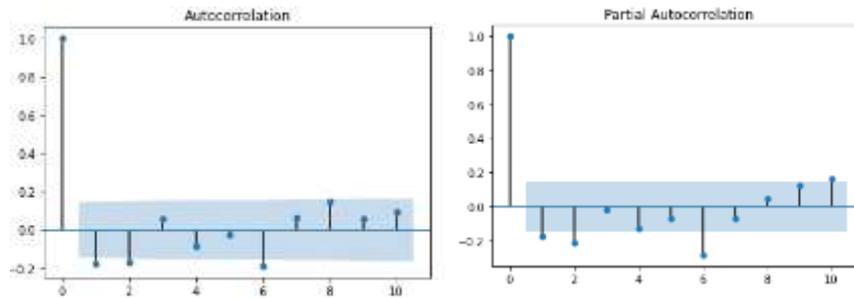
4.1. Model ARIMA

Model ARIMA merupakan model yang mempunyai syarat dimana data yang diproses merupakan data stasioner. Oleh karena itu, dilakukan pengujian kestasioneritas dengan menggunakan metode *Augmented Dickey Fuller*. Dengan bantuan *library* pada bahasa pemrograman Python yaitu *Adfuller*, maka hasil uji ADF yang didapat adalah sebagai berikut:

Table 1. Hasil uji ADF

Data Harga Logam Mulia Antam		Data Harga Logam Mulia Antam setelah <i>differencing</i> pertama	
<i>p-value</i>	Keputusan	<i>p-value</i>	Keputusan
0,268	Data tidak stasioner	0,000	Data stasioner

Tabel 1 menunjukkan bahwa H_0 ditolak pada harga logam mulia Antam *differencing* pertama karena hasil *p-value* < 0.05 yang berarti data tersebut terbukti merupakan data stasioner. Tahap selanjutnya adalah identifikasi (p,d,q) menggunakan ACF untuk order (q) dan PACF untuk order (p). Hasil ACF dan PACF yang didapat adalah sebagai berikut:



Gambar 7. Plot ACF (kiri) dan PACF (kanan)

Berdasarkan Gambar 7, diketahui bahwa hasil ACF dan PACF menunjukkan pada lag ke-0 memiliki nilai korelasi sebesar 1.0 dan dari kedua hasil tersebut menunjukkan terdapat *cut-off* setelah lag ke-2. Sehingga lag yang dipilih adalah lag ke-0 dengan nilai korelasi 1.0, dan lag ke-1 dengan nilai korelasi -0.2 untuk ACF dan mendekati -0.2 untuk PACF, dan lag ke-2 dengan nilai korelasi mendekati -0.2 untuk ACF dan 0.2 untuk PACF. Nilai korelasi tersebut menunjukkan tingkat hubungan antar data pada saat t dengan data pada saat lag ke-0,1,2. Dari hasil tersebut membentuk beberapa kombinasi model ARIMA sementara, diantaranya ARIMA (0,1,1), ARIMA (0,1,2), ARIMA (1,1,0), dan ARIMA (1,1,1). Serta ARIMA (1,1,2), ARIMA (2,1,0), ARIMA (2,1,1) dan ARIMA (2,1,2). Setelah itu dilakukan perhitungan AIC untuk menentukan model terbaik dari model ARIMA sementara yang sudah diidentifikasi. Adapun hasil perhitungan AIC untuk model ARIMA dengan kombinasi order berdasarkan *cut-off* ACF dan PACF sebagai berikut:

Table 2. Hasil perhitungan AIC

Model	AIC
ARIMA (0,1,1)	4046
ARIMA (0,1,2)	4039
ARIMA (1,1,0)	4049
ARIMA (1,1,1)	4040
ARIMA (1,1,2)	4041
ARIMA (2,1,0)	4043
ARIMA (2,1,1)	4042
ARIMA (2,1,2)	-

Berdasarkan Tabel 2, diketahui bahwa model ARIMA (0,1,2) merupakan model terbaik dikarenakan nilai AIC terkecil yaitu 4039. Oleh karena itu, pada tahap selanjutnya menggunakan model ARIMA (0,1,2). Adapun persamaan untuk model ARIMA (0,1,2) sebagai berikut:

$$\begin{aligned}
 A_t &= s + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} \\
 P_t - P_{t-1} &= s + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} \\
 P_t &= s + P_{t-1} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2}
 \end{aligned} \tag{24}$$

Tahap selanjutnya adalah menentukan parameter. Untuk menguji kelayakan parameter maka dilakukan uji signifikansi. Hasil uji signifikansi untuk model ARIMA (0,1,2) dapat dilihat pada tabel dibawah ini:

Table 3. Hasil Uji Signifikansi

Model	Parameter	P > z	Keputusan
ARIMA (0,1,2)	-0,2395 (θ_1)	0,001	Signifikan
	-0,2519 (θ_2)	0,001	Signifikan

Tabel 3 membuktikan bahwa setiap parameter pada model ARIMA (0,1,2) terbukti signifikan sehingga bisa dikatakan bahwa model ARIMA ini sudah layak untuk digunakan. Selanjutnya adalah cek diagnosis menggunakan uji Ljung-Box, adapun hasil yang didapat adalah sebagai berikut:

Table 4. Hasil Uji Ljung-Box

Lag	p-value	Keputusan
-----	---------	-----------

1	0,999	<i>Independent</i>
2	0,892	<i>Independent</i>
3	0,935	<i>Independent</i>
4	0,535	<i>Independent</i>
5	0,608	<i>Independent</i>

Berdasarkan hasil pada Tabel 4, diketahui bahwa H_0 telah diterima. Hal ini dikarenakan setiap lag mempunyai nilai *p-value* yang lebih besar dari $\alpha = 0.05$ (taraf signifikan 5%). Hasil ini menunjukkan terdapat independensi residual pada model ARIMA (0,1,2), sehingga bisa dikatakan bahwa model ARIMA ini merupakan model yang baik. Berdasarkan hasil analisis parameter model ARIMA (0,1,2) yang dilakukan pada skenario A, skenario B, dan skenario C diperoleh nilai parameter sebagai berikut:

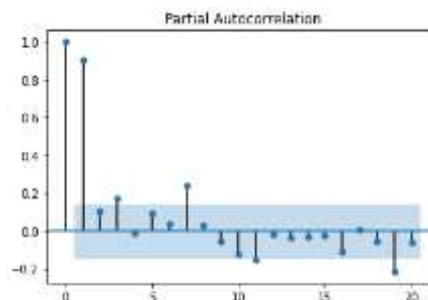
Tabel 5. Nilai parameter pada tiap skenario

Skenario	Parameter		
	S	θ_1	θ_2
A	327,07	-0,2594	-0,2590
B	213,41	-0,2418	-0,2519
C	294,66	-0,2390	-0,2503

Tabel 5 digunakan untuk mendapatkan hasil peramalan dengan menggunakan Model ARIMA (0,1,2) pada Persamaan 24.

4.2. Model Support Vector Regression (SVR)

Model SVR adalah model yang berfokus pada kasus regresi, maka pada model ini diperlukan variabel *independent* sebagai data *input* SVR.



Gambar 8. Plot PACF Data Harga Logam Mulia Antam

Gambar 8 menunjukkan bahwa lag PACF yang signifikan berada pada lag ke-1,3,7,11,19. Sehingga pada penelitian ini, data harga antam pada lag ke-1,3,7,11,19 dijadikan variabel *independent* dan data *input* model SVR. Untuk meminimalisir nilai error maka perlu dilakukan pengubahan nilai atau normalisasi menggunakan metode *MinMax Normalization* untuk variabel *independent*. Setelah melakukan normalisasi pada data, tahap selanjutnya adalah menginisialisasi *hyperparameter* untuk membangun model, adapun *list hyperparameter* yang di uji coba kedalam model pelatihan sebagai berikut:

Tabel 7. Inisialisasi Hyperparameter

<i>Hyperparameter</i>	Rentang Nilai
C	1, 10, 100, 1000, 10000, 100000
Epsilon	0,00001, 0,0001, 0,001, 0,01, 0,1,1
γ	0,001, 0,01, 0,1, 1, 10
Kernel	Polynomial, RBF

Setelah itu, tahap selanjutnya adalah membuat model pelatihan menggunakan semua data berdasarkan *list hyperparameter* yang sudah di inisialisasikan. Model pelatihan tersebut menggunakan metode *Grid Search-10 Fold Time Series Cross Validation*. Adapun hasil perhitungan *10 Fold Time Series Cross Validation* sebagai berikut:

Table 8. Hasil perhitungan 10 Fold Time Series Cross Validation

	Ukuran data latih	Ukuran data valid
Fold-1	24	16
Fold-2	40	16
Fold-3	56	16
Fold-4	72	16
Fold-5	88	16
Fold-6	104	16
Fold-7	120	16
Fold-8	136	16
Fold-9	152	16
Fold-10	168	16

Pada model pelatihan, *hyperparameter* dikombinasikan satu sama lain lalu dimasukkan kedalam persamaan model SVR untuk dilatih mempelajari pola data. Pelatihan model untuk setiap kombinasi *hyperparameter* dilakukan pada setiap *fold* dengan ukuran sampel data yang telah dijelaskan pada Tabel 8. Setelah itu, model dilatih untuk melakukan peramalan dengan memakai sampel data valid. Lalu dihitung nilai error pada masing-masing *fold* menggunakan Mean Absolute Error (MAE). Setelah itu rata-rata nilai MAE tersebut menjadi nilai MAE utama pada kombinasi *hyperparameter* tersebut. Hasil yang didapat oleh metode *Grid Search-10 Fold Time Series Cross Validation* dari masing-masing skenario sebagai berikut:

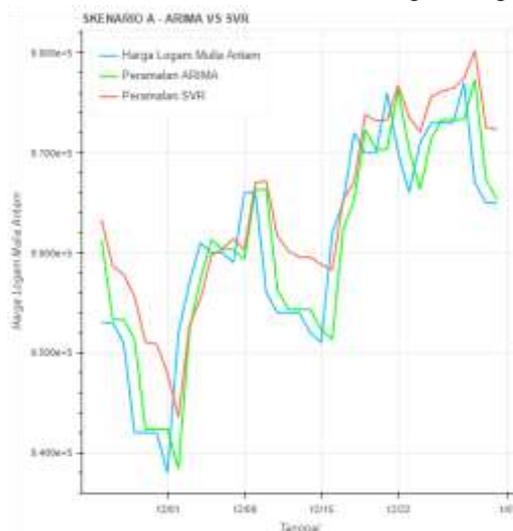
Tabel 9. Hyperparameter terbaik

C	Epsilon	γ	Kernel	MAE
100000	0,00001	10	RBF	14.529

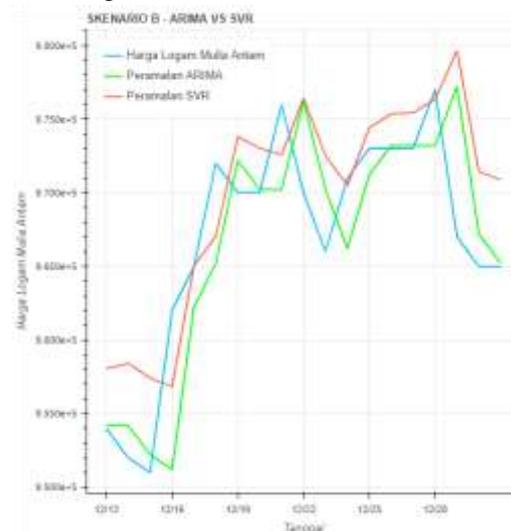
Pada Tabel 9, menunjukkan bahwa *hyperparameter* tersebut merupakan *hyperparameter* terbaik. Hal ini disebabkan karena model latih dengan kombinasi *hyperparameter* tersebut memiliki nilai MAE terkecil diantara model-model latih lainnya. Hal ini juga membuktikan bahwa model latih tersebut mampu mengenali dan mempelajari pola data dengan baik. Oleh karena itu, *hyperparameter* tersebut digunakan untuk mendapatkan hasil peramalan menggunakan model SVR.

4.3. Hasil perbandingan peramalan model ARIMA dan Support Vector Regression

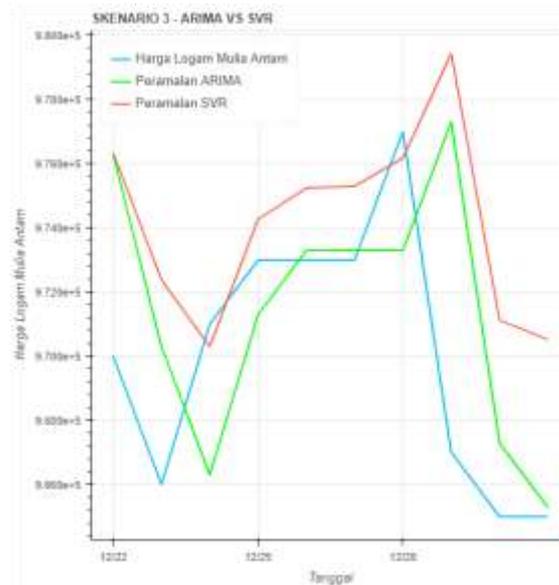
Berdasarkan penjelasan hasil diatas, maka hasil peramalan yang telah didapat menggunakan model ARIMA dan SVR dari masing-masing skenario sebagai berikut:



(a)



(b)



(c)

Gambar 9. Grafik Perbandingan Hasil Perbandingan Peramalan ARIMA-SVR

(a) Skenario A (b) Skenario B (c) Skenario C

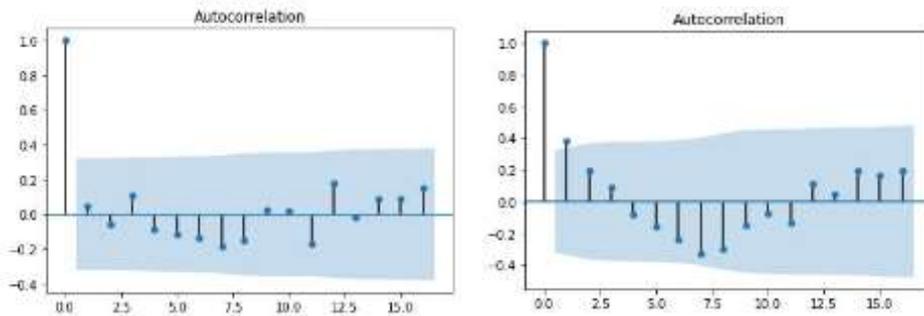
Berdasarkan Gambar 9, hasil peramalan model ARIMA dan SVR pada skenario A, B dan C diawali pada titik yang lebih tinggi dibandingkan titik awal nilai aktual. Berbeda dengan titik awal model ARIMA yang mendekati titik awal nilai aktual sampai titik terakhir. Selain itu, secara garis besar model ARIMA dan SVR sudah mengikuti pola garis aktual sehingga bisa dikatakan bahwa model ARIMA dan SVR telah mempelajari pola data dengan baik. Perbandingan nilai error pada model ARIMA dan SVR dari setiap skenario dapat dilihat dengan MAE. Adapun hasil MAE dan rata-rata data harga logam mulia Antam adalah sebagai berikut:

Tabel 10. Hasil MAE

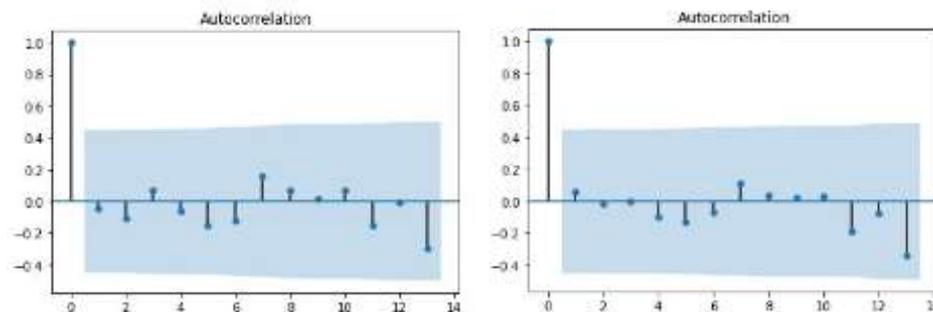
Skenario	Model ARIMA	Model SVR	Rata-rata Harga Logam Mulia Antam
A	3.699	5.681	Rp. 960.486
B	3.477	4.345	Rp. 966.947
C	3.417	4.411	Rp. 970.545

Tabel 10 menunjukkan bahwa model ARIMA dan SVR menghasilkan hasil peramalan yang tergolong akurat. Hal ini dikarenakan nilai MAE dengan rata-rata harga logam mulia Antam dari masing-masing skenario, mempunyai perbandingan yang cukup signifikan. Model ARIMA memiliki optimalisasi tertinggi pada skenario C, dengan memiliki nilai MAE sebesar 3.417. Hal ini membuktikan bahwa optimalisasi pada model ARIMA sangat tergantung pada kuantitas data latih. Semakin besar kuantitas data latih maka peramalan dengan menggunakan model ARIMA semakin akurat. Pada skenario A, model SVR memiliki nilai MAE sebesar 5.681. Hal ini membuktikan bahwa model SVR pada skenario A kurang optimal, dikarenakan data latih yang dimiliki lebih sedikit dibandingkan data latih pada skenario B. Lalu hasil MAE pada skenario C lebih besar dibandingkan hasil MAE pada skenario B. Hal ini menunjukkan bahwa model SVR memiliki optimalisasi tertinggi pada skenario B.

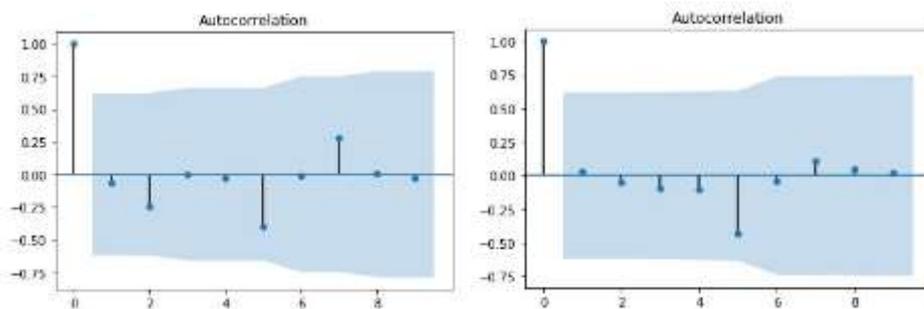
Selain melakukan perbandingan nilai error dengan MAE. Penelitian ini juga membandingkan korelasi antara hasil selisih harga aktual dan harga peramalan atau residu. Hal ini bertujuan untuk melihat korelasi antar residu pada masing-masing model. Adapun hasil korelasi dengan menggunakan ACF sebagai berikut



Gambar 10. Plot ACF-residu skenario A Model ARIMA (kiri) dan Model SVR (kanan)



Gambar 11. Plot ACF-residu skenario B Model ARIMA (kiri) dan Model SVR (kanan)



Gambar 12. Plot ACF-residu skenario C Model ARIMA (kiri) dan Model SVR (kanan)

Gambar 10 menunjukkan bahwa hasil ACF pada model SVR memiliki *cut-off* setelah lag ke-1 sehingga bisa dikatakan residu pada model SVR pada skenario A memiliki korelasi pada lag ke-1 sedangkan pada model ARIMA tidak. Gambar 11 dan Gambar 12 menunjukkan bahwa tidak ada korelasi antar residu yang dihasilkan oleh model ARIMA maupun model SVR, sehingga bisa dikatakan bahwa model ARIMA dan SVR telah memahami pola data dengan baik. Hal ini menunjukkan bahwa residual yang berkorelasi memiliki nilai MAE yang lebih tinggi. Hal ini terbukti dengan hasil MAE pada Tabel 10, dimana model SVR pada skenario A memiliki nilai MAE terbesar dibandingkan nilai MAE lainnya.

5. Kesimpulan

Berdasarkan evaluasi yang telah dijelaskan pada Bab 4, maka kesimpulan yang bisa didapat, yaitu:

- Peramalan harga logam mulia Antam periode 1 Juli 2020-31 Desember 2021 menunjukkan bahwa model ARIMA (0,1,2) adalah model terbaik. Hal ini dikarenakan model ARIMA memiliki nilai MAE yang lebih kecil dibandingkan nilai MAE yang dihasilkan model SVR pada setiap skenario.
- Optimalisasi model ARIMA tertinggi berada pada skenario C dengan perbandingan jumlah data, yaitu 95% data latih dan 5% data uji. Hal ini menunjukkan bahwa optimalisasi model ARIMA sangat tergantung dengan jumlah data latih. Hal ini dibuktikan dengan model ARIMA yang mengalami penurunan nilai error pada setiap penambahan jumlah data latih sehingga bisa dikatakan bahwa semakin banyak data latih, maka semakin baik model ARIMA dalam meramalkan sesuatu dengan nilai error terkecil.
- Optimalisasi model SVR tertinggi berada pada skenario B dengan perbandingan jumlah data sebesar 90% data latih dan 10% data uji. Selain itu, residual yang berkorelasi sangat mempengaruhi

hasil peramalan dan bisa meningkatkan nilai MAE. Hal ini dibuktikan dengan adanya residual yang berkorelasi pada model SVR di skenario A. Nilai MAE yang dihasilkan pada skenario ini lebih tinggi dibandingkan nilai MAE pada model lainnya.

Daftar Pustaka

- [1] Anggraeni, D. P., Rosadi, D., Hermansah, H., & Rizal, A. A. (2020). Prediksi Harga Emas Dunia di Masa Pandemi Covid-19 Menggunakan Model ARIMA. *Jurnal Aplikasi Statistika & Komputasi Statistik*, 12(1), 71-84
- [2] Sunyanti, S., & Mukhaiyar, U. (2019). PREDIKSI HARGA EMAS DENGAN PENDEKATAN MODEL DERET WAKTU ARIMA. *Procuratio: Jurnal Ilmiah Manajemen*, 7(4), 379-390.
- [3] Purnama, D. I. (2021). Peramalan Harga Emas Saat Pandemi Covid-19 Menggunakan Model Hybrid Autoregressive Integrated Moving Average-Support Vector Regression. *Jambura Journal of Mathematics*, 3(1), 52-65.
- [4] Ongsrirakul, P., & Soonthornphisaj, N. (2003, July). Apply decision tree and support vector regression to predict the gold price. In *Proceedings of the International Joint Conference on Neural Networks, 2003*. (Vol. 4, pp. 2488-2492). IEEE.
- [5] Wang, J., Chen, S., Wang, B., & Yang, K. A Forecasting Model of Financial Assets' Price Based on Support Vector Regression.
- [6] Azzahra, M., Setiawan, B. D., & Adikara, P. P. (2017). Optimasi Parameter Support Vector Regression Dengan Algoritme Genetika Untuk Prediksi Harga Emas. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer e-ISSN*, 2548, 964X.
- [7] ANTAM. "Antam in Glance". PT ANTAM Tbk | About
- [8] di Bandara Sultan, P. P. D. Support Vector Regression (SVR) Model for Forecasting Number of Passengers on Domestic Flights at Sultan Hasanudin Airport Makassar.
- [9] Amirkhalili, Y. S., Aghsami, A., & Jolai, F. Comparison of Time Series ARIMA Model and Support Vector Regression.
- [10] Mauludiyanto, A., Hendrantoro, G., & Suhartono, S. (2010). Pemodelan ARIMA dan Deteksi Outlier Data Curah Hujan Sebagai Evaluasi Sistem Radio Gelombang Milimeter. *Jurnal Ilmiah Teknologi Informasi*, 7(3), 107-112.
- [11] Abdullah, L. (2012). ARIMA model for gold bullion coin selling prices forecasting. *International Journal of Advances in Applied Sciences*, 1(4), 153-158.
- [12] Yani, A. (2018). Analisis teknikal harga saham dengan metode ARIMA. *Jurnal Ilmu Manajemen dan Akuntansi Terapan (JIMAT)*, 9(2), 1-16.
- [13] Julia, J., Wahyuningsih, S., & Hayati, M. N. (2019). Analisis Model Threshold Generalized Autoregressive Conditional Heteroskedasticity (TGARCH) dan Model Exponential Generalized Autoregressive Conditional Heteroskedasticity (EGARCH). *JURNAL EKSPONENSIAL*, 9(2), 127-136.
- [14] Fahrin, E., Hayati, M. N., & Siringoringo, M. (2020). Penerapan Model Seasonal Autoregressive Fractionally Integrated Moving Average Pada Data Inflasi di Indonesia. *JURNAL EKSPONENSIAL*, 10(2), 113-118.
- [15] Miswan, N. H., Said, R. M., & Anuar, S. H. H. (2016). ARIMA with regression : model in modelling electricity load demand. *Journal of Telecommunication, Electronic and Computer Engineering (JTEC)*, 8(12), 113-116.
- [16] Smola, A. J., & Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and computing*, 14(3), 199-222.
- [17] Patriya, E. (2020). Implementasi Support Vector Machine Pada Prediksi Harga Saham Gabungan (IHSG). *Jurnal Ilmiah Teknologi dan Rekayasa*, 25(1), 24-38.
- [18] Saputra, G. H., Wigena, A. H., & Sartono, B. (2019). Penggunaan support vector regression dalam pemodelan indeks saham syariah indonesia dengan algoritme grid search. *Indonesian Journal of Statistics and Its Applications*, 3(2), 148-160.
- [19] Maharesi, R. (2013). Penggunaan Support Vector Regression (Svr) Pada Prediksi Return Saham Syariah Bei. *Prosiding PESAT*, 5.
- [20] Sangeetha, R., & Kalpana, B. (2011). Performance evaluation of kernels in multiclass support vector machines. *training*, 2, 2.
- [21] Paranita, C. (2015). Analisis kinerja investasi dalam reksadana saham (equity funds) dengan metode sharpe dan treynor. *Jurnal Administrasi Bisnis*, 27(1).
- [22] Yang, J. F., Zhai, Y. J., Wang, D. F., & Xu, D. P. (2005). Time series prediction based on support vector regression. *PROCEEDINGS-CHINESE SOCIETY OF ELECTRICAL ENGINEERING*, 25(17), 110.

- [23] Perdana, A. (2018). *Penerapan Algoritma Support Vector Machine (SVM) Pada Pengklasifikasian Penyakit Kejiwaan Skizofrenia (Studi Kasus: RSJ. Radjiman Wediodiningrat, Lawang)* (Doctoral dissertation, Universitas Brawijaya).
- [24] Azwar, S. (2005). Signifikan atau sangat signifikan. *Buletin Psikologi UGM*, 13(1), 38-44.