

Peramalan Harga Minyak Menggunakan *Support Vector Regression*

Decesa Erla Krislianti¹, Etik Zukhronah², Yuliana Susanti³
Prodi Statistika, Universitas Sebelas Maret^{1,2,3}
decesaerla@student.uns.ac.id

Abstrak— Indonesia merupakan negara yang kaya akan minyak mentah, fluktuasi harga minyak mentah membawa pengaruh dalam pertumbuhan ekonomi. Oleh karena itu, diperlukan suatu metode untuk meramalkan harga minyak mentah di Indonesia. Metode peramalan yang dapat digunakan salah satunya yaitu *Support Vector Regression* (SVR). Tujuan dari penelitian ini adalah meramalkan harga minyak menggunakan SVR sehingga didapatkan metode peramalan yang lebih baik dengan nilai *error* terkecil. Data yang digunakan dalam penelitian ini adalah data Harga Minyak di Indonesia pada Januari 2017 hingga November 2022. SVR adalah metode peramalan yang baik untuk meramalkan data yang bersifat non-linear yang cocok untuk mengatasi *overfitting*. Penentuan model SVR terbaik dapat dilakukan dengan menentukan *timesteps* dan parameter terbaik, selanjutnya dilakukan metode *grid search* dan *k-fold cross validation*. Berdasarkan hasil analisis diketahui bahwa model SVR terbaik adalah dengan nilai $p = 10$ dan parameter $C = 1000$, $\epsilon = 0,0001$, $\gamma = 0,01$, dan fungsi kernel sigmoid. Dilihat dari nilai akurasi peramalan data *testing*-nya metode SVR menghasilkan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 3,618% yang berarti SVR merupakan metode yang baik karena menghasilkan nilai *error* yang kecil.

Kata kunci: MAPE, SVR, Harga Minyak Mentah

I. PENDAHULUAN

Indonesia sejak dahulu dikenal sebagai negara yang kaya akan hasil bumi dan barang tambangnya. Salah satu barang tambang yang menjadi sumber daya alam yang melimpah di Indonesia adalah minyak mentah. Minyak mentah adalah salah satu sumber daya energi utama yang memiliki peran penting dalam perekonomian. Minyak mentah merupakan input vital dalam proses produksi industri terutama untuk menghasilkan listrik, menjalankan mesin produksi dan mengangkut hasil produksi ke pasar. Meningkatnya kebutuhan minyak mentah yang tinggi tetapi tidak diimbangi dengan peningkatan hasil produksi dapat menyebabkan jumlah pasokan minyak mentah semakin menurun. Hal ini menyebabkan meningkatnya harga minyak yang tidak sepadan dengan kemampuan ekonomi masyarakat di Indonesia. Fluktuasi harga minyak mentah dapat membawa dampak pada pertumbuhan ekonomi, laju inflasi jumlah uang yang beredar, nilai tukar riil rupiah terhadap US dolar dan suku bunga [1]. Oleh karena itu, perlu dilakukan peramalan mengenai harga minyak mentah pada periode berikutnya.

Terdapat banyak metode peramalan yang dapat digunakan, salah satunya adalah *Support Vector Regression* (SVR). SVR adalah metode peramalan yang digunakan untuk memprediksi data runtun waktu nonlinear [2]. SVR adalah metode yang dapat mengatasi *overfitting*, sehingga menghasilkan performa yang bagus dengan nilai *error* yang kecil [3]. Selain itu, terdapat metode peramalan yang biasa digunakan dalam meramalkan data jangka pendek yaitu metode *Autoregressive Intergrated Moving Average* (ARIMA) yang dapat digunakan sebagai pembanding apakah metode SVR merupakan metode yang lebih baik dibanding metode ARIMA.

Beberapa penelitian sebelumnya telah melakukan peramalan harga minyak mentah di Indonesia dengan menggunakan metode *Fuzzy Time Series* (FTS) [4]. Penelitian tersebut melakukan peramalan harga beberapa jenis minyak mentah yang bukan patokan untuk harga minyak di pasar Indonesia, untuk itu perlu dilakukan penelitian mengenai peramalan harga minyak mentah yang dijadikan patokan di pasar Indonesia. Selain itu, terdapat penelitian mengenai studi komparasi peramalan harga minyak menggunakan metode *Generalized Regression Neural Network* (GRNN) dan *Feed Forward Neural Network* (FFNN) [5]. Penelitian lain membandingkan *Ridge Regression* dan SVR untuk Prediksi Indeks Batubara di PT XYZ [6]. Berdasarkan hasil penelitian tersebut, diperoleh kesimpulan bahwa metode SVR lebih baik dari *Ridge Regression* karena mampu memprediksi indeks batubara dengan baik. Berdasarkan beberapa penelitian yang telah dilakukan sebelumnya maka dilakukan peramalan harga minyak mentah di Indonesia dengan menggunakan metode SVR pada periode Januari 2017 hingga November 2022 untuk mengetahui apakah

metode SVR lebih baik jika dibandingkan dengan metode yang telah digunakan sebelumnya berdasarkan nilai MAPE terkecil.

II. METODE PENELITIAN

Penelitian ini menggunakan data harga minyak di Indonesia pada Januari 2017 hingga November 2022. Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari *website databook.katadata.co.id* yang diakses pada 25 Juni 2022 [7]. Peneliti membagi data keseluruhan yang berjumlah 71 data menjadi dua yaitu data *training* dari bulan Januari 2017 hingga Desember 2021 dan data *testing* dari Januari 2022 hingga November 2022. Berikut landasan teori yang digunakan dalam penelitian ini.

A. Model Support Vector Regression (SVR)

SVR adalah algoritma yang dapat memprediksi data analisis runtun waktu dengan fungsi kernel [8]. Peramalan menggunakan SVR mempertimbangkan hubungan antara nilai pada periode y_t dan nilai dari data elemen deret waktu sebelumnya, menggunakan beberapa jeda waktu [9]. Fungsi regresi dari metode SVR untuk komponen nonlinear dapat dituliskan dengan persamaan sebagai berikut.

$$f(x_i) = \sum_{i=1}^m (\alpha_i - \alpha_i^*) \varphi(x_i) \varphi(x) + b \quad (1)$$

dengan $f(x_i)$ merupakan fungsi SVR, α_i dan α_i^* merupakan koefisien *lagrange*, $\varphi(x_i)$ merupakan fungsi yang memetakan x_i , $\varphi(x)$ merupakan fungsi yang memetakan x , serta b adalah bias. x_i merupakan data *input* ke- i , sedangkan x adalah data *input* untuk memetakan fungsi ke ruang fitur [10]. Kerja algoritma SVR ditentukan oleh jenis fungsi kernel yang dipakai. Terdapat beberapa jenis fungsi kernel, diantaranya seperti:

1. Kernel Linear

$$K(x_i, x) = x_i \cdot x \quad (2)$$

2. Kernel *Radial Basis Function* (RBF)

$$K(x_i, x) = \exp\left(-\frac{1}{2\sigma^2} \|x_i - x\|^2\right) \quad (3)$$

3. Kernel Sigmoid

$$K(x_i, x) = \tanh(\sigma(x_i \cdot x) + c) \quad (4)$$

Grid search adalah metode untuk mengidentifikasi parameter optimal dalam data *training*, sehingga model tersebut mampu secara akurat memprediksi data *testing* dan diperoleh parameter terbaik berdasarkan nilai *error* terendah [11]. Proses untuk melakukan *grid search* secara lengkap memerlukan waktu yang sangat lama sehingga disarankan untuk melakukan *grid search* dengan dua tahap yaitu *loose grid* dan *finer grid*. *Loose grid* adalah proses pemilihan C dan γ dengan pangkat bilangan bulat. Pemilihan parameter C dan γ menggunakan urutan angka eksponensial. Misalnya rentang parameter C adalah $2^{-5}, 2^{-3}, \dots, 2^{-15}$, sedangkan rentang parameter γ adalah $2^{-15}, 2^{-13}, \dots, 2^{-5}$. *Finer grid* adalah proses lanjutan dari *loose grid* dengan pemilihan *loose grid*. Parameter ε dari tahap *loose grid* tetap digunakan pada tahap *finer grid*. Setelah itu, dilakukan uji *k-fold cross validation* untuk mengevaluasi dan membandingkan algoritma pembelajaran dengan membagi data menjadi k kelompok dengan ukuran yang sama. Setiap iterasi, satu atau lebih algoritma melakukan pembelajaran menggunakan $k - 1$ lipatan data untuk mempelajari model kemudian model tersebut diminta untuk membuat prediksi pada lipatan data uji.

Dalam menentukan suatu model peramalan tepat digunakan untuk meramalkan suatu kejadian adalah melalui nilai kesalahan peramalan (*error*). Ada beberapa pengukuran yang dapat digunakan untuk mencari nilai *error* salah satunya *Mean Absolute Percentage Error* (MAPE). MAPE dihitung dengan menggunakan kesalahan absolut pada tiap periode dibagi dengan nilai observasi yang nyata untuk periode itu. Kemudian, merata-rata kesalahan persentase absolut tersebut. MAPE dirumuskan sebagai persamaan,

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right|}{n} \quad (5)$$

dengan Y_t adalah nilai actual pada period ke- t , dan \hat{Y}_t adalah nilai peramalan pada period ke- t .

B. Model Autoregressive Intergrated Moving Average (ARIMA)

ARIMA adalah metode peramalan yang baik untuk meramalkan jangka pendek [12]. Notasinya dapat dituliskan menjadi ARIMA (p,d,q) dimana p merupakan notasi orde AR, d merupakan notasi untuk *differencing*, dan q merupakan notasi orde MA. Secara umum model ARIMA *non seasonal* ditulis sebagai berikut

$$\phi_p(B)(1 - B)^d Y_t = \theta_0 + \theta_q a_t \tag{6}$$

dengan $\phi_p(B)$ dan $\theta_q(B)$ merupakan derajat polinomial dari p dan q, $\phi_p(B) \neq 0$ untuk $|\phi_p(B)| < 1$ dan a_t adalah residu yang *white noise* dan berdistribusi normal.

Pemodelan ARIMA perlu diuji stasioneritasnya terlebih dahulu. Stasioneritas sendiri dibagi menjadi dua, yaitu stasioner dalam variansi dan stasioner dalam rata-rata [13]. Stasioner dalam variansi apabila mempunyai fluktuasi data yang tetap atau konstan dari waktu ke waktu jika dilihat dari plot runtun waktunya. Data yang tidak stasioner terhadap variansi maka perlu dilakukan transformasi *Box-Cox* berdasarkan nilai estimasi parameternya atau λ [14]. Stasioner dalam rata-rata berarti bahwa data memiliki fluktuasi di sekitar suatu nilai rata-rata yang konstan, tidak bergantung pada waktu dan variansi dari fluktuasi tersebut. Data yang tidak stasioner dalam rata-rata maka perlu dilakukan *differencing* [15]. Selanjutnya, beberapa model ARIMA perlu diuji signifikansi parameter berdasarkan nilai *p-value*-nya. Model dinyatakan signifikan jika *p - value* < α . Setelah ditemukan beberapa model yang signifikan maka akan diuji asumsi residu, yaitu uji indepedensi dan uji normalitas. Uji Indepedensi digunakan untuk mengetahui apakah data bersifat random atau tidak berkorelasi dan berdistribusi normal dengan rata-rata dan variansi konstan. Uji indepedensi dapat dilakukan menggunakan Uji Ljung-Box sebagai berikut

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_k = 0 \text{ (residu memenuhi syarat white noise).}$$

$$H_1 : \text{Minimal ada satu } \rho_k \neq 0 \text{ dengan } k = 1, 2, \dots, K \text{ (residu tidak memenuhi syarat white noise).}$$

Statistik Uji :

$$Q = n(n + 2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{(n-k)} \tag{7}$$

dengan n adalah jumlah observasi, Q adalah persamaan uji Ljung-Box, k adalah *lag* waktu, dan $\hat{\rho}_k^2$ adalah fungsi autokorelasi sampel dari residu *lag* ke-k. Uji normalitas adalah uji yang dilakukan untuk mengetahui apakah residu yang dihasilkan mengikuti distribusi normal atau tidak. Terdapat beberapa cara untuk uji normalitas, salah satunya adalah uji Kolmogorov-smirnov sebagai berikut.

$$H_0 : F(x) = F_0(x) \text{ (residu berdistribusi normal)}$$

$$H_1 : F(x) \neq F_0(x) \text{ (residu tidak berdistribusi normal)}$$

Statistik Uji :

$$D = \sup_x |S(x) - F_0(x)| \tag{8}$$

dengan $F_0(x)$ adalah fungsi yang dihipotesiskan yaitu berdistribusi normal, $S(x)$ adalah fungsi distribusi kumulatif dari data asal, dan D adalah persamaan Kolmogorov-Smirnov. Pemilihan model ARIMA terbaik dapat menggunakan nilai MAPE terkecil dengan persamaan,

C. Analisis Data

1. Langkah-Langkah Pada Pemodelan SVR
 - a. Melakukan *pre-processing* pada data yaitu normalisasi data dan menentukan jumlah *timesteps* sebagai input melalui *trial* dan *error* serta menentukan rentang nilai hyperparameter C, ϵ dan uji coba kernel linear, RBF, *sigmoid* dan parameter γ serta d yang digunakan.
 - b. Melakukan *tuning hyperparameter* menggunakan *grid search* dengan *k-fold cross validation* sebanyak lima untuk data training.
 - c. Meramalkan data *testing* menggunakan parameter yang optimal.
 - d. Mengevaluasi hasil peramalan menggunakan nilai MAPE.
2. Langkah-Langkah Pada Pemodelan ARIMA
 - a. Menguji stasioneritas data *training* dengan membuat plot runtun waktu dan plot ACF serta menguji stasioneritas data dalam variansi dan dalam mean.
 - b. Membuat plot ACF dan PACF data yang sudah stasioner dan berdasarkan data yang sudah stasioner dilakukan pemodelan ARIMA dengan nilai orde yang telah ditentukan.
 - c. Melakukan uji signifikansi parameter dan uji asumsi residu yang meliputi uji Kolmogorov-smirnov dan uji Ljung-Box terhadap model yang telah terbentuk.
 - d. Mencari model terbaik dari orde yang telah ditentukan dengan membandingkan nilai MAPE.
3. Membandingkan metode ARIMA dan SVR berdasarkan nilai MAPE
4. Menentukan metode peramalan yang lebih baik diantara metode ARIMA dan SVR

III. HASIL DAN PEMBAHASAN

Data awal dibagi menjadi data latih dan uji, selanjutnya data tersebut *discaling* menggunakan skala MinMax. Peramalan menggunakan SVR mempertimbangkan hubungan antara nilai pada periode y_t dan nilai dari data elemen deret waktu sebelumnya, menggunakan beberapa jeda waktu. Dataset $X_i = \{x_i, x_{i+1}, \dots, x_{i+t-1}\} \in \mathfrak{R}^t$ dan $Y_i = \{X_{i+t}\} \in \mathfrak{R}$ dimana t merupakan *embedding dimension*.

Penentuan jumlah *timesteps* yang akan digunakan dengan *trial* dan *error* yang dihasilkan dengan nilai eror terkecil. Rentang nilai *timesteps* yang digunakan yaitu 2,3,4,...,11 dengan MAPE yang ditunjukkan pada Tabel 1.

TABEL 1. MAPE *Training* dan *Testing*

Timesteps	MAPE <i>Training</i>	MAPE <i>Testing</i>
2	6,985	8,889
3	7,455	23,660
4	5,925	7,472
5	6,026	11,211
6	5,694	16,004
7	5,923	3,618
8	5,694	16,004
9	5,208	10,821
10	5,110	6,013
11	5,476	6,826

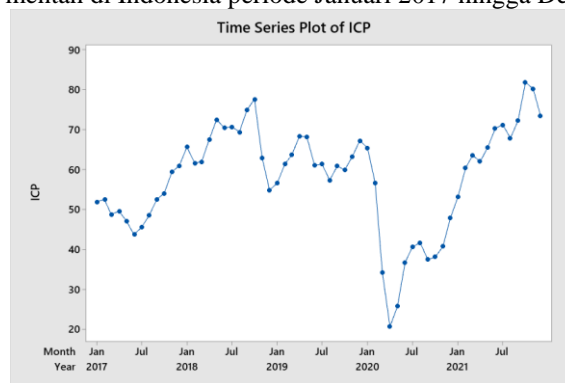
Tabel 1 menunjukkan bahwa nilai MAPE untuk data *testing* yang paling baik adalah *timesteps*=7 dengan MAPE untuk data *training* sebesar 5,923 dan untuk data *testing* sebesar 3,618 karena memiliki nilai MAPE yang paling kecil dibanding yang lain. Selanjutnya dilakukan penentuan rentang untuk parameter C, ϵ , jenis fungsi kernel dengan $t=7$ yang ditunjukkan pada Tabel 2.

TABEL 2. Rentang Nilai Parameter dan Fungsi Kernel

Parameter	Rentang Nilai
C	$10^{-4}, 10^{-3}, 10^{-2}, 10^{-1}, 10, 10^2, 10^3$
ε	$10^{-4}, 10^{-3}, 10^{-2}, 10^{-1}, 10, 10^2, 10^3$
γ	$10^{-4}, 10^{-3}, 10^{-2}, 10^{-1}, 10, 10^2, 10^3$
d	2,3,4,5

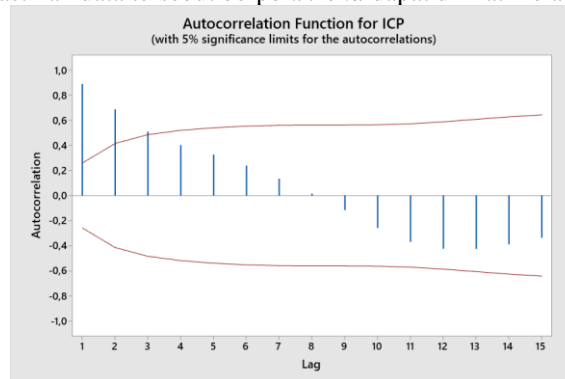
Penentuan parameter dan kernel terbaik dilakukan dengan *tuning SVR* menggunakan *grid search* dan *k-fold cross validation*, pada penelitian ini digunakan $k = 5$ dalam melakukan *training* pada data *training*. Pada Tabel 2 dapat diketahui bahwa hasil analisis dalam meramalkan harga minyak mentah di Indonesia dengan menggunakan metode SVR didapatkan parameter yang terbaik yaitu parameter C sebesar 1.000, epsilon sebesar 0,01, dan gamma sebesar 0,0001 serta fungsi kernel Linear.

Selanjutnya dilakukan analisis ARIMA dengan langkah awal memperhatikan lot runtun waktu untuk data *training* harga minyak mentah di Indonesia periode Januari 2017 hingga Desember 2021.




GAMBAR 1. Plot Runtun Waktu Data *Training*

Gambar 1 menunjukkan bahwa data *training* tersebut berpola *trend*, yang artinya data belum stasioner, Uji lebih lanjut untuk memastikan data tersebut berpola *trend* dapat dilihat melalui plot ACF.



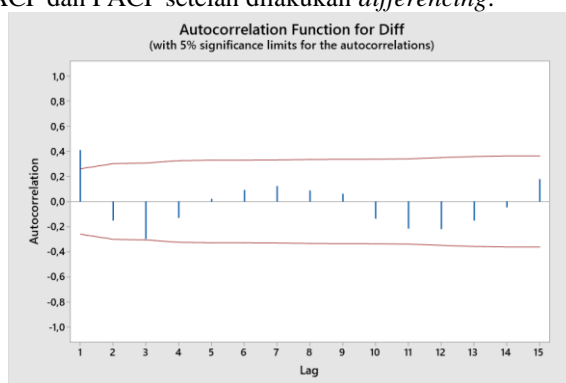
GAMBAR 2. Plot ACF Data *Training*

Gambar 2 menunjukkan bahwa *lag*-nya turun secara perlahan yang berarti data berpola *trend*, sehingga dapat dikatakan bahwa data tidak stasioner dan perlu dilakukan *differencing* yang plot runtun waktunya.




GAMBAR 3. Plot Runtun Waktu Setelah *Differencing*

Gambar 3 menunjukkan plot runtun waktu data *training* yang sudah dilakukan *differencing lag 1* dan diketahui bahwa data sudah stasioner karena pergerakannya cenderung konstan, untuk itu dilakukan pengamatan terhadap plot ACF dan PACF setelah dilakukan *differencing*.



GAMBAR 4. Plot ACF Setelah *Differencing*

Gambar 4 menunjukkan plot ACF data setelah *differencing lag 1*, dimana *lag* ke-1 keluar dari batas pita konfidensi yang mengindikasikan terdapat *lag* yang tidak signifikan dan data bersifat stasioner. Berdasarkan gambar 4 juga diketahui bahwa orde q yang mungkin yaitu 0 dan 1 karena terdapat *lag* yang keluar dari batas pita konfidensi, yakni pada *lag* ke-1. Selanjutnya dibuat plot PACF seperti pada Gambar 5,



GAMBAR 5. Plot PACF Setelah *Differencing*

Gambar 5 merupakan plot PACF data setelah dilakukan *differencing lag 1*, dimana *lag* ke-1 dan ke-2 keluar dari batas pita konfidensi yang mengindikasikan terdapat *lag* yang tidak signifikan dan data bersifat stasioner. Berdasarkan gambar 5 juga diketahui bahwa orde p yang mungkin yaitu 0,1, dan 2 karena terdapat *lag* yang keluar dari batas pita konfidensi, yakni pada *lag* ke-1 dan ke-2. Berdasarkan orde p , d , dan q diperoleh kemungkinan model ARIMA sementara adalah ARIMA (2,1,0), ARIMA (2,1,1), ARIMA

(1,1,0), ARIMA (1,1,1), dan ARIMA (0,1,1). Kelima kemungkinan model ARIMA tersebut diuji apakah semua parameternya signifikan.

TABEL 3. Uji Signifikansi Parameter

Model ARIMA	Uji Signifikansi Parameter
ARIMA (2,1,0)	Semua parameter signifikan
ARIMA (2,1,1)	Parameter MA (1) tidak signifikan
ARIMA (1,1,0)	Semua parameter signifikan
ARIMA (1,1,1)	Parameter AR (1) tidak signifikan
ARIMA (0,1,1)	Semua parameter signifikan

Tabel 3 menunjukkan bahwa diantara 5 kemungkinan model ARIMA, terdapat 3 parameter yang signifikan yaitu ARIMA (2,1,0), ARIMA (1,1,0), dan ARIMA (0,1,1). Penentuan model ARIMA terbaik dapat dilakukan dengan menguji asumsi residu terlebih dahulu yaitu uji normalitas untuk mengetahui apakah residu data mengikuti distribusi normal atau tidak dan uji independensi untuk mengetahui apakah data bersifat random atau tidak. Uji normalitas yang digunakan adalah uji Kolmogorov-Smirnov yang ditampilkan pada Tabel 4.

TABEL 4. Uji Normalitas

Model ARIMA	<i>p-value</i>	Keterangan
ARIMA (2,1,0)	>0,150	Memenuhi
ARIMA (1,1,0)	0,093	Memenuhi
ARIMA (0,1,1)	>0,150	Memenuhi

Tabel 4 menunjukkan bahwa untuk ketiga model ARIMA tersebut memenuhi uji normalitas karena semua parameternya memiliki nilai *p-value* lebih dari $\alpha = 0,05$ yang artinya semua model signifikan dan berdistribusi normal. Selanjutnya akan dilakukan uji independensi menggunakan uji Ljung-Box yang ditampilkan pada Tabel 5.

TABEL 5. Uji Independensi

Model ARIMA	<i>p-value lag ke-24</i>	Keterangan
ARIMA (2,1,0)	0,243	Memenuhi
ARIMA (1,1,0)	0,002	Tidak Memenuhi
ARIMA (0,1,1)	0,044	Tidak Memenuhi

Tabel 5 menunjukkan bahwa untuk model ARIMA (2,1,0) memiliki nilai *p-value* pada *lag ke-24* yang lebih dari $\alpha = 0,05$, artinya model tersebut memenuhi uji independensi yang berarti tidak terdapat autokorelasi antar residu model dan artinya sudah memenuhi syarat *white noise*. Selanjutnya dilakukan pengecekan nilai MAPE untuk data *training* dan data *testing* untuk mengetahui apakah model ARIMA tersebut dapat meramalkan dengan baik atau tidak.

TABEL 6. MAPE Data *Training* dan *Testing*

Model ARIMA	MAPE <i>Training</i> (%)	MAPE <i>Testing</i> (%)
ARIMA (2,1,0)	6,880%	9,223%

Tabel 6 menunjukkan bahwa model ARIMA (2,1,0) memiliki nilai MAPE yang kecil, baik pada data *training* dan data *testing* karena nilainya kurang dari 10%. Dapat dikatakan bahwa model ARIMA (2,1,0) merupakan model ARIMA terbaik dengan persamaan sebagai berikut,

$$y_t = 1,591y_{t-1} - 0,991y_{t-2} + 0,4y_{t-3} + \varepsilon_t \quad (9)$$

Pemilihan model yang lebih baik dapat ditentukan melalui nilai MAPE terkecil pada data *training* dan data *testing*-nya. Perbandingan nilai MAPE untuk data *training* dan data *testing* untuk metode SVR dan ARIMA ditampilkan pada Tabel 7,

TABEL 7. Perbandingan MAPE Metode SVR dan ARIMA

	SVR	ARIMA
Data <i>Training</i>	5,923%	6,880%
Data <i>Testing</i>	3,618%	9,323%

Tabel 7 menunjukkan bahwa metode SVR lebih baik dibandingkan metode ARIMA karena memiliki nilai akurasi hasil peramalan yang lebih kecil baik pada data *training* dan *testing* nya yang berarti akurasi dalam peramalannya lebih tinggi dan akan menghasilkan peramalan yang lebih baik karena lebih akurat.

IV. SIMPULAN DAN SARAN

Model terbaik untuk meramalkan data harga minyak mentah di Indonesia adalah dengan menggunakan metode SVR dibentuk dengan nilai $t = 7$ dan parameter terbaik C sebesar 1,000, epsilon sebesar 0,01, dan gamma sebesar 0,0001 serta fungsi kernel Linear. Parameter dan fungsi kernel tersebut didapatkan dengan bantuan *grid search* menggunakan *k-fold cross validation* sebesar 5. Metode SVR menghasilkan nilai MAPE untuk data *training* sebesar 5,923% dan data *testing* sebesar 3,618%. Berdasarkan hasil nilai MAPE, metode SVR lebih baik dibandingkan metode ARIMA yang merupakan metode dasar yang biasa digunakan dalam teknik peramalan. Hasil tersebut juga berarti bahwa peramalan tersebut menghasilkan peramalan yang baik karena nilai *error* dalam peramalan kecil yaitu hanya 3,618% untuk meramalkan data *testing*, maka hal ini juga berarti bahwa akurasi dalam meramalkan data menggunakan SVR juga tinggi. Saran untuk penelitian selanjutnya diharapkan dapat menggunakan parameter yang lebih bervariasi dan rentang parameter yang lebih lebar untuk digunakan dalam metode SVR.

DAFTAR PUSTAKA

- [1] Nizar, M. A. (2012). Dampak Fluktuasi Harga Minyak Dunia Terhadap Perekonomian Indonesia. *Buletin Ilmiah Litbang Perdagangan*, 189-210.
- [2] Purnama, D. I., & Hendarsin, O. P. (2020). Peramalan Jumlah Penumpang Berangkat Melalui Transportasi Udara di Sulawesi Tengah Menggunakan Support Vector Regression (SVR). *Jambura Journal Of Mathematics*, 49-59.
- [3] Putra, A. L., & Kurniawati, A. (2021). Analisis Prediksi Harga Saham PT. Astra International Tbk Menggunakan Metode Autoregressive Integrated Moving Average (ARIMA) dan Support Vector Regression (SVR). *Jurnal Ilmiah Komputasi*, 417-423.
- [4] Wibowo, T. W. L. (2015). Peramalan Harga Minyak Mentah di Indonesia dengan Menggunakan Metode Fuzzy Time Series. Laporan. Institut Teknologi Sepuluh Nopember, Surabaya.
- [5] Putri, F. A.Y (2018). Studi Komparasi Peramalan Harga Minyak Mentah Menggunakan Metode Generalized Regression Neural Network dan Feed Forward Neural Network. Tugas Akhir. Universitas Islam Indonesia, Yogyakarta.
- [6] Putri, R. A., Winahju, W. S., dan Mashuri, M. (2020). Penerapan Metode Ridge Regression dan Support Vector Regression (SVR) untuk Prediksi Indeks Batubara di PT XYZ. *Jurnal Sains dan Seni ITS*, 64-71.
- [7] Katadata Media Network. 2022. Diakses pada Maret 2022 dari <https://databoks.katadata.co.id/datapublish/2022/04/08/tertinggi-sejak-2013-icp-maret-2022-capai-us1135-per-barel>.
- [8] Sihombing, C. V., Martha, S., dan Huda, M. (2022). Analisis Metode Hybrid ARIMA-SVR Pada Indeks Harga Saham Gabungan. *Buletin Ilmiah Math. Stat. dan Terapannya (Bimaster)*, 413-422.
- [9] Cortez, P., & Donate, J. (2012). Evolutionary Support Vector Machines for Time Series Forecasting. *ICANN Part II*, LNCS 7553: 523-530.
- [10] Sriyana, Martha, S., & Sulistianingsih. (2019). Prediksi Nilai Tukar Dolar Amerika Serikat Terhadap Rupiah dengan Metode Support Vector Regression (SVR). *Buletin Ilmiah Math, Stat, dan Terapannya (Bimaster)*, 1-10.
- [11] Lin, K., Lin, Q., Zhou, C., dan Yao, J. (2007). Time Series Prediction Based on Linear Regression and SVR. *Third International Conference on Natural Computation (ICNC)*.
- [12] Elvani, S. P., Utary, A. R., dan Yudaruddin, R. (2016). Peramalan Jumlah Produksi Tanaman Kelapa Sawit dengan Menggunakan Metode ARIMA (Autoregressive Integrated Moving Average). *Jurnal Manajemen*, 95-112.
- [13] Montgomery, D. C., Jennings, C. L., dan Kulachi, M. (2008). *Introduction to Time Series Analysis and Forecasting*. Wiley Series in Probability and Statistics, New Jersey.
- [14] Wei, W. W. (2006). *Time Series: Analysis Univariate and Multivariate Methods Second Edition*. Pearson Education Inc., New York.
- [15] Yunita, T. (2019). Peramalan Jumlah Penggunaan Kuota Internet Menggunakan Metode Autoregressive Intergrated Moving Average (ARIMA). *Journal of Mathematics: Theory and Applications*, 16-22.