

Prediksi Harga Ekspor Non Migas di Indonesia Berdasarkan Metode Estimator Deret *Fourier* dan *Support Vector Regression*

Chaerobby Fakhri Fauzaan Purwoko¹, Sediono^{1*}, Toha Saifudin¹, dan M. Fariz Fadillah Mardianto¹

¹Statistics Study Program: Department of Mathematics, Universitas Airlangga, Surabaya, Indonesia

*Corresponding author: sediono@fsaintek.unair.ac.id

Received: 9 January 2023

Revised: 16 January 2023

Accepted: 23 January 2023

ABSTRAK – Pertumbuhan ekonomi merupakan salah satu indikator dalam *Sustainable Development Goals* (SDGs) pada peningkatan kegiatan ekonomi. Salah satu kegiatan yang menopang berjalannya perekonomian adalah perdagangan antar negara, seperti ekspor. Di Indonesia, ekspor non migas memegang peranan penting dalam total ekspor beberapa tahun terakhir, diantaranya ekspor batu bara menjadi ekspor utama. Oleh karena itu, prediksi harga ekspor non migas Indonesia menjadi sangat penting sebagai bahan evaluasi kebijakan untuk mendorong pertumbuhan ekonomi. Hal tersebut menjadi fokus utama dari penelitian ini. Dalam studi ini, prakiraan harga ekspor non migas dibuat dengan mempertimbangkan isu-isu terkini seperti pandemi COVID-19 dan perang Rusia-Ukraina. Keakuratan model yang diperoleh dari estimator deret *Fourier* dan *Support Vector Regression* (SVR) diselidiki dengan membandingkan nilai *Mean Absolute Percentage Error* (MAPE) untuk memprediksi harga ekspor non migas Indonesia. Hasil penelitian menunjukkan bahwa masalah pandemi COVID-19 dan perang Rusia-Ukraina berdampak signifikan terhadap harga ekspor non migas. Model SVR dengan kernel *Radial Basis Function* (RBF) menunjukkan akurasi yang lebih baik daripada model estimator deret *Fourier* fungsi cos sin, dengan masing-masing nilai MAPE sebesar 9,29 dan 15,26% untuk setiap data uji. Oleh karena itu, kajian ini diharapkan dapat menjadi dasar untuk merumuskan kebijakan terkait pengaturan proses ekspor non migas untuk mendukung pertumbuhan ekonomi di Indonesia.

Kata kunci– ekspor, non migas, estimator deret *Fourier*, *support vector regression*, *radial basis function*.

ABSTRACT – Economic growth is one of the indicators in the Sustainable Development Goals (SDGs) on increasing economic activity. One of the activities that supports the running of the economy is trade between countries, such as exports. In Indonesia, non-oil and gas exports have played an important role in total exports in recent years, including coal exports being the main export. Therefore, price predictions for Indonesia's non-oil and gas exports are very important as material for evaluating policies to encourage economic growth. This is the main focus of this research. In this study, non-oil and gas export price forecasts are made taking into account current issues such as the COVID-19 pandemic and the Russia-Ukraine war. The accuracy of the model obtained from the Fourier series estimator and Support Vector Regression (SVR) is investigated by comparing the Mean Absolute Percentage Error (MAPE) value to predict Indonesia's non-oil and gas export prices. The results of the study show that the COVID-19 pandemic and the Russia-Ukraine war have had a significant impact on non-oil and gas export prices. The SVR model with the Radial Basis Function (RBF) kernel shows better accuracy than the Fourier series estimator model of the cos sin function, with MAPE values of 9.29 and 15.26% for each test data, respectively. Therefore, this study is expected to be the basis for formulating policies related to regulating non-oil and gas export processes to support economic growth in Indonesia.

Keywords– export, non oil and gas, Fourier Series Estimator, support vector regression, radial basis function.

I. PENDAHULUAN

Indonesia masih menghadapi tantangan untuk mewujudkan tujuan *Sustainable Development Goals* (SDGs). Salah satunya, upaya meningkatkan pekerjaan layak dan pertumbuhan ekonomi. Secara umum, pertumbuhan ekonomi dapat diukur dengan Produk Domestik Bruto (PDB) suatu negara. Dalam hal ini, PDB yang tinggi menunjukkan bahwa perekonomian negara juga dalam kondisi yang baik. Hal tersebut memberikan informasi tentang tingkat perkembangan ekonomi dengan membandingkan nilai PDB per kapita di beberapa negara. Semua negara tentunya menginginkan pertumbuhan ekonomi yang tinggi guna meningkatkan taraf hidup dan kesejahteraan rakyatnya. Dalam pertumbuhan ekonomi, peningkatan pendapatan per kapita tidak bergantung pada perubahan struktur ekonomi. [1].

Pertumbuhan ekonomi tergantung pada beberapa faktor, yakni sumber daya manusia, alam, daya modal, dan teknologi [2]. Pertumbuhan ekonomi merupakan ukuran keberhasilan pembangunan ekonomi daerah. Menurut teori keuntungan, yang dijelaskan oleh ekonom Adam Smith, suatu negara akan makmur jika dapat memperluas produksi melalui perdagangan. Ketika produksi meningkat, pertukaran internasional atau transnasional, seperti impor dan ekspor, dapat terjadi [3]. Pada suatu negara, mengekspor barang dapat membuat negara makmur dan mengimpor barang dan jasa dapat memenuhi kebutuhan yang tidak dapat diciptakan oleh negara tersebut. Dalam aktivitas perdagangan luar negeri, ekspor dibagi menjadi minyak dan gas (migas) dan non minyak dan gas (non migas). Produk ekstraksi nonmigas meliputi konsentrat batubara, timah, bauksit, bijih nikel, emas, perak, dan tembaga. Ekspor batubara tetap menjadi produk ekspor utama Indonesia, dan ekspor nonmigas saat ini sedang meningkat [4]. Hal ini dikarenakan ekspor non migas luar negeri lebih diminati daripada ekspor migas, dimana Indonesia telah memasuki era perdagangan

bebas di ASEAN dan proses menuju perdagangan secara global sesuai kesepakatan *World Trade Organization* (WTO). Porsi ekspor non migas terhadap total ekspor Indonesia semakin meningkat, sehingga ketergantungan terhadap ekspor migas berangsur-angsur berkurang [5].

Neraca perdagangan September 2022 merupakan hasil surplus neraca perdagangan non migas dalam kondisi defisit, dibandingkan neraca perdagangan migas yang sedikit meningkat. Pada September 2022, laba perdagangan (tidak termasuk minyak dan gas) adalah 7,09 miliar dolar AS, turun dari 7,73 miliar dolar AS pada bulan sebelumnya. Perkembangan ini disebabkan oleh kinerja ekspor non migas September sebesar 23,48 miliar dolar AS, turun dari 26,18 miliar dolar AS pada bulan sebelumnya [6]. Kenaikan harga ekspor yang signifikan di luar non migas merupakan dampak dari pasca pandemi *Coronavirus Disease-19* (COVID-19), serta perang antara Rusia-Ukraina. [7].

Dalam hal ini, proses prediksi harga ekspor non migas dapat dilakukan dengan membandingkan metode *time series* klasik dan modern. Pada analisis *time series* klasik, metode prediksi yang dapat digunakan adalah estimator deret *Fourier* yang termasuk dalam metode nonparameterik [8]. Metode estimator deret *Fourier* dipilih karena memiliki fleksibilitas dalam memodelkan pola data yang bentuk osilasinya tidak diketahui [8]. Pada analisis *time series* modern, metode prediksi yang digunakan adalah *Support Vector Regression* (SVR). Metode SVR dipilih karena termasuk metode nonparameterik yang berbasis *machine learning* tanpa memerlukan asumsi sehingga dapat digunakan untuk mengatasi batasan pada analisis regresi dengan data deret waktu [9]. Metode SVR merupakan model prediktif yang dapat digunakan untuk memprediksi data *time series* nonlinier [10]. SVR sendiri merupakan bagian dari metode pembelajaran mesin yang dikenal dengan *Support Vector Machines* (SVM). Model SVR dapat menghindari masalah minimum lokal yang disebabkan oleh optimasi nonlinier dan masalah hilangnya fungsi yang tidak sensitif terhadap ϵ , yang merupakan kesalahan standar yang digunakan oleh SVR untuk mengatasi *outlier* pada data *training*. *Support Vector* (SV) adalah teknik statistik yang menggunakan konsep seperti jaringan saraf dan *Radial Basis Function* (RBF) sebagai kasus jaringan khusus. Algoritma SV pada kasus RBF secara otomatis menentukan pusat, bobot, dan *threshold* yang diharapkan pada kesalahan pengujian [11].

Sebelumnya telah dilakukan penelitian mengenai prediksi cadangan klaim asuransi pendidikan dengan pendekatan regresi nonparameterik estimator deret *Fourier* yang memberikan hasil akurasi prediksi dengan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 15,42 % pada data *testing* [12]. Penelitian lain dilakukan dengan menggunakan SVR tentang peramalan jumlah penumpang pesawat di Sulawesi Tengah yang memberikan hasil akurasi prediksi yang baik dengan nilai *Mean Absolute Percentage Error* (MAPE) 7,28% pada data *training* dan 18,67% pada data *testing* [13].

Berdasarkan uraian tersebut, kebaruan dari penelitian ini adalah membandingkan fungsi kernel pada SVR terhadap harga ekspor non migas di Indonesia. Metode SVR dipilih dalam proses prediksi harga ekspor non migas di Indonesia dikarenakan Pemilihan metode terbaik untuk memprediksi harga ekspor non migas di Indonesia dengan melihat nilai *Root Mean Squared Error* (RMSE) dan MAPE sebagai salah satu ukuran akurasi yang umumnya digunakan dalam analisis prediksi. Urgensi penelitian ini adalah memberikan pertimbangan bagi pemerintah Indonesia dalam mengatur strategi penjualan ekspor non migas sehingga dapat mengoptimalkan produk komoditas yang ada di Indonesia.

II. TINJAUAN PUSTAKA

A. Ekspor di Indonesia

Dalam Peraturan Pemerintah Nomor 10 Tahun 2021, ekspor merupakan kegiatan lintas batas di bidang perdagangan dan meningkatkan permintaan dalam negeri yang akan berdampak pada tumbuhnya pabrik-pabrik baru dengan struktur politik dan pranata sosial yang tangguh [14]. Menurut data Kementerian Keuangan Republik Indonesia tahun 2022, ekspor Indonesia pada Oktober 2022 tetap berjalan dengan baik, dengan ekspor sebesar 24,81 miliar dolar AS, meningkat 12,3% *year on year* (yoy). Pertumbuhan ekspor didorong oleh komoditas berkualitas tinggi seperti produk minyak sawit, bahan bakar mineral, dan baja. Secara bulanan, ekspor meningkat 0,13% dan ekspor kumulatif dari Januari hingga Oktober 2022 sebesar 244,14 miliar dolar AS, meningkat 30,97% dibandingkan periode yang sama tahun 2021 [15].

B. Non Minyak dan Gas (Non Migas)

Ekspor non migas mencakup berbagai komoditas, yaitu pertanian, perikanan, manufaktur, produk kayu olahan, logam dasar, batu bara, dan lain sebagainya. Saat ini ekspor non migas masih menjadi komoditas utama, khususnya sektor batu bara sebagai sumber energi utama. Selain itu, kelapa sawit juga merupakan komoditas utama yang dimiliki oleh Indonesia. Pada September 2022, ekspor non migas Indonesia mencapai 23,48 miliar dolar AS, turun 10,31% dari Agustus 2022 dan meningkat 19,26% dari September 2021. Secara kumulatif, total nilai ekspor Indonesia dari Januari hingga Oktober akan mencapai 219,35 miliar dolar AS dan pada September 2022, meningkat 33,49% dibanding periode yang sama tahun 2021. Ekspor non migas terbesar pada September 2022 adalah China sebesar 6,16 miliar dolar AS, disusul Amerika Serikat sebesar 2,11 miliar dolar AS, dan Jepang sebesar 2,10 miliar dolar AS, tiga negara penyumbang terbesar 44,17% [16].

C. Uji Nonlinieritas

Uji nonlinieritas perlu dilakukan untuk mengetahui pola data linier atau nonlinier. Terdapat beberapa uji nonlinieritas yang sudah dikembangkan, di antaranya adalah uji *Terasvirta*, uji *White Test*, dan uji *Ramsey-Reset*. Uji

Terasvirta dinyatakan sebagai uji nonlinieritas yang memiliki performa terbaik dalam mendeteksi nonlinieritas dalam data [17]. Uji *Terasvirta* merupakan salah satu jenis uji dalam mengetahui nonlinieritas data yang merupakan pengembangan dari model *neural network* dan tergolong pengujian *Lagrange Multiplier* (LM) yang dikembangkan dengan ekspansi *Taylor* [18]. Model *neural network* yang bersifat nonlinier dapat dirumuskan sebagai berikut:

$$Z_t = \varphi(\gamma'w_t) + \beta'w_t + \varepsilon_t \tag{1}$$

dengan $\beta'w$ merupakan komponen linier, $\varphi(\gamma'w)$ merupakan komponen nonlinier, γ' merupakan pembobot dalam model *neural network* dari *input layer* ke *hidden layer* untuk komponen nonlinier, β' merupakan pembobot dalam model *neural network* dari *input layer* ke *output layer* untuk komponen linier, dan φ merupakan fungsi aktivasi *sigmoid*. Lebih lanjut, persamaan (1) dapat dinyatakan sebagai berikut:

$$Z_t = \beta'w_t + \sum_{j=1}^q \theta_{0j} \left\{ \varphi(\gamma'w_t) - \frac{1}{2} \right\} + \varepsilon_t \tag{2}$$

dengan θ_{0j} merupakan pembobot dalam model *neural network* dari *hidden layer* ke *output layer* untuk komponen nonlinier. Apabila komponen nonlinier sebanyak 0, maka data dapat dikatakan mengandung pola linier. Hipotesis yang diujikan dalam uji *Terasvirta* adalah sebagai berikut:

- H_0 : $\theta_{01} = \theta_{02} = \dots = \theta_{0q}$ (Data mengandung pola linier)
- H_1 : Setidaknya terdapat satu $\theta_{0q} \neq 0$ (Data mengandung pola nonlinier)

Berdasarkan ekspansi deret *Taylor* untuk memperoleh nilai parameter *neural network* dalam uji *Terasvirta*, maka dapat dibentuk model sebagai berikut:

$$Z_t = \beta'w_t + \sum_{i=1}^p \sum_{j=1}^p \delta_{ij} Z_{t-i} Z_{t-j} + \sum_{i=1}^p \sum_{j=1}^p \sum_{k=1}^p \delta_{ijk} Z_{t-i} Z_{t-j} Z_{t-k} + \varepsilon_t \tag{3}$$

Jika komponen kuadrat dan kubik bernilai 0, maka H_0 gagal ditolak sehingga diperoleh model linier. Uji *Terasvirta* dapat dilakukan dengan menggunakan distribusi *chi-square* dan F. Namun, [19] Uji *Terasvirta* dapat diuji dengan menggunakan distribusi chi-kuadrat dan distribusi F, mirip dengan uji *White*. Prosedur dalam uji *Terasvirta* dengan distribusi chi-kuadrat adalah sebagai berikut [20]:

1. Meregresikan Z_t dengan $1, X_1, \dots, X_p$, dilanjutkan dengan menghitung nilai residual $\hat{\varepsilon}_t = Z_t - \hat{Z}_t$, dan menghitung jumlah kuadrat dari $\hat{\varepsilon}_t$ (*Sum Square of Residuals*) yang dinyatakan dengan $SSR_0 = \sum \hat{\varepsilon}_t^2$.
2. Meregresikan $\hat{\varepsilon}_t$ dengan $1, X_1, \dots, X_p$ dan prediktor m tambahan yang merupakan nilai komponen kuadrat dan kubik dari ekspansi *Taylor*, kemudian menghitung koefisien determinasi (R^2) dari regresi. Prediktor m adalah komponen kuadrat dan kubik dari ekspansi deret *Taylor*.
3. Menghitung

$$X^2 = nR^2 \tag{4}$$

dengan n merupakan banyak observasi. Apabila $nR^2 > X_{(m)}^2$ maka H_0 ditolak.

D. Estimator Deret Fourier

Estimator deret *Fourier* didasarkan pada dua parameter, yaitu parameter osilasi sebagai representasi *bandwidth* dan parameter *Fourier*. Salah satu keunggulan pendekatan regresi nonparametrik dengan estimator deret *Fourier* di antaranya dapat mengatasi data dengan pola periodik, dalam hal ini diwakili oleh fungsi trigonometri [21]. Oleh karena itu, deret *Fourier* didefinisikan sebagai fungsi polinomial trigonometri yang mempunyai tingkat fleksibilitas tinggi karena berupa kurva yang menunjukkan fungsi sinus dan cosinus [22]. Deret *Fourier* secara lengkap terdiri dari fungsi cosinus dan sinus. Diberikan data berpasangan (x_i, y_i) maka persamaan regresi nonparametrik dengan estimator deret *Fourier* ditunjukkan sebagai berikut.

$$y_i = \frac{\alpha_0}{2} + \omega x_i + \sum_{k=1}^k (\alpha_k \cos kx_i + \beta_k \sin kx_i) + \varepsilon_i; \varepsilon_i \sim N(0, \sigma^2) \tag{5}$$

Diberikan data berpasangan $(x_{i1}, x_{i2}, \dots, x_{ip}, y_i)$ maka persamaan deret regresi nonparametrik dengan estimator deret *Fourier* multiprediktor ditunjukkan sebagai berikut.

$$y_i = \sum_{j=1}^p \left(\frac{a_{0j}}{2} + \omega_j x_{ij} + \sum_{k=1}^k \alpha_{kj} \cos kx_{ij} + \beta_{kj} \sin kx_{ij} \right) + \varepsilon_i; \varepsilon_i \sim N(0, \sigma^2) \tag{6}$$

Dalam bentuk persamaan matriks, model regresi nonparametrik dengan estimator deret *Fourier* untuk kasus satu prediktor dan multiprediktor dapat dinyatakan sebagai berikut.

$$y = X\beta + \varepsilon; \varepsilon \sim N(0, \sigma^2) \tag{7}$$

Dari persamaan (7), untuk kasus multiprediktor dengan p variabel prediktor dengan n pengamatan, dapat dijabarkan sebagai berikut.

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} = \begin{bmatrix} 1 & x_{11} & \cos x_{11} & \dots & \cos kx_{1p} & \sin x_{11} & \dots & \sin kx_{1p} \\ 1 & x_{21} & \cos x_{21} & \dots & \cos kx_{2p} & \sin x_{21} & \dots & \sin kx_{2p} \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & \cos x_{n1} & \dots & \cos kx_{np} & \sin x_{n1} & \dots & \sin kx_{np} \end{bmatrix} \begin{bmatrix} \alpha_0/2 \\ \omega_1 \\ \alpha_{11} \\ \vdots \\ \alpha_{k1} \\ \beta_{11} \\ \vdots \\ \beta_{kp} \end{bmatrix} \tag{8}$$

Berdasarkan metode *Ordinary Least Square* (OLS), diperoleh estimator untuk vektor parameter β pada Persamaan (7) adalah sebagai berikut.

$$\hat{\beta} = (X^T X)^{-1} X^T y \tag{9}$$

sehingga estimator untuk kurva regresi pada persamaan (3) adalah

$$\hat{y} = X\hat{\beta} \tag{10}$$

Dengan demikian, dalam bentuk persamaan skalar, diperoleh

$$\hat{y}_i = \sum_{j=1}^p \left(\frac{\hat{\alpha}_{0j}}{2} + \hat{\omega}_j x_{ij} + \sum_{k=1}^k \hat{\alpha}_{kj} \cos kx_{ij} + \hat{\beta}_{kj} \sin kx_{ij} \right) \tag{11}$$

E. Pemilihan Parameter Osilasi

Estimator regresi nonparametrik berdasarkan estimator deret *Fourier* diperoleh dengan menyelesaikan optimasi OLS. Untuk mendapatkan parameter osilasi optimal digunakan metode *Generalized Cross Validation* (GCV). Jika GCV dibandingkan dengan metode lain, misalnya *Cross Validation* (CV) dan metode *Unbiased Risk* (UBR), maka metode ini memiliki sifat optimal asimtotik [23]. Untuk memperoleh parameter osilasi optimal dapat dilihat dari nilai GCV yang paling minimum. Metode GCV secara umum didefinisikan sebagai berikut [8].

$$GCV(K) = \frac{MSE(K)}{(n^{-1} \text{trace}[I - A(K)])^2} \tag{12}$$

dengan

$$MSE(K) = n^{-1} y^T (I - A(K))^T (I - A(K)) y \tag{13}$$

dengan

$$A(K) = X(X^T X)^{-1} X^T \tag{14}$$

F. Support Vector Regression (SVR)

Metode SVR merupakan hasil modifikasi SVM dalam mengatasi masalah regresi, dimana keluaran dari SVR direpresentasikan sebagai bilangan riil dan kontinu [24]. Sama halnya dengan SVM, metode SVR dapat digunakan untuk menentukan *hyperplane* terbaik sebagai fungsi regresi, dan meminimalkan kemungkinan kesalahan dengan memaksimalkan batas. Konsep metode SVR adalah dengan memiliki data training $\{(x_1, y_1), (x_2, y_2), \dots, (x_i, y_i)\}$ dimana $x_i \in \mathbb{R}^d$ adalah masukkan *vector* ke- i dengan $i = 1, 2, \dots, n$, d adalah dimensi dan y_i adalah nilai tujuan atau target. Persamaan umum dari model SVR dapat ditulis sebagai berikut [25]:

$$f(x) = w^T \varphi(x) + b \tag{15}$$

dengan,

- w : n vektor pembobotan dimensi
- $\varphi(x)$: fungsi yang memetakan x dalam ruang n dimensi
- b : bias

Untuk memperoleh generalisasi yang baik pada fungsi regresi $f(x)$, langkah selanjutnya adalah meminimumkan kriteria w terkecil. Berdasarkan hal tersebut, solusi untuk masalah optimisasi adalah sebagai berikut:

$$\min_w \frac{1}{2} \|w\|^2 \text{ dengan } \begin{cases} y_i - w^T x_i - b \leq \varepsilon \\ w^T x_i + b - y_i \leq \varepsilon \end{cases} \tag{16}$$

Pada fungsi regresi f , diasumsikan semua titik dalam rentang $f(\mathbf{x}) \pm \varepsilon$ dikatakan layak, dan titik-titik di luar rentang tersebut dikatakan tidak layak, sehingga variabel *slack* ξ dan ξ^* ditambahkan ke mengatasi keterbatasan yang tidak sesuai dari masalah optimisasi. Selanjutnya, persamaan (16) dapat ditransformasikan dalam bentuk sebagai berikut:

$$\min_w \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \tag{17}$$

Masalah optimisasi memiliki fungsi kendala berikut:

$$\begin{aligned} y_i - \mathbf{w}^T \mathbf{x}_i - b &\leq \varepsilon + \xi_i \\ \mathbf{w}^T \mathbf{x}_i + b - y_i &\leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* &\geq 0 \end{aligned} \tag{18}$$

Dengan memecahkan masalah optimasi, diperoleh bahwa:

$$\mathbf{w} = \sum_{i=1}^n (\alpha_i^* - \alpha_i) \varphi(\mathbf{x}_i) \tag{19}$$

Data yang termuat dalam vektor \mathbf{x} dari ruang inputan dapat dipetakan ke ruang fitur yang berdimensi lebih tinggi dengan fungsi φ yang didekati dengan fungsi kernel sehingga fungsi SVR dapat didefinisikan sebagai berikut:

$$f(\mathbf{x}) = \sum_{i=1}^n (\alpha_i^* - \alpha_i) K(\mathbf{x}_i, \mathbf{x}) + b \tag{20}$$

G. Fungsi Kernel

Untuk mengatasi masalah nonlinier dimensi tinggi, yang perlu dilakukan adalah mengganti hasil kali dalam (\mathbf{x}_i dan \mathbf{x}) dengan fungsi kernel yang dipilih [26]. Pada SVR, fungsi kernel yang digunakan disajikan pada Tabel 1.

Tabel 1 Fungsi Kernel

No	Tipe Kernel	Formula
1.	Linier	$K(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i^T - \mathbf{x}_j)$
2.	Polynomial	$K(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i \cdot \mathbf{x}_j + 1)^p$
3.	Radial Basis Function	$K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma(\mathbf{x}_i - \mathbf{x}_j)^2)$
4.	Sigmoid	$K(\mathbf{x}_i, \mathbf{x}_j) = \tanh(g\mathbf{x}_i^T \mathbf{x} + 1)$

Fungsi kernel yang digunakan pada penelitian ini adalah kernel RBF yang didefinisikan sebagai berikut:

$$K(\mathbf{x}_i, \mathbf{x}) = \exp(-\gamma(\mathbf{x}_i - \mathbf{x}_j)^2) \tag{21}$$

dengan,

$$\gamma = \frac{1}{2\sigma^2} \tag{22}$$

Oleh karena itu, penggunaan SVR dengan tipe kernel RBF memerlukan penentuan 3 parameter yaitu *cost* (C), *gamma* (γ), dan *epsilon* (ε) [27]. Dalam mencari parameter nilai optimal, salah satu metode yang dapat digunakan adalah metode *grid search*.

H. Grid Search Optimization

Dalam penentuan parameter optimal dari model SVR, dapat dilakukan dengan menggunakan *Grid Search Optimization* (GSO) dengan mengatur *range* parameter yang akan dioptimasi menjadi sebuah *grid* dan menyilangkan semua titik guna memperoleh parameter yang optimal [28]. Kisaran yang umum digunakan adalah $\varepsilon = (0; 0,1; 0,2; \dots; 1)$, $C = (2^{-5}, 2^{-4}, \dots, 2^{15})$, dan $\gamma = (2^{-3}, 2^{-4}, \dots, 2^{15})$ dengan C dan γ adalah deret eksponensial [28]. *Grid search* akan membentuk beberapa pola pasangan untuk memilih pasangan dengan kesalahan rata-rata terkecil.

Dalam penerapannya, GSO dihitung menggunakan *Cross Validation* (CV) dalam data *training*. Oleh karena itu, perlu dilakukan uji coba beberapa macam kombinasi parameter pada *hyperplane* pada SVR [29]. CV merupakan tes yang umum dilakukan dalam memprediksi tingkat kesalahan. Segmentasi data latih secara acak, lalu menghitung tingkat kesalahan rata-rata untuk mendapatkan tingkat kesalahan secara keseluruhan [30].

Karena durasi proses GSO umumnya singkat, pencarian *grid* dapat dibagi menjadi *loose grid* dan *finer grid*. *Loose grid* merupakan langkah untuk memilih nilai C dan γ dengan pangkat *integer*, sedangkan *finer grid* merupakan kelanjutan dari tahap *loose grid*, bertujuan untuk mendapatkan nilai C dan γ dengan kesalahan yang paling kecil [31]. Berdasarkan hal tersebut, penelitian ini mengadopsi dua tahap pencarian *grid* yakni *loose grid* dan *fine grid*, untuk mendapatkan nilai

parameter yang optimal. Parameter yang optimal digunakan untuk memberikan akurasi pada pemodelan terbaik dan nilai kesalahan terendah.

I. Pemilihan Model Terbaik

Dalam mengukur ketepatan prediksi perlu dilakukan perhitungan guna mengetahui kesesuaian antara data aktual dan data hasil prediksi. Terdapat beberapa perhitungan yang umumnya digunakan untuk mengukur keakuratan hasil prediksi, yaitu RMSE dan MAPE [32].

1. *Root Mean Square Error* (RMSE)

RMSE merupakan besar kecilnya tingkat kesalahan yang diperoleh dari hasil prediksi. Semakin kecil nilai RMSE atau mendekati 0, maka tingkat keakuratannya semakin baik. Perhitungan pada RMSE yakni mengurangi nilai prediksi dari nilai sebenarnya, menguadratkannya, menjumlahkan hasil total, dan membaginya dengan jumlah data prediksi. Lebih lanjut, RMSE dapat dinyatakan secara matematis sebagai berikut:

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (Z_t - \hat{Z}_t)^2}{n}} \tag{23}$$

Keterangan:

- Z_t : data aktual pada waktu ke- t
- \hat{Z}_t : data hasil prediksi pada waktu ke- t
- n : banyak data prediksi

2. *Mean Absolute Percentage Error* (MAPE)

MAPE mendefinisikan persentase kesalahan hasil prediksi dari data aktual dari waktu ke waktu, dengan memberikan informasi terkait persentase kesalahan yang tinggi ataupun rendah. Perhitungan pada MAPE dengan membagi kesalahan absolut untuk setiap periode dengan pengamatan aktual untuk periode tersebut. Persentase kesalahan absolut kemudian dirata-ratakan untuk setiap periode perkiraan. MAPE dapat dinyatakan secara matematis sebagai berikut:

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{Z_i - \hat{Z}_i}{Z_i} \right|}{n} \times 100\% \tag{24}$$

Keterangan:

- Z_t : data aktual pada waktu ke- t
- \hat{Z}_t : data hasil prediksi pada waktu ke- t
- n : banyak data prediksi

III. METODOLOGI

A. Sumber Data dan Variabel Penelitian

Data yang digunakan dalam penelitian ini adalah data ekspor non migas di Indonesia berupa data bulanan dari Badan Pusat Statistik Indonesia yang diperoleh melalui *website bps.go.id* mulai bulan Juli 2016 sampai Juli 2022. Studi empirik membuktikan bahwa hasil prediksi terbaik diperoleh ketika data *set* dibagi menjadi 80-90% data *training*, dan 20-30% data *testing* [33]. Dalam proses analisis, pemodelan menggunakan data *training*, sedangkan data *testing* digunakan untuk membandingkan hasil peramalan dengan data aktual. Maka dari itu data bulan Juli 2016 sampai September 2021 (63 data) sebagai data *training* dan data bulan Oktober 2021 sampai Juli 2022 (10 data) sebagai data *testing*. Lebih lanjut, variabel penelitian ditunjukkan pada Tabel 2.

Tabel 2 Variabel Penelitian

Variabel Penelitian	Informasi
Harga ekspor non migas (Z_t)	Dalam satuan harga
Periode waktu (x)	Dalam periode bulanan

B. Langkah Penelitian

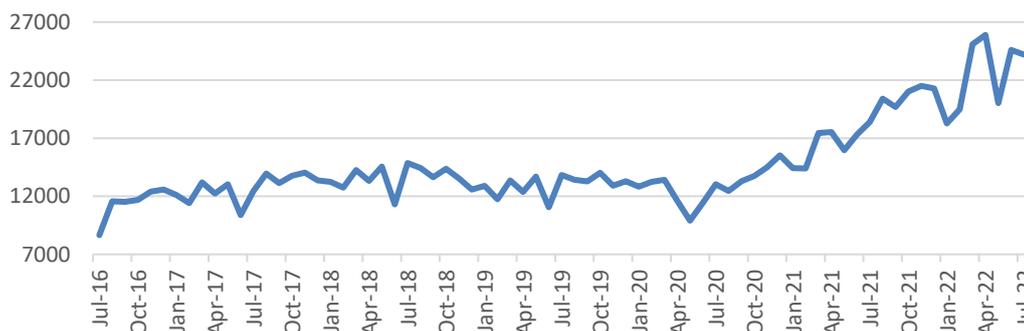
Prosedur atau tahapan metode analisis dalam penelitian ini secara sistematis dapat dijelaskan sebagai berikut:

- a. Tahapan untuk mengetahui gambaran deskriptif harga ekspor non migas di Indonesia berdasarkan langkah-langkah sebagai berikut:
 - i. Membuat plot *time series* yang menggambarkan pergerakan harga bulanan ekspor non migas di Indonesia.
 - ii. Mendeskripsikan data harga ekspor non migas berdasarkan plot *time series* yang telah terbentuk.
- b. Melakukan pembagian data kedalam data *training* dan *testing*.

- c. Melakukan pengujian linieritas dengan menggunakan uji *Terasvirta* untuk mengetahui apakah data mengandung pola nonlinier.
- d. Melakukan pemodelan dan prediksi dengan pendekatan estimator deret *Fourier* dengan langkah-langkah sebagai berikut:
 - i. Menentukan formula GCV dan RMSE berdasarkan hasil estimator deret cosinus *Fourier*.
 - ii. Membuat program penentuan parameter osilasi (k) optimal berdasarkan kriteria GCV.
 - iii. Menentukan k optimal berdasarkan nilai GCV terkecil dan konsep model *parsimony*.
 - iv. Membuat program penentuan nilai estimator untuk model regresi nonparametrik dengan pendekatan deret cosinus *Fourier* terpilih.
 - v. Menentukan estimator berdasarkan nilai k optimal.
 - vi. Menghitung R^2 berdasarkan nilai k optimal.
 - vii. Menghitung RMSE dan MAPE nilai prediksi data *testing* yang diperoleh dari model deret *Fourier* terbaik
- e. Melakukan pemodelan dan prediksi dengan pendekatan SVR dengan langkah-langkah sebagai berikut:
 - i. Melakukan penentuan *lag* yang berpengaruh dengan menggunakan plot PACF, dilanjutkan dengan mengonversikan data harga ekspor non migas menjadi bentuk *time lag* yang bertujuan sebagai data *input* pada model SVR.
 - ii. Menentukan parameter C, γ , dan ϵ optimal menggunakan *grid search* dengan dua tahapan, yaitu *loose grid* dan *finer grid*.
 - iii. Membentuk model SVR dengan menggunakan parameter optimal.
 - iv. Melakukan prediksi terhadap harga ekspor non migas berdasarkan model SVR yang memuat parameter optimal.
 - v. Menghitung RMSE dan MAPE nilai prediksi data *testing* yang diperoleh dari model SVR terbaik.
- f. Menentukan hasil prediksi berdasarkan model terbaik yang dipilih.
- g. Membandingkan hasil prediksi pada model estimator deret *Fourier* dan SVR berdasarkan nilai MAPE terkecil.

IV. HASIL DAN PEMBAHASAN

Secara deskriptif harga ekspor non migas di Indonesia setiap bulan dari Juli 2016 hingga Juli 2022 dapat dilihat pada Gambar 1. Dalam 73 data bulanan harga ekspor non migas di Indonesia, terhitung harga rata-rata sebesar 14.684,83 dengan standar deviasi yang sebesar yaitu sebesar 3.657,28. Secara umum harga ekspor non migas cenderung meningkat setiap tahunnya hingga mencapai nilai tertinggi pada bulan April 2022 dengan harga 25.889. Lebih lanjut, harga ekspor non migas mengalami peningkatan cukup drastis di masa pandemi COVID-19 dan perang Rusia-Ukraina yang terjadi mulai bulan Februari 2022.



Gambar 1 Plot Data Harga Ekspor Non Migas di Indonesia Periode Juli 2016 hingga Juli 2022

Sebelum menentukan model estimator deret *Fourier* dan SVR, pengujian linieritas menggunakan uji *Terasvirta* perlu dilakukan sebagai dasar menggunakan metode *time series* yang nonlinier. Dalam hal ini, direpresentasikan oleh fungsi nonparametrik pada data harga ekspor non migas di Indonesia selama periode Juli 2016 hingga Juli 2022 dengan menggunakan perhitungan pada persamaan (4) dimana hasil perhitungan ditunjukkan pada Tabel 3.

Tabel 3 Uji *Terasvirta* pada Data Harga Ekspor Non Migas

Statistika Uji (<i>Terasvirta</i>)	<i>p</i> – value
19,984	0,000045

Terlihat dari Tabel 3 bahwa nilai statistika uji *Terasvirta* lebih besar dari $X^2_{(2,0,05)} = 5,991465$ atau nilai $p - value < \alpha = 5\%$ yang berarti H_0 ditolak. Hal tersebut mengartikan bahwa data harga ekspor non migas di Indonesia mengandung pola nonlinier.

A. Model Estimator Deret Fourier

Model regresi nonparametrik dengan estimator deret *Fourier* memiliki parameter osilasi (k). Metode GCV digunakan untuk menentukan nilai optimum. Hasil perhitungan GCV optimum menggunakan *software* R untuk data *in sample* disajikan dalam Tabel 4.

Tabel 4 Nilai GCV

Fungsi	k	Nilai GCV
sin	4	3.332.497
cos	1	4.513.086
cos sin	7	2.653.582

Berdasarkan nilai parameter osilasi (k) yang optimum pada fungsi cossin yaitu sebesar 7, diperoleh model estimator deret *Fourier* dalam regresi nonparameterik sebagai berikut:

$$\hat{z}_t = \frac{\alpha_0}{2} + \gamma_1 + \sum_{k=1}^7 (\alpha_k \cos kt + \beta_k \sin kt) \tag{25}$$

$$\hat{z}_t = \frac{\alpha_0}{2} + \gamma_1 + \alpha_1 \cos t + \beta_1 \sin t + \alpha_2 \cos 2t + \beta_2 \sin 2t + \alpha_3 \cos 3t + \beta_3 \sin 3t + \alpha_4 \cos 4t + \beta_4 \sin 4t + \alpha_5 \cos 5t + \beta_5 \sin 5t + \alpha_6 \cos 6t + \beta_6 \sin 6t + \alpha_7 \cos 7t + \beta_7 \sin 7t \tag{26}$$

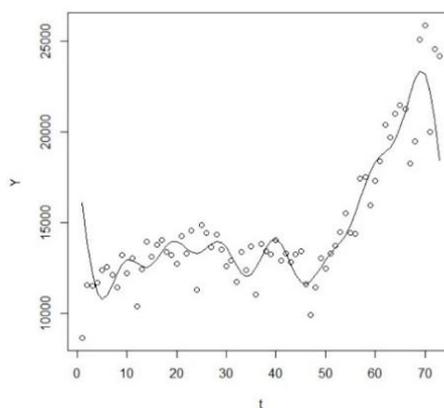
Sehingga estimasi model regresi nonparameterik dengan pendekatan estimator deret *Fourier* untuk harga ekspor non migas di Indonesia adalah sebagai berikut:

$$\hat{z}_t = 4,672 + 18,523\gamma_1 + 3,241 \cos t + 1,346 \sin t + 0,376 \cos 2t - 1,251 \sin 2t + 1,469 \cos 3t + 1,148 \sin 3t + 5,821 \cos 4t - 0,247 \sin 4t + 3,152 \cos 5t - 2,312 \sin 5t + 1,342 \cos 6t - 2,608 \sin 6t - 0,437 \cos 7t + 3,112 \sin 7t \tag{27}$$

Model tersebut memiliki kriteria kebaikan dengan nilai sama dengan 7 yang ditampilkan pada Tabel 5. Secara umum pergerakan harga ekspor non migas di Indonesia dapat diprediksi dengan menggunakan model estimator Deret *Fourier*. Grafik perbandingan antara nilai prediksi dan data aktual pada pemodelan data training dengan model SVR disajikan pada Gambar 2.

Tabel 5 Nilai Kebaikan Model Estimator Deret *Fourier*

Fungsi	R ²	RMSE	MAPE
cos sin	0,9994	4.350,368	15,25%



Gambar 2 Perbandingan Data Aktual dengan Hasil Prediksi Model Estimator Deret *Fourier*

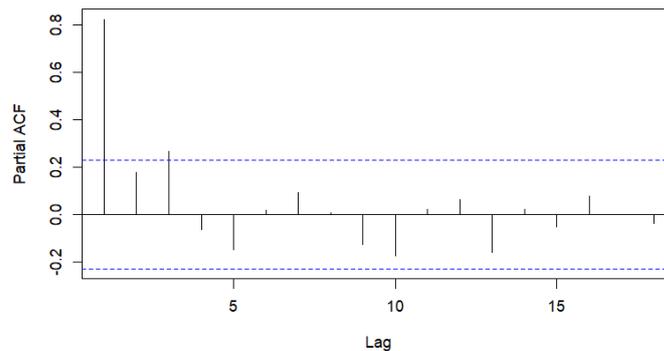
Lebih lanjut, hasil prediksi menggunakan metode estimator deret *Fourier* pada harga ekspor non migas Indonesia periode Oktober 2021 sampai dengan Juli 2022 disajikan pada Tabel 6.

Tabel 6 Pebandingan Data Aktual dan Data Prediksi Deret *Fourier* Harga Ekspor Non Migas di Indonesia Periode Oktober 2021 hingga Juli 2022

Bulan	Data Aktual	Data Prediksi
Oktober 2021	21.026,7	18.774,21
November 2021	21.505,9	18.734,10
Desember 2021	21.289,7	18.695,14
Januari 2022	18.272,5	18.657,27
Februari 2022	19.478,1	18.620,46
Maret 2022	25.092,4	18.584,66
April 2022	25.889,0	18.549,83
Mei 2022	20.013,7	18.515,93
Juni 2022	24.600,8	18.482,93
Juli 2022	24.195,3	18.450,93

B. Model SVR

Sebelum memulai pemodelan dengan SVR, langkah pertama adalah mengubah data harga ekspor nonmigas Indonesia ke dalam bentuk *time lag* berdasarkan skema PACF. Plot PACF untuk harga ekspor nonmigas Indonesia ditunjukkan pada Gambar 3.



Gambar 3 Plot PACF Data Harga Ekspor Non Migas di Indonesia

Berdasarkan plot PACF pada Gambar 3, lag 1 dan 3 merupakan lag yang signifikan, sehingga terdapat 2 lag untuk data SVR sebagai *time lag*.

Dalam melatih model SVR, langkah awal yang dapat dilakukan adalah menentukan parameter optimal dengan tahapan GSO. Dalam penelitian ini, peneliti membatasi dengan menggunakan fungsi kernel RBF dan *polynomial*. Kernel RBF memiliki parameter C , γ , dan ϵ yang harus ditentukan, sementara kernel *polynomial* memiliki parameter C , ϵ , dan *degree*. Dalam penentuan parameter yang optimal, digunakan metode *grid search* dengan dua tahap yaitu *loose grid* dan *finer grid*. Pada tahapan *grid search*, langkah pertama yang dilakukan adalah melakukan penentuan pada *range* nilai dari parameter. Pada langkah *loose grid*, menggunakan bilangan bulat untuk nilai parameter C dan γ , sementara nilai ϵ ditentukan sebelumnya. Kisaran nilai pada parameter yang digunakan untuk langkah *loose grid* RBF ditunjukkan pada Tabel 7.

Tabel 7 Rentang Nilai Parameter Tahapan *Loose Grid* Metode *Grid Search*

Parameter	Rentang Nilai
C	$2^{-5}, 2^{-3}, \dots, 2^5, 2^9$
γ	$2^{-9}, 2^{-7}, \dots, 2^3, 2^5$
ϵ	0,0001; 0,001; ... ; 0,05; 0,1

Kisaran parameter yang tercantum dalam Tabel 7 digunakan saat menentukan parameter model SVR. Pada proses *loose grid*, didapatkan nilai optimal dari parameter model SVR sebesar $C = 2^5, \gamma = 2^{-2}$ dan $\epsilon = 0,0001$. Nilai tersebut digunakan untuk melakukan pencarian *grid* yang lebih halus. *Finer grid* adalah fase pencarian *grid* yang diperoleh dengan menggunakan nilai perkiraan C , γ , dan ϵ pada tahap *loose grid*. Kisaran nilai parameter pada *finer grid* ditunjukkan pada Tabel 8.

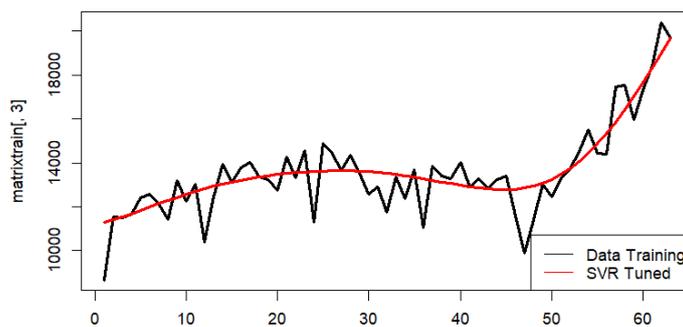
Tabel 8 Rentang Nilai Parameter Tahapan *Finer Grid* Metode *Grid Search*

Parameter	Rentang Nilai
C	$2^4, 2^{4,25}, 2^{4,5}, 2^{4,75}, 2^5, 2^{5,25}, 2^{5,5}, 2^{5,75}, 2^6$
γ	$2^{-3}, 2^{-3,25}, 2^{-3,5}, 2^{-3,75}, 2^{-2}, 2^{-2,25}, 2^{-2,5}, 2^{-2,75}, 2^{-1}$
ϵ	0,0001

Dengan metode *Grid Search*, nilai parameter optimal untuk setiap parameter *cost*, *gamma*, dan *epsilon* berturut-turut adalah $2^{5,5}$, 2^{-2} , dan 0,0001. Besaran evaluasi model SVR disajikan pada Tabel 9. Model SVR memiliki akurasi yang sangat tinggi dalam memprediksi data latih dengan MAPE sebesar 5,88%. Secara umum pergerakan harga ekspor non migas di Indonesia dapat diprediksi dengan menggunakan model SVR. Grafik perbandingan antara nilai prediksi dan data aktual pada pemodelan data training dengan model SVR disajikan pada Gambar 4.

Tabel 9 Ukuran Evaluasi Model Data *Training*

RMSE	MAPE
1.010,04	5,88%



Gambar 4 Perbandingan Data *Training* dengan Hasil Prediksi Model SVR pada Data *Training Tuned*

Berdasarkan nilai MAPE pada Tabel 9, model SVR yang dihasilkan menunjukkan kemampuan prediksi yang sangat akurat sebesar 5,88%. Model *training* tersebut digunakan untuk memprediksi pada data *testing*. Lebih lanjut, hasil prediksi harga ekspor non migas Indonesia periode Oktober 2021 sampai dengan Juli 2022 disajikan pada Tabel 10.

Tabel 10 Perbandingan Data Aktual dan Data Prediksi SVR Harga Ekspor Non Migas di Indonesia Periode Oktober 2021 hingga Juli 2022

Bulan	Data Aktual	Data Prediksi
Oktober 2021	21.026,7	20.383,0
November 2021	21.505,9	21.079,4
Desember 2021	21.289,7	21.765,5
Januari 2022	18.272,5	22.433,4
Februari 2022	19.478,1	23.075,2
Maret 2022	25.092,4	23.683,8
April 2022	25.889,0	24.252,5
Mei 2022	20.013,7	24.774,9
Juni 2022	24.600,8	25.245,9
Juli 2022	24.195,3	25.660,9

Model SVR memiliki akurasi yang sangat tinggi dalam memprediksi data *testing* dengan MAPE sebesar 9,29%. Besaran evaluasi model SVR ditunjukkan pada Tabel 11.

Tabel 11 Ukuran Evaluasi Model Data *Testing*

RMSE	MAPE
2.469,21	9,29%

Selanjutnya membandingkan performa metode estimator deret *Fourier* dan SVR dapat dilakukan. Hasil perbandingan disajikan pada Tabel 12.

Tabel 12 Perbandingan Performa Kernel RBF dan *Polynomial*

Metode	Fungsi	RMSE	MAPE
Deret <i>Fourier</i>	cos	12.427,21	21,46%
	cos sin	4.350,37	15,26%
SVR	RBF	2.469,21	9,29%
	<i>Polynomial</i>	7.481,32	16,03%

V. KESIMPULAN DAN SARAN

Pandemi COVID-19 dan perang Rusia-Ukraina berdampak besar terhadap harga ekspor non migas di Indonesia. Pada hasil analisis menggunakan *time series* dengan membandingkan metode *time series* klasik dan *modern* untuk memprediksi harga ekspor non migas di Indonesia dengan metode estimator deret *Fourier* dan SVR, didapatkan pemodelan estimator deret *Fourier* dan SVR kernel RBF dengan melihat perbandingan dari performa yang dihasilkan oleh nilai MAPE masing-masing sebesar 15,26% dan 9,29%. Hasil prediksi tersebut diharapkan dapat menjadi bahan pertimbangan dalam mengevaluasi proses produksi ekspor non migas di Indonesia dalam meningkatkan pertumbuhan ekonomi Indonesia.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Program Studi Statistika, Fakultas Sains dan Teknologi, dan Universitas Airlangga, serta semua pihak yang turut terlibat dalam mendukung penelitian dan publikasi ini.

DAFTAR PUSTAKA

- [1] M. Muqorrobin dan A. Sejoto, "Pengaruh Indeks Pembangunan Manusia (IPM) Terhadap Pertumbuhan Ekonomi Provinsi Jawa Timur," *Jurnal Pendidikan Ekonomi (JUPE)*, vol. 5, no. 3, p. 2-6, 2017.
- [2] D. Yunianto, "Analisis Pertumbuhan dan Kepadatan Penduduk Terhadap Pertumbuhan Ekonomi," *Forum Ekonomi*, vol. 23, no. 4, p. 687-698, 2021.
- [3] M. Hasan dan M. Azis, "Pembangunan Ekonomi & Pemberdayaan Masyarakat: Strategi Pembangunan Manusia Dalam Perspektif Ekonomi Lokal," 2nd ed, Makassar: Nur Lina Publisher, 2018.
- [4] D. P. Aristiyanti, "Pengaruh Produksi, Harga Batu Bara Acuan, Harga Batu Bara Australia, dan Kurs Terhadap Ekspor Batu Bara di Indonesia," *Skripsi*, Universitas Islam Negeri Syarif Hidayatullah, Jakarta, 2020.
- [5] D. R. M. Salsabila, "Analisis Pengaruh Ekspor Migas dan Non Migas Terhadap Pertumbuhan Ekonomi Indonesia," *Jurnal Akuntansi dan Manajemen (JAM)*, vol. 18, no. 1, p. 1-8, 2021.
- [6] Bank Indonesia, "Laporan Akhir Tahun Bank Indonesia Tahun 2017," Jakarta: Departemen Komunikasi, 2017.
- [7] Badan Pusat Statistika, "Dampak Perang Rusia-Ukraina Bagi Ekspor Impor Indonesia," *Berita Resmi Statistik*, 2022.
- [8] M. F. F. Mardianto, S. H. Kartiko, dan H. Utami, "Prediction the Number of Students in Indonesia who Study in Tutoring Agency and Their Motivations based on Fourier Series Estimator and Structural Equation Modelling," *International Journal of Innovation, Creativity, and Change*, vol. 5, no. 3, 2019.
- [9] S. M. Ulyah dan M. F. F. Mardianto, "Comparing the Performance of Seasonal ARIMAX Model and Nonparametric Regression Model in Predicting Claim Reserve of Education Insurance," *Journal of Physics: Conference Series*, vol. 1397, no. 1, 012074, 2019.
- [10] D. I. Purnama dan S. Setianingsih, "Model Support Regression (SVR) Untuk Peramalan Jumlah Penumpang Penerbangan Domestik di Bandara Sultan Hasanuddin Makassar," *Jurnal Matematika, Statistik, dan Komputasi*, vol. 16, no. 3, p. 391-403, 2020.
- [11] R. Isnaeni, Sudarmin, dan Z. Rais, "Analisis Support Vector Regression (SVR) dengan Kernel Radial Basis Function (RBF) Untuk Memprediksi Laju Inflasi di Indonesia," *Variansi: Journal of Statistics and Its Application on Teaching and Research*, vol. 4, no. 1, p. 30-38, 2022.
- [12] M. F. F. Mardianto, "Prediksi Cadangan Klaim Asuransi Pendidikan dengan Pendekatan Regresi Nonparametrik Deret Fourier," *Prosiding Konferensi Nasional Penelitian Matematika dan Pembelajarannya (KNPMP) III*, 2018.
- [13] D. I. Purnama dan O. P. Hendrasin, "Peramalan Jumlah Penumpang Berangkat Melalui Transportasi Udara di Sulawesi Tengah Menggunakan Support Vector Regression (SVR)," *Jambura Journal of Mathematics*, vol. 2, no. 2, p. 49-59, 2020.
- [14] Badan Pemeriksa Keuangan, "Salinan Pajak Daerah Dan Retribusi Daerah Dalam Rangka Mendukung Kemudahan Berusaha Dan Layanan Daerah," *Jaringan Dokumentasi dan Informasi Hukum Nasional (JDIHN) BPK RI Database Peraturan*, Jakarta, 2021.
- [15] Kementerian Keuangan Republik Indonesia, "Ekspor Indonesia Terus Melanjutkan Kinerja Positif," *Berita Utama Manajemen Situs Kemenkeu*, Jakarta, 2022.
- [16] Badan Pusat Statistika, "Ekspor dan Impor," *Berita Resmi Statistik*, 2022.
- [17] T. Terasvirta, C. F. Lin, dan C. W. Granger, "Power of the Neural Network Linearity Test," *Journal of Time Series Analysis*, vol. 14, no. 2, p. 209-220, 1993.
- [18] H. Fahmy, "Clean Energy Deserve to Be an Asset Class : A Volatility-Reward Analysis," *Economic Modelling*, vol. 106, 105696, 2022.
- [19] M. Surahamanto, E. Utami, dan H. Al Fatta, "Prediksi Kapasitas Kargo Pada Bandara Deo Sorong," *Insect (Information and Security): Jurnal Teknik Informatika*, vol. 8, no. 1, p. 58-66, 2022.
- [20] M. D. Moura, Z. Enrico, L. D. Isis, dan D. Enrique, "Failure and Realibility Prediction by Support Vector Machines Regression of Time Series Data," *Reliability Engineering and System Safety*, vol. XCVI, no. 11, p. 1527-1534, 2011.
- [21] P. Bloomfield, "Fourier Analysis of Time Series: An Introduction," *Journal of the American Statistical Association*, vol. 74, no. 368, p. 924-926, 1979.
- [22] A. Sholiha, K. Kuzairi, dan M. F. F. Mardianto, "Estimator Deret Fourier Dalam Regresi Nonparameterik dengan Pembobot Untuk Perencanaan Penjualan Camilan Khas Madura," *Zeta-Math Journal*, vol. 4, no. 1, p. 18-23, 2018.
- [23] B. Bidayani, M. Hadijati, dan N. Fitriyani, "Model Regresi Semiparameterik Spline Hasil Produksi Padi di Kabupaten Lombok Timur," *EIGEN MATHEMATICS JOURNAL*, vol. 1, no. 1, p. 6-12, 2019.
- [24] A. J. Smola dan B. Scholkopf, "A Tutorial on Support Vector Regression," *Statistics and Computing*, vol. 12, p. 199-222, 2004.
- [25] R. P. Furi, Jondri, dan D. Saepudin, "Peramalan Financial Time Series Menggunakan Independent Component Analysis dan Support Vector Regression," *Skripsi*, Telkom University, Bandung, 2015.
- [26] I. N. D. Pradnyandita, A. A. Rohmawati, dan Indwiarti, "Electronic Money Transactions Forecasting with Support Vector Regression (SVR) and Vector Autoregressive Moving Average (VARMA)," *International Journal on Information and Communication Technology (IJOICT)*, vol. 8, no. 1, 2022.
- [27] H. Jiawei, K. Micheline, dan P. Jian, "Data Mining Concepts and Techniques," San Francisco: Morgan Kaufmann, 2011.
- [28] A. Asyiva, "Prediksi Laju Inflasi Indonesia menggunakan Metode Support Vector Regression dengan Kernel Radial Basis Function," *Skripsi*, UIN Syarif Hidayatullah, Jakarta, 2019.
- [29] C. W. Hsu, C. Chang, dan C. J. Lin, "A Practical Guide to Support Vector Classification," *Department of Computer Science and Information Engineering*, Taiwan, 2016.
- [30] B. Santosa, "Data Mining Teknik Pemanfaatan Data Untuk Keperluan Bisnis," Yogyakarta: Graha Ilmu, 2007.
- [31] N. P. N. Hendayanti, I. K. P. Suniantara, dan M. Nurhidayati, "Penerapan Support Vector Regression (SVR) dalam Memprediksi Jumlah Kunjungan Wisatawan Domestik ke Bali," *Jurnal Varians*, vol. 3, no. 1, p. 43-50, 2019.
- [32] X. Guo, Y. Gao, Li, D. Zheng, dan D. Zheng, "Short-Term Household Load Forecasting Based on Long-and Short-Term Time Series Network," *Energy Reports*, vol. 7, p. 58-64, 2021.
- [33] E. Karyadiputra dan N. Hijriana, "Analisis Pengembangan Algoritma Naïve Bayes untuk Klasifikasi prioritas Pengembangan Jalan di Provinsi Kalimantan Selatan," *Jurnal Ilmiah "Technologia"*, vol. 9 no. 2, p. 105-108, 2018.



© 2023 by the authors. This work is licensed under a Creative Commons Attribution-ShareAlike 4.0 International License (<http://creativecommons.org/licenses/by-sa/4.0/>).