

Optimasi Parameter *Support Vector Regression* pada Prediksi Nilai Tukar Dolar Amerika terhadap Rupiah dengan Menggunakan *Genetic Algorithm* dan *Particle Swarm Optimization*

Amelia Soraya Putri, Soehardjoepri, dan Agus Suharsono
Departemen Aktuaria, Institut Teknologi Sepuluh Nopember (ITS)
e-mail: joepri_its@yahoo.com

Abstrak—Nilai tukar mata uang suatu negara merupakan salah satu indikator penting dalam suatu perekonomian. Dimana perubahan nilai tukar yang sangat cepat dan tidak stabil diyakini akan mengganggu kestabilan kegiatan perdagangan internasional dan berimbas pada pelarian modal internasional. Pandemi COVID-19 dalam beberapa tahun ini juga memberikan pengaruh besar, seperti depresiasi nilai tukar mata uang dolar Amerika terhadap rupiah. Melakukan prediksi bisa menjadi strategi yang baik sebagai bahan pertimbangan dalam pengambilan keputusan oleh pihak terkait. Penelitian ini bertujuan untuk mendapatkan parameter *Support Vector Regression* (SVR) yang optimal pada prediksi nilai tukar dolar Amerika terhadap rupiah dengan menggunakan algoritma *Genetic Algorithm* (GA) dan *Particle Swarm Optimization* (PSO). Dimana parameter yang optimal dapat menghasilkan hasil prediksi yang baik pula. Sumber data yang digunakan pada penelitian ini berasal dari Bank Indonesia. Variabel pada penelitian ini adalah nilai tukar jual harian dolar Amerika terhadap rupiah periode 1 Januari 2021 hingga 31 Januari 2022. Pada penelitian ini dilakukan analisis menggunakan metode SVR dengan tiga kernel yaitu *Linear*, *Polynomial*, dan *Radial Basis Function* (RBF), dan kernel yang memberikan hasil terbaik yang kemudian dioptimasi menggunakan SVR-GA dan SVR-PSO, dimana dihasilkan parameter C (*cost*), γ (*gamma*), dan ϵ (*epsilon*) yang optimal berdasarkan nilai MAPE terkecil. Hasil dari penelitian ini adalah pada analisis *Support Vector Regression* dengan kernel *Linear*, *Polynomial*, dan RBF didapatkan hasil bahwa kernel RBF memberikan nilai MAPE terkecil yaitu sebesar 0,7142588% pada data *training* dan 0,2187573% pada data *testing*, dengan kombinasi nilai C sebesar 0,1, nilai γ sebesar 0,01, dan nilai ϵ sebesar 0,01. Pada optimasi nilai parameter SVR kernel RBF menggunakan SVR-GA dan SVR-PSO, nilai MAPE terkecil diberikan pada metode SVR-GA yaitu sebesar 0,7242439% pada data *training* dan 0,2184038% pada data *testing* dengan nilai parameter optimal C sebesar 0,09629636, nilai γ sebesar 0,008874816, dan nilai ϵ sebesar 0,009756693. Metode SVR-GA dengan kernel RBF berhasil mengoptimasi parameter SVR pada data nilai tukar jual dolar Amerika terhadap rupiah periode 1 Januari 2021 hingga 31 Januari 2022.

Kata Kunci—Nilai Tukar Jual, Optimasi, SVR-GA, SVR-PSO, Kernel.

I. PENDAHULUAN

NILAI tukar mata uang atau yang sering disebut kurs valuta adalah harga atau nilai mata uang sesuatu negara dinyatakan dalam nilai mata uang negara lain [1]. Salah satu valuta asing yang digunakan sebagai alat transaksi Internasional adalah dolar Amerika yang sudah lama menjadi mata uang acuan dalam transaksi global oleh berbagai negara di seluruh dunia. Menurut Haryanto (2020) dalam jurnalnya

memaparkan bahwa COVID-19 berdampak pada depresiasi nilai tukar mata uang dolar Amerika terhadap rupiah. Sebelum naiknya dolar karena dampak COVID-19, nilai tukar rupiah per dolar AS pada kisaran Rp.14.000/US\$ dan saat pandemi Covid-19, rupiah sempat terdepresiasi hingga Rp.16.600/per US\$ nya [2]. Menurut Anwary (2011) dalam Putri dan Widodo (2021) menyebutkan bahwa nilai tukar mata uang suatu negara merupakan salah satu indikator penting dalam suatu perekonomian. Kebijakan dari otoritas moneter maupun pelaku pasar keuangan sangat penting dilakukan untuk tetap menjaga stabilitas dan terus mendorong perbaikan ekonomi nasional [3].

Berdasarkan permasalahan di atas, penulis bermaksud melakukan prediksi nilai tukar dolar Amerika terhadap rupiah, dimana bisa menjadi suatu hal yang penting dan strategi yang baik sebagai bahan pertimbangan dalam pengambilan keputusan oleh pihak terkait [4]. Salah satu metode untuk mendapatkan hasil prediksi adalah *Support Vector Regression* (SVR). Konsep SVR didasarkan pada *risk minimization*, yaitu untuk mengestimasi suatu fungsi dengan cara meminimalkan batas dari *generalization error*, sehingga SVR mampu mengatasi *overfitting*.

Pada suatu penelitian telah dibandingkan metode *fuzzy linear regression* (FLR) dengan *Support Vector Regression* (SVR) dan memberikan hasil bahwa metode SVR lebih baik dalam memprediksi GSR dengan estimasi akurasi yang tinggi dan waktu komputasi yang pendek [5]. Pada penelitian lainnya penerapan metode *Support Vector Regression* (SVR) dan *ridge regression* menyimpulkan bahwa hasil prediksi menggunakan metode SVR dengan kernel *polynomial* dapat memprediksi dengan baik daripada SVR kernel linier, *Radial Basis Function* (RBF), dan *ridge regression* [6].

Fungsi kernel dapat digunakan untuk mengubah data yang memiliki fungsi non-linier ke ruang dimensi yang lebih tinggi atau yang disebut sebagai *kernel space* untuk mencapai akurasi yang lebih tinggi [7]. Pada suatu penelitian yang menggunakan metode *Support Vector Regression* (SVR) dengan membandingkan tiga kernel yaitu *linear*, *polynomial*, dan *Radial Basis Function* (RBF) pada model prediksinya, menyebutkan bahwa kernel RBF memberikan hasil terbaik [8]. Kualitas model SVR tergantung pada pengaturan parameter model SVR yang tepat. Parameter biasanya ditentukan dengan proses *trial-and-error* yang kurang efisien dan tidak mudah untuk mendapatkan set parameter yang optimal yang menjanjikan kinerja model [6].

Optimasi parameter dapat dilakukan mengoptimalkan parameter dari model SVR sehingga kemampuan

Tabel 1.
Skala Akurasi Peramalan

MAPE	Tingkat Akurasi Peramalan
≤ 10%	Highly accurate
11% - 20%	Good forecast
21% - 50%	Reasonable forecast
51% - lebih	Inaccurate forecast

menggeneralisasi dan akurasi peramalan dapat ditingkatkan. Pada suatu penelitian disebutkan bahwa metode *Genetic Algorithm – Support Vector Regression* (GA-SVR) dapat memberikan akurasi peramalan yang tinggi daripada metode *Artificial Neural Network* (ANN) [9]. Pada peramalan menggunakan *Support Vector Regression* (SVR) dengan metode optimasi *Genetic Algorithm* (GA) dan *Particle Swarm Optimization* (PSO) yang dibandingkan dengan metode ARIMA, memberikan hasil bahwa metode optimasi SVR-GA memiliki hasil optimasi yang lebih baik berdasarkan nilai kebaikan model [10].

Pada penelitian lain, prediksi menggunakan *Support Vector Regression* (SVR) dengan *Particle Swarm Optimization* (PSO) menunjukkan kinerja yang baik dengan nilai *Normalized Mean Square Error* (NMSE) yang relatif kecil [11]. Pada penelitian peramalan menggunakan *Support Vector Regression* (SVR) yang dioptimasi dengan algoritma *Particle Swarm Optimization* (PSO) menunjukkan bahwa hasil peramalan dengan parameter yang telah dioptimasi memiliki nilai MAPE yang lebih kecil dibandingkan jika hanya dengan menggunakan SVR saja [12].

Pada penelitian ini akan dilakukan perbandingan antara kedua metode optimasi yaitu *Genetic Algorithm* (GA) dan *Particle Swarm Optimization* (PSO) dengan menggunakan tiga kernel yaitu *linear*, *polynomial*, dan *Radial Basis Function* (RBF) pada prediksi nilai tukar dolar Amerika terhadap rupiah sehingga didapatkan parameter yang optimal dan memberikan model dan hasil prediksi terbaik. Untuk melihat seberapa baik model yang didapatkan maka digunakan nilai *Mean Absolute Percentage Error* (MAPE) sebagai ukuran.

II. TINJAUAN PUSTAKA

A. Nilai Tukar Mata Uang

Nilai tukar mata uang atau yang sering disebut kurs valuta tukar mata uang atau yang sering disebut kurs valuta adalah harga atau nilai mata uang sesuatu negara dinyatakan dalam nilai mata uang negara lain [1]. Indonesia sendiri sejak 14 Agustus 1997 mulai menerapkan sistem nilai tukar mengambang. Dimana dalam sistem nilai tukar mengambang, nilai tukar dibiarkan bergerak sesuai dengan kekuatan permintaan dan penawaran yang terjadi di pasar. Dengan demikian, nilai tukar akan menguat apabila terjadi kelebihan penawaran valuta asing dan sebaliknya nilai tukar mata uang domestik akan melemah apabila terjadi kelebihan permintaan valuta asing [13].

B. Prediksi

Prediksi adalah suatu proses memperkirakan secara sistematis tentang sesuatu yang paling mungkin terjadi di masa depan berdasarkan informasi masa lalu dan sekarang yang dimiliki, agar kesalahannya dapat diperkecil. Menurut kamus besar bahasa Indonesia, prediksi adalah hasil dari

Tabel 2.
Struktur Data Penelitian

t	y_t (target)	y_{t-1}	y_{t-2}	y_{t-3}	y_{t-4}	y_{t-5}
6	data ₆	data ₅	data ₄	data ₃	data ₂	data ₁
7	data ₇	data ₆	data ₅	data ₄	data ₃	data ₂
⋮	⋮	⋮	⋮	⋮	⋮	⋮
526	data ₅₂₆	data ₅₂₅	data ₅₂₄	data ₅₂₃	data ₅₂₂	data ₅₂₁

kegiatan memprediksi atau meramal atau memperkirakan nilai pada masa yang akan datang dengan menggunakan data masa lalu [14].

C. Support Vector Regression (SVR)

SVR digunakan untuk menemukan suatu fungsi yang memiliki deviasi paling besar ϵ dari target aktual y_i . SVR digunakan pada kasus regresi yang menghasilkan *output* berupa bilangan riil dan kontinu. Penggunaan metode SVR mempunyai kelebihan dibandingkan metode *Linier Regression* (regresi linier) yaitu jika regresi linier menghasilkan fungsi linier yang berupa garis lurus, pada algoritma SVR menghasilkan *trend* data yang bergelombang mengikuti jalur data yang terbentuk, sehingga prediksi data yang dihasilkan lebih akurat [15]. Diberikan fungsi linier f sebagai berikut

$$f(x) = \langle w, x \rangle + b, w \in X, b \in \mathbb{R} \quad (1)$$

dengan

$$w = \sum_{i=1}^{\ell} (\alpha_i - \alpha_i^*) x_i. \quad (2)$$

Maka fungsi regresi dapat dirumuskan sebagai berikut.

$$f(x) = \sum_{i=1}^{\ell} (\alpha_i - \alpha_i^*) \langle x_i, x \rangle + b. \quad (3)$$

Apabila terdapat ℓ data *training*, $(x_i, y_i), i = 1, \dots, \ell$ dengan data input $x = \{x_1, \dots, x_{\ell}\} \subseteq \mathbb{R}^N$ dan data output $y = \{y_1, \dots, y_{\ell}\} \subseteq \mathbb{R}$ dan ℓ adalah banyaknya data *training*, dan fungsi regresi linier dari SVR diberikan sebagai berikut,

$$f(x) = w^T \varphi(x) + b \quad (4)$$

dengan $\varphi(x)$ merupakan fungsi yang memetakan x dalam suatu dimensi, w adalah vektor pembobot, dan b adalah bias, maka secara eksplisit fungsi regresi dapat dirumuskan sebagai berikut [16].

$$f(x) = \sum_{i=1}^{\ell} (\alpha_i - \alpha_i^*) K(x_i, x) + b \quad (5)$$

Dimana $K(x_i, x)$ adalah fungsi kernel yang memiliki nilai *inner product* dari dua vektor x_i dan x , selisih antara α_i dan α_i^* menghasilkan nilai beta dan b adalah bias.

D. Kernel

Fungsi Kernel adalah metode untuk memecahkan masalah non-linier dengan memetakan dataset ke ruang dimensi yang lebih tinggi (*higher-dimensional*). Dengan metode kernel suatu data x di *input space* dipetakan ke *feature space* dengan dimensi yang lebih tinggi melalui φ [17].

$$\varphi: x \rightarrow \varphi(x) \quad (6)$$

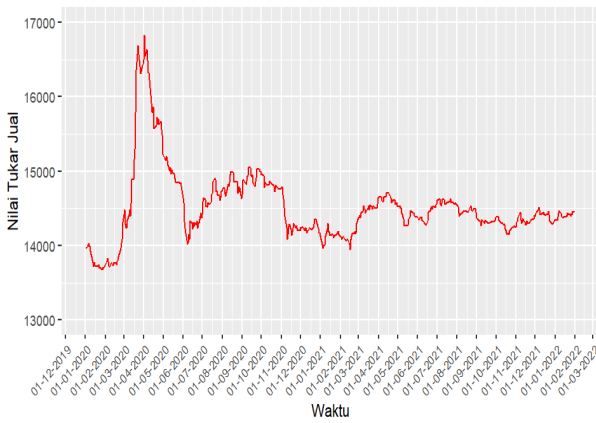
a. Kernel Linear: Kernel linier dapat dituliskan sebagai berikut [8].

$$K(x, y) = x^T y + c \quad (7)$$

b. Kernel *Polynomial*: Kernel polinomial dapat dituliskan sebagai berikut [8].

$$K(x, y) = (\alpha x^T y + c)^d \quad (8)$$

c. Kernel *Radial Basis Function* (RBF): Kernel *Radial Basis Function* (RBF) dapat dituliskan sebagai berikut [8].



Gambar 1. Grafik Data Nilai tukar Jual Dolar Amerika terhadap Rupiah.

$$K(x, y) = \exp(-\gamma \|x - y\|^2) \tag{9}$$

E. Genetic Algorithm (GA)

Algoritma genetika menerapkan versi sederhana dari evolusi Darwin yang terjadi di alam. yaitu mereka yang beradaptasi lebih baik dengan lingkungannya memiliki peluang lebih besar untuk bertahan hidup, berkembang biak, dan mewariskan sifat-sifat mereka ke generasi berikutnya [18-19].

Prosedur awal yang harus dilakukan yaitu membuat populasi awal (*initial population*), menentukan rumusan fungsi *fitness*, dan menetapkan nilai parameter yang berupa ukuran populasi, jumlah iterasi, peluang pindah silang, peluang mutasi, dan elitism [10].

GA memiliki 7 tahapan utama yang perlu dilakukan. *Pertama*, didefinisikan variabel yang dianggap sebagai kromosom. *Kedua*, dilakukan inisialisasi jumlah populasi sebesar P dari N kromosom yang mengandung solusi. *Ketiga*, *Fitness Function* digunakan untuk mengevaluasi daya tahan untuk hidup dari sebuah kromosom. *Keempat*, seleksi untuk mendapatkan calon orang tua yang akan dipindah silangkan pada tahapan berikutnya. *Kelima*, pindah silang yaitu memasang dua kromosom yang telah terpilih pada tahap sebelumnya dan menukarkan satu sel dari tiga sel antar kromosom tersebut sehingga menghasilkan dua kromosom baru. *Keenam*, mutasi dimana setiap kromosom diberi sebuah bilangan random yang berdistribusi uniform (0,1). Jika nilai bilangan random yang dimiliki kromosom tersebut bernilai lebih kecil dari nilai peluang mutasi maka kromosom tersebut merupakan kromosom yang mengalami mutasi. *Ketujuh*, *replace*, dimana semua kromosom, hasil pindah silang dan mutasi, yang dimiliki akan dihitung nilai dari *fitness function*-nya, mengurutkan kromosom dari nilai *fitness* terbesar hingga terkecil, dan mengambil N kromosom dengan nilai *fitness* tertinggi sebagai generasi baru. *Kedelapan*, *test* atau jika *stopping criteria* telah terpenuhi maka iterasi dapat dihentikan dan jika belum maka akan kembali pada tahap kedua.

F. Particle Swarm Optimizaation (PSO)

Algoritma optimasi lainnya adalah *Particle Swarm Optimization* (PSO) yang mengambil inspirasi dari pengelompokan alami organisme individu. Partikel atau individu bergerak di ruang pencarian, mencari solusi terbaik, dan pergerakannya diatur oleh aturan sederhana yang

melibatkan posisi dan kecepatannya (kecepatan arah) [19]. Berikut ini adalah langkah yang dilakukan dalam *Particle Swarm Optimization*.

1. Mendefinisikan jumlah partikel, batas iterasi maksimum, bobot inersia (*w*), batas maksimum kecepatan (*v_{max}*), koefisien komponen tiap partikel (*C₁*) dan koefisien semua partikel (*C₂*).
2. Menginisialisasi vektor posisi dari setiap partikel. Dimensi dari partikel PSO ditentukan dari jumlah parameter yang akan dioptimasi. Pada penelitian ini parameter yang dioptimasi adalah *C* (Cost) dan ϵ (epsilon), γ (gamma). Sehingga vektor posisi terbentuk dalam vektor berukuran 3 x 1. Posisi parameter akan di *generate* secara random diantara *range* parameter yang digunakan.
3. Menentukan *fitness function* yang merupakan kandungan jumlah makanan. *Fitness function* yang digunakan adalah MAPE. Dari N vektor posisi dihitung nilai *fitness*-nya dan kemudian diurutkan dari nilai terkecil hingga terbesar.
4. Melakukan pergeseran partikel dengan menggunakan persamaan berikut.

$$X_j(i) = X_j(i - 1) + V_j(i); j = 1, 2, \dots, N \tag{10}$$

Vektor posisi suatu partikel akan ditambah dengan vektor kecepatan dan menjadi sebuah posisi baru. Vektor kecepatan tersebut dihitung dengan persamaan berikut.

$$V_j(i) = wV_j(i - 1) + c_1r_1[P_{best,j} - x_j(i - 1)] + c_2r_2[G_{best} - x_j(i - 1)]; \tag{11}$$

dengan $j=1, 2, \dots, N$, dimana *P_{best}* atau *local best* merupakan nilai *fitness* terbaik dari suatu partikel dan *G_{best}* atau *global best* merupakan nilai *fitness* terbaik dari keseluruhan partikel. Setelah dilakukan pergeseran, selanjutnya dihitung nilai *fitness* dari posisi partikel yang baru.

Langkah-langkah diatas diulang hingga mencapai batas iterasi atau hingga semua partikel menghasilkan *fitness* yang konvergen.

G. Normalisasi Data

Untuk menghindari penyimpangan data yang terlalu jauh atau data yang dinilai kurang baik sebelum proses perhitungan dilakukan tahap *pre-processing* data untuk memastikan data mentah yang diambil cocok untuk digunakan pada suatu pemodelan tertentu. Keseluruhan data akan dinormalisasi dengan fungsi linier sebagai berikut [20].

$$X' = \frac{x - x_{min}}{x_{min,max}} \tag{12}$$

Dimana *X'* adala hasil normalisasi dengan nilai antara 0 sampai 1, *x* aalah data asli, *x_{min}* adalah nilai minimum dari data asli, dan *x_{max}* adalah nilai maksimum dari data asli.

H. Nilai Akurasi Peramalan

Pada penelitian ini digunakan nilai tengah galat persentase absolut *Mean Absolute Percentage Error* (MAPE) sebagai alat untuk menganalisis tingkat *error* [21]. Skala akurasi peramalan ditunjukkan oleh Tabel 1. Semakin kecil nilai MAPE yang dihasilkan maka semakin baik dan akurat pula model tersebut untuk digunakan. Persamaan MAPE dapat dilihat pada persamaan sebagai berikut [12].

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{X_i - F_i}{X_i} \right| \times 100\% \tag{13}$$

Tabel 3.
Pola Data *Testing* dan *Training*

	t	y_t (target)	y_{t-1}	y_{t-2}	y_{t-3}	y_{t-4}	y_{t-5}
<i>Training</i>	6	data ₆	data ₅	data ₄	data ₃	data ₂	data ₁
	7	data ₇	data ₆	data ₅	data ₄	data ₃	data ₂
	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	422	data ₄₂₂	data ₄₂₁	data ₄₂₀	data ₄₁₉	data ₄₁₈	data ₄₁₇
<i>Testing</i>	423	data ₄₂₃	data ₄₂₂	data ₄₂₁	data ₄₂₀	data ₄₁₉	data ₄₁₈
	424	data ₄₂₄	data ₄₂₃	data ₄₂₂	data ₄₂₁	data ₄₂₀	data ₄₁₉
	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	526	data ₅₂₆	data ₅₂₅	data ₅₂₄	data ₅₂₃	data ₅₂₂	data ₅₂₁

III. METODOLOGI PENELITIAN

A. Data dan Variabel Penelitian

Data yang digunakan merupakan data sekunder yang diambil dari laman resmi Bank Indonesia (BI) berupa nilai tukar jual harian dolar Amerika terhadap rupiah periode 1 Januari 2021 hingga 31 Januari 2022 sebanyak 526 data. Variabel yang digunakan adalah nilai tukar jual harian dolar Amerika terhadap rupiah. Variabel yang digunakan adalah variabel dependen (y_t) adalah data nilai tukar jual harian dolar Amerika terhadap rupiah yang dijadikan sebagai target. Variabel independen (x) adalah data nilai tukar jual harian dolar Amerika terhadap rupiah pada waktu sebelumnya ($y_{t-1}, y_{t-2}, \dots, y_{t-n}$). Struktur data penelitian ditunjukkan oleh Tabel 2.

B. Langkah Analisis

Pada penelitian ini akan dilakukan analisis menggunakan metode *Support Vector Regression* (SVR) dengan tiga kernel yaitu *Linear*, *Polynomial*, dan *Radial Basis Function* (RBF), dimana parameter yang dioptimasi adalah C (*cost*), γ (*gamma*), dan ϵ (*epsilon*). Kernel yang memberikan hasil terbaik, kemudian dioptimasi menggunakan *Support Vector Regression - Genetic Algorithm* (SVR-GA) dan *Support Vector Regression - Particle Swarm Optimization* (SVR-PSO), dimana akan dihasilkan parameter yang optimal berdasarkan nilai MAPE terkecil. Langkah dalam analisis menggunakan SVR adalah sebagai berikut.

1. Mengunduh data nilai tukar jual harian dolar Amerika terhadap rupiah.
2. Melakukan normalisasi data.
3. Membagi data menjadi 80% data training dan 20% data testing dan menyusun data.
4. Menentukan kombinasi nilai parameter C , γ dan ϵ untuk kernel Linier, Polynomial, dan Radial Basis Function (RBF).
5. Melakukan training pada model SVR.
6. Menerapkan model SVR pada prediksi data testing.
7. Melakukan denormalisasi menggunakan persamaan (12) pada hasil prediksi.
8. Mengevaluasi model dengan MAPE menggunakan persamaan (13).
9. Membandingkan nilai MAPE setiap kernel dan mencari yang terkecil
10. Menghasilkan kernel terbaik dengan nilai MAPE terkecil dan parameter SVR.
11. Parameter SVR terbaik akan dioptimasi menggunakan SVR-GA dan SVR-PSO.

12. Membandingkan hasil akhir dari optimasi menggunakan SRV-GA dan SVR-PSO dan mencari hasil terbaik

Langkah dalam analisis menggunakan SVR-GA adalah sebagai berikut.

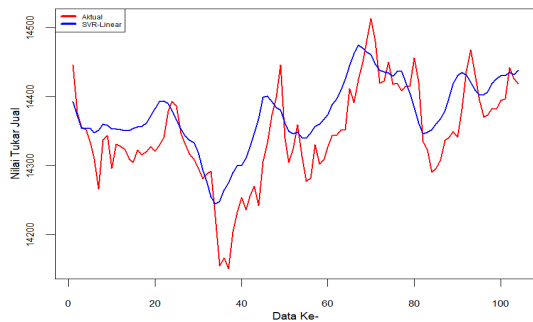
1. Menggunakan nilai parameter (C , γ dan ϵ) yang didapatkan dari metode SVR sebelumnya sebagai *good initial value*.
2. Menyusun kromosom dan inialisasi parameter yang diperlukan dalam optimasi GA.
3. Menentukan fitness function dima fitness function yang digunakan adalah nilai MAPE.
4. Melakukan pemilihan orang tua menggunakan seleksi *roulette wheel*.
5. Melakukan pindah silang pada individu yang terpilih sebagai orang tua dan mendapatkan individu baru.
6. Melakukan mutasi pada individu.
7. Mempertahankan individu dengan nilai fitness terbaik.
8. Melakukan tahapan hingga iterasi berakhir.
9. Mendapatkan nilai optimal dari nilai parameter SVR.
10. Melakukan training pada model SVR.
11. Menerapkan model SVR pada prediksi data testing.
12. Melakukan denormalisasi menggunakan persamaan (12) pada hasil prediksi.
13. Mengevaluasi model dengan MAPE dengan MAPE menggunakan persamaan (13).

Langkah dalam analisis menggunakan SVR-PSO adalah sebagai berikut.


1. Menggunakan nilai parameter (C , γ dan ϵ) yang didapatkan dari metode SVR sebelumnya.
2. Mendefinisikann parameter-parameter yang digunakan dalam PSO.
3. Menentukan posisi (*position*) dari partikel dan kecepatan (*velocity*) dari partikel.
4. Melakukan *training* SVR.
5. Menghitung fungsi objektif dari proses *training*.
6. Perhitungan fungsi objektif, dapat diketahui *local best fitness* dan *local best position*.
7. Mencari nilai *global best fitness*.
8. Menentukan *global best position*.
9. Memperbarui kecepatan dan posisi partikel.
10. Mengulangi langkah 4 sampai 9 hingga syarat batas iterasi terpenuhi.
11. Mendapatkan nilai optimal dari nilai parameter SVR.
12. Melakukan *training* pada model SVR.
13. Menerapkan model SVR pada prediksi data *testing*.
14. Melakukan denormalisasi hasil prediksi menggunakan persamaan (12).
15. Mengevaluasi model dengan MAPE menggunakan persamaan (13).

Tabel 4.
Kombinasi Nilai Parameter


Cost (C)	Gamma (γ)	Epsilon (ϵ)
0,001	10	1
0,01	1	0,1
0,1	0,1	0,01
1	0,01	0,001
10	0,001	0,0001
100	0,0001	
1000		



Gambar 2. Plot Data Aktual dan Prediksi dengan Metode SVR Kernel Linear.



Gambar 3. Plot Data Aktual dan Prediksi dengan Metode SVR Kernel Polynomial.



Gambar 4. Plot Data Aktual dan Prediksi dengan Metode SVR Kernel RBF.

IV. HASIL DAN PEMBAHASAN

A. Analisis Deskriptif

Untuk melihat pola data nilai tukar jual dolar Amerika terhadap rupiah periode 1 Januari 2021 hingga 31 Januari 2022. Gambar 1 memperlihatkan pola data *trend* yang naik pada kuartal pertama tahun 2020, dan *trend* turun hingga kuartal kedua tahun 2020, dan mengalami *trend* naik turun pada periode berikutnya. Kurs jual terendah berada pada tanggal 27 Januari 2020 yaitu sebesar Rp 13.680,06 yang artinya mata uang rupiah menguat dikarenakan pelemahan mata uang dolar Amerika. Kurs jual tertinggi berapa pada tanggal 2 April 2020 yaitu sebesar Rp 16.824,71, yang artinya mata uang rupiah melemah dikarenakan pelemahan mata uang Dolar Amerika. Faktor yang mendorong pelemahan Rupiah adalah sejak diumumkannya kasus pertama COVID-19 pada 2 Maret 2020, sehingga Rupiah mulai melemah. Setelah itu Rupiah mulai kembali menguat pada kisaran Rp 15.000 hingga Rp 14.000. Rata-rata dari kurs jual yaitu sebesar Rp 14.508,29, kuartil pertama yaitu sebesar Rp 14.259,95, median sebesar Rp 14.414,72, kuartil ketiga sebesar Rp 14.648,63, dan standar deviasi sebesar Rp 490,2716.

B. Prapemrosesan Data

Sebelum dilakukan analisis, data terlebih dahulu diproses sehingga dapat maksimal saat digunakan. Data diolah menggunakan *software* Microsoft Excel dan RStudio. Berikut adalah tahapan prapemrosesan data.

1) Normalisasi

Data nilai tukar pada Microsoft Excel terlebih dahulu dilakukan normalisasi dengan rentang 0 sampai 1 menggunakan persamaan (16). Hal ini dikarenakan SVR akan bekerja lebih efektif dengan data yang memiliki rentang skala yang kecil.

2) Penyusunan dan Pembagian Data

Data yang telah dinormalisasi, kemudian disusun menjadi

data *training* sebesar 80% dan data *testing* sebesar 20% seperti pada Tabel 3.

C. Analisis Menggunakan SVR

Pada analisis menggunakan SVR, *Package* R yang digunakan adalah e1071. Pada analisis ini dengan kernel *Linear*, *Polynomial*, dan *Radial Basis Function* (RBF), digunakan beberapa kombinasi dari nilai parameter C , γ , dan ϵ , dimana dilakukan *training* pada model SVR. Berikut adalah nilai-nilai dari parameter-parameter yang dikombinasikan pada penelitian ini. Dari Tabel 4 dihasilkan beberapa kombinasi nilai dan satu-persatu di-*training* pada model SVR. Selanjutnya dilakukan prediksi pada data *testing* berdasarkan model SVR tersebut. Data prediksi yang didapatkan didenormalisasi terlebih dahulu dan selanjutnya dihitung nilai MAPE untuk melihat kebaikan model yang didapatkan.

1) Kernel Linear


Pada analisis SVR menggunakan kernel *linear*, dengan mengombinasikan nilai C dan ϵ berdasarkan nilai pada Tabel 4, dihasilkan kombinasi sebanyak 35 kombinasi nilai C dan ϵ . Kombinasi-kombinasi tersebut satu-persatu di-*training* pada model SVR dan dihitung nilai MAPE-nya. Dari analisis yang telah dilakukan didapatkan hasil bahwa kombinasi nilai C sebesar 0,001 dan ϵ sebesar 0,01 memiliki nilai MAPE terkecil yaitu sebesar 0,2825132%. *Plot* dari data aktual dan prediksi SVR untuk kernel *linear* ditunjukkan oleh Gambar 2. Dapat diketahui bahwa *plot* SVR kernel *linear* memiliki bentuk *plot* yang mendekati bentuk *plot* dari data aktual. Dengan nilai MAPE yang didapatkan, hasil prediksi dapat dikatakan sangat baik atau *highly accurate* karena nilai MAPE berada dibawah 10%.

2) Kernel Polynomial

Pada analisis SVR menggunakan kernel *polynomial*, dengan mengombinasikan nilai C , γ , dan ϵ berdasarkan nilai pada Tabel 4, dihasilkan kombinasi sebanyak 210 kombinasi

Tabel 5.
Nilai MAPE dan Parameter SVR

Kernel	C	γ	ϵ	Training	Testing
Linear	0,001	-	0,01	0,7493505	0,2825132
Polynomial	10	1	0,01	2,0235250	0,3753359
RBF	0,1	0,01	0,01	0,7142588	0,2187573



Gambar 5. Plot Data Aktual dan Prediksi SVR.

nilai C , γ , dan ϵ . Kombinasi-kombinasi tersebut satu-persatu di-training pada model SVR dan selanjutnya dihitung nilai MAPE-nya. Dari analisis yang telah dilakukan didapatkan hasil bahwa kombinasi nilai C sebesar 10, γ sebesar 1, dan ϵ sebesar 0,01 memberikan nilai MAPE terkecil yaitu sebesar 0,3753359%. Plot dari data aktual dan prediksi SVR untuk kernel *polynomial* ditunjukkan oleh Gambar 3. Dapat diketahui bahwa plot SVR kernel *polynomial* memiliki bentuk plot yang mendekati bentuk plot dari data aktual. Dengan nilai MAPE yang didapatkan, hasil prediksi dapat dikatakan sangat baik atau *highly accurate* karena nilai MAPE berada dibawah 10%.


3) Kernel Radial Basis Function (RBF)

Pada analisis SVR menggunakan kernel RBF, dengan mengombinasikan nilai C , γ , dan ϵ berdasarkan nilai pada Tabel 4, dihasilkan kombinasi sebanyak 210 kombinasi nilai C , γ , dan ϵ . Kombinasi-kombinasi tersebut satu-persatu di-training pada model SVR dan selanjutnya dihitung nilai MAPE untuk melihat kebaikan model. Dari analisis yang telah dilakukan didapatkan hasil bahwa kombinasi nilai C sebesar 0,1, γ sebesar 0,01, dan ϵ sebesar 0,01 memberikan nilai MAPE terkecil yaitu sebesar 0,218757%. Plot dari data aktual dan prediksi SVR untuk kernel RBF ditunjukkan oleh Gambar 4. Dapat diketahui bahwa plot SVR kernel RBF memiliki bentuk plot yang mendekati bentuk plot dari data aktual. Dengan nilai MAPE yang didapatkan, hasil prediksi dapat dikatakan sangat baik atau *highly accurate* karena nilai MAPE berada dibawah 10%.


4) Perbandingan Antara SVR Kernel Linear, Polynomial, dan RBF

Berdasarkan uji coba yang telah dilakukan, berikut adalah nilai parameter dengan MAPE terbaik yang didapatkan untuk setiap jenis kernel yang dipakai pada analisis SVR. Dari Tabel 5 dapat diketahui bahwa kernel RBF memberikan nilai MAPE terbaik yaitu sebesar 0,7142588 % pada data *training*, dan 0,2187573 % pada data *testing*, dengan kombinasi nilai C sebesar 0,1, nilai γ sebesar 0,01, dan nilai ϵ sebesar 0,01. Gambar 5 adalah plot hasil prediksi pada data *testing* untuk setiap kernel dan data aktual.

Berdasarkan Gambar 5 dapat diketahui bahwa plot kernel *Linear* dan RBF memiliki bentuk plot yang mendekati bentuk



Gambar 6. Plot Data Aktual dan Prediksi dengan Metode SVR-RBF-GA.



Gambar 7. Plot Data Aktual dan Prediksi dengan Metode SVR-RBF-PSO.

plot dari data aktual, daripada kernel *Polynomial*. Akan tetapi, jika dilihat juga dari nilai MAPE yang didapatkan, model SVR dengan kernel RBF memberikan hasil yang terbaik. Maka dapat ditarik kesimpulan model SVR dengan kernel RBF pada proses *training* memiliki keakuratan yang baik saat diuji menggunakan data *testing* dengan pemilihan kombinasi nilai parameter yang dilakukan secara *trial* dan *error*. Pengambilan secara *trial* dan *error*, belum tentu memberikan hasil yang terbaik dan optimal. Sehingga, pada tahapan analisis selanjutnya dilakukan optimasi parameter menggunakan SVR-GA dan SVR-PSO.

D. Optimasi Parameter SVR

Metode optimasi yang digunakan pada penelitian ini adalah menggunakan *Genetic Algorithm* dan *Particle Swarm Optimization*. Package R yang digunakan adalah *e1071* untuk SVR dan GA untuk *Genetic Algorithm* dan *psoptim* untuk *Particle Swarm Optimization*.

1) Optimasi Menggunakan SVR-GA

Pada optimasi parameter SVR menggunakan *Genetic Algorithm*, jumlah populasi yang digunakan adalah sebanyak 100 kromosom dengan batas iterasi maksimum sebanyak 20 iterasi. Untuk peluang pindah silang adalah 0,8 dan peluang terjadi mutasi adalah 0,1. Kromosom yang terpilih dalam proses *elitism* sebanyak lima kromosom.

Pada analisis SVR sebelumnya, didapatkan bahwa SVR dengan kernel *Radial Basis Function* (RBF) memberikan nilai MAPE paling kecil. Parameter yang dioptimasi yaitu C (*Cost*), γ (*gamma*), dan ϵ (*epsilon*), sehingga kromosom terbentuk dari vektor 3 x 1. Pada analisis ini digunakan *range* parameter yaitu 0,01-0,1 untuk C , 0,001-0,01 untuk γ , dan 0,001-0,01 untuk ϵ . Kemudian di-generate sebanyak jumlah populasi. Nilai-nilai tersebut diproses sesuai tahapan dalam *Genetic Algorithm*, hingga iterasi berakhir. Setelah proses optimasi selesai, didapatkan nilai parameter terbaik yaitu nilai C sebesar 0,09629636, γ sebesar 0,008874816, dan ϵ sebesar 0,009756693, dengan nilai MAPE sebesar 0,2184038

Tabel 6.
Nilai MAPE dan Parameter Optimal SVR, SVR-GA, dan SVR-PSO

Metode	SVR-RBF	SVR-GA-RBF	SVR-PSO-RBF
Parameter Optimal			
C	0,1	0,09629636	0,04036283
γ	0,01	0,008874816	0,058223
ϵ	0,01	0,009756693	0,03975945
MAPE (%)			
Training	0,7142588	0,7242439	0,9362159
Testing	0,2187573	0,2184038	0,2319654

% Plot data aktual dan data prediksi terhadap data testing dari SVR-RBF-GA ditunjukkan oleh Gambar 6.

Melalui Gambar 6 dapat diketahui bahwa plot SVR-GA kernel RBF memiliki bentuk plot yang mendekati bentuk plot dari data aktual. Dengan nilai MAPE yang didapatkan, hasil prediksi dapat dikatakan sangat baik karena nilai MAPE berada dibawah 10%.

2) Optimasi Menggunakan SVR-PSO


Pada optimasi parameter SVR menggunakan Particle Swarm Optimization, jumlah partikel (N) yang digunakan sebanyak 20 partikel dengan batas iterasi maksimum adalah 50 iterasi. Bobot inersia (w) bernilai 0,9 dan batas kecepatan maksimum $v_{max} = [0.1, 0.01, 0.01]$. C_1 dan C_2 bernilai sama dengan 2.

Vektor posisi dari setiap partikel diinisialisasi. Pada tahap ini digunakan kernel Radial Basis Function dari analisis SVR sebelumnya, dimana parameter yang dioptimasi yaitu C (Cost), γ (gamma), dan ϵ (epsilon), sehingga kromosom terbentuk dari vektor 3 x 1. Range nilai parameter yang digunakan yaitu 0,01-0,1 untuk C , 0,001-0,01 untuk γ , dan 0,001-0,01 untuk ϵ . Nilai-nilai tersebut diproses sesuai tahapan dalam Particle Swarm Optimization, hingga iterasi berakhir. Setelah proses optimasi selesai, didapatkan nilai parameter terbaik yaitu nilai C sebesar 0,04036283, γ sebesar 0,058223, dan ϵ sebesar 0,03975945, dengan nilai MAPE sebesar 0,2319654 %. Plot data aktual dan data prediksi terhadap data testing dari SVR-RBF-PSO ditunjukkan oleh Gambar 7. Dapat diketahui bahwa plot SVR-PSO kernel RBF memiliki bentuk plot yang mendekati bentuk plot dari data aktual. Dengan nilai MAPE yang didapatkan, hasil prediksi dapat dikatakan sangat baik karena nilai MAPE berada dibawah 10%.

E. Perbandingan Hasil Antara SVR, SVR-GA, dan SVR-PSO

Setelah dilakukan optimasi parameter SVR kernel RBF menggunakan SVR-GA dan SVR-PSO, maka didapatkan hasil pada Tabel 6. Dari Tabel 6 dapat diketahui bahwa optimasi menggunakan SVR-GA memberikan hasil yang terbaik, didasarkan pada nilai MAPE pada data testing yang dihasilkan lebih kecil daripada SVR-PSO, dan SVR sebelum dilakukan optimasi, yaitu sebesar 0,7242439 % pada data training, dan 0,2184038 % pada data testing, dengan kombinasi nilai C sebesar 0,09629636, nilai γ sebesar 0,008874816, dan nilai ϵ sebesar 0,009756693. Hasil plot hasil prediksi pada data testing dari SVR-RBF, SVR-GA-RBF, SVR-PSO-RBF, dan data actual ditunjukkan oleh Gambar 8.

Berdasarkan Gambar 8 dapat diketahui bahwa plot SVR, SVR-GA, dan SVR-PSO memiliki bentuk plot yang mendekati bentuk plot dari data aktual. Akan tetapi, jika



Gambar 8. Plot Data Aktual Prediksi dengan Metode SVR-RBF, SVR-RBF-GA, SVR-RBF-PSO.

dilihat juga dari nilai MAPE yang didapatkan, model SVR-GA memberikan hasil yang terbaik. Maka dapat dikatakan bahwa model SVR-GA pada proses training memiliki keakuratan yang baik saat di uji dengan menggunakan data testing. Setelah dilakukannya optimasi dengan GA, parameter SVR untuk kernel RBF memberikan nilai MAPE lebih kecil daripada sebelum dilakukan optimasi. Maka dapat dikatakan juga metode SVR-GA dengan kernel RBF berhasil mengoptimasi parameter SVR pada data nilai tukar jual dolar Amerika terhadap rupiah periode 1 Januari 2021 hingga 31 Januari 2022.

V. KESIMPULAN DAN SARAN

A. Kesimpulan

Setelah dilakukan analisis dan pembahasan pada Bab IV, berikut adalah kesimpulan yang dapat diambil dari penelitian ini yang berkaitan dengan latar belakang dan tujuan penelitian. Pada analisis Support Vector Regression dengan kernel Linear, Polynomial, dan Radial Basis Function didapatkan hasil bahwa kernel Radial Basis Function (RBF) memberikan nilai MAPE terkecil yaitu sebesar 0,7142588% pada data training, dan 0,2187573% pada data testing, dengan kombinasi nilai C (cost) sebesar 0,1, nilai γ (gamma) sebesar 0,01, dan nilai ϵ (epsilon) sebesar 0,01. Pada optimasi menggunakan Support Vector Regression (SVR) - Genetic Algorithm (GA) dan Support Vector Regression (SVR) - Particle Swarm Optimization (PSO) dengan kernel RBF, nilai MAPE terkecil diberikan pada metode SVR-GA yaitu sebesar 0,7242439% pada data training, dan 0,2184038% pada data testing dengan nilai parameter optimal C sebesar 0,09629636, nilai γ sebesar 0,008874816, dan nilai ϵ sebesar 0,009756693. Metode SVR-GA dengan kernel RBF berhasil mengoptimasi parameter SVR pada data nilai tukar jual dolar Amerika terhadap rupiah periode 1 Januari 2021 hingga 31 Januari 2022.

B. Saran

Berdasarkan hasil analisis yang telah dilakukan, berikut adalah saran untuk pengembangan di masa yang akan datang. Menerapkan algoritma optimasi selain Genetic Algorithm dan Particle Swarm Optimization, seperti Butterfly Optimization Algorithm (BAO). Menggunakan kombinasi nilai parameter SVR selain C (cost), γ (gamma), dan ϵ (epsilon), seperti parameter coefficient Learning Rate (cLR) dan sigma (σ), sehingga dapat memberikan hasil yang lebih baik. Menambahkan variabel berupa faktor eksternal yang memengaruhi nilai tukar jual dolar Amerika terhadap rupiah, seperti inflasi dan tingkat suku bunga.

DAFTAR PUSTAKA

- [1] S. Sukirno, *Pengantar Teori Makroekonomi*. Jakarta: PT. RajaGrafindo Persada, ISBN: 979-421-413-2, 2001.
- [2] Haryanto, "Dampak Covid-19 terhadap pergerakan nilai tukar Rupiah dan indeks harga saham gabungan (IHSG)," *J. Perenc. Pembang. Indones. J. Dev. Plan.*, vol. 4, no. 2, pp. 151–165, Jun. 2020, doi: 10.36574/jpp.v4i2.114.
- [3] Bank Indonesia, *Laporan Perekonomian Indonesia 2021*. Jakarta: Bank Indonesia, 2021.
- [4] R. M. Putri and E. Widodo, "Application of Support Vector Machine Method for Rupiah Exchange Rate to US Dollar Forecasting," in *Seminar Nasional Edusainstek FMIPA UNIMUS 2018*, 2018, pp. 27–36.
- [5] Z. Ramedani, M. Omid, A. Keyhani, B. Khoshnevisan, and H. Saboohi, "A comparative study between fuzzy linear regression and support vector regression for global solar radiation prediction in Iran," *Sol. Energy*, vol. 109, pp. 135–143, Nov. 2014, doi: 10.1016/j.solener.2014.08.023.
- [6] R. A. Putri, W. S. Winahju, and M. Mashuri, "Penerapan metode ridge regression dan support vector regression (SVR) untuk prediksi indeks batubara di PT XYZ," *J. Sains dan Seni ITS*, vol. 9, no. 1, Jun. 2020, doi: 10.12962/j23373520.v9i1.51021.
- [7] M. Awad and R. Khanna, *Efficient Learning Machines*. Berkeley, CA: Apress, ISBN: 978-1-4302-5989-3, 2015.
- [8] M. Alida and M. Mustikasari, "Rupiah exchange prediction of US Dollar using linear, polynomial, and radial basis function kernel in support vector regression," *JOIN (Jurnal Online Inform.)*, vol. 5, no. 1, pp. 53–60, 2020, doi: 10.15575/join.v5i1.537.
- [9] F.-C. Yuan, "Parameters optimization uUsing genetic algorithms in support vector regression for sales volume forecasting," *Appl. Math.*, vol. 03, no. 10, pp. 1480–1486, 2012, doi: 10.4236/am.2012.330207.
- [10] A. S. Wijaya, "Optimasi Parameter Model Support Vector Regression Untuk Pemodelan Beban Listrik di Empat Belas Wilayah di Jawa Timur Dengan Menggunakan Genetic Algorithm dan Particle Swarm Optimization," Departemen Statistika, Institut Teknologi Sepuluh Nopember, Surabaya, 2017.
- [11] Z. Rustam and P. Kintandani, "Application of support vector regression in Indonesian stock price prediction with feature selection using particle swarm optimisation," *Model. Simul. Eng.*, vol. 2019, pp. 1–5, Apr. 2019, doi: 10.1155/2019/8962717.
- [12] A. Rinaldy, "Peramalan Kurs Eur/Usd Pada Pasar Forex Online Menggunakan Support Vector Regression Yang Dioptimasi Dengan Algoritma Particle Swarm Optimization," Departemen Matematika, Institut Teknologi Sepuluh Nopember, Surabaya, 2015.
- [13] F. Syarifuddin, *Konsep, Dinamika, dan Respon Kebijakan Nilai Tukar di Indonesia*. Jakarta: BI Institute, 2015.
- [14] M. Kafil, "Penerapan metode K-Nearst neighbors untuk prediksi penjualan berbasis web pada Boutiq Dealove Bondowoso," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 3, no. 2, pp. 59–66, Sep. 2019, doi: 10.36040/jati.v3i2.860.
- [15] R. E. Cahyono, J. P. Sugiono, and S. Tjandra, "Analisis kinerja metode support vector regression (SVR) dalam memprediksi indeks harga konsumen," *JTIM J. Teknol. Inf. dan Multimed.*, vol. 1, no. 2, pp. 106–116, Aug. 2019, doi: 10.35746/jtim.v1i2.22.
- [16] A. J. Smola and B. Schölkopf, "A tutorial on support vector regression," *Stat. Comput.*, vol. 14, pp. 199–222, 2004.
- [17] R. Amanda, H. Yasin, and A. Prahutama, "Analisis support vector regression (SVR) dalam memprediksi kurs Rupiah terhadap Dollar Amerika Serikat," *J. Gaussian*, vol. 3, no. 4, pp. 849–858, 2014, doi: <https://doi.org/10.14710/j.gauss.3.4.849-858>.
- [18] F. Jiang and W. Wu, "Hybrid Genetic Algorithm and Support Vector Regression Performance in CNY Exchange Rate Prediction," 2016, doi: 10.2991/esm-16.2016.32.
- [19] E. Wirsansky, *Hands-On Genetic Algorithms with Python*. Birmingham: Packt, ISBN: 9781838557744, 2020.
- [20] M. Azzahra, B. D. Setiawan, and P. P. Adikara, "Optimasi parameter support vector regression dengan algoritme genetika untuk prediksi harga emas," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 2, no. 1, pp. 273–281, 2017.
- [21] R. E. Caraka, H. Yasin, and A. W. Basyiruddin, "Peramalan crude palm oil (CPO) menggunakan support vector regression kernel radial basis," *J. Mat.*, vol. 7, no. 1, p. 43, Jun. 2017, doi: 10.24843/JMAT.2017.v07.i01.p81.