

Evaluation of Support Vector Regression Methods in Predictions Bitcoin's Close Price

Wulan Septya Zulmawati, Nonong Amalita*, Syafrandi, Admi Salma

Departemen Statistika, Universitas Negeri Padang, Padang, Indonesia

*Corresponding author: nongmat@fmipa.unp.ac.id

Submitted : 11 Oktober 2023

Revised : 30 Oktober 2023

Accepted : 30 November 2023

ABSTRACT

Cryptocurrency provides the most return compared to other investment instruments, causing many novice traders to be attracted to crypto as a tool to make significant profits in the short term. One of the most widely used cryptocurrencies is Bitcoin. Trading is closely related to technical analysis. Various techniques in technical analysis cause beginner traders to have difficulties choosing the right technique. Machine learning methods can be an alternative to overcoming the barriers of beginner traders in the crypto market with predictive methods. One method of machine learning for prediction is Support Vector Regression (SVR). Using the grid search algorithm shows that this method has a good predictive accuracy value of 99,25% and MAPE 0,1206%.

Keywords: *Bitcoin, Cryptocurrency, Grid Search, Prediction, Support Vector Regression.*




This is an open access article under the Creative Commons 4.0 Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited. ©2022 by author and Universitas Negeri Padang.

I. PENDAHULUAN

Sektor keuangan telah banyak mengalami transformasi sebagai akibat dari revolusi industri 4.0, hal ini terlihat dari banyaknya praktik *trading* atau investasi yang melibatkan aset digital seperti *cryptocurrency*. Berdasarkan data terakhir dari Badan Pengawas Perdagangan Berjangka Komoditi (BAPPEBTI) di bulan September 2023, jumlah investor *crypto* di Indonesia mencapai 17,91 juta investor (Investor Daily, 2023). Menurut Syamsiah (2017: 54) *cryptocurrency* adalah sistem mata uang virtual yang memungkinkan penggunaannya untuk melakukan pembayaran secara virtual atas transaksi yang terjadi tanpa biaya jasa namun tetap memiliki otoritas kepercayaan yang terpusat.

Bitcoin sebagai mata uang *crypto* pertama dan paling terkenal terus mendominasi pasar *crypto*. Terlepas dari kenyataan bahwa *Bitcoin* bukan satu satunya mata uang *crypto* yang ada, namun keberadaannya saat ini masih memiliki harga jual yang lebih tinggi dibandingkan mata uang *crypto* lainnya (Wijaya, 2016: 15). Pergerakan harga *Bitcoin* sangat fluktuatif bahkan dapat berubah tiap menit. Pergerakan harga *Bitcoin* periode 14 September 2020 – 14 September 2023 dapat dilihat pada Gambar 1.



Gambar 1. Harga Penutupan Harian *Bitcoin* Periode 14 September 2020 – 14 September 2023

Tampak pada Gambar 1 bahwa lonjakan kenaikan dan penurunan harga *Bitcoin* sangat ekstrem. Harga *Bitcoin* cenderung mengalami kenaikan hingga mencapai US\$65.000 per keping pada periode Oktober hingga November 2022. Setelah itu terjadi penurunan harga sampai akhir tahun 2022. Situasi ini menyulitkan para investor dan *trader* pemula untuk memprediksi harga *crypto* akan naik atau turun pada hari tertentu.

Safitri (2021) menyatakan bahwa *crypto* memberikan *return* paling banyak dibandingkan *instrument* investasi lain. Hal inilah yang menyebabkan banyak masyarakat awam atau *trader* pemula tertarik pada *crypto* sebagai alat untuk mendapatkan keuntungan yang signifikan dalam jangka pendek. *Trading* erat kaitannya dengan *technical analysis*, digunakan oleh para *trader* untuk memprediksi pergerakan arah dengan menganalisis aksi pasar guna memperoleh keuntungan dalam jangka waktu pendek (Ong, 2017: 7). Beragam teknik dalam *technical analysis* menyebabkan *trader* pemula mengalami kesulitan dalam pemilihan teknik yang tepat (Ong, 2017: 353). Selain itu, penggunaan *technical analysis* kurang efisien untuk mengidentifikasi pola-pola tersembunyi dan hubungan yang kompleks dalam kumpulan data yang besar.

Metode *machine learning* dapat menjadi alternatif untuk mengatasi kendala para *trader* pemula di pasar *crypto* yakni dengan metode prediksi. Salah satu metode *machine learning* untuk memprediksi adalah *Support Vector Regression* (SVR). SVR telah banyak digunakan untuk peramalan harga saham dan menunjukkan kinerja yang lebih baik daripada metode prediksi lainnya (Santosa, 2007).

SVR dengan kasus nonlinear dapat diatasi menggunakan fungsi kernel. Kernel yang digunakan pada penelitian ini adalah kernel linear dan kernel *Radial Basis Function* (RBF). Praghakusuma dan Charibaldi (2021) menyebutkan bahwa penggunaan kernel linear dapat mempercepat proses pelatihan, sehingga lebih cocok untuk data dengan dimensi besar. Sementara itu, alasan penggunaan kernel RBF karena kernel ini umumnya digunakan ketika data tidak dapat dipisahkan secara linear, serta penelitian sebelumnya telah membuktikan bahwa RBF lebih unggul dibandingkan jenis kernel lainnya (Joachims, 1998).

Kendala yang dihadapi dalam penggunaan SVR adalah pemilihan parameter optimal. Oleh karena itu, algoritma *grid search* dapat digunakan untuk mengatasi masalah tersebut. Cara kerja dari algoritma *grid search* yaitu dengan mengkombinasikan parameter satu persatu dan membandingkan nilai galat terkecil parameter tersebut (Saputra *et al.*, 2019). Zhang dan Qi (2019) memaparkan bahwa SVR memiliki kemampuan yang baik dalam menangani *outlier* sehingga dapat mengurangi dampak perubahan harga yang ekstrem terhadap model prediksi. Hal ini dibuktikan oleh penelitian yang dilakukan oleh Haryadi *et al* (2022) tentang implementasi SVR untuk memprediksi harga *crypto* polkadot menghasilkan bahwa metode SVR dengan RBF menghasilkan akurasi sebesar 90% dan kernel linear memperoleh akurasi sebesar 87,68%.

Selanjutnya penelitian yang dilakukan oleh Atmaja dan Hakim (2022) tentang prediksi harga *Bitcoin* menggunakan SVR dengan kernel linear menghasilkan akurasi lebih baik, yaitu sebesar 97,44% dibandingkan kernel RBF sebesar 87,76%. Selain itu, pada penelitian yang dilakukan oleh Prakoso (2019) tentang prediksi Inflasi Indeks Harga Konsumen dengan SVR menghasilkan nilai akurasi kesalahan dibawah 10% yang berarti SVR mampu menghasilkan model prediksi yang optimal. Berdasarkan permasalahan tersebut maka tujuan dari penelitian ini adalah untuk memprediksi harga *Bitcoin* menggunakan SVR dengan algoritma *grid search*.

II. METODE PENELITIAN

A. Jenis Penelitian dan Sumber Data

Penelitian ini menggunakan data sekunder yang diperoleh dari *website Yahoo Finance* untuk memperoleh data harga harian penutupan *Bitcoin* periode 14 September 2020 – 14 September 2023. Variabel inti yang digunakan yaitu *close price* (harga penutupan) *Bitcoin* dengan variabel *output* (Y) merupakan harga penutupan hari ke i (x_i) dan variabel *input* (X) merupakan harga pada satu hari sebelumnya (x_{i-1}).

B. Langkah-Langkah Analisis

Adapun langkah-langkah analisis yang dilakukan dalam penelitian ini adalah sebagai berikut ini.

1. Mempersiapkan data harga penutupan harian *Bitcoin* periode 14 September 2020 hingga 14 September 2023 yang diperoleh dari *website Yahoo Finance*.
2. Melakukan analisis deskriptif terhadap data harga penutupan harian *Bitcoin* dengan membuat plot data.
3. Melakukan *preprocessing* data dengan menentukan *input* variabel dan *output* variabel serta membagi data menjadi data latih dan data uji yaitu 80% data latih dan 20% data uji. Data yang digunakan terdiri dari 1097 amatan dimana 878 amatan untuk data latih dan 219 amatan untuk data uji.

Menurut Jatiningrum (2008) pemodelan regresi pada data *time series* dapat menggunakan periode sebelumnya, tidak hanya menggunakan pengaruh data *input* (X) terhadap data *output* (Y) dalam periode yang sama. Mengacu pada penelitian yang dilakukan oleh Atmaja dan Hakim (2022), data harga hari sekarang (x_i) yang bergantung pada satu hari sebelumnya (x_{i-1}). Penerapan dalam penentuan *input* dan *output* variabel pada data harga penutupan harian *Bitcoin* dapat dilihat pada Tabel 1.

Tabel 1. *Input dan Output Variabel Data Bitcoin*

No	X	Y
1	10680,83789	10796,95117
2	10796,95117	10974,90527
3	10974,90527	10948,99023
4	10948,99023	10944,58594
⋮	⋮	⋮
1094	25832,22656	25162,6543
1095	25162,6543	25833,34375
1096	25833,34375	26228,32422
1097	26228,32422	26618,20313

4. Melakukan standardisasi data.

Standardisasi merupakan proses mengkonversi data sehingga data memiliki rata-rata 0 dan varians 1 menjadi ukuran standar yang digunakan. Standardisasi dilakukan apabila data memiliki satuan yang berbeda (Laura & Santi, 2017: 47). Standardisasi data dapat menggunakan Persamaan (1).

$$Z_i = \frac{(x_i - \mu)}{\sigma} \tag{1}$$

dimana Z_i merupakan nilai standar z pada waktu ke- i , x_i merupakan nilai pengamatan pada waktu ke- i , μ merupakan rata-rata, dan σ merupakan standar deviasi.

5. Menentukan fungsi kernel yang digunakan.

Salah satu metode yang memungkinkan digunakan untuk mengatasi permasalahan non linear pada SVR adalah menggunakan fungsi kernel. Fungsi kernel yang digunakan pada penelitian ini adalah kernel linear dan RBF. Persamaan kedua kernel ini ditunjukkan pada Tabel 2 (Muttaqin & Khairisudin, 2021).

Tabel 2. Jenis Fungsi Kernel

Kernel	Fungsi Kernel
Linear	$K(x_i, x_j) = x_i \cdot x_j$
Gaussian/ RBF	$K(x_i, x_j) = \exp\left(\frac{-\ x_i - x_j\ ^2}{2\sigma^2}\right)$


dimana $(x_i \cdot x_j)$ merupakan perkalian skalar (*dot product*) dua data latih, d merupakan derajat polinomial, $\|x_i \cdot x_j\|^2$ jarak *Euclidean* kuadrat antara dua vektor fitur yaitu (x_i, x_j) , γ merupakan lebar parameter kernel Gaussian, dan σ merupakan nilai parameter SVR.

6. Menentukan rentang nilai parameter yang akan digunakan yaitu C, ϵ , dan γ untuk masing-masing fungsi kernel.

SVR merupakan salah satu metode *machine learning* untuk kasus regresi. SVR bertujuan untuk mendapatkan *hyperplane* optimal sebagai bidang yang dapat memprediksi data aktual. Selain itu, bertujuan untuk mencari fungsi $f(x)$ yang mempunyai penyimpangan tidak lebih dari ϵ (Smola & Schölkopf, 2004). Bentuk umum SVR ditulis pada Persamaan (2).

$$f(x) = w^T \varphi(x) + b \tag{2}$$

dimana $f(x)$ merupakan fungsi regresi dari SVR, w^T merupakan vektor bobot, $\varphi(x)$ merupakan fungsi yang memetakan x pada ruang fitur, dan b merupakan bias (Awad & Khanna, 2015: 68). Gambar 2 ditampilkan ilustrasi dari SVR.



Gambar 2. Ilustrasi SVR

Garis yang berada di tengah yang terlihat pada Gambar 2 merupakan *hyperplane* yang diperoleh dari $f(x)$ dan dua garis yang berada di sekitar *hyperplane* adalah *boundary lines*. *Margin* atau ϵ adalah jarak dari *hyperplane* dengan data yang terdekat. Data yang paling dekat dari *margin* disebut *support vector*. Data yang berada jauh dari *boundary lines* disebut dengan variabel *slack* atau ξ .

Menurut Rezzy *et al.* (2017) agar mendapatkan generalisasi yang baik untuk fungsi regresi $f(x)$, dapat dilakukan dengan cara meminimalkan nilai dari w . Diasumsikan bahwa semua titik berada dalam rentang $f(x) \pm \epsilon$ (*feasible*). Apabila titik keluar dari rentang tersebut maka dibutuhkan *soft margin* sehingga dapat ditambahkan variabel *slack* ξ dan ξ^* . Variabel ini berguna untuk mengatasi masalah pembatas (*boundary lines*) yang tidak layak (*infeasible constraints*) dalam masalah optimasi (Sari, 2009) yang dapat ditulis pada Persamaan (3).

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i, \xi_i^*$$

dengan syarat:

$$y_i - w^T \varphi(x_i) \leq \epsilon + \xi_i^* \quad \text{dimana } i = 1, \dots, N \quad (3)$$

$$w^T \varphi(x_i) - y_i \leq \epsilon + \xi_i \quad \text{dimana } i = 1, \dots, N$$

$$\xi_i, \xi_i^* \geq 0 \quad i = 1, \dots, N$$

$\|w\|^2$ merupakan vektor *norm* yang digunakan untuk menghasilkan *margin* yang maksimum dan C merupakan penalti yang akan diberikan pada variabel *slack*. Nilai *slack* yang tinggi akan mengakibatkan kesalahan empiris pada perhitungan (Yudhawan, 2020). Data yang berada jauh dari *boundary lines* menjadi sebuah masalah optimasi.

SVR menggunakan *loss function* yaitu fungsi yang meminimalkan resiko empiris (selisih hasil estimasi dengan nilai aktual) dalam membangun model. Menurut Amanda (2014) *loss function* yang paling sederhana adalah ϵ -*insensitive loss function*, dimana data latih yang berada di dalam garis batas dianggap memiliki nilai kesalahan 0 atau $\epsilon = 0$. Data latih yang berada di luar *boundary lines* akan menjadi variabel *slack*. ϵ -*insensitive loss function* ditunjukkan oleh Persamaan (4).

$$L_\epsilon(y_i, f(x_i)) = \begin{cases} 0 & , \text{ untuk } |y_i, f(x_i)| < \epsilon \\ |y_i - f(x_i)| - \epsilon, & \text{ untuk } |y_i, f(x_i)| \geq \epsilon \end{cases} \quad (4)$$

Solusi untuk permasalahan optimasi akan lebih mudah jika diselesaikan menggunakan formulasi dual pada fungsi *lagrange multiplier* pada Persamaan (5).

$$\begin{aligned} \mathcal{L}(\mathbf{w}, \xi^*, \xi, \lambda, \lambda^*, \alpha, \alpha^*) &= \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^l \xi_i + \xi_i^* + \sum_{i=1}^l \alpha_i^* (y_i - \\ \mathbf{w}^T \mathbf{x}_i - \epsilon - \xi_i^*) &+ \sum_{i=1}^l \alpha_i (-y_i + \mathbf{w}^T \mathbf{x}_i - \epsilon - \xi_i) - \sum_{i=1}^l \lambda_i \xi_i + \lambda_i^* \xi_i^* \end{aligned} \quad (5)$$

Setelah itu, dilakukan turunan parsial untuk mendapatkan solusi yang optimal berdasarkan kondisi *Karush Kuhn Tucker* (KKT) yang menurunkan secara parsial persamaan dari fungsi *lagrange multiplier* sehingga diperoleh hasil persamaan untuk menghitung nilai parameter \mathbf{w} dan b pada Persamaan (6) dan (7).

$$\mathbf{w} = \sum_{i=1}^l (\alpha_i^* - \alpha_i) \varphi(\mathbf{x}_i) \quad (6)$$


$$b = y_i - \mathbf{w}^T \varphi(\mathbf{x}_i) - \epsilon$$

$$b = -y_i + \mathbf{w}^T \varphi(\mathbf{x}_i) - \epsilon \quad (7)$$

Setelah mendapat nilai \mathbf{w} dan b , maka diperoleh persamaan baru yang ditunjukkan pada persamaan (2).

7. Memilih parameter terbaik menggunakan algoritma *grid search*.

Grid search merupakan sebuah algoritma untuk menentukan parameter optimal pada model SVR. Prinsip kerja metode ini dengan menentukan beberapa nilai parameter pada rentang tertentu, kemudian memilih parameter pada nilai terbaik pada rentang tersebut dan melakukan pencarian berulang pada *grid*. Setiap kombinasi parameter akan dihitung *error*, kemudian dipilih kombinasi parameter yang memiliki *error* terkecil (Mustakim *et. al*, 2015). Berikut gambaran dari algoritma *grid search* dengan mengkombinasikan dua parameter SVR untuk parameter optimal (Saputra, 2019) ditunjukkan oleh Gambar 3.



Gambar 3. Ilustrasi Algoritma *Grid Search* dengan Kombinasi 2 Parameter

Ilustrasi pada Gambar 3 menggambarkan proses pencarian parameter optimal untuk dua parameter SVR menggunakan algoritma *grid search*. Pasangan parameter C dan ϵ pertama kali disusun dalam grid-grid. Kemudian pada baris ke- i kolom ke- j dicari kombinasi parameter terbaik dengan nilai *error* terkecil sehingga diperoleh i_{34} sebagai parameter optimal.

8. Melakukan evaluasi model untuk menentukan parameter terbaik berdasarkan MAPE terendah menggunakan persamaan (9) dan R^2 tertinggi menggunakan Persamaan (8).

Mean Absolute Percentage Error (MAPE) adalah ukuran ketetapan relatif untuk menghitung persentase hasil dari penyimpangan peramalan dengan cara menghitung kesalahan *absolute* pada setiap periode dibagi dengan hasil observasi nyata pada periode tersebut kemudian dihitung rata-ratanya. Semakin kecil nilai MAPE yang diperoleh maka kemampuan model memprediksi semakin baik (Mubarak & Esyudha, 2020). Perhitungan MAPE dapat menggunakan Persamaan (8).

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (8)$$

dimana, y_i merupakan nilai pengamatan pada waktu ke- i dan \hat{y}_i adalah nilai prediksi pada waktu ke- i .

Menurut Ghozali (2018: 179) R^2 digunakan untuk mengukur seberapa baik garis regresi sesuai dengan data aktualnya (*goodness of fit*). Nilai R^2 ini mengukur persentase total varian variabel *output* yang dijelaskan oleh variabel *input* di dalam garis regresi. Perhitungan R^2 dapat menggunakan Persamaan (9).

$$R^2 = 1 - \frac{\sum(y_i - \hat{y}_i)^2}{\sum(y_i - \bar{y})^2} \text{ atau } R^2 = \frac{\sum(\hat{y}_i - \bar{y})^2}{\sum(y_i - \bar{y})^2} \quad (9)$$

dimana, y_i merupakan nilai pengamatan pada waktu ke- i , \hat{y}_i adalah nilai prediksi pada waktu ke- i dan \bar{y} nilai rata rata *output variable*.

9. Membandingkan nilai prediksi dengan nilai aktual pada data uji.

III. HASIL DAN PEMBAHASAN

A. Deskriptif Data

Analisis deskriptif pada data harga penutupan *Bitcoin* dilakukan untuk mengetahui gambaran harga *Bitcoin* tanggal 14 September 2020 hingga 14 September 2023. Tampak pada Gambar 1 bahwa pergerakan harga *Bitcoin* sangat rentan terhadap *fluktuasi* besar dan perubahan yang cepat. Periode Oktober hingga November 2022, harga *Bitcoin* cenderung mengalami kenaikan hingga mencapai US\$65.000 per keping. Setelah itu terjadi penurunan harga sampai akhir tahun 2022. Hal ini disebabkan karena *volatilitas cryptocurrency* hanya dipengaruhi oleh harga masa lalu dan tidak dipengaruhi oleh variabel lain sehingga sulit diprediksi (Warsito, 2020). Oleh karena itu, diperlukan *machine learning* untuk memudahkan dalam memprediksi harga *crypto*.


B. Analisis Support Vector Regression

Pencarian menggunakan SVR dengan pengoptimalan parameter menggunakan algoritma *Grid Search* dengan data latih sebanyak 409 amatan menunjukkan tingkat akurasi yang sangat baik. Tabel 3 menyajikan hasil perbandingan parameter C , ϵ , dan γ pada tiap kernel dengan perolehan nilai MAPE dan nilai akurasi pada setiap kombinasi.

Tabel 3. Kombinasi Parameter Terbaik dengan Algoritma *Grid Search*

Kernel	Parameter			MAPE	R^2
	C	ϵ	γ	Data Uji	Data Uji
Linear	0,10	0,01		0,1208	0,9924
RBF	100	0,01	0,010	0,1206	0,9925

Terlihat pada Tabel 3 bahwa kombinasi parameter terbaik SVR menggunakan algoritma *grid search* adalah kernel RBF dengan $C = 100$, $\epsilon = 0,01$, dan $\gamma = 0,001$ karena menghasilkan MAPE terkecil dan nilai akurasi (R^2) tertinggi. Diperoleh nilai MAPE yaitu sebesar 0,1206% dan nilai akurasi (R^2) sebesar 0,9925. Hal ini menunjukkan bahwa dengan mencari parameter C , ϵ , dan γ terbaik akan menghasilkan model optimal, dengan begitu model dapat menghasilkan prediksi harga *Bitcoin* dengan baik. Performansi model terbaik dapat dilihat dari grafik perbandingan nilai aktual data uji dengan nilai prediksi yang ditampilkan pada Gambar 4.



Gambar 4. Perbandingan Data Aktual dan Data Prediksi Harga Penutupan Harian *Bitcoin*

Gambar 4 memperlihatkan bahwa plot data hasil prediksi cenderung mengikuti plot data aktual. Ini menunjukkan tidak terdapat perbedaan yang signifikan antara data aktual dengan data hasil prediksi. Perbandingan data hasil prediksi dengan nilai aktual pada data uji *Bitcoin* dapat dilihat pada Tabel 3.

Tabel 2. Perbandingan Data Aktual dan Data Prediksi

Data	Nilai Aktual	Nilai Prediksi
1	18543,28	20583,48
2	19222,68	187795,74
3	19044,12	19301,41
4	27702,35	27725,81,
5	41557,91	42312,06
.	.	.
.	.	.
215	22939,39	23236,48
216	24375,96	24718,22
217	15332,32	15515,71
218	22353,35	22336,45
219	36926,07	37507,74

Terlihat pada Tabel 3 menghasilkan nilai prediksi yang mendekati nilai aktual dengan menggunakan 219 amatan pada data uji. Ini membuktikan bahwa metode SVR dengan algoritma *Grid Search* mampu menghasilkan prediksi pada harga *Bitcoin* dengan baik. Prediksi yang dihasilkan oleh model terbaik menunjukkan bahwa harga penutupan (*close price*) harian *Bitcoin* hari saat ini (x_i) dipengaruhi harga *Bitcoin* satu hari sebelumnya (x_{i-1}).

IV. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan mengenai prediksi harga salah satu *crypto* yaitu *Bitcoin* menggunakan SVR dengan algoritma *Grid Search* menghasilkan parameter terbaik dengan kernel RBF, $C = 100$, $\epsilon = 0,01$, dan $\gamma = 0,01$ diperoleh akurasi sebesar 99,25% dan MAPE sebesar 0,1206%. Artinya model memiliki kemampuan prediksi yang baik. Berdasarkan perolehan hasil penelitian menggunakan 219 amatan dari data uji menunjukkan bahwa SVR mampu menghasilkan sebuah prediksi yang baik pada data nonlinear. Untuk penelitian selanjutnya dapat menggunakan algoritma selain *grid search* dalam menentukan parameter terbaik atau menambahkan variabel lain yang berpengaruh.

DAFTAR PUSTAKA

- Awad, M., and Khanna, R. (2015). *Efficient learning machines: theories, concepts, and applications for engineers and system designers*. New York: Apress Media.
- Bank Indonesia. (2019). Buletin Hukum Kebankesentralan. Vol 16 No.1. 1 Januari-Juni 2019. Jakarta: Bank Indonesia
- Haryadi, D., Hakim, A. R., Atmaja, D. M. U., & Yutia, S. N. (2022). Implementation of Support Vector Regression for Polkadot Cryptocurrency Price Prediction. *JOIV: International Journal on Informatics Visualization*, 6(1-2), 201-207.
- Laura, I., and Santi, S. (2017). *Introduction to Data Science: A Python Approach to Concepts, Techniques and Applications*. Switzerland: Springer.
- Mustakim, A. B., & Hermadi, I. (2015). Support vector regression untuk prediksi produktivitas kelapa sawit di provinsi riau. *J. Sains, Teknol. dan Ind*, 12(2), 179-188.
- Muttaqin, M. N., & Khairisudin, I. (2021). Analisis Sentimen Aplikasi Gojek Menggunakan Support Vector Machine dan K-Nearest Neighbor. *UNNES Journal of Mathematics*, 10(2), 22-27.
- Nugraha, E. S., & Sulasmiyati, S. (2017). Analisis Nilai Intrinsik Saham Dengan Relative Valuation Techniques (Studi Pada Perusahaan Sub Sektor Rokok yang Terdaftar di Bursa Efek Indonesia Periode 2013–2016). *Jurnal Administrasi Bisnis*, Vol. 52, No. 1, Hal. 106-113.

- Ong, E. (2016). *Technical Analysis For Mega Profit (Hc)*. Gramedia Pustaka Utama.
- Prakoso, B. H. (2019). Implementasi Support Vector Regression pada prediksi inflasi indeks harga konsumen. *Jurnal Manajemen, Teknik Informatika Dan Rekayasa Komputer*, 19(1), 155-162.
- Safitri, K. (2021). Aset Kripto Berpeluang Tumbuh Subur di Indonesia. *Kompas*. <https://money.kompas.com/read/2021/06/17/194959726/aset-kripto-berpeluang-tumbuh-subur-di-indonesia>.
- Saputra, G., Wigena, A., & Sartono, B. (2019). Penggunaan Support Vector Regression dalam Pemodelan Indeks Saham Syariah Indonesia dengan Algoritme Grid Search. *Indonesian Journal of Statistics and Its Applications*, 3(2), 148 - 160.
- Serfiyani, D. C. Y., SH, M., Purnomo, I. R. S. D., Hariyani, I., dan SH, M. (2021). *Capital market top secret: Ramuan sukses bisnis pasar modal Indonesia*. Yogyakarta: Penerbit Andi.
- Smola, A. J., & Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and computing*, Vol. 14, Hal. 199-222.
- Sugiharti, L., Fariyah, E., Hartadinata, O., & Ajija, S. (2021). *STATISTIK MULTIVARIAT UNTUK EKONOMI DAN BISNIS: Menggunakan Software SPSS*. Surabaya: Airlangga University Press.
- Suroyo, K. (2022). Implementasi Metode SVR (Support Vector Regression) untuk Prediksi Jumlah Positif COVID-19 di Jawa Timur. Skripsi, Universitas Islam Negeri Sunan Ampel, Surabaya.
- Syamsiah, N. O. (2017). Kajian atas cryptocurrency sebagai alat pembayaran di Indonesia. *Journal on Networking and Security* Chang, P. C., Wang, Y. W., and Liu, C. H. (2007). The development of a weighted evolving fuzzy neural network for PCB sales forecasting. *Expert Systems with Applications*, Vol. 32, No. 1, Hal. 86-96.
- Wijaya, Dimaz Ankaa. 2016. *Mengenal Bitcoin dan Cryptocurrency*. Pusantara: Medan.
- Zhang, Z., & Qi, Y. (2019). A Novel Price Prediction Method for Cryptocurrencies Based on SVM Regression. 2019 International Conference on Computer Information and Big Data Applications (CIBDA). DOI: 10.1109/CIBDA48078.2019.9035821.