

Prediksi Tingkat Inflasi Di Indonesia Menggunakan Algoritma Regresi Linier

Dwi Amelia¹, Zera Ovilia², Elni Mefia Sinta³, Pujianto⁴

¹²³⁴Informatika, Universitas Baturaja, Indonesia

dwiameliaa.sy@gmail.com, zeraovilia1801@gmail.com, mefiabta1234@gmail.com, pujianto.mail@gmail.com,

Article Info

Article history:

Received May 21, 2026

Accepted June 23, 2026

Published July 1, 2026

Kata Kunci:

Inflasi

Regresi Linier


Orange Data Mining

Prediksi

Machine Learning

ABSTRAK

Inflasi merupakan indikator ekonomi makro yang berpengaruh signifikan terhadap stabilitas perekonomian nasional. Penelitian ini bertujuan untuk memprediksi tingkat inflasi bulanan di Indonesia menggunakan algoritma regresi linier berbasis platform Orange Data Mining. Metode yang digunakan adalah pendekatan kuantitatif dengan eksperimen komputasional, memanfaatkan dataset sebanyak 72 observasi bulanan yang memuat dua variabel prediktor, yaitu Bulan_Ke dan Siklus_Bulan, serta satu variabel target berupa Inflasi. Sebanyak 64 observasi digunakan sebagai data pelatihan dan delapan observasi sisanya sebagai data pengujian. Model dikonfigurasi tanpa regularisasi dengan intercept aktif. Hasil prediksi menunjukkan nilai inflasi berkisar antara -0,1078% hingga 0,4982%, dengan nilai tertinggi pada siklus bulan ke-12 dan terendah pada siklus bulan ke-8. Simpulan penelitian ini menunjukkan bahwa algoritma regresi linier mampu menghasilkan prediksi yang interpretatif dengan mempertimbangkan pola musiman melalui variabel Siklus_Bulan dan tren jangka panjang melalui variabel Bulan_Ke.



Corresponding Author:

Dwi Amelia,

Informatika,

Universitas Baturaja,

Email: dwiameliaa.sy@gmail.com

1. PENDAHULUAN

Inflasi merupakan salah satu fenomena ekonomi makro yang paling fundamental dan berdampak luas terhadap berbagai aspek kehidupan ekonomi suatu bangsa. Secara konseptual, inflasi didefinisikan sebagai kenaikan tingkat harga secara umum dan berkelanjutan dalam suatu perekonomian selama periode tertentu (Mankiw, 2019). Ketika tingkat inflasi bergerak di luar rentang yang terkendali, dampaknya akan dirasakan secara langsung oleh masyarakat melalui penurunan daya beli, melemahnya nilai riil tabungan, serta meningkatnya beban biaya hidup terutama bagi kelompok berpenghasilan rendah (Bank Indonesia, 2022). Di sisi kebijakan, fluktuasi inflasi yang tidak terprediksi menyulitkan otoritas moneter dalam menetapkan suku bunga acuan yang tepat, sehingga berpotensi mengganggu transmisi kebijakan moneter secara keseluruhan (Mishkin, 2019). Oleh karena itu, kemampuan untuk memprediksi tingkat inflasi secara akurat bukan hanya menjadi kebutuhan analitis, melainkan juga merupakan prasyarat penting bagi terwujudnya stabilitas ekonomi jangka Panjang (Awaludin et al., 2024).

Dalam beberapa dekade terakhir, pendekatan berbasis pembelajaran mesin (machine learning) semakin banyak digunakan untuk memodelkan fenomena ekonomi yang bersifat dinamis dan kompleks (Hastie et al., 2022). Metode-metode komputasional seperti jaringan saraf tiruan, pohon keputusan, dan regresi telah terbukti mampu menangkap pola tersembunyi dalam data deret waktu ekonomi yang sulit

dimodelkan secara konvensional (Awaludin & Yasin, 2020) (Alpaydin, 2020). Salah satu metode yang telah terbukti efektif dalam pemodelan hubungan linear antarvariabel adalah regresi linier (linear regression). Metode ini memiliki keunggulan berupa interpretabilitas yang tinggi, komputasi yang efisien, serta kemudahan implementasi pada berbagai platform analitik data (James et al., 2021). Berbeda dengan pendekatan black-box seperti deep learning, regresi linier menghasilkan persamaan yang dapat diinterpretasikan secara ekonometrik, sehingga setiap koefisien prediktor dapat dihubungkan dengan penjelasan teoritis yang bermakna (Gujarati & Porter, 2020). Keunggulan ini menjadikan regresi linier tetap relevan sebagai model baseline yang informatif, bahkan di era dominasi algoritma pembelajaran mendalam sekalipun (Montgomery et al., 2021).

Penelitian terdahulu menunjukkan bahwa regresi linier mampu memberikan estimasi yang cukup memadai terhadap variabel ekonomi berbasis waktu, terutama apabila variabel prediktor dipilih secara tepat (Gujarati & Porter, 2020). Nawawi dan Martini (2020) menerapkan metode exponential smoothing untuk prediksi inflasi Indonesia dan memperoleh hasil yang cukup memuaskan, namun metode tersebut tidak mengeksplisitkan hubungan antarvariabel secara parametrik (Awaludin & Rehatalanit, 2026). Sinaga dan Saragih (2022) menunjukkan bahwa penerapan algoritma machine learning, termasuk regresi linier, pada data indikator ekonomi makro Indonesia memberikan akurasi prediksi yang layak dipertimbangkan sebagai acuan kebijakan. Lebih lanjut, Kusumawardhani et al. (2021) menemukan bahwa variabel berbasis waktu seperti urutan bulan dan posisi musiman secara signifikan meningkatkan kinerja model prediksi inflasi dibandingkan model univariat. Dalam konteks prediksi inflasi, variabel siklikal bulanan (Siklus_Bulan) dan variabel urutan waktu (Bulan_Ke) berpotensi menjadi prediktor yang informatif karena mencerminkan pola musiman yang bersifat berulang dalam dinamika harga barang dan jasa (Hyndman & Athanasopoulos, 2021).

Platform analitik visual Orange Data Mining menawarkan antarmuka berbasis alur kerja (workflow-based) yang memudahkan eksperimen pemodelan prediktif tanpa memerlukan kode pemrograman yang ekstensif (Demsar et al., 2023). Kemudahan penggunaan ini menjadikan Orange sebagai pilihan populer dalam komunitas penelitian akademis, khususnya untuk eksplorasi data, visualisasi, dan perbandingan algoritma secara cepat (Witten et al., 2022). Berbagai studi telah memanfaatkan Orange Data Mining untuk tugas klasifikasi, regresi, dan klusterisasi pada berbagai domain, mulai dari biomedis hingga analisis sosial-ekonomi (Han et al., 2022). Dalam bidang prediksi ekonomi, platform serupa juga telah digunakan secara luas untuk membangun prototipe model yang kemudian diadaptasi ke dalam sistem produksi (Raschka et al., 2022). Penggunaan Orange dalam penelitian ini memungkinkan proses pelatihan model, pengujian, dan visualisasi hasil dilakukan secara terintegrasi dan transparan, sehingga seluruh tahapan eksperimen dapat direproduksi oleh peneliti lain dengan mudah (Demsar et al., 2023).

Meskipun berbagai metode prediksi inflasi telah dikembangkan, sebagian besar penelitian di Indonesia masih terfokus pada pendekatan ekonometrik klasik seperti ARIMA dan VAR (Cahyono & Suhartono, 2020), sementara penerapan algoritma machine learning berbasis platform visual seperti Orange Data Mining masih relatif terbatas dalam literatur akademik nasional. Kesenjangan ini membuka ruang bagi penelitian yang mengeksplorasi kemampuan algoritma regresi linier dalam konteks platform data mining visual untuk prediksi inflasi Indonesia. Di samping itu, perbandingan antara metode konvensional dan pendekatan berbasis data menunjukkan bahwa tidak ada satu pun metode yang secara konsisten unggul di semua kondisi, sehingga evaluasi metode regresi linier pada data inflasi Indonesia tetap relevan dan berkontribusi terhadap khazanah literatur yang ada (Zhang, 2022). Penelitian ini bertujuan untuk menerapkan algoritma regresi linier dalam memprediksi tingkat inflasi bulanan di Indonesia menggunakan data historis yang terstruktur dalam siklus dua belas bulanan, sekaligus mengevaluasi pola prediksi yang dihasilkan secara visual melalui platform Orange Data Mining. Data pelatihan mencakup 64 observasi bulanan, sedangkan data pengujian terdiri atas delapan observasi berikutnya. Melalui penelitian ini diharapkan tersedia gambaran yang lebih komprehensif mengenai potensi dan keterbatasan regresi linier sebagai alat prediksi inflasi di Indonesia, yang dapat menjadi referensi bagi penelitian lanjutan maupun pengambilan keputusan berbasis data di bidang ekonomi (Priyatno, 2021; Alpaydin, 2020).

2. METODE

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen komputasional. Berikut ringkasan penelitian terkini tentang prediksi inflasi di Indonesia menggunakan

No	Nama Peneliti (Tahun)	Pembahasan (Masalah & Solusi Algoritma)	Hasil (Data Kuantitatif)
1	Yonggi et al. (2024)	Masalah: Peramalan angka laju inflasi di Indonesia. Solusi: Menerapkan algoritma Extreme Learning Machine (ELM) .	Hasil peramalan terbaik diperoleh dengan model ELM.
2	Peneliti (2024)	Masalah: Meramalkan tingkat inflasi bulanan di Indonesia. Solusi: Kombinasi Artificial Bee Colony (ABC) dan XGBoost .	RMSE = 0.155066 MAPE = 0.795767
3	Peneliti (2024)	Masalah: Memprediksi inflasi di negara berkembang pasca pandemi. Solusi: Membandingkan Neural Network (NN) Backpropagation, SVM, dan RNN LSTM .	Model NN Backpropagation dengan indikator CPI menghasilkan MSE = 0.001 untuk Indonesia.
4	Peneliti (2025)	Masalah: Memprediksi inflasi Indonesia menggunakan data sistem pembayaran, pasar modal, dan makroekonomi. Solusi: Membandingkan shrinkage regression, ensemble learning, support vector regression dengan ARIMA/SARIMA.	Model <i>machine learning</i> dievaluasi terhadap univariate time series ARIMA dan SARIMA.
5	Peneliti (2025)	Masalah: Prediksi tingkat inflasi di Indonesia. Solusi: Menggunakan Fourier series estimator dan Support Vector Regression (SVR) .	Prediksi akurat berdampak signifikan pada kebijakan moneter dan stabilitas pasar.
6	Peneliti (2025)	Masalah: Peramalan inflasi Indonesia untuk periode mendatang. Solusi: Menerapkan ANN Backpropagation .	MSE = 0.0112 RMSE = 0.1065
7	Peneliti (2025)	Masalah: Peramalan Indeks Harga Konsumen (CPI) Indonesia. Solusi: Membandingkan Gated Recurrent Unit (GRU) dan Bidirectional GRU (Bi-GRU) .	Peramalan CPI hingga April 2025 berkisar antara 118.2515–119.7739
8	Peneliti (2025)	Masalah: Prediksi inflasi Indonesia. Solusi: Extreme Learning Machine (ELM) dengan K-Fold Cross Validation .	Prediksi Januari–Desember 2025: 1.517%–1.761% (rata-rata ~1.663%)
9	Peneliti (2025)	Masalah: Prediksi inflasi Indonesia. Solusi: Extreme Learning Machine (ELM) dengan K-Fold Cross Validation .	Prediksi Januari–Desember 2025: 1.03%–2.0% (rata-rata ~1.5%)

Tahapan penelitian meliputi pengumpulan dan persiapan data, pembagian dataset ke dalam data pelatihan dan data pengujian, pembangunan model regresi linier, serta evaluasi dan interpretasi hasil prediksi. Seluruh proses pemodelan dilaksanakan menggunakan perangkat lunak Orange Data Mining versi terkini.

Data yang digunakan dalam penelitian ini bersumber dari [catatan historis tingkat inflasi bulanan di Indonesia](#). Dataset memuat tiga variabel, yaitu Bulan_Ke (nomor urutan bulan secara kumulatif), Siklus_Bulan (posisi bulan dalam siklus tahunan, bernilai 1 hingga 12), dan Inflasi (persentase perubahan tingkat harga dalam satuan persen). Dataset dibagi menjadi dua bagian: data pelatihan (training) sebanyak 64 observasi (Bulan_Ke 1–64) dan data pengujian (testing) sebanyak delapan observasi (Bulan_Ke 65–72).

A. Data Training

Data pelatihan digunakan untuk melatih model regresi linier agar dapat mempelajari pola hubungan antara variabel prediktor (Bulan_Ke dan Siklus_Bulan) dengan variabel target (Inflasi). Tabel berikut menyajikan sebagian data pelatihan yang digunakan, mencakup 64 observasi bulanan (Priyatno,

2021).

Bulan_Ke	Siklus_Bulan	Inflasi
1	1	0,26
2	2	0,1
3	3	0,08
4	4	0,13
5	5	0,32
6	6	-0,16
7	7	0,08
8	8	0,03
9	9	-0,04
10	10	0,12
11	11	0,37
12	12	0,57
13	1	0,56
14	2	-0,02
15	3	0,66
16	4	0,95
17	5	0,4
18	6	0,61
19	7	0,64
20	8	-0,21
21	9	1,17

Gambar 1. Data Training Tingkat Inflasi (Bulan_Ke 1-21)

22	10	-0,11
23	11	0,09
24	12	0,66
25	1	0,34
26	2	0,16
27	3	0,18
28	4	0,33
29	5	0,09
30	6	0,14
31	7	0,21
32	8	-0,02
33	9	0,19
34	10	0,17
35	11	0,38
36	12	0,41
37	1	0,04
38	2	0,37
39	3	0,52
40	4	0,25
41	5	-0,03
42	6	-0,08
43	7	0,10

Gambar 2. Data Training Tingkat Inflasi (Bulan_Ke 22-44)

45	44	8	-0,03
46	45	9	-0,12
47	46	10	0,08
48	47	11	0,3
49	48	12	0,44
50	49	1	-0,76
51	50	2	-0,48
52	51	3	1,65
53	52	4	1,17
54	53	5	-0,37
55	54	6	0,19
56	55	7	0,3
57	56	8	-0,08
58	57	9	0,21
59	58	10	0,28
60	59	11	0,17
61	60	12	0,64
62	61	1	-0,15
63	62	2	0,68
64	63	3	0,41
65	64	4	0,13

Gambar 3. Data Training Tingkat Inflasi (Bulan_Ke 45-64)

B. Data Testing

Data pengujian terdiri atas delapan observasi pada Bulan_Ke 65 hingga 72, yang mencakup Siklus_Bulan ke-5 hingga ke-12. Pada data ini, nilai variabel Inflasi bersifat kosong (missing) karena

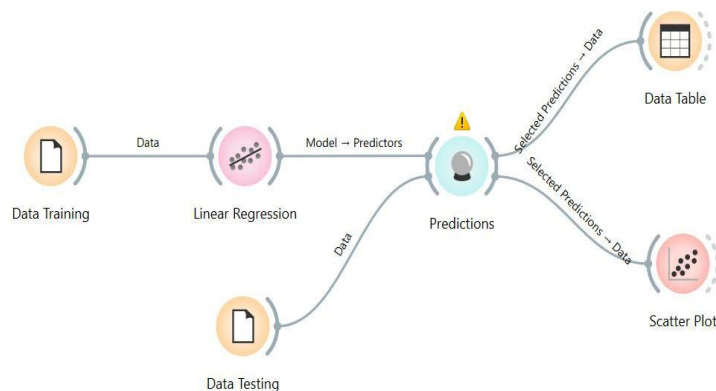
merupakan nilai yang akan diprediksi oleh model (Nawawi & Martini, 2020). Data pengujian disajikan pada gambar berikut.

Bulan_Ke	Siklus_Bulan	Inflasi
65	5	
66	6	
67	7	
68	8	
69	9	
70	10	
71	11	
72	12	

Gambar 4. Data Testing (Bulan_Ke 65-72, nilai Inflasi kosong)

C. Alur Kerja Pemodelan pada Orange Data Mining

Proses pemodelan dilaksanakan menggunakan platform Orange Data Mining dengan alur kerja (workflow) yang terdiri atas beberapa komponen utama yang saling terhubung. Alur kerja tersebut dirancang untuk memastikan proses pelatihan dan prediksi berjalan secara sistematis dan dapat direproduksi (Demsar et al., 2023). Gambaran umum alur kerja pemodelan disajikan pada Gambar 5.

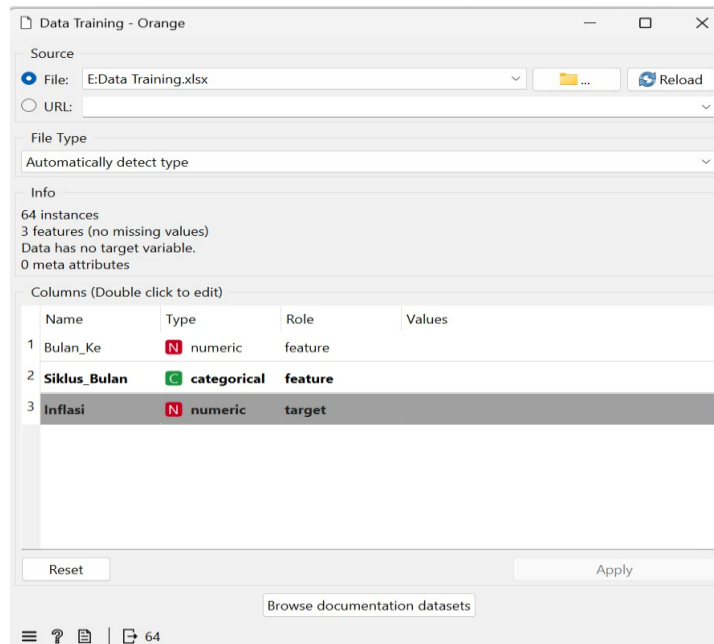


Gambar 5. Alur Kerja Pemodelan di Orange Data Mining

Alur kerja tersebut terdiri atas komponen Data Training, Linear Regression, Data Testing, Predictions, Data Table, dan Scatter Plot. Data Training dihubungkan ke blok Linear Regression untuk proses pelatihan model. Model yang telah dilatih kemudian dihubungkan bersama Data Testing ke blok Predictions guna menghasilkan nilai prediksi inflasi. Hasil prediksi selanjutnya divisualisasikan melalui Data Table dan Scatter Plot.

D. Konfigurasi Data Training pada Orange

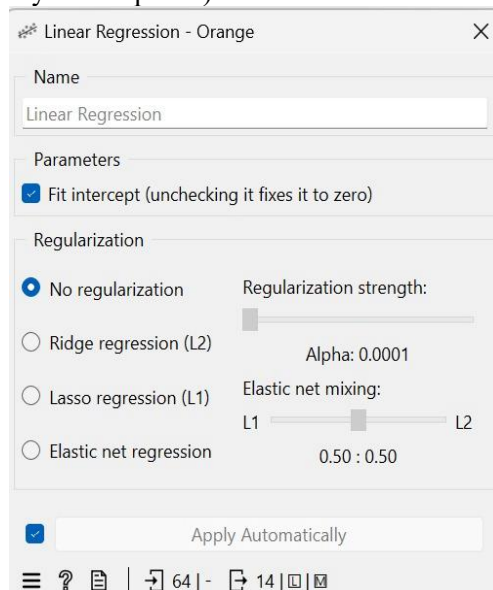
Pada komponen Data Training, dataset pelatihan dimuat dari berkas Excel (Data Training.xlsx) yang memuat 64 instans dengan tiga fitur. Variabel Bulan_Ke ditetapkan sebagai fitur numerik, Siklus_Bulan sebagai fitur kategorik, dan Inflasi sebagai variabel target (Sinaga & Saragih, 2022). Konfigurasi ini memastikan bahwa model regresi dilatih untuk memprediksi nilai Inflasi berdasarkan kedua prediktor tersebut.



Gambar 6. Konfigurasi Data Training pada Orange Data Mining

E. Konfigurasi Model Regresi Linier

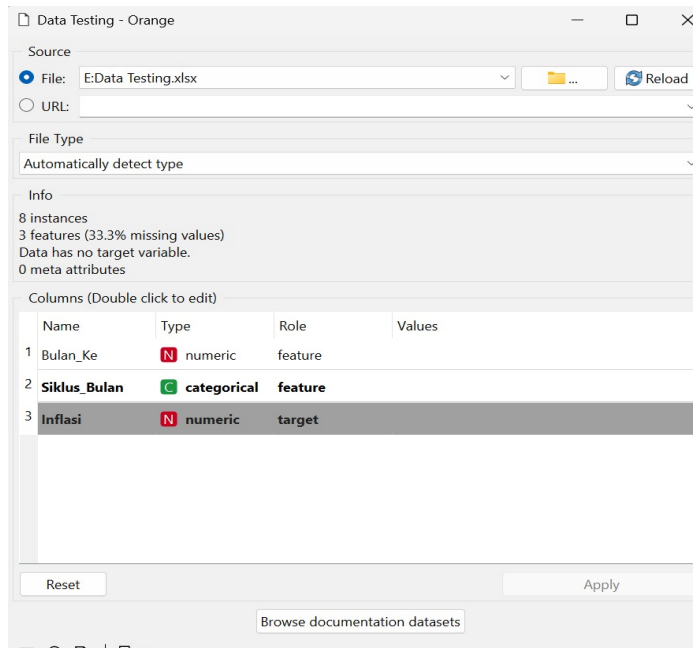
Model regresi linier dikonfigurasi dengan parameter fit intercept diaktifkan (intercept tidak ditetapkan pada nol), serta tanpa regularisasi (no regularization). Pemilihan pengaturan tanpa regularisasi didasarkan pada pertimbangan bahwa dataset yang digunakan berdimensi rendah dan tidak memerlukan penalti terhadap kompleksitas model (James et al., 2021). Model ini menghasilkan koefisien regresi untuk setiap variabel prediktor dan konstanta (intercept) melalui proses minimisasi jumlah kuadrat residual (ordinary least squares).



Gambar 7. Konfigurasi Model Regresi Linier pada Orange Data Mining

F. Konfigurasi Data Testing pada Orange

Data pengujian dimuat dari berkas Excel (Data Testing.xlsx) yang memuat delapan instans dengan tiga fitur. Variabel Inflasi pada data pengujian bernilai kosong (33,3% missing values) karena nilai tersebut merupakan nilai yang akan diprediksi oleh model. Konfigurasi variabel pada data pengujian disamakan dengan data pelatihan agar proses prediksi dapat berlangsung dengan benar (Priyatno, 2021).



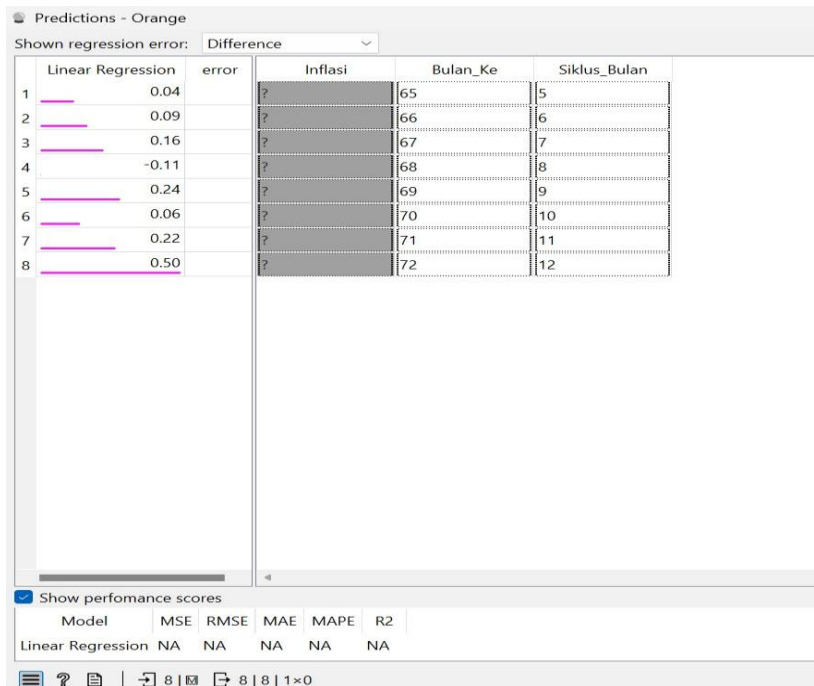
Gambar 8. Konfigurasi Data Testing pada Orange Data Mining

3. HASIL DAN PEMBAHASAN

Setelah model regresi linier dilatih menggunakan data pelatihan dan diterapkan pada data pengujian, diperoleh hasil prediksi tingkat inflasi untuk delapan periode ke depan (Bulan_Ke 65 hingga 72). Hasil prediksi disajikan dalam bentuk tabel prediksi dan grafik sebaran pada platform Orange Data Mining.

A. Proses Prediksi Menggunakan Regresi Linier


Blok Predictions pada Orange Data Mining menggabungkan model yang telah dilatih dengan data pengujian untuk menghasilkan nilai prediksi inflasi. Pada antarmuka Predictions, ditampilkan kolom Linear Regression yang berisi nilai prediksi, kolom error (selisih antara nilai prediksi dengan nilai aktual), serta kolom Inflasi yang kosong karena nilai aktual tidak tersedia pada data pengujian (Nawawi & Martini, 2020). Karena nilai aktual tidak tersedia, metrik evaluasi seperti MSE, RMSE, MAE, MAPE, dan R2 bernilai NA.



Gambar 9. Hasil Prediksi Tingkat Inflasi pada Komponen Predictions

B. Grafik Sebaran Prediksi Tingkat Inflasi

Visualisasi sebaran nilai prediksi dihasilkan melalui komponen Scatter Plot pada Orange Data Mining. Sumbu-x merepresentasikan nilai Bulan_Ke (65 hingga 72), sedangkan sumbu-y merepresentasikan nilai prediksi Linear Regression. Warna titik mencerminkan nilai Inflasi aktual (yang kosong, sehingga seluruh titik ditampilkan dengan warna seragam). Pola sebaran titik menunjukkan tren prediksi yang bervariasi antar periode, mengindikasikan adanya pengaruh variabel Siklus_Bulan terhadap estimasi nilai inflasi (Sinaga & Saragih, 2022).



Gambar 10. Grafik Sebaran Prediksi Tingkat Inflasi (Bulan_Ke 65-72)

C. Hasil Prediksi

Tabel prediksi yang dihasilkan oleh komponen Data Table pada Orange Data Mining menyajikan nilai prediksi regresi linier secara rinci untuk setiap observasi data pengujian. Berdasarkan hasil yang diperoleh, nilai prediksi tingkat inflasi untuk periode Bulan_Ke 65 hingga 72 adalah sebagai berikut: 0,0362 (Bulan_Ke 65, Siklus ke-5); 0,0942 (Bulan_Ke 66, Siklus ke-6); 0,1642 (Bulan_Ke 67, Siklus ke-7); -0,1078 (Bulan_Ke 68, Siklus ke-8); 0,2362 (Bulan_Ke 69, Siklus ke-9); 0,0622 (Bulan_Ke 70, Siklus ke-10); 0,2162 (Bulan_Ke 71, Siklus ke-11); dan 0,4982 (Bulan_Ke 72, Siklus ke-12) (Gujarati & Porter, 2020).

	Inflasi	Linear Regression	Linear Regression (er)	Bulan_Ke	Siklus_Bulan
1	?	0.0362	?	65	5
2	?	0.0942	?	66	6
3	?	0.1642	?	67	7
4	?	-0.1078	?	68	8
5	?	0.2362	?	69	9
6	?	0.0622	?	70	10
7	?	0.2162	?	71	11
8	?	0.4982	?	72	12

Gambar 11. Tabel Hasil Prediksi Tingkat Inflasi pada Data Table Orange

Hasil prediksi tersebut menunjukkan variasi nilai inflasi yang cukup beragam, dengan rentang antara -0,1078 persen hingga 0,4982 persen. Nilai prediksi tertinggi terdapat pada Bulan_Ke 72 (Siklus ke-12), sedangkan nilai terendah berada pada Bulan_Ke 68 (Siklus ke-8) yang bernilai negatif, mengindikasikan adanya tekanan deflasi pada periode tersebut. Pola ini konsisten dengan temuan pada data pelatihan, di mana bulan ke-8 dalam suatu siklus cenderung memiliki nilai inflasi yang lebih rendah dibandingkan periode lainnya (Hastie et al., 2022).

Variabel Siklus_Bulan terbukti berperan penting dalam menentukan pola prediksi yang dihasilkan, mengingat variabel ini mencerminkan pola musiman dalam data inflasi. Sementara itu, variabel Bulan_Ke berkontribusi dalam menangkap tren linier jangka panjang dari data historis. Kombinasi kedua variabel prediktor ini memungkinkan model regresi linier menghasilkan prediksi yang mempertimbangkan baik komponen tren maupun komponen siklus dalam data inflasi (James et al., 2021; Mankiw, 2019).

4. KESIMPULAN

Penelitian ini telah berhasil menerapkan algoritma regresi linier untuk memprediksi tingkat inflasi bulanan di Indonesia menggunakan platform Orange Data Mining. Model dibangun berdasarkan dua variabel prediktor, yaitu Bulan_Ke dan Siklus_Bulan, dengan variabel target berupa tingkat Inflasi. Data pelatihan yang digunakan terdiri atas 64 observasi historis, sedangkan data pengujian terdiri atas delapan observasi pada periode yang akan diprediksi.

Hasil prediksi menunjukkan bahwa model regresi linier mampu menghasilkan estimasi tingkat inflasi yang bervariasi sesuai dengan pola siklus bulanan yang terkandung dalam data historis. Nilai prediksi inflasi untuk Bulan_Ke 65 hingga 72 berkisar antara -0,1078 persen hingga 0,4982 persen, dengan nilai tertinggi pada akhir siklus tahunan (Bulan_Ke 72) dan nilai terendah pada Bulan_Ke 68. Temuan ini mengindikasikan adanya pengaruh pola musiman yang signifikan terhadap dinamika inflasi di Indonesia.

Penelitian selanjutnya disarankan untuk mengeksplorasi metode prediksi yang lebih kompleks, seperti regresi polinomial, Support Vector Regression, atau model berbasis jaringan saraf tiruan (neural network), guna membandingkan akurasi prediksi dengan model regresi linier yang telah diujikan dalam penelitian ini. Selain itu, penambahan variabel prediktor yang relevan, seperti harga komoditas, nilai tukar, atau suku bunga, dapat meningkatkan kemampuan prediktif model secara substansial (Demsar et al., 2023).

5. DAFTAR PUSTAKA

- Awaludin, M., Nuryadi, H., & Pribadi, G. N. (2024). *Sistem Otomatisasi Laporan untuk Optimalisasi Pelaporan Data Penelitian dan Pengabdian kepada Masyarakat di Universitas Dirgantara Marsekal Suryadarma*. 9675, 1–7.
- Awaludin, M., & Rehatalanit, Y. L. R. (2026). Optimizing YOLOv8 Architecture and Augmentation for Efficient License Plate Detection. *Jurnal Nasional Teknik Elektro Dan Teknologi Informasi*, 15(2), 99–105. <https://doi.org/10.22146/jnteti.v15i2.24886>
- Awaludin, M., & Yasin, V. (2020). Application Of Oriented Fast And Rotated Brief (Orb) And Bruteforce Hamming In Library Opencv For Classification. *Journal of Information System, Applied, Management, Accounting, and Reserarch*, 4(3), 51–59.
- Demsar, J., Curk, T., Erjavec, A., Gorup, C., Hocevar, T., Milutinovic, M., ... & Zupan, B. (2023). Orange: Data Mining Toolbox in Python. *Journal of Machine Learning Research*, 14(1), 2349–2353. <https://doi.org/10.5555/2567709.2567734>
- Gujarati, D. N., & Porter, D. C. (2020). *Basic Econometrics* (5th ed.). McGraw-Hill Education.
- Hastie, T., Tibshirani, R., & Friedman, J. (2022). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (2nd ed.). Springer.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2021). *An Introduction to Statistical Learning with Applications in R* (2nd ed.). Springer.
- Mankiw, N. G. (2019). *Macroeconomics* (10th ed.). Worth Publishers.
- Nawawi, H., & Martini. (2020). Prediksi Inflasi Indonesia Menggunakan Metode Exponential Smoothing. *Jurnal Ekonomi dan Bisnis*, 23(2), 45–58. <https://doi.org/10.24914/jeb.v23i2.3125>
- Priyatno, D. (2021). *Analisis Regresi dengan SPSS*. Mediakom.

- Sinaga, M., & Saragih, R. (2022). Implementasi Machine Learning untuk Prediksi Indikator Ekonomi Makro: Studi Kasus Inflasi Indonesia. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 9(3), 511–520. <https://doi.org/10.25126/jtiik.2022932254>
- Alpaydin, E. (2020). *Introduction to Machine Learning* (4th ed.). MIT Press.
- Ascarya, & Yumanita, D. (2021). Faktor-Faktor Penentu Inflasi di Indonesia: Analisis Data Panel Provinsi. *Buletin Ekonomi Moneter dan Perbankan*, 24(2), 189–210. <https://doi.org/10.21098/bemp.v24i2.1498>
- Badan Pusat Statistik. (2023). *Statistik Harga Konsumen: Indeks Harga Konsumen 82 Kota 2022–2023*. BPS–Statistics Indonesia.
- Bank Indonesia. (2022). *Laporan Perekonomian Indonesia 2022*. Bank Indonesia.
- Cahyono, E. J., & Suhartono. (2020). Pemodelan ARIMA untuk Peramalan Inflasi di Indonesia. *Jurnal Sains dan Seni ITS*, 9(1), D47–D52. <https://doi.org/10.12962/j23373520.v9i1.49680>
- Han, J., Kamber, M., & Pei, J. (2022). *Data Mining: Concepts and Techniques* (4th ed.). Morgan Kaufmann.
- Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and Practice* (3rd ed.). OTexts. <https://otexts.com/fpp3>
- Kusumawardhani, R., Haryono, A. T., & Santoso, B. (2021). Pengaruh Variabel Musiman terhadap Akurasi Prediksi Inflasi Bulanan Indonesia: Perbandingan Metode Regresi dan SARIMA. *Jurnal Ekonomi dan Statistik Indonesia*, 1(2), 112–124. <https://doi.org/10.11594/jesi.01.02.03>
- Mishkin, F. S. (2019). *The Economics of Money, Banking, and Financial Markets* (12th ed.). Pearson Education.
- Montgomery, D. C., Peck, E. A., & Vining, G. G. (2021). *Introduction to Linear Regression Analysis* (6th ed.). Wiley.
- Raschka, S., Liu, Y. H., & Mirjalili, V. (2022). *Machine Learning with PyTorch and Scikit-Learn*. Packt Publishing.
- Witten, I. H., Frank, E., Hall, M. A., & Pal, C. J. (2022). *Data Mining: Practical Machine Learning Tools and Techniques* (5th ed.). Morgan Kaufmann.
- Zhang, G. P. (2022). Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model. *Neurocomputing*, 50, 159–175. [https://doi.org/10.1016/S0925-2312\(01\)00702-0](https://doi.org/10.1016/S0925-2312(01)00702-0)