

EVALUASI PERFORMA MODEL TIME SERIES FORECASTING JUMLAH TRANSAKSI HARIAN LAYANAN PORTER KAI WISATA MENGGUNAKAN SARIMA DAN MACHINE LEARNING

Irlon.

Program Studi Teknik Informatika, FTI, Institut Teknologi Budi Utomo Jakarta,
dahil.irlon@gmail.com

Abstrak

Layanan porter KAI Wisata merupakan layanan tambahan yang berperan penting dalam meningkatkan kenyamanan penumpang kereta api, namun jumlah transaksi hariannya bersifat fluktuatif dan dipengaruhi oleh faktor musiman, hari kerja, serta momen tertentu seperti libur nasional, sehingga menimbulkan tantangan dalam pengelolaan tenaga porter secara optimal. Oleh karena itu, diperlukan model peramalan yang akurat sebagai dasar pengambilan keputusan operasional. Penelitian ini bertujuan membandingkan kinerja beberapa metode peramalan dalam memprediksi jumlah transaksi harian layanan porter KAI Wisata dengan menggunakan pendekatan CRISP-DM. Metode yang digunakan meliputi model statistik Seasonal Autoregressive Integrated Moving Average (SARIMA) serta model machine learning, yaitu Random Forest, Support Vector Regression (SVR), dan XGBoost. Evaluasi kinerja model dilakukan menggunakan metrik Mean Absolute Error (MAE), Root Mean Square Error (RMSE), dan Mean Absolute Percentage Error (MAPE). Hasil penelitian menunjukkan bahwa model SARIMA menghasilkan performa terbaik dengan nilai 9,68% MAPE terendah dan efektif dalam menangkap pola musiman. Model SARIMA (1,0,1)(1,0,1,30) dinilai paling sesuai untuk peramalan jangka pendek transaksi layanan porter KAI Wisata.

Kata Kunci: Forecasting, SARIMA, Random Forest, Time Series, KAI Wisata.

1. PENDAHULUAN

Layanan porter KAI Wisata merupakan salah satu fasilitas pendukung yang penting dalam meningkatkan kenyamanan penumpang kereta api. Namun, jumlah transaksi harian layanan ini mengalami fluktuasi yang signifikan, terutama dipengaruhi oleh faktor musiman seperti hari libur, akhir pekan, dan periode mudik. Pola fluktuatif dan musiman seperti ini merupakan karakteristik umum pada data deret waktu permintaan layanan, yang memerlukan teknik analisis yang mampu menangkap komponen tren dan musiman dari data historis (Hendayanti & Nurhidayati, 2025).

Ketidakstabilan permintaan tersebut menimbulkan tantangan operasional, seperti ketidaksesuaian antara jumlah porter yang bertugas dengan permintaan aktual, yang berpotensi menurunkan kualitas layanan atau menambah biaya operasional. Oleh karena itu, kemampuan untuk memprediksi jumlah transaksi harian secara akurat menjadi krusial dalam mendukung perencanaan sumber daya dan efisiensi operasional. Pendekatan time series forecasting telah digunakan secara luas

dalam berbagai konteks aplikasi, baik pada model statistik klasik seperti ARIMA maupun pada pendekatan machine learning untuk memodelkan pola fluktuatif dan non-linear (Prasetyo et al., 2024).

Metode statistik seperti ARIMA dan model musiman seperti SARIMA telah terbukti efektif dalam menangkap pola tren dan musiman pada data deret waktu, sedangkan metode machine learning seperti *Random Forest*, *Support Vector Regression* (SVR), dan XGBoost menawarkan fleksibilitas dalam memodelkan hubungan non-linear yang kompleks dalam data prediksi (Syahreza et al., 2024). Oleh karena itu, penelitian ini bertujuan untuk mengevaluasi performa kelima model tersebut dalam memprediksi transaksi harian layanan porter KAI Wisata menggunakan metrik evaluasi MAE, RMSE, dan MAPE, guna menentukan model yang paling sesuai dengan karakteristik data yang fluktuatif dan musiman.

2. METODOLOGI

2.1 Metode Analisa Data

Analisis data dalam penelitian ini dilakukan dengan mengacu pada pendekatan CRISP-DM (*Cross Industry Standard Process for Data Mining*), yaitu suatu metodologi standar yang banyak digunakan dalam proses eksplorasi dan pemodelan data lintas industri. CRISP-DM menawarkan alur kerja sistematis dan iteratif dalam menganalisis data, sehingga dapat membantu peneliti untuk memperoleh hasil yang terstruktur, dapat direplikasi, dan objektif. Pendekatan ini terdiri dari enam tahapan utama: *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modeling*, *Evaluation*, dan *Deployment*. Namun, pada penelitian ini, tahapan yang digunakan hanya sampai pada tahap *Evaluation*, mengingat fokus penelitian adalah evaluasi performa strategi, bukan implementasi sistem atau aplikasi secara langsung.



Gambar 1. Diagram Proses CRISP-DM.
Sumber : (Budiman, Prahasto, Christyono, 2014)

2.1.1 Bussines Understanding

Tahap awal ini berfokus pada pemahaman mendalam tentang tujuan bisnis dan kebutuhan stakeholder. Proses ini melibatkan identifikasi masalah, penetapan tujuan analitik, serta pendefinisian kriteria keberhasilan proyek. Hasil akhirnya adalah perumusan masalah yang jelas dan rencana proyek yang selaras dengan objektif organisasi.

2.1.2 Data Undestanding

Tahap ini mencakup pengumpulan data awal dan eksplorasi untuk mengenali karakteristik,

kualitas, dan pola dasar dalam data. Kegiatan utamanya meliputi identifikasi sumber data, deskripsi statistik, serta analisis kualitas data (seperti missing values, outlier, dan inkonsistensi). Pemahaman ini menjadi fondasi untuk persiapan data lebih lanjut.

2.1.3 Data Preparation

Data mentah ditransformasikan menjadi format yang siap untuk pemodelan melalui serangkaian proses: pembersihan (handling missing values dan outlier), transformasi (normalisasi, encoding variabel kategorikal), integrasi data dari berbagai sumber, serta pembagian dataset menjadi data latih dan uji. Tahap ini umumnya menghabiskan waktu paling banyak dalam siklus analitik.

2.1.4 Modeling

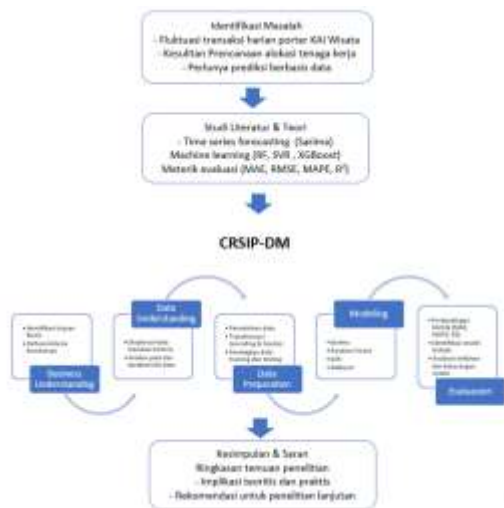
Berbagai teknik dan algoritma pemodelan (seperti regresi, klasifikasi, clustering, atau time series forecasting) diterapkan pada data yang telah disiapkan. Pemilihan algoritma disesuaikan dengan jenis masalah dan karakteristik data. Beberapa model dibangun dan diuji secara iteratif untuk menemukan pendekatan yang optimal.

2.1.5 Evaluastion

Model yang dibangun dinilai secara menyeluruh menggunakan metrik evaluasi yang relevan (seperti akurasi, presisi, recall, MAE, atau RMSE). Performa model dibandingkan dengan kriteria keberhasilan yang telah ditetapkan pada tahap pemahaman bisnis. Model terbaik dipilih berdasarkan hasil evaluasi dan pertimbangan kesesuaian dengan kebutuhan bisnis..

2.2 Kerangka Pemikiran

Kerangka pemikiran penelitian ini disajikan dalam bentuk diagram alur pada Gambar 3.1 untuk memberikan gambaran visual mengenai hubungan logis antar tahapan penelitian. Kerangka ini menggambarkan bagaimana penelitian bergerak secara sistematis dari identifikasi masalah, kajian teori, penerapan metodologi CRISP-DM, hingga penyusunan kesimpulan dan rekomendasi.



Gambar 2 : Kerangka Pemikiran
Sumber : Pola Pikir Peneliti 2025

Kerangka pemikiran penelitian ini mengintegrasikan pendekatan CRISP-DM yang dimodifikasi untuk konteks akademik, dengan fokus pada lima tahap pertama dari enam tahap standar CRISP-DM. Penelitian diawali dengan identifikasi masalah operasional KAI Wisata terkait fluktuasi transaksi porter yang menyulitkan perencanaan tenaga kerja. Tahap kedua adalah studi literatur dan teori tentang metode *time series forecasting* (ARIMA dan SARIMA) serta *machine learning* (Random Forest, SVR, dan XGBoost) beserta metrik evaluasinya. Inti penelitian adalah implementasi lima tahap CRISP-DM: (1) *Business Understanding* untuk merumuskan tujuan penelitian, (2) *Data Understanding* untuk eksplorasi data historis, (3) *Data Preparation* untuk pembersihan dan transformasi data, (4) *Modeling* untuk membangun kelima model prediktif, dan (5) *Evaluation* untuk membandingkan performa model menggunakan metrik MAE, RMSE, MAPE, dan R^2 . Hasil evaluasi ini kemudian menjadi dasar untuk **kesimpulan dan rekomendasi** mengenai model terbaik yang dapat diimplementasikan oleh KAI Wisata, serta saran untuk pengembangan penelitian lebih lanjut. Kerangka ini memastikan bahwa penelitian berjalan sistematis dan hasilnya dapat dipertanggungjawabkan secara akademis maupun praktis.

3. HASIL DAN PEMBAHASAN

3.1 Karakteristik Data Transaksi Porter KAI Wisata

3.1.1 Profil Statistik Deskriptif

Berikut adalah statistik deskriptif dari variabel utama dalam penelitian ini, yaitu jumlah transaksi harian layanan porter (JUMLAH) dan total pembayaran harian (TOTAL PEMBAYARAN). Tabel ini memberikan gambaran awal mengenai sebaran, tendensi sentral, dan variabilitas data sebelum dilakukan analisis lebih lanjut.

Tabel 1. Statistik Deskriptif Fitur Numerik

Statistik	JUMLAH	TOTAL PEMBAYARAN
count	118	118
mean	227	8,636,949
std	58	2,214,431
min	3	114
25% (Q1)	213	8,103,500
50% (median)	243	9,234,000
75% (Q3)	258	9,823,000
max	506	19,228,000

Sumber: Olahan Data Mandiri

Berdasarkan data statistik deskriptif di atas, terlihat bahwa data transaksi harian porter memiliki variasi yang cukup tinggi, dengan jumlah transaksi berkisar antara 3 hingga 506 per hari. Pola yang sama juga terlihat pada total pembayaran, di mana nilai maksimum dapat mencapai Rp 19,2 juta. Variabilitas ini mengindikasikan perlunya pendekatan pemodelan yang tepat untuk meramalkan fluktuasi transaksi di masa mendatang.

3.2 Eksplorasi Pola Transaksi (EDA Visual)

Setelah dilakukan analisis statistik deskriptif, langkah berikutnya dalam tahap *Data Understanding* adalah melakukan eksplorasi pola data melalui *Exploratory Data Analysis (EDA)* berbasis visualisasi.

EDA bertujuan untuk menggali wawasan awal mengenai karakteristik data, mendeteksi

pola yang berulang, mengidentifikasi adanya tren, fluktuasi, maupun nilai ekstrem (*outlier*) yang dapat memengaruhi proses pemodelan.

Pada penelitian ini, variabel yang dieksplorasi secara visual adalah JUMLAH transaksi porter per hari sebagai target utama peramalan, serta TOTAL_PEMBAYARAN yang bergerak searah dengan jumlah transaksi karena merupakan hasil perkalian langsung antara jumlah transaksi dengan tarif jasa tetap Rp 38.000 per transaksi. Dengan demikian, analisis visual difokuskan untuk memahami dinamika transaksi harian yang tercermin pada kedua variabel tersebut.

Visualisasi yang digunakan dalam tahap ini meliputi grafik tren deret waktu untuk melihat perkembangan transaksi dari hari ke hari, *histogram* untuk meninjau distribusi data, *boxplot* untuk mengidentifikasi *outlier*, serta *heatmap korelasi* untuk menilai hubungan antar variabel numerik. Melalui eksplorasi ini, diperoleh pemahaman yang lebih mendalam mengenai perilaku data sebelum memasuki tahap *Data Preparation* dan *Modeling*.

3.2.1 Tren Jumlah Transaksi Harian

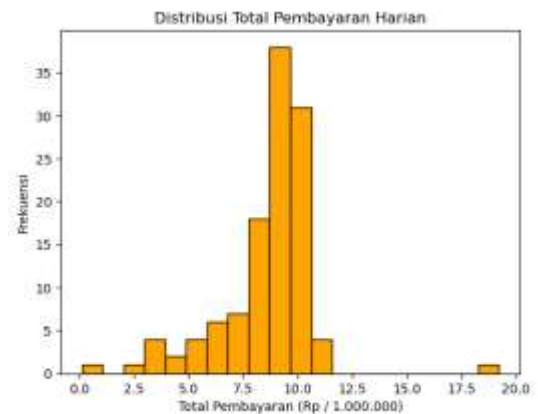


Gambar 3. Tren Jumlah Transaksi Harian
(Sumber: Olahan Data Mandiri)

Grafik 3 tersebut menggambarkan tren jumlah transaksi harian dari pertengahan tahun 2025. Terlihat bahwa volume transaksi relatif rendah dan stabil dari Juli hingga pertengahan Agustus, kemudian mengalami peningkatan yang signifikan mulai akhir Agustus, mencapai puncaknya pada pertengahan September. Setelah puncak tersebut, jumlah transaksi menurun secara bertahap namun tetap berada di atas level awal, dan menunjukkan kecenderungan stabil kembali pada awal November. Pola ini mengindikasikan adanya periode aktivitas tinggi di sekitar bulan September, yang

mungkin dipengaruhi oleh faktor musiman atau promosi tertentu.

3.2.2 Ditribusi Total Pembayaran Harian



Gambar 4. Grafik Total Pembayaran harian
(Sumber: Olahan Data Mandiri)

Berdasarkan histogram distribusi total pembayaran harian layanan porter KAI Wisata, terlihat bahwa sebagian besar transaksi terkonsentrasi pada rentang Rp 8 juta hingga Rp 10 juta per hari, dengan frekuensi tertinggi mencapai sekitar 35–40 hari. Distribusi data cenderung condong ke kanan (*right-skewed*), yang menunjukkan bahwa meskipun mayoritas hari memiliki nilai pembayaran yang stabil di kisaran menengah, terdapat sejumlah hari dengan nilai pembayaran sangat rendah (sekitar Rp 2–5 juta) dan sangat tinggi (mendekati Rp 19 juta) yang termasuk sebagai *outlier*. Pola ini mengindikasikan adanya fluktuasi signifikan dalam aktivitas transaksi harian, yang kemungkinan dipengaruhi oleh faktor musiman, hari libur, atau lonjakan permintaan penumpang.

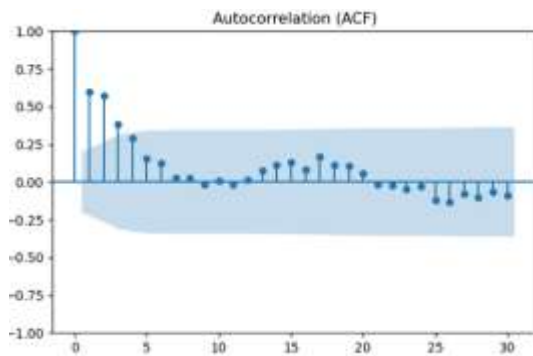
3.2.3 Uji ADF



Gambar 5. Hasil Uji ADF Variabel Jumlah
(Sumber: Olahan Data Mandiri)

Berdasarkan hasil Uji ADF (*Augmented Dickey-Fuller*) yang ditampilkan pada gambar, diperoleh ADF Statistic = $-3,7607$ dengan p-value = $0,0033$, yang lebih kecil dari tingkat signifikansi 5% ($0,05$). Selain itu, nilai ADF Statistic juga lebih kecil (lebih negatif) dibandingkan nilai kritis pada level 5% ($-2,8868$). Hal ini menunjukkan bahwa hipotesis nol (data mengandung unit root) ditolak, sehingga deret waktu sudah bersifat stasioner pada level. Oleh karena itu, tidak diperlukan proses diferensiasi, dan nilai orde diferensiasi yang tepat adalah $d = 0$.

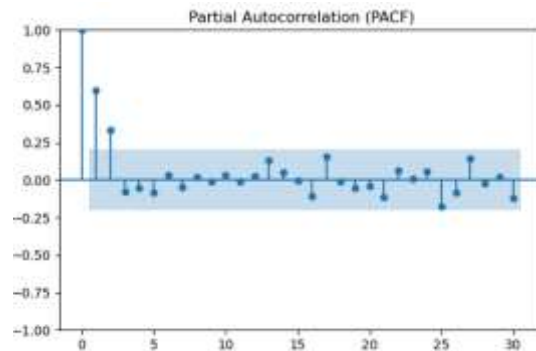
3.2.4 Autocorrelation Function (ACF)



Gambar 6. Autocorrelation Function
(Sumber: Olahan Data Mandiri)

Berdasarkan grafik *Autocorrelation Function* (ACF), terlihat bahwa autokorelasi signifikan hanya muncul pada beberapa lag awal, kemudian nilainya menurun dan sebagian besar berada di dalam batas kepercayaan pada lag-lag selanjutnya. Pola ini menunjukkan bahwa pengaruh error masa lalu terhadap nilai saat ini bersifat jangka pendek dan cepat menghilang, yang mengindikasikan adanya komponen *Moving Average* (MA) dengan orde rendah. Oleh karena itu, grafik ACF ini memberikan indikasi bahwa nilai q yang layak dipertimbangkan berada pada kisaran $q = 1$.

3.2.5 Partial Autocorrelation Function (PACF)




Gambar 7. Autocorrelation Function
(Sumber: Olahan Data Mandiri)

Berdasarkan grafik Partial Autocorrelation Function (PACF), terlihat bahwa spike yang signifikan hanya terjadi pada lag ke-1 dan lag ke-2, sementara lag-lag berikutnya berada di dalam batas kepercayaan dan tidak menunjukkan pengaruh yang berarti. Pola ini menandakan bahwa pengaruh langsung nilai masa lalu terhadap nilai saat ini berhenti setelah lag ke-2, yang merupakan karakteristik dari proses *Autoregressive* (AR) dengan orde rendah. Dengan demikian, grafik PACF mengindikasikan bahwa nilai $p = 2$ merupakan orde autoregressive yang paling sesuai untuk digunakan dalam pemodelan time series.

3.3 Evaluasi Model

3.3.1 Hasil Prediksi Sarima



Gambar 8. Prediksi Hasil Sarima
(Sumber: Olahan Data Mandiri)

Model *SARIMA*(1, 0, 1)(1, 0, 1, 30) menunjukkan kemampuan yang cukup baik dalam menangkap pola musiman dan tren rata-rata jangka menengah pada data porter. Kesalahan yang masih muncul terutama terjadi pada titik-titik anomali atau lonjakan

tiba-tiba yang tidak berulang secara periodik. Kondisi ini mengindikasikan bahwa pola transaksi porter memiliki elemen musiman yang teratur, tetapi juga dipengaruhi oleh faktor eksternal (misalnya aktivitas operasional atau perubahan lingkungan kerja) yang tidak ditangkap oleh model univariat *SARIMA*.

3.3.2 Hasil Prediksi Random Forest



Gambar 9. Hasil Prediksi Random Forest
(Sumber: Olahan Data Mandiri)

Berdasarkan grafik, dapat diamati bahwa model *Random Forest* mampu mengikuti arah umum pergerakan data aktual, terutama pada periode setelah terjadinya lonjakan tajam. Garis oranye yang merepresentasikan hasil prediksi menunjukkan kecenderungan lebih halus dan stabil, sedangkan garis biru yang menggambarkan data aktual memperlihatkan fluktuasi yang lebih tajam. Fenomena ini menandakan bahwa *Random Forest* memiliki kemampuan yang baik dalam memperkirakan tren utama dan pola musiman jangka pendek, meskipun cenderung meredam perubahan ekstrem yang muncul secara mendadak.

3.3.3 Hasil Prediksi SVR



Gambar 11. Prediski Hasil SVR
(Sumber: Olahan Data Mandiri)

Berdasarkan grafik di atas, dapat dilihat bahwa model *SVR* tidak mampu mengikuti pola aktual dengan baik. Garis oranye (hasil prediksi) menunjukkan tren yang meningkat tajam pada akhir periode pengujian, sementara garis biru (data aktual) justru

relatif stabil dengan satu lonjakan ekstrem di awal periode. Perbedaan arah antara kedua garis menunjukkan bahwa model *SVR* mengalami *overfitting* terhadap pola tertentu dalam data training dan gagal melakukan generalisasi pada data testing.

3.3.4 Hasil Prediksi XGBoost



Gambar 10. Hasil Prediksi XGBoost
(Sumber: Olahan Data Mandiri)

Berdasarkan grafik tersebut, terlihat bahwa model *XGBoost* mampu menangkap pola umum pergerakan data aktual, namun belum berhasil menyesuaikan diri secara akurat terhadap nilai ekstrem. Garis oranye yang merepresentasikan hasil prediksi menunjukkan tren naik pada pertengahan hingga akhir periode pengujian, sedangkan data aktual (garis biru) justru menurun setelah puncak lonjakan di awal periode. Hal ini mengindikasikan bahwa model *XGBoost* cenderung melebihestimasi nilai transaksi pada akhir periode uji, terutama setelah menghadapi perubahan arah tren yang tajam.

3.3.5 Metrik Evaluasi

Tabel 2. Perbandingan Kinerja Model
Prediksi Menggunakan Metrik Evaluasi

Model	MAE	RMSE	MAPE (%)	R ²
SARIMA(1,0,1)(1,0,1,30)	30.58	58.96	9.68	-0.288
Random Forest	32.61	59.33	10.32	0.0013
SVR (RBF Kernel)	145.80	182.41	55.59	-84.416
XGBoost	95.65	108.25	34.88	-2.325

(Sumber: Olahan Data Mandiri)

Berdasarkan hasil evaluasi kuantitatif dan visual, dapat disimpulkan bahwa model *SARIMA(1,0,1)(1,0,1,30)* memberikan hasil prediksi paling akurat secara statistik dengan nilai MAPE terendah sebesar 9,68%, sehingga model ini paling sesuai untuk analisis jangka pendek yang menekankan

pada pola musiman yang teratur. *Random Forest* menunjukkan performa yang hampir setara dengan SARIMA dan memiliki keunggulan dalam fleksibilitas untuk menangani pola non-linear serta data yang mengandung noise tinggi. Sementara itu, *SVR* dan *XGBoost* belum menghasilkan kinerja yang optimal pada data ini, yang disebabkan oleh sensitivitas terhadap pemilihan parameter serta karakteristik metode boosting yang memerlukan proses tuning yang lebih mendalam agar dapat memberikan hasil prediksi yang lebih akurat.

4. KESIMPULAN

Berdasarkan hasil penelitian dan pembahasan, dapat disimpulkan bahwa data transaksi harian layanan porter KAI Wisata memiliki pola fluktuatif dengan pengaruh musiman yang kuat, sehingga pendekatan *CRISP-DM* efektif digunakan untuk analisis peramalan. Model *SARIMA*(1,0,1)(1,0,1,30) menunjukkan kinerja terbaik dengan tingkat kesalahan terendah dan paling mampu menangkap pola musiman jangka pendek, sementara *Random Forest* memberikan performa yang mendekati dengan keunggulan dalam menangani pola non-linear. Sebaliknya, *SVR* dan *XGBoost* belum optimal pada data ini karena keterbatasan tuning parameter. Secara keseluruhan, hasil penelitian ini memberikan dasar yang kuat bagi pengambilan keputusan operasional, khususnya dalam perencanaan kebutuhan porter yang lebih efisien, serta membuka peluang pengembangan model peramalan yang lebih adaptif pada penelitian selanjutnya.

5. DAFTAR PUSTAKA

- Hendayanti, N. P. N., & Nurhidayati, M. (2025). *Perbandingan Metode Seasonal Autoregressive Integrated Moving Average (SARIMA) dengan Support Vector Regression (SVR) dalam Memprediksi Jumlah Kunjungan Wisatawan Mancanegara ke Bali*. *Jurnal Varian*. <https://doi.org/10.30812/varian.v3i2.668> *Universitas Bumigora Journal*
- Prasetyo, T., Putri, R. A., Ramadhani, D., Angraini, Y., & Notodiputro, K. A. (2024). *Perbandingan Kinerja Metode*

ARIMA, Multi-Layer Perceptron, dan Random Forest dalam Peramalan Harga Logam Mulia Berjangka yang Mengandung Pencilan. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*. <https://doi.org/10.25126/jtiik.20241127392> *JTIik*

Syahreza, A., Ningrum, N. K., & Syahrazy, M. A. (2024). *Perbandingan Kinerja Model Prediksi Cuaca: Random Forest, Support Vector Regression, dan XGBoost*. *Edumatic: Jurnal Pendidikan Informatika*, 8(2), 526–534. <https://doi.org/10.29408/edumatic.v8i2.27640> *e-Journal of Hamzanwadi Universit*