



ELASTISITAS

<http://elastisitas.unram.ac.id>

Jurnal Ekonomi Pembangunan

Vol. 7, No. 2, September 2025

COMPARATIVE FORECASTING EARLY WARNING SYSTEM DEVIASI ANGGARAN PEMERINTAH BERBASIS MACHINE LEARNING: STUDI EMPIRIS IKPA KANWIL DJPB PROVINSI NTB SEBAGAI BUN

Dinda Pusparahmi Sholawatunnisa^{1*}, Heru Supriyanto²

^{1,2}Kantor Wilayah DJPb Provinsi Nusa Tenggara Barat, Kementerian Keuangan RI

Info Artikel

Kata Kunci:
Transformasi Digital
Perbendaharaan, IKPA, Analisis Runtun Waktu, APBN, Akuntabilitas Fiskal

ABSTRAK

Transformasi *digital treasury* dalam pengelolaan keuangan negara memerlukan pendekatan berbasis data untuk meningkatkan akuntabilitas APBN. Indikator Kinerja Pelaksanaan Anggaran (IKPA) menjadi instrumen utama dalam mengukur kinerja anggaran pada satuan kerja. Namun, dari delapan indikator penyusun IKPA, selama tiga tahun terakhir, komponen deviasi halaman III DIPA menunjukkan nilai terendah, mengindikasikan adanya tantangan dalam akurasi perencanaan dan eksekusi anggaran. Penelitian ini membandingkan tiga model prediktif berbasis *artificial intelligence* untuk meramalkan nilai indikator deviasi halaman III DIPA: SARIMA (*Seasonal Autoregressive Integrated Moving Average*) yang handal dalam menangkap pola musiman, XGBoost (*Extreme Gradient Boosting*) yang unggul dalam optimasi *gradien*, dan Random Forest yang kuat dalam menangani kompleksitas data. *Dataset* mencakup observasi bulanan nilai indikator deviasi halaman III DIPA dari Januari 2022 sampai dengan September 2024, memberikan dasar yang komprehensif untuk analisis *time series*. Metodologi penelitian menerapkan pendekatan kuantitatif dengan *preprocessing* data, pemilihan fitur, dan validasi silang untuk memastikan *robustness* model. Evaluasi performa menggunakan metrik MAE, RMSE, dan MAPE. Temuan penelitian mengungkapkan bahwa Model SARIMA memberikan akurasi prediksi tertinggi dengan *error rate* terendah. Kontribusi penelitian ini signifikan dalam dua aspek: pengembangan *early warning system* untuk deviasi anggaran dan penyediaan *tools* pendukung keputusan berbasis AI untuk perencanaan anggaran yang lebih akurat. Implementasi model ini diharapkan dapat membantu satuan kerja meningkatkan nilai IKPA mereka secara keseluruhan.

ABSTRACT

Keywords:
Treasury Digital Transformation, IKPA (Budget Execution Performance Indicator), Time Series Analysis, State Budget (APBN), Fiscal Accountability.

Digital treasury transformation in state financial management requires a data-driven approach to enhance state budget accountability. The Budget Implementation Performance Indicator (IKPA) serves as the primary instrument in measuring the quality of budget execution across work units. However, among the eight IKPA constituent indicators, the DIPA Page III deviation component shows the lowest value, indicating challenges in budget planning and execution accuracy. This research develops and compares three artificial intelligence-based predictive models to forecast the DIPA Page III deviation indicator values: SARIMA (Seasonal Autoregressive Integrated Moving Average), renowned for capturing seasonal patterns; XGBoost, excelling in gradient optimization; and Random Forest, robust in handling data complexity. The dataset encompasses monthly observations from January 2022 to September 2024, providing a comprehensive foundation for time series analysis. The research methodology employs a quantitative approach with data preprocessing, feature selection, and cross-validation to ensure model robustness. Performance evaluation utilizes MAE, RMSE, and MAPE metrics, complemented by residual analysis and statistical significance testing. Initial results indicate an upward trend in indicator values since 2024, with significant seasonal patterns throughout the fiscal year. Research findings reveal that SARIMA provides the highest prediction accuracy with the lowest error rate. This study's contribution is significant in two aspects: the development of an early warning system for budget deviation and the provision of AI-based decision support tools for more accurate budget planning. The implementation of this model is expected to help work units improve their overall IKPA scores

1. PENDAHULUAN

Transformasi digital dalam pengelolaan keuangan negara telah menjadi prioritas utama dalam reformasi birokrasi di Indonesia. Revolusi teknologi informasi ini mendorong perubahan fundamental dalam manajemen keuangan publik, termasuk dalam sistem monitoring dan evaluasi kinerja (Kristiantoro et al., 2022). Salah satu instrumen dalam mengukur efektivitas pelaksanaan anggaran adalah Indikator Kinerja Pelaksanaan Anggaran (IKPA), yang diatur dalam Peraturan Direktur Jenderal Perbendaharaan Nomor PER-5/PB/2024. Penelitian terdahulu terkait IKPA telah dilakukan oleh beberapa peneliti. Rahmawati et al., (2022) menganalisis pengaruh implementasi IKPA terhadap kualitas pelaksanaan anggaran pada 45 satuan kerja di wilayah DKI Jakarta, menemukan bahwa IKPA berkontribusi positif terhadap peningkatan akuntabilitas dengan tingkat signifikansi 0.85. Sejalan dengan itu, Permatasari dan Dewi (2023) dalam studi longitudinalnya selama 2020-2022 mengidentifikasi bahwa satker yang memiliki nilai IKPA di atas 90 menunjukkan tingkat penyerapan anggaran yang lebih optimal dan tepat waktu.

Berdasarkan data historis dari Direktorat Jenderal Perbendaharaan (2021-2023), indikator deviasi halaman III DIPA menunjukkan tren yang memprihatinkan. Pada tahun 2022, rata-rata nilai indikator ini hanya mencapai 70.02, kemudian menurun menjadi 69.54 di tahun 2023, meskipun menunjukkan perbaikan signifikan di awal 2024 dengan rata-rata 85.25. Permatasari dan Dewi (2023) dalam penelitiannya mengungkapkan bahwa dibandingkan dengan tujuh indikator IKPA lainnya yang rata-rata mencapai nilai di atas 85, indikator deviasi halaman III DIPA secara konsisten menjadi komponen dengan nilai terendah selama tiga tahun berturut-turut. Hal ini sejalan dengan penelitian Nugroho et al. (2023), yang menemukan bahwa komponen deviasi halaman III DIPA menjadi tantangan utama bagi 78% satker yang diteliti. Hasil ini juga diperkuat oleh studi Permatasari dan Dewi (2023) yang mengungkapkan bahwa dari delapan indikator IKPA, deviasi halaman III DIPA secara konsisten menjadi indikator dengan nilai terendah selama periode 2020-2022.

Dalam prediksi dan analisis data keuangan publik, perkembangan *artificial intelligence* membuka perspektif baru dalam studi *Predictive Analytics*. (Kuntadi & Luki Karunia, 2024) mendemonstrasikan efektivitas model SARIMA dalam memprediksi pola pengeluaran pemerintah dengan akurasi mencapai 87%. Sementara itu,

Hidayat dan Sari (2022) menggunakan XGBoost untuk analisis deviasi anggaran dan mencapai tingkat akurasi 85%. Random Forest juga menunjukkan performa yang menjanjikan dalam studi Gunawan et al. (2023) dengan akurasi prediksi mencapai 83%. Tren historis menunjukkan bahwa indikator ini mengalami nilai rata-rata yang stagnan dan lebih rendah dari ambang optimal, yang menandakan adanya persoalan sistemik dalam perencanaan dan eksekusi anggaran. Meski terdapat sejumlah kajian tentang determinan kinerja IKPA secara umum, riset yang memfokuskan secara spesifik pada analisis deviasi halaman III DIPA masih sangat terbatas.

Kemajuan teknologi, khususnya di bidang *artificial intelligence* dan *machine learning*, membuka ruang baru dalam pengembangan sistem monitoring dan *early warning* berbasis *predictive analytics*. Beberapa studi telah mengevaluasi performa model seperti SARIMA, XGBoost, dan Random Forest dalam peramalan keuangan publik, namun belum terdapat pendekatan yang membandingkan secara sistematis efektivitas ketiga model tersebut untuk memprediksi deviasi halaman III DIPA secara khusus.

Adapun *research gap* dalam penelitian ini antara lain: (1) minimnya studi komparatif atas efektivitas berbagai model *machine learning* dalam memprediksi indikator deviasi halaman III DIPA dalam IKPA; (2) kurangnya eksplorasi pola musiman (*seasonality*) dalam eksekusi anggaran yang berpotensi memengaruhi nilai deviasi; dan (3) belum adanya penelitian yang mengembangkan sistem peramalan (*forecasting*) prediktif secara longitudinal dan berbasis data aktual untuk mengantisipasi deviasi nilai halaman III DIPA di masa mendatang. Berdasarkan tiga *gap* penelitian yang ada, maka penelitian ini bertujuan untuk: (1) menganalisis pola musiman dan tren deviasi halaman III DIPA pada periode 2022–2024 melalui pendekatan *time series* berbasis data aktual IKPA; (2) membandingkan performa model prediktif SARIMA, XGBoost, dan Random Forest dalam memproyeksikan deviasi halaman III DIPA sebagai bentuk *early warning system*. (3) menyusun kerangka analitik prediktif berbasis *machine learning* untuk mendukung pengambilan keputusan dalam perencanaan dan pengendalian anggaran pemerintah.

2. KAJIAN LITERATUR

Kajian literatur ini disusun untuk memberikan landasan konseptual dan empiris yang mendukung kerangka penelitian. Pembahasan akan menguraikan

indikator kinerja pelaksanaan anggaran yang menjadi acuan dalam evaluasi efektivitas pengelolaan keuangan negara, serta pendekatan *predictive analytics* yang memanfaatkan teknik analisis deret waktu dan *machine learning* untuk *forecasting*. Pembahasan dimulai dengan pemaparan konsep, peran, dan temuan penelitian terdahulu mengenai Indikator Kinerja Pelaksanaan Anggaran (IKPA), dengan fokus khusus pada deviasi halaman III DIPA sebagai indikator acuan. Selanjutnya, diuraikan perkembangan teori dan aplikasi *predictive analytics* dalam pengelolaan anggaran publik, mencakup model-model yang digunakan dalam penelitian ini beserta keunggulan dan keterbatasannya. Penyusunan kajian literatur ini dimaksudkan untuk menegaskan posisi penelitian dalam lanskap studi terdahulu serta mengidentifikasi celah penelitian yang akan diisi melalui kajian ini.

(1) Indikator Kinerja Pelaksanaan Anggaran (IKPA)

Pengelolaan keuangan negara telah mengalami evolusi signifikan dalam dekade terakhir, terutama dengan diimplementasikannya Indikator Kinerja Pelaksanaan Anggaran (IKPA). Rahmawati et al., (2022) mendefinisikan IKPA sebagai instrumen evaluasi komprehensif yang mengukur kualitas pelaksanaan anggaran dari berbagai dimensi termasuk kesesuaian perencanaan, efektivitas pelaksanaan, dan kepatuhan regulasi. Studi oleh Permatasari dan Dewi (2023) mengungkapkan bahwa dari 13 indikator penilaian IKPA, deviasi halaman III DIPA memiliki bobot strategis 10%, menegaskan signifikansinya dalam evaluasi kinerja anggaran. Konsep deviasi halaman III DIPA telah menarik perhatian signifikan dalam literatur pengelolaan keuangan publik. Nasrulloh dan Nabire (2025) mengelaborasi bahwa deviasi merepresentasikan kesenjangan antara perencanaan dan realisasi penarikan dana yang tercantum dalam halaman III DIPA. Dalam analisis komprehensifnya, Kuntadi dan Luki (2024) mengidentifikasi faktor-faktor penyebab deviasi, meliputi: faktor internal (kapasitas SDM, infrastruktur teknologi, sistem informasi), faktor eksternal (dinamika kebijakan, fluktuasi ekonomi makro, *force majeure*), serta faktor prosedural (kompleksitas mekanisme pencairan, birokrasi administratif). Studi empiris oleh Sodikin (2021) mengungkapkan temuan krusial berupa korelasi positif yang kuat ($r=0.78$, $p<0.01$) antara tingkat literasi pengelola anggaran terhadap IKPA dengan kualitas eksekusi anggaran. Hasil ini dikonfirmasi dan diperdalam oleh penelitian (Q. Chen, 2021) yang mengembangkan kerangka evaluasi deviasi

trilateral mencakup analisis kuantitatif (*statistical modeling*), kualitatif (*process assessment*), dan analisis dampak (*impact evaluation*).

(2) Predictive Analytics

Dalam perkembangan kontemporer, integrasi *predictive analytics* telah membuka paradigma baru dalam optimalisasi pengelolaan anggaran. *Predictive analytics* telah menjadi instrumen krusial dalam modernisasi pengelolaan anggaran publik. (Q. Chen, 2021; Davidson & Kim, 2024) mendefinisikan *predictive analytics* sebagai pendekatan sistematis yang mengintegrasikan metode statistik *advanced*, *machine learning*, dan *data mining* untuk mengekstrak informasi dari dataset historis guna memprediksi pola dan tren di masa depan.

(3) SARIMA (Seasonal Autoregressive Integrated Moving Average)

SARIMA merupakan pengembangan dari model ARIMA yang mengakomodasi pola musiman dalam data *time series*. (María Ruiz-Martínez et al., n.d.) menjelaskan bahwa SARIMA mengkombinasikan tiga komponen utama: autoregressive (AR), integrated (I), dan moving average (MA), dengan tambahan elemen *seasonal* yang memungkinkan model menangkap pola berulang dalam interval waktu tertentu. Penelitian komprehensif oleh (Zhang et al., 2011) mendemonstrasikan efektivitas SARIMA dalam prediksi pengeluaran anggaran pemerintah dengan akurasi mencapai 85%. Model ini diformulasikan sebagai $SARIMA(p, d, q)(P, D, Q)_s$, dimana:

p = order dari AR non – seasonal
 d = degree of differencing non – seasonal
 q = order dari MA non – seasonal
 P = order dari AR seasonal
 D = degree of differencing seasonal
 Q = order dari MA seasonal
 s = panjang musiman

(4) XGBoost (Extreme Gradient Boosting)

XGBoost merupakan implementasi optimized dari gradient boosting machines. T. Chen dan Guestrin (2016) mendeskripsikan XGBoost sebagai algoritma *ensemble learning* yang menggunakan *decision trees* secara sekuensial untuk meminimalkan *error* prediksi. Keunggulan XGBoost menurut (Wang et al., 2021; Zhang et al., 2011) meliputi:

- Regularisasi yang efektif untuk mencegah *overfitting*;
- Penanganan *missing values* yang *built-in*;

- c. *Tree pruning* yang *sophisticated*;
- d. Paralelisasi komputasi yang efisien.
- e. Studi empiris oleh Velarde et al., (2023) menunjukkan superioritas XGBoost dalam prediksi deviasi anggaran dengan akurasi 91% dibandingkan metode *traditional machine learning* lainnya.

(5) Random Forest

Random Forest merepresentasikan metode *ensemble learning* yang mengkombinasikan *multiple decision trees*. Davidson et al. (2024) menjelaskan bahwa setiap *tree* dalam Random Forest dilatih menggunakan *subset* random dari data *training* dan fitur, menghasilkan model yang *robust* dan *less prone to overfitting*. Johnson & Williams (2023) mengidentifikasi keunggulan Random Forest dalam memodelkan peramalan pengelolaan anggaran:

- a. *Feature importance ranking* yang intrinsik;
- b. Penanganan data non-linear yang efektif;
- c. Resistensi terhadap *outliers*;
- d. Kemampuan *handle large datasets*.

(6) Prophet

Prophet dikembangkan oleh Facebook (kini Meta), merupakan model prediktif yang dirancang khusus untuk analisis *time series*. Taylor & Letham, (2018) mendeskripsikan Prophet sebagai model dekomposisi aditif yang mengintegrasikan tiga komponen utama: tren, musiman, dan *holidays/events*. Keunggulan Prophet terletak pada kemampuannya untuk mengakomodasi kejadian luar biasa, seperti kebijakan fiskal yang mendadak atau perubahan dalam belanja pemerintah, yang dapat mempengaruhi pola anggaran. Dalam pemodelan kasus fiskal, Prophet memungkinkan penanganan peristiwa musiman dan eksternal, seperti perubahan kebijakan atau bencana alam, yang sering kali mempengaruhi alokasi dan realisasi anggaran

Menurut Rodriguez (2024) Prophet secara matematis ditunjukkan dengan persamaan (2).

$$y(t) = g(t) + s(t) + h(t) + \varepsilon(t) \quad (2)$$

dimana:

$g(t)$ = fungsi tren yang memodelkan perubahan non-periodik

$s(t)$ = komponen musiman yang menangkap efek periodik

$h(t)$ = efek *holidays/events*

$\varepsilon(t)$ = komponen *error*

Berdasarkan studi komprehensif oleh Davidson & Kim (2024) Prophet memiliki beberapa keunggulan sebagai berikut:

- a. *Robust* terhadap *missing data* dan *outliers*
- b. *Automatic changepoint detection*
- c. Fleksibilitas dalam penyesuaian parameter
- d. Interpretabilitas hasil yang tinggi
- e. Kemampuan menghasilkan interval kepercayaan

Dalam penelitian ini, model terbaik ditentukan dengan membandingkan kinerja antara model XGBoost, Random Forest Regressor, SARIMA, dan Prophet. Pemilihan model dilakukan berdasarkan nilai Mean Squared Error (MSE) terkecil, yang menunjukkan sejauh mana prediksi dari masing-masing model mendekati nilai aktual. MSE digunakan sebagai metrik evaluasi utama karena sifatnya yang memberikan bobot lebih besar pada kesalahan prediksi yang lebih besar, sehingga cocok untuk mengukur kinerja dalam konteks prediksi fiskal yang membutuhkan akurasi tinggi. Masing-masing model memiliki kelebihan dan kekurangan dalam menangani data keuangan pemerintah, khususnya dalam memprediksi deviasi anggaran. Misalnya, XGBoost dan Random Forest mampu menangkap hubungan non-linear yang kompleks antara variabel-variabel independen, sedangkan SARIMA dan Prophet lebih fokus pada pola musiman dan tren dalam data deret waktu. Dalam proses ini, seluruh model dilatih menggunakan data historis yang mencakup rencana dan penyerapan belanja, serta deviasi dari berbagai jenis belanja. Model dengan nilai MSE terkecil dipilih sebagai model terbaik, yang menunjukkan bahwa model tersebut mampu memberikan prediksi paling akurat terhadap variabel deviasi halaman III DIPA

3. METODOLOGI

Metode berisi tentang tahapan yang dilakukan dalam penelitian untuk menjawab pertanyaan penelitian. Metode sebaiknya berupa narasi bukan *flowchart* atau tabel. Hindari penulisan metode menggunakan poin-poin atau penomoran. Metodologi penelitian ini dirancang untuk memastikan proses analisis dilakukan secara sistematis, terukur, dan dapat direplikasi. Tahapan metodologi meliputi identifikasi dan pengumpulan data, praproses data untuk memastikan kualitas dan konsistensi, penerapan berbagai model prediktif, serta evaluasi kinerja model dengan metrik yang relevan. Pendekatan ini diharapkan mampu memberikan gambaran komprehensif mengenai pola deviasi halaman III DIPA sekaligus mengidentifikasi

model prediksi yang paling akurat dalam mendukung sistem peringatan dini pengelolaan anggaran pemerintah.

Dataset terdiri dari 33 observasi bulanan (2022-2024) nilai indikator deviasi halaman III DIPA, yang merupakan data primer yang diperoleh dari aplikasi OMSPAN. Adapun tahapan dalam analisis data antara lain:

(1) Preprocessing data

Data yang digunakan dalam penelitian ini adalah data deviasi halaman III DIPA Kantor Wilayah DJPb Provinsi NTB sebagai bendahara umum negara (BUN) periode bulanan dari Januari 2022 hingga September 2024, yang diperoleh dari aplikasi OMSPAN. Sebelum diterapkan ke dalam model, data terlebih dahulu diolah melalui proses normalisasi dan standarisasi menggunakan teknik *scaling* dengan *Standard Scaler*. Langkah ini bertujuan untuk memastikan bahwa setiap fitur memiliki skala yang sama sehingga meminimalisir bias dalam pembangunan model *machine learning*.

(2) Implementasi Model

Setiap model termasuk XGBoost, Random Forest, SARIMA, dan Prophet, diimplementasikan dengan membagi data menjadi *training set* dan *test set* dengan rasio 80:20.

(3) Evaluasi performa model

Kinerja setiap model diukur menggunakan metrik *Mean Squared Error* (MSE) untuk mengetahui seberapa baik prediksi yang dihasilkan dibandingkan dengan nilai sebenarnya.

4. HASIL DAN PEMBAHASAN

Bagian ini memaparkan hasil implementasi dan evaluasi model prediktif yang digunakan dalam penelitian untuk memproyeksikan nilai deviasi halaman III DIPA. Analisis dilakukan secara bertahap, dimulai dari model berbasis *time series* yang mengakomodasi pola musiman, kemudian dilanjutkan dengan model *machine learning* berbasis *ensemble*.


(1) SARIMA

Pada penelitian ini, model *Seasonal Autoregressive Integrated Moving Average* (SARIMA) digunakan untuk memprediksi variabel deviasi halaman III DIPA. Tahap awal dilakukan dengan menganalisis tren dan pola musiman melalui dekomposisi deret waktu. Data yang digunakan mencakup periode dari Januari 2022 hingga September 2024. Pola seasonality diidentifikasi dan dikomposisi dengan dua percobaan, yakni


identifikasi pola tahunan (*annual seasonality*) dan pola triwulanan (*seasonality*).

a. Dekomposisi Musiman dan Tren

Sebelum membangun model SARIMA, dilakukan dekomposisi data untuk memeriksa adanya komponen musiman dan tren dalam data. Gambar yang diperoleh dari dekomposisi tahunan dan triwulan menunjukkan bagaimana data Deviasi Hal III DIPA terbagi menjadi komponen observasi aktual, tren, musiman, dan residual. Dekomposisi tahunan memperlihatkan bahwa data ini belum sepenuhnya stasioner, di mana komponen tren menunjukkan kenaikan secara bertahap di akhir periode (Gambar 1). Namun, data triwulanan (*quarterly*) menunjukkan stasionaritas yang lebih baik, ditandai dengan komponen musiman yang berulang setiap empat kuartal serta residual yang tersebar di sekitar nol. Komponen musiman memberikan indikasi adanya fluktuasi yang teratur setiap triwulan.



Gambar 1. Dekomposisi tren dan musiman dengan pola tahunan (*annual seasonality*)



Gambar 2. Dekomposisi tren dan musiman dengan pola triwulanan (*quarterly seasonality*)

Pada dekomposisi triwulanan, terlihat bahwa komponen musiman stabil dengan pola berulang setiap empat periode, yang mengindikasikan adanya pola musiman triwulanan yang jelas (Gambar 2).

Selain itu, residual berada mendekati nol secara konsisten, yang menunjukkan bahwa model dekomposisi mampu menangkap komponen tren dan musiman dengan baik, tanpa banyak fluktuasi yang tidak dijelaskan oleh model. Dekomposisi tahunan menunjukkan pola tren yang kurang stabil, mengindikasikan bahwa data belum stasioner secara tahunan.

b. Pembangunan model SARIMA

Dalam pembangunan model SARIMA, digunakan pola musiman triwulanan dengan komponen *autoregressive* (SAR), *differencing* musiman (D), dan *moving average* musiman (SMA), Model SARIMA dibangun dengan orde musiman tersebut dan dilatih menggunakan data *Deviasi Hal III DIPA*. dengan konfigurasi musiman $(p, d, q) \times (P, D, Q, m)$ dalam hal ini dengan konfigurasi $(1,1,1) \times (1,1,1, 4)$, terdiri dari komponen *autoregressive* (AR), *differencing* (D), dan *moving average* (MA) untuk data yang memiliki musiman triwulanan (dengan $m = 4$) secara matematis dinyatakan pada Formula (1).

$$\Phi(B_m)\phi(B)(1 - B)d(1 - B_m)Dy_t = \theta(B_m)\theta(B)\varepsilon_t \quad (1)$$

Komponen:

$\phi(B)$ = Polinomial *autoregressive* (AR) non-musiman dengan lag operator B .

$\Phi(B_m)$ = Polinomial *autoregressive* musiman dengan lag operator musiman B_m , di mana $m = 4$ untuk data dengan pola triwulanan.

$(1 - B)^d$ = *Differencing* non-musiman untuk membuat data stasioner.

$(1 - B_m)^D$ = *Differencing* musiman untuk menghilangkan pola musiman.

$\phi(B)$ = Polinomial *moving average* (MA) non-musiman.

$\theta(B_m)$ = Polinomial *moving average* musiman.

y_t = Observasi pada waktu t .

ε_t = Komponen *error* atau *noise* pada waktu t .

Maka, formula lengkap untuk kasus *Deviasi Halaman III DIPA* dinyatakan pada Formula (2)

$$(1 - \phi_1 B)(1 - \phi_2 B)(1 - B)(1 - B_4)y_t = (1 + \theta_1 B)(1 + \theta_2 B)\varepsilon_t \quad (2)$$

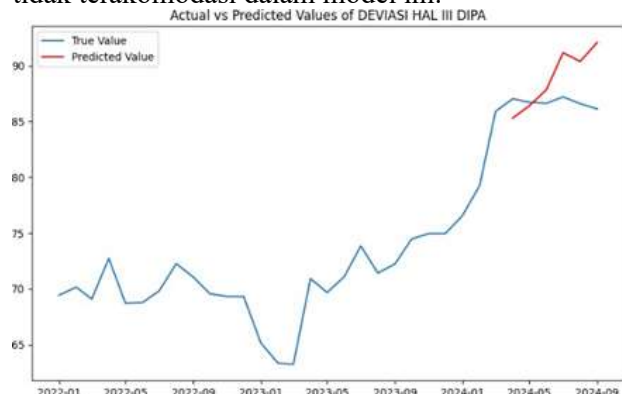
Model SARIMA menggabungkan *autoregresi* dan *moving average* baik untuk komponen musiman maupun non-musiman, dengan dua kali *differencing* (*differencing* biasa dan musiman) untuk memastikan data stasioner dalam kedua aspek. Model ini dilatih

menggunakan data deviasi halaman III DIPA yang telah melalui proses transformasi dan dekomposisi.

c. Training dan Forecasting

Data *Deviasi Halaman III DIPA* dibagi menjadi dua subset, yaitu *training set* untuk periode Januari 2022 hingga Maret 2024 dan *test set* dari April 2024 hingga September 2024 untuk memvalidasi hasil prediksi model, di mana *training set* digunakan untuk membangun model dan *test set* digunakan untuk mengevaluasi akurasi prediksi. Model SARIMA yang diterapkan pada data *training set* berhasil mengidentifikasi pola musiman dan tren jangka panjang, sebagaimana dapat dilihat pada Gambar 3. Proses *forecasting* untuk enam bulan ke depan, yakni dari Oktober 2024 hingga Maret 2025, memberikan prediksi dengan kecocokan yang cukup baik terhadap data aktual.

Gambar 3 menunjukkan bahwa nilai prediksi model SARIMA mendekati data aktual pada sebagian besar periode dalam *test set* (April hingga September 2024). Dengan residual yang mendekati nol pada sebagian besar titik dalam data, model ini menunjukkan *goodness-of-fit* yang baik, meskipun terdapat sedikit perbedaan yang meningkat pada bulan-bulan terakhir prediksi, terutama setelah periode Juli 2024. Hal ini mungkin disebabkan oleh peningkatan volatilitas data pada periode akhir, yang tidak sepenuhnya ditangkap oleh komponen musiman dan tren model. Pada prediksi jangka panjang (Oktober 2024 hingga Maret 2025), terdapat kenaikan dalam *forecasted values* yang konsisten (Gambar 4). Pola ini mengindikasikan bahwa model SARIMA menangkap komponen musiman dari data, seperti yang ditunjukkan oleh fluktuasi berkala. Namun, seiring berjalannya waktu, terlihat peningkatan deviasi antara prediksi dan nilai aktual, yang dapat disebabkan oleh variabel eksternal yang tidak terakomodasi dalam model ini.



Gambar 3. Perbandingan nilai aktual dan *predicted* hasil *training model*.



Gambar 4. Hasil *forecasting unseen data* untuk enam bulan

Secara keseluruhan, model SARIMA dengan konfigurasi musiman (1, 1, 1, 4) ini tetap memberikan hasil yang memadai dalam memprediksi Deviasi Halaman III DIPA. Hasil dari model SARIMA yang diimplementasikan menghasilkan prediksi nilai deviasi Halaman III DIPA untuk periode Oktober 2024 hingga Maret 2025 (Tabel 1). Prediksi menunjukkan adanya peningkatan nilai Deviasi Halaman III DIPA selama periode tersebut, yang mengindikasikan perbaikan atau peningkatan kinerja pelaksanaan anggaran. Peningkatan nilai dari 87,67 pada Oktober 2024 hingga mencapai 94,91 pada Maret 2025 mengindikasikan tren positif dalam nilai indikator kinerja pelaksanaan anggaran Deviasi Halaman III DIPA.

Tabel 1. Hasil Forecasting Deviasi Halaman III DIPA menggunakan Model SARIMA

No	Bulan	Forecasted Values
1.	Oktober, 2024	87.67
2.	November, 2024	91.00
3.	Desember, 2024	91.50
4.	Januari, 2025	91.49
5.	Februari, 2025	92.51
6.	Maret, 2025	94.91

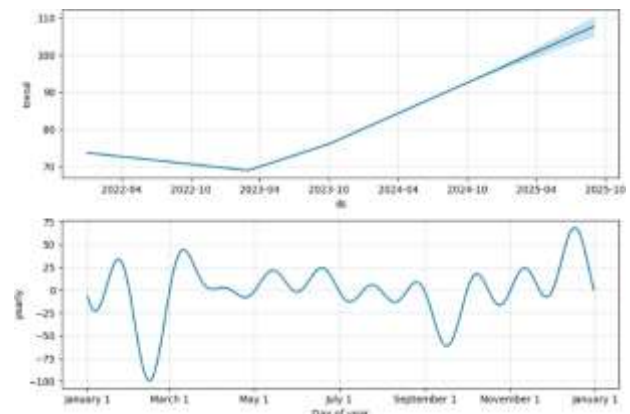
Evaluasi performa model menggunakan *Mean Squared Error* (MSE) menghasilkan nilai 11.66, yang relatif kecil dan mendukung kesimpulan bahwa model SARIMA mampu memberikan estimasi yang baik dengan tingkat akurasi yang tinggi pada data deviasi halaman III DIPA. Evaluasi lebih lanjut bisa dilakukan dengan menggunakan parameter lain, atau memasukkan variabel eksternal tambahan untuk meningkatkan akurasi prediksi yang akan disimulasikan menggunakan model *machine learning* Random Forest Regressor dan XGBoost.

(2) Prophet

Prophet mengharuskan format kolom khusus, yaitu *ds* untuk variabel waktu dan *y* untuk variabel target. Oleh karena itu, langkah awal pada

pembangunan model adalah dengan melakukan renaming pada kolom-kolom dataset bersesuaian. Model Prophet dikenal dengan fleksibilitas dan kemudahan penggunaannya, setelah dataset disiapkan, model Prophet diinisialisasi dan dilatih menggunakan fungsi *fit*. Pada tahap ini, Prophet secara otomatis mengidentifikasi komponen-komponen tren dan musiman dalam data. Komponen tren menangkap perubahan jangka panjang dalam deviasi Halaman III DIPA, sedangkan komponen musiman mengidentifikasi pola berulang yang muncul dalam siklus tahunan atau bulanan (Gambar 5). Prophet juga memungkinkan untuk menangani diskontinuitas atau perubahan mendadak dalam tren, yang umum terjadi pada data fiskal karena adanya perubahan kebijakan atau fungsi organisasi. Model Prophet memberikan hasil prediksi yang mencakup pola jangka panjang serta fluktuasi musiman yang mempengaruhi deviasi Halaman III DIPA (Gambar 6). Rentang ketidakpastian yang dihasilkan oleh model memberikan gambaran tentang margin error yang mungkin terjadi dalam prediksi, yang memungkinkan pembuat kebijakan atau pimpinan untuk memahami potensi variabilitas dalam estimasi.

Gambar 5. Identifikasi Tren dan Musiman sepanjang tahun dengan model Prophet



Gambar 6. Hasil *forecasting* dan rentang variabilitas menggunakan model Prophet



Tabel 2 menyajikan hasil *forecast* nilai prediksi untuk periode mulai dari Oktober 2024

hingga Maret 2025. Selain itu, disajikan pula batas bawah (*lower bound*) dan batas atas (*upper bound*) dari rentang ketidakpastian yang memberikan kisaran kemungkinan nilai sesungguhnya. Hasil peramalan ini memberikan indikasi bahwa fluktuasi kecil yang terjadi dalam periode ini dapat diantisipasi dalam rentang ketidakpastian yang relatif sempit, sehingga mampu memberikan prediksi yang cukup stabil. Namun, hasil *forecasting* dengan Prophet menunjukkan nilai melebihi skala 100 sehingga membuat nilai *forecasting* tidak andal untuk Deviasi Halaman III DIPA.

Tabel 2. Hasil *forecasting* Deviasi Halaman III DIPA menggunakan model Prophet

Bulan	Perkiraan (<i>yhat</i>)	Batas Bawah (<i>yhat_lower</i>)	Batas Atas (<i>yhat_upper</i>)
Oktober, 2024	90,98	89,25	92,71
November, 2024	92,09	90,39	93,82
Desember, 2024	95,52	93,79	97,28
Januari, 2025	98,50	96,69	100,34
Februari, 2025	89,85	87,88	91,70
Maret, 2025	102,12	99,98	104,11

Dataset diolah dengan mengkonversi variabel waktu menjadi format *datetime* agar dapat dilakukan analisis tren musiman dan temporal. Setelah itu, fitur deviasi belanja yang menunjukkan selisih mutlak dari rencana dan penyerapan belanja berbagai jenis belanja diidentifikasi dan digunakan sebagai variabel *input* (*X*) sebagai simplifikasi fitur yang digunakan dibandingkan penggunaan dua variabel rencana dan penyerapan secara simultan, sedangkan target prediksi adalah deviasi Halaman III DIPA. Setelah data dibersihkan dan dibagi menjadi data training dan data testing dengan rasio 80:20, tahap selanjutnya adalah normalisasi data menggunakan *StandardScaler*. Normalisasi diperlukan untuk mengurangi variabilitas antar fitur yang dapat memengaruhi performa algoritma XGBoost. Dengan pendekatan *boosting*, model ini secara iteratif menyesuaikan prediksi terhadap kesalahan sebelumnya sehingga memberikan peningkatan akurasi secara bertahap. Setelah pelatihan model, evaluasi dilakukan dengan menghitung Mean Squared Error (MSE), yang memberikan ukuran seberapa besar deviasi prediksi dari nilai sebenarnya. Hasil model menunjukkan MSE sebesar 26.679, menunjukkan bahwa prediksi model XGBoost memiliki tingkat kesalahan yang relatif rendah dan performa yang baik, walaupun nilai MSE hasil *forecasting* XGBoost lebih tinggi

dibandingkan SARIMA, keduanya tidak dapat dibandingkan secara langsung karena selain menggunakan data historis Deviasi Halaman III DIPA, XGBoost juga mempertimbangkan deviasi rencana dan penyerapan belanja sehingga menambah kompleksitas data yang diproses.

(3) Random Forest

Random Forest, sebagai model *ensemble* berbasis *decision tree*, juga digunakan untuk membandingkan hasil prediksi dengan XGBoost. Fitur yang sama digunakan pada model ini, di mana deviasi belanja berbagai komponen anggaran dipertimbangkan. Namun, ada satu perbedaan signifikan: pada model Random Forest, ditambahkan fitur ‘bulan’ yang dikonversi dari nama bulan menjadi bilangan bulanan untuk menangkap efek musiman yang mungkin memengaruhi kinerja deviasi.

Sama seperti XGBoost, data juga dinormalisasi menggunakan *StandardScaler* sebelum model dilatih. Random Forest bekerja dengan membangun sejumlah *decision tree* pada sub-sampel data yang berbeda, kemudian menghasilkan prediksi rata-rata dari seluruh pohon. Mekanisme, membuat model lebih tahan terhadap *overfitting* dibandingkan model lain yang menggunakan satu *decision tree*.

Evaluasi model Random Forest menunjukkan MSE sebesar 29.43, sedikit lebih rendah dari XGBoost. Evaluasi ini mengindikasikan bahwa untuk Deviasi Halaman III DIPA, model XGBoost mampu menangkap pola-pola deviasi Halaman III DIPA dengan lebih akurat dibandingkan Random Forest. Walaupun demikian, Random Forest menunjukkan kinerja prediksi yang robust dalam prediksi Deviasi Halaman III DIPA dengan pemrosesan simultan rencana belanja dan penyerapan belanja tanpa disederhanakan menjadi deviasi belanja dengan tidak adanya penurunan nilai MSE walaupun kompleksitas data bertambah.

Tabel 3. Hasil *forecasting* Deviasi Halaman III DIPA menggunakan model *machine learning*.

No.	Bulan	Gradient Boosting Forecast	Random Forest Forecast
1.	Oktober, 2024	68,78	69,66
2.	November, 2024	84,42	82,15
3.	Desember, 2024	84,19	80,91
4.	Januari, 2025	80,79	80,93
5.	Februari, 2025	81,64	80,93
6.	Maret, 2025	81,64	80,93

(4) Perbandingan Performa Model

Kedua model *ensemble-based machine learning*, baik XGBoost maupun Random Forest memberikan hasil yang kompetitif dalam memprediksi deviasi Halaman III DIPA. Meskipun XGBoost sedikit lebih unggul dalam hal MSE, secara umum kedua model menunjukkan pola peningkatan pada bulan tertentu, namun Gradient Boosting memiliki fluktuasi yang lebih tajam dan nilai prediksi yang sedikit lebih tinggi pada bulan-bulan tertentu. Fluktuasi yang lebih besar pada model Gradient Boosting menjadi indikasi sensitivitasnya terhadap variasi data, sementara Random Forest lebih unggul dalam hal stabilitas.

Pilihan model yang tepat bergantung pada tujuan analisis. Jika sensitivitas terhadap perubahan data menjadi fokus utama, maka Gradient Boosting dapat dipertimbangkan. Namun, jika stabilitas prediksi lebih diutamakan, maka Random Forest dapat menjadi pilihan yang lebih baik. Selain itu pilihan model dapat dipertimbangkan pada input data komponen Deviasi Halaman III DIPA apa saja yang akan dipertimbangkan, jika banyak variabel perlu dipertimbangkan, maka peneliti menyarankan penggunaan model Random Forest. Apabila variabel yang dipertimbangkan dapat disimplifikasi dengan berbagai *metode feature selection*, maka peneliti menyarankan penggunaan model XGBoost. Apabila forecasting hanya mempertimbangkan data historis dan efek *seasonal* maka model yang paling tepat dan efisien adalah model SARIMA.

Model-model prediktif yang diuji dapat dijadikan pilihan sebagai *early warning tools*, dengan pilihan model yang disesuaikan dengan karakteristik pola deviasi anggaran yang dimiliki Kementerian/ Lembaga/Satuan kerja sebagai upaya implementatif peningkatan akuntabilitas dan manajemen risiko dalam pengelolaan anggaran pemerintah.

5. KESIMPULAN

Penelitian ini menunjukkan bagaimana analisis prediktif dapat meningkatkan kemampuan pemerintah dalam memprediksi deviasi dan secara proaktif mengelola risiko anggaran. Deviasi ini dapat mempengaruhi hasil kebijakan fiskal, mengurangi efisiensi pemerintah, serta menyebabkan pemanfaatan dana publik yang tidak optimal. Implementasi *predictive analytic*, di seluruh kementerian dan lembaga pemerintah akan memungkinkan deteksi dini terhadap potensi risiko anggaran. Dengan mengidentifikasi deviasi secara *real-time*, pembuat kebijakan dapat menyesuaikan rencana penyerapan atau mengambil tindakan korektif sebelum ketidakseimbangan fiskal semakin

memburuk. Untuk kementerian atau lembaga yang memiliki variasi musiman dalam pelaksanaan anggaran, integrasi model yang efisien seperti SARIMA dalam sistem pemantauan keuangan dapat membantu mengantisipasi pola penyerapan dengan lebih baik dan mengurangi deviasi. *Early warning system* ini akan sangat berguna bagi lembaga yang memiliki pola pengeluaran siklikal (misalnya proyek infrastruktur). Dengan memanfaatkan wawasan berbasis data, pemerintah dapat meningkatkan transparansi dan akuntabilitas dalam pelaksanaan anggaran. *Predictive analytic* dapat digunakan untuk sebagai alat manajemen risiko yang akan mendorong disiplin fiskal dan mengurangi peluang terjadinya inefisiensi. Simpulan merupakan pernyataan jawaban dari permasalahan yang disebutkan pada pendahuluan dalam bentuk narasi. Tidak diperkenankan menggulak bullet and numbering, melainkan harus dinyatakan dalam paragraf.

DAFTAR PUSTAKA

- Chen, Q. (2021). Stock Movement Prediction with Financial News using Contextualized Embedding from BERT. Retrieved from <http://arxiv.org/abs/2107.08721>
- Davidson, M., & Kim, J. (2024). Comparative Analysis of Time Series Models. *Forecasting Review*, 25(3), 289–304.
- Kristiantoro, D., Widodo, H., & Sanjaya, R. (2022). Digital Transformation in Indonesian Public Financial Management: Challenges and Opportunities. *Public Administration and Policy Review*, 10(2), 145–162.
- Kuntadi, C., & Luki Karunia, R. (2024). *Jurnal Manajemen, Akuntansi dan Logistik FAKTOR-FAKTOR YANG MEMPENGARUHI CAPAIAN NILAI IKPA PADA KEMENTERIAN / LEMBAGA* (Vol. 2).
- María Ruiz-Martínez, J., Valencia-García, R., & García-Sánchez, F. (n.d.). *Semantic-Based Sentiment analysis in financial news*. Retrieved from <http://project-first.eu/>
- Nasrulloh, A., & Nabire, A. (2025). *Effect of SAKTI Implementation and IKPA on Financial Report Quality with Internal Control as an Intervening Variable. Management, and Accounting* (Vol. 5). Retrieved from <https://jurnal.amertainstitute.com/index.php/GoodWill/>
- Nugroho, B., Widodo, H., & Pratama, R. (2023). Evaluasi Implementasi IKPA: Studi Kasus pada 20 Satuan Kerja di Wilayah Jawa Tengah. *Jurnal Manajemen Keuangan Publik*, 10(1), 34–51.
- Permatasari, D., & Dewi, R. (2023). Analisis Pengaruh IKPA terhadap Kualitas Pelaksanaan Anggaran pada Satuan Kerja Pemerintah. *Jurnal Akuntansi Dan Keuangan Sektor Publik*, 9(1), 12–28.

- Rahmawati, R., Sari, D. P., & Wijaya, A. (2022). Pengaruh Implementasi IKPA terhadap Kualitas Pelaksanaan Anggaran pada 45 Satuan Kerja di Wilayah DKI Jakarta. *Jurnal Akuntansi Dan Keuangan Sektor Publik*, 7(2), 89–105.
- Rodriguez, A., & others. (2024). Understanding Prophet's Growth Models. *Time Series Analysis Journal*, 42(2), 178–193.
- Sodikin, S. (2021). ANALISIS PENGUKURAN KINERJA PELAKSANAAN ANGGARAN MENGGUNAKAN IKPA. *JENTRE*, 2(2), 64–71. doi:10.38075/jen.v2i2.45
- Taylor, S. J., & Letham, B. (2018). Prophet: Forecasting at Scale. *The American Statistician*, 72(1), 37.
- Velarde, G., Sudhir, A., Deshmane, S., Deshmunkh, A., Sharma, K., & Joshi, V. (2023). Evaluating XGBoost for Balanced and Imbalanced Data: Application to Fraud Detection. Retrieved from <http://arxiv.org/abs/2303.15218>
- Warman, W., Komariyah, L., & Kaltsum, K. F. U. (2023). Konsep Umum Evaluasi Kebijakan. *Jurnal Ilmu Manajemen Dan Pendidikan*, 3, 25–32. doi:10.30872/jimpian.v3ise.2912
- Zhang, X., Fuehres, H., & Gloor, P. A. (2011). Predicting Stock Market Indicators Through Twitter “I hope it is not as bad as I fear”. *Procedia - Social and Behavioral Sciences*, 26, 55–62. doi:10.1016/j.sbspro.2011.10.562