

**KEMENTERIAN KEUANGAN REPUBLIK INDONESIA
BADAN PENDIDIKAN DAN PELATIHAN KEUANGAN
POLITEKNIK KEUANGAN NEGARA STAN
TANGERANG SELATAN**

**LAPORAN PRAKTIKUM ANALITIKA DATA KEUANGAN SEKTOR
PUBLIK**

**ANALISIS DERET WAKTU DAN PERAMALAN PENERIMAAN
NEGARA BUKAN PAJAK (PNBP) SEKTOR SUMBER DAYA ALAM
DENGAN METODE ARIMA**

*Studi Kasus Proyeksi Penerimaan SDA Bulanan Periode 2014–2025 untuk Perencanaan
Anggaran Tahun 2026*

**Disusun Oleh:
KELOMPOK 4**

No.	Nama Mahasiswa	NIM
1.	FAIZ ATHALLAH AKHSAN	4131230059
2.	FRENDY ARYA PRATAMA	4131230148
3.	SURYA KENCANA PUTRA	4131230315

**PROGRAM STUDI DIPLOMA IV AKUNTANSI SEKTOR PUBLIK
JURUSAN AKUNTANSI KEUANGAN SEKTOR PUBLIK
TAHUN 2026**

BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah

Penerimaan Negara Bukan Pajak dari Sektor Sumber Daya Alam (PNBP SDA) merupakan salah satu sumber pendapatan negara yang sangat penting di dalam Anggaran Pendapatan dan Belanja Negara (APBN). Penerimaan ini berasal dari pemanfaatan kekayaan alam nasional yang mencakup sektor Minyak dan Gas Bumi (Migas) serta Non-Migas seperti pertambangan batubara, mineral, kehutanan, dan perikanan. Selain menopang kas pemerintah pusat, realisasi PNBP SDA juga menjadi dasar pembagian Dana Bagi Hasil (DBH SDA) untuk pemerintah daerah penghasil.

Berbeda dengan penerimaan perpajakan yang cenderung stabil dan sejalan dengan pertumbuhan ekonomi, realisasi PNBP SDA memiliki volatilitas (fluktuasi naik-turun) yang sangat tinggi. Hal ini terjadi karena penerimaan SDA sangat bergantung pada faktor-faktor eksternal di luar kendali pemerintah, seperti harga minyak mentah Indonesia (ICP), harga batubara dunia, nilai tukar Rupiah terhadap Dolar AS, serta jumlah produksi atau lifting di dalam negeri.

1.2 Karakteristik Pola Data

Secara umum, deret waktu penerimaan PNBP SDA tidak memiliki pola musiman 12 bulanan yang berulang seperti belanja negara (yang selalu tinggi di akhir tahun) atau pajak (yang naik saat batas akhir SPT di bulan Maret/April). Pola PNBP SDA lebih mengikuti siklus harga komoditas global yang berdurasi antara 2 sampai 5 tahun. Pada saat harga minyak dan batubara dunia sedang melonjak tinggi (seperti periode 2021–2022), penerimaan negara akan meningkat drastis. Sebaliknya, saat harga komoditas jatuh (seperti tahun 2016), penerimaan SDA juga ikut merosot tajam.

1.3 Tujuan Praktikum dan Peramalan

Mengingat penerimaan SDA yang sangat fluktuatif, pemerintah membutuhkan angka perkiraan (proyeksi) penerimaan yang akurat dan dapat dipertanggungjawabkan. Target yang dipasang terlalu tinggi berisiko membuat APBN defisit lebih besar dari

rencana, sedangkan target yang terlalu rendah dapat membuat pembagian belanja ke daerah menjadi kurang optimal.

Tujuan dari praktikum ini adalah melakukan analisis deret waktu menggunakan metode Box-Jenkins (ARIMA) dengan bantuan software Orange Data Mining. Analisis ini bertujuan untuk menemukan model peramalan terbaik dan memproyeksikan estimasi penerimaan bulanan PNBPD SDA selama 12 bulan pada Tahun Anggaran 2026.

BAB II
EKSPLORASI DATA DAN KOMPONEN DERET WAKTU

2.1 Deskripsi Data

Data yang digunakan dalam analisis ini adalah data bulanan realisasi PNBPD SDA dari bulan Januari 2014 sampai Desember 2025 (total 144 bulan atau 12 tahun penuh) yang bersumber dari berkas dataset K4_pnbpd_sda.csv. Variabel yang dianalisis adalah pnbpd_sda_miliar_rp (dalam satuan Miliar Rupiah).


Tabel 1. Statistik Deskriptif Penerimaan PNBPD SDA Bulanan (2014–2025)

Ukuran Statistik	Nilai	Penjelasan Praktis
Jumlah Observasi (N)	144 bulan	Data bulanan selama 12 tahun penuh (2014–2025)
Rata-rata (Mean)	Rp 615,58 Miliar	Rata-rata realisasi penerimaan PNBPD SDA per bulan
Standar Deviasi	Rp 137,38 Miliar	Tingkat sebaran atau variasi data bulanan
Nilai Minimum	Rp 309,21 Miliar	Penerimaan terendah saat harga minyak jatuh di 2016
Kuartil 1 (Q1)	Rp 521,15 Miliar	25% data penerimaan berada di bawah nilai ini
Median (Nilai Tengah)	Rp 625,43 Miliar	Titik tengah dari seluruh distribusi data penerimaan
Kuartil 3 (Q3)	Rp 719,63 Miliar	75% data penerimaan berada di bawah nilai ini
Nilai Maksimum	Rp 887,33 Miliar	Puncak penerimaan tertinggi saat lonjakan komoditas di 2022

2.2 Perkembangan Data Historis

Dari grafik historis pada Gambar 1, terlihat pergerakan penerimaan SDA Indonesia melewati beberapa fase:

- **Tahun 2014–2015:** Penerimaan berada pada tingkat normal sekitar Rp 500–650 miliar/bulan.
- **Tahun 2016:** Terjadi penurunan tajam ke titik terendah Rp 309,21 miliar/bulan akibat harga minyak mentah dunia anjlok di bawah USD 35/barel.
- **Tahun 2017–2019:** Penerimaan berangsur pulih ke level rata-rata Rp 550–700 miliar/bulan.
- **Tahun 2020:** Sempat turun sementara waktu akibat dampak pandemi Covid-19 terhadap permintaan energi dunia.
- **Tahun 2021–2023:** Penerimaan naik sangat pesat hingga mencapai rekor tertinggi Rp 887,33 miliar/bulan karena kenaikan harga batubara dan minyak bumi global.
- **Tahun 2024–2025:** Penerimaan mulai stabil pada kisaran yang cukup tinggi di Rp 750–880 miliar/bulan.




Gambar 1. Tampilan Widget Line Chart pada Orange Data Mining (Data Historis PNBP SDA 2014–2025)

2.3 Analisis Autokorelasi Data Asli (Correlogram)

Pemeriksaan grafik Correlogram pada Gambar 2 menampilkan grafik autokorelasi data asli pada Orange Data Mining. Sesuai arsitektur modul timeseries Orange, widget Correlogram secara otomatis menyaring dan hanya memplot titik-titik puncak ekstrem lokal (local extrema peaks) untuk mendeteksi siklus. Terlihat bahwa pada data asli, nilai autokorelasi (ACF) turun sangat lambat (slow decay) dengan puncak ekstrem yang jelas

di Lag 20 (-0.25), Lag 42 (+0.49), dan Lag 62 (-0.31). Hal ini membuktikan bahwa data asli masih mengandung inersia siklus panjang dan belum stasioner.



Gambar 2. Tampilan Widget Correlogram pada Orange Data Mining (Plot ACF dan PACF Data Asli)

BAB III

ANALISIS STASIONERITAS DAN PRA-PEMROSESAN DATA

3.1 Peran Widget Difference pada Orange Data Mining


Dalam perangkat lunak Orange Data Mining, widget Difference adalah widget fungsional murni untuk transformasi data deret waktu yang tidak memiliki jendela grafik visual tersendiri. Ketika dibuka, widget ini menyediakan opsi operasi matematika diskrit untuk mengubah deret waktu menjadi stasioner. Operasi yang dipilih pada penugasan ini adalah First order difference (Delta) dengan periode pergeseran 1 ($d=1$):

$\Delta Y(t) = Y(t) - Y(t-1)$ [Realisasi Bulan Berjalan - Realisasi Bulan Sebelumnya]

Hasil perhitungan diferensiasi ini secara otomatis diteruskan sebagai aliran data ke widget berikutnya di kanvas Orange, yaitu widget Correlogram - d1, untuk dievaluasi pola autokorelasinya.

3.2 Evaluasi Autokorelasi pada Widget Correlogram - d1

Pemeriksaan kestasioneran dan identifikasi ordo dilakukan pada jendela widget Correlogram - d1 sebagaimana ditampilkan pada Gambar 3 (tangkapan layar langsung dari kanvas kerja Orange).



Gambar 3. Tampilan Jendela Widget Correlogram - d1 pada Orange Data Mining (ACF Kiri dan PACF Kanan)

Berdasarkan Gambar 3, terlihat karakteristik penting dalam penentuan model ARIMA:

- **1. Grafik Autokorelasi (ACF):** Pada jendela Correlogram - d1 (kiri), grafik autokorelasi menyajikan titik puncak ekstrem siklikal yang terdeteksi oleh algoritma Orange. Fluktuasi autokorelasi terputus secara bertahap yang memberikan petunjuk kebutuhan komponen Moving Average orde 1 ($q=1$).
- **2. Grafik Autokorelasi Parsial (PACF):** Pada jendela Correlogram - d1 dengan opsi Compute partial auto-correlation dicentang (kanan), teridentifikasi puncak-puncak ekstrem lokal yang terputus (cuts off). Karakteristik ini menjadi rujukan untuk menguji komponen Autoregressive orde 1 dan orde 2 ($p=1$ dan $p=2$).

BAB IV PEMBANGUNAN MODEL, EVALUASI, DAN PERAMALAN

4.1 Pemilihan Model Kandidat ARIMA

Berdasarkan petunjuk grafik ACF dan PACF pada widget Correlogram, kita menguji 4 kombinasi model ARIMA pada kanvas kerja Orange Data Mining:

- **1. ARIMA(0,1,1):** Model dasar Moving Average (setara perataan eksponensial).
- **2. ARIMA(1,1,0):** Model dasar Autoregressive orde 1.
- **3. ARIMA(1,1,1):** Model gabungan standar AR(1) dan MA(1).
- **4. ARIMA(2,1,1):** Model gabungan AR(2) dan MA(1) untuk menangkap arah dan pembalikan tren.

4.2 Hasil Evaluasi dan Pemilihan Model Terbaik pada Orange

Keempat model diuji menggunakan widget Model Evaluation di Orange Data Mining dengan metode Time Series Cross-Validation (20 putaran iterasi/folds, langkah proyeksi forecast_steps = 3). Tabel 2 menyajikan hasil evaluasi resmi sebagaimana yang ditampilkan pada jendela Model Evaluation Orange:

Tabel 2. Hasil Evaluasi Model pada Widget Model Evaluation Orange Data Mining


Model	Fold RMSE	Fold MAE	Fold MAPE	POCID	R ²	In-Sample RMSE	Keterangan
ARIMA(0,1,1)	55.77 M	39.58 M	6.21%	22.03%	0.750	67.10 M	Model Dasar MA
ARIMA(1,1,0)	55.36 M	40.24 M	6.23%	49.15%	0.754	66.96 M	Model Dasar AR
ARIMA(1,1,1)	55.38 M	40.19 M	6.23%	49.15%	0.753	66.96 M	Model Gabungan 1
ARIMA(2,1,1)	52.77 M	35.78 M	6.16%	54.24%	0.776	66.48 M	Champion (Terbaik)

Berdasarkan hasil pengujian resmi pada Tabel 2 dan Gambar 4, model ARIMA(2,1,1) terpilih sebagai model terbaik (champion model) karena unggul pada seluruh metrik evaluasi Orange:

- **1. Nilai Kesalahan Terendah:** ARIMA(2,1,1) menghasilkan nilai Root Mean Squared Error (RMSE) terkecil sebesar 52,77 Miliar Rp (dibandingkan 55,36–55,77 Miliar Rp pada model lain), serta Median Absolute Error (MAE) terendah sebesar 35,78 Miliar Rp.
- **2. Persentase Kesalahan Sangat Akurat:** Tingkat persentase error (MAPE) hanya sebesar 6,16% (berada jauh di bawah ambang batas 10% yang menunjukkan kemampuan peramalan sangat akurat / highly accurate).
- **3. Prediksi Arah Fluktuasi Terbaik (POCID):** Nilai Prediction on Change in Direction (POCID) mencapai 54,24%, membuktikan bahwa ordo $p=2$ (AR lag 2) sangat efektif membaca titik balik momentum kenaikan atau penurunan harga komoditas.
- **4. Koefisien Determinasi Tertinggi:** Nilai R^2 pengujian mencapai 0,776 (dan 0,764 pada data in-sample), menjelaskan variasi data secara konsisten.

Model Evaluation - Jendela Resmi Orange Data Mining (20 Folds, Steps=3)

Model	RMSE	MAE	MAPE	POCID	R2
ARIMA(0,1,1)	55.77	39.58	0.062	22.03%	0.750
ARIMA(0,1,1) (in-sample)	67.10	38.43	0.073	42.66%	0.760
ARIMA(1,1,0)	55.36	40.24	0.062	49.15%	0.754
ARIMA(1,1,0) (in-sample)	66.96	38.53	0.073	41.26%	0.761
ARIMA(1,1,1)	55.38	40.19	0.062	49.15%	0.753
ARIMA(1,1,1) (in-sample)	66.96	38.55	0.073	41.26%	0.761
ARIMA(2,1,1) (BEST)	52.77	35.78	0.062	54.24%	0.776
ARIMA(2,1,1) (in-sample)	66.48	37.63	0.072	44.76%	0.764



Gambar 4. Tampilan Tabel dan Grafik Metrik Evaluasi Model pada Orange Data Mining

Catatan Kritis (Pertanyaan Dosen Pengampu): Mengapa Nilai In-Sample RMSE Lebih Besar Dibandingkan Fold RMSE?

Terdapat temuan metodologis yang sangat menarik pada Tabel 2 dan Gambar 4: nilai kesalahan In-Sample RMSE pada seluruh model berkisar antara 66,48 hingga 67,10 Miliar Rp, yang mana lebih besar dibandingkan nilai Fold RMSE (52,77–55,77 Miliar Rp). Dalam teori pembelajaran mesin (machine learning) data tabular konvensional, galat in-sample umumnya lebih kecil dari galat out-of-sample karena risiko overfitting. Namun, pada konteks pemodelan deret waktu di Orange Data Mining, fenomena ini terjadi karena dua faktor fundamental:


- 1. Efek Galat Inisialisasi Titik Awal ($t=0$):** Model ARIMA(2,1,1) memerlukan diferensiasi $d=1$ (membutuhkan $t-1$) dan komponen autoregresif $p=2$ (membutuhkan $t-2$). Pada observasi paling awal (Januari 2014), model belum memiliki riwayat observasi masa lalu sama sekali sehingga nilai taksiran awalnya adalah nol. Akibatnya, timbul lonjakan galat inisialisasi awal yang sangat besar (+530,57 Miliar Rp). Karena formulasi RMSE mengkuadratkan selisih galat ($530,57^2 = 281.504$), satu angka ekstrem di titik nol ini mendongkrak rata-rata kuadrat galat seluruh 144 bulan menjadi 66,48 Miliar Rp. Faktanya, jika titik inisialisasi pertama ini dikeluarkan, nilai in-sample RMSE murni sebenarnya hanya sebesar 49,82 Miliar Rp (lebih kecil dari Fold RMSE 52,77 Miliar Rp).
- 2. Perbedaan Karakteristik Periode Waktu yang Diuji:** Evaluasi in-sample mencakup keseluruhan 144 bulan (2014–2025) yang memotret seluruh guncangan krisis masa lalu, seperti anjloknya harga minyak mentah dunia di 2016 (Rp 309 M) dan disrupted pandemi 2020. Sebaliknya, evaluasi Cross-Validation (20 putaran iterasi) menguji peramalan bergulir 3 langkah ke depan pada data yang sudah

memiliki riwayat sejarah panjang dan matang tanpa mengalami galat inisialisasi titik awal.

Kondisi ini memberikan konfirmasi empiris yang sangat positif: model ARIMA(2,1,1) Kelompok 4 terbukti terbebas dari masalah overfitting (tidak sekadar menghafal pola data historis), melainkan memiliki daya adaptasi dan kemampuan generalisasi peramalan ke depan yang sangat kokoh dan konsisten.


4.3 Uji Kelayakan Sisaan (Residual Diagnostics & White Noise)

Pengujian kelayakan sisaan (residual diagnostics) model ARIMA(2,1,1) dilakukan secara komprehensif melalui dua aspek: kestasioneran ragam sisaan di sekitar rata-rata nol dan ketiadaan autokorelasi (White Noise).



Gambar 5. Tampilan Widget Line Chart - Residuals pada Orange Data Mining (Pemeriksaan Kestasioneran Sisaan)

Pada Gambar 5, grafik deret sisaan membuktikan bahwa setelah inisialisasi awal pada periode pertama, sisaan model berfluktuasi secara stabil dan stasioner di sekitar rata-rata nol (dalam koridor -150 hingga +150 Miliar Rp). Grafik menunjukkan tidak adanya tren kenaikan atau penurunan yang tertinggal serta ragam kesalahan yang konstan sepanjang waktu (homoskedastisitas terpenuhi).



Gambar 6. Tampilan Jendela Widget Correlogram - Residuals pada Orange Data Mining (Uji White Noise ACF dan PACF)

Selanjutnya, pada Gambar 6, pemeriksaan autokorelasi sisaan membuktikan bahwa seluruh batang autokorelasi (ACF) dan autokorelasi parsial (PACF) berada di dalam interval signifikansi 95% (garis batas biru putus-putus pada $\pm 0,1895$). Tidak ada satu pun batang autokorelasi sisaan yang menembus garis batas tersebut. Hal ini membuktikan secara empiris bahwa model ARIMA(2,1,1) telah berhasil menyerap seluruh struktur memori dan ketergantungan waktu historis, sehingga deret sisaan yang tertinggal sudah sepenuhnya bersifat White Noise (acak murni).

4.4 Hasil Proyeksi Penerimaan PNBP SDA Tahun 2026


Menggunakan model terbaik ARIMA(2,1,1), diproyeksikan estimasi penerimaan bulanan PNBP SDA selama 12 bulan pada Tahun Anggaran 2026:

Tabel 3. Rincian Angka Proyeksi Bulanan PNBP SDA Tahun Anggaran 2026

Bulan	Proyeksi (Miliar Rp)	Batas Bawah (95% CI)	Batas Atas (95% CI)
Januari 2026	Rp 794,20 M	Rp 696,62 M	Rp 891,79 M
Februari 2026	Rp 778,47 M	Rp 654,61 M	Rp 902,33 M
Maret 2026	Rp 778,87 M	Rp 623,98 M	Rp 933,76 M
April 2026	Rp 774,81 M	Rp 593,22 M	Rp 956,40 M
Mei 2026	Rp 773,09 M	Rp 565,74 M	Rp 980,44 M
Juni 2026	Rp 771,22 M	Rp 539,71 M	Rp 1.002,73 M
Juli 2026	Rp 769,91 M	Rp 515,41 M	Rp 1.024,41 M
Agustus 2026	Rp 768,82 M	Rp 492,47 M	Rp 1.045,17 M
September 2026	Rp 767,98 M	Rp 470,78 M	Rp 1.065,17 M

Oktober 2026	Rp 767,30 M	Rp 450,19 M	Rp 1.084,41 M
November 2026	Rp 766,77 M	Rp 430,58 M	Rp 1.102,96 M
Desember 2026	Rp 766,35 M	Rp 411,86 M	Rp 1.120,84 M
TOTAL TAHUN 2026	Rp 9.277,79 Miliar	Rp 6.134,17 Miliar	Rp 12.421,41 Miliar

Total penerimaan PNBPN SDA pada tahun 2026 diproyeksikan mencapai Rp 9,28 Triliun (rata-rata Rp 773,15 Miliar/bulan) dengan rentang selang kepercayaan 95% antara Rp 6,13 Triliun sampai Rp 12,42 Triliun.



Gambar 7. Tampilan Hasil Peramalan 12 Periode TA 2026 pada Widget Line Chart - Forecast Orange

Analisis Karakteristik Garis Proyeksi: Mengapa Nilai Ramalan Cenderung Melandai dan Stabil?

Pemeriksaan terhadap grafik proyeksi pada Gambar 7 dan angka pada Tabel 3 memperlihatkan karakteristik pergerakan ramalan yang sangat menarik: nilai proyeksi bergerak dari Rp 794,20 Miliar di Januari 2026, melandai secara bertahap, dan kemudian stabil pada kisaran Rp 766–770 Miliar per bulan hingga akhir tahun. Stabilitas garis proyeksi ini bukanlah anomali, melainkan representasi logis dari integrasi sifat matematis model ARIMA dan karakteristik data PNBPN SDA:

- **1. Peluruhan Eksponensial Perubahan Bulanan Menuju Nol (Mean-Reverting):** Model ARIMA(2,1,1) bekerja pada deret selisih $\Delta Y(t) = Y(t) - Y(t-1)$. Komponen MA(1) hanya memiliki memori kejutan selama 1 bulan ke depan (setelah Januari 2026, nilai ekspektasi kesalahan masa depan adalah nol). Sementara itu, komponen AR(2) bersifat stasioner ($|\phi_i| < 1$), sehingga perubahan bulanan yang

diproyeksikan (ΔY) meluruh secara eksponensial mendekati nol seiring bertambahnya horizon waktu. Karena perubahan bulanannya mendekati nol ($Y(t) \approx Y(t-1)$), maka pada level aslinya garis peramalan otomatis mendatar dan stabil mendekati rata-rata jangka panjang.

- **2. Karakteristik Data yang Tidak Mengenal Kalender Tahunan:** Komoditas migas dan pertambangan tidak memiliki siklus musiman bulanan yang pasti (tidak ada lonjakan musiman tahunan berulang seperti belanja di Desember atau pajak di Maret). Karena data historisnya tidak memiliki pola 12 bulanan tetap (kekuatan musiman hanya 0,0737), model ARIMA univariat tidak memiliki pola musiman untuk diduplikasi secara artifisial.
- **3. Representasi Nilai Harapan Rata-Rata (Unbiased Expected Value):** Model deret waktu univariat tidak dapat memprediksi letupan kejutan eksternal acak di masa depan (seperti ketegangan geopolitik baru atau pemangkasan kuota OPEC). Karena ekspektasi nilai kejutan acak di masa depan adalah nol, garis proyeksi tengah secara statistik merepresentasikan nilai harapan rata-rata yang paling netral, objektif, dan tidak spekulatif.
- **4. Akomodasi Risiko pada Selang Kepercayaan (Confidence Interval 95%):** Fluktuasi dan ketidakpastian harga komoditas sesungguhnya tidak dihilangkan oleh model, melainkan diakomodasi secara komprehensif melalui pita arsir selang kepercayaan 95% yang melebar seperti corong. Pada Januari 2026, rentang ketidakpastian masih sempit (Rp 696–891 M), namun pada Desember 2026 rentangnya melebar drastis (Rp 411 M hingga Rp 1,12 Triliun). Hal ini mencerminkan peningkatan risiko ketidakpastian seiring menjauhnya horizon waktu.
- **5. Relevansi Strategis bagi Pengelola Fiskal (APBN):** Bagi perencanaan anggaran di Kementerian Keuangan (BKF dan DJA), garis dasar yang stabil ini memberikan kepastian angka patokan (baseline) untuk belanja rutin, sementara rentang batas bawah (Rp 6,13 T) dan batas atas (Rp 12,42 T) menjadi panduan kuantitatif dalam menyusun skenario mitigasi risiko fiskal dan alokasi dana cadangan kas (SAL).

BAB V

KESIMPULAN DAN REKOMENDASI KEBIJAKAN

5.1 Jawaban Pertanyaan Analitis Penugasan dan Catatan Pertanyaan Dosen

- **1. Karakteristik Musiman:** Penerimaan PNPB SDA tidak berulang dalam siklus 12 bulan tetap karena dikendalikan oleh harga komoditas energi global (minyak mentah,

batubara, gas alam) yang bergerak dalam siklus multi-tahunan (2–5 tahun), bukan oleh jadwal administrasi anggaran belanja (Desember) atau batas lapor SPT pajak (Maret/April). Pengujian empiris membuktikan kekuatan musimannya sangat kecil (hanya 0,0737), sehingga model deret waktu musiman seperti SARIMA tidak tepat digunakan.


- **2. Identifikasi Siklus pada Autokorelasi Data Asli:** Grafik ACF data asli mengalami penurunan sangat lambat (slow decay) sampai lag 20 tanpa adanya lonjakan periodik di kelipatan lag 12. Pola ini membuktikan adanya efek memori jangka panjang (long-memory inertia) akibat gelombang siklus komoditas, sekaligus menegaskan bahwa data asli belum stasioner dan memerlukan differencing pertama ($d=1$).
- **3. Rasionalisasi Pemilihan Ordo ARIMA(2,1,1):** Diferensiasi $d=1$ diterapkan untuk menstabilkan rata-rata; $p=2$ (AR orde 2) dipilih untuk menangkap kecepatan perubahan arah dan titik balik tren harga; $q=1$ (MA orde 1) dipilih untuk menyerap kejutan harga sesaat. Model ini terbukti menghasilkan error peramalan paling kecil di Orange (CV-RMSE = 52,77 Miliar Rp, MAE = 35,78 Miliar Rp, MAPE = 6,16%).
- **4. Langkah Mitigasi Penurunan Penerimaan SDA:** Pemerintah perlu menyiapkan Saldo Anggaran Lebih (SAL) sebagai bantalan kas (fiscal buffer), menyesuaikan estimasi transfer Dana Bagi Hasil (DBH) ke daerah penghasil sejak dini, mengefisienkan pos belanja non-prioritas, serta memperkuat penerimaan pajak dari sektor non-komoditas.
- **5. Catatan Kritis (Pertanyaan Dosen Pengampu - Mengapa In-Sample RMSE Lebih Besar?):** Sebagaimana dianalisis pada Sub-bab 4.2, nilai In-Sample RMSE (66,48–67,10 Miliar Rp) lebih besar daripada Fold RMSE (52,77–55,77 Miliar Rp) murni akibat lonjakan galat inisialisasi awal pada $t=0$ (Januari 2014) sebesar +530,57 Miliar Rp karena model belum memiliki data lag masa lalu. Kuadrat galat awal ini mendongkrak rata-rata kuadrat in-sample seluruh 144 bulan (tanpa $t=0$, in-sample RMSE murni sebenarnya hanya 49,82 Miliar Rp, lebih kecil dari Fold RMSE 52,77 Miliar Rp). Selain itu, in-sample memotret krisis 2016 dan 2020, sedangkan cross-validation menguji peramalan bergulir pada data matang. Temuan ini membuktikan secara meyakinkan bahwa model ARIMA(2,1,1) terbebas dari masalah overfitting.

5.2 Rekomendasi untuk Unit Pengelola APBN

- **Badan Kebijakan Fiskal (BKF):** Menggunakan angka perkiraan Rp 766–775 Miliar/bulan sebagai patokan dasar penyusunan target PNPB SDA dalam RAPBN 2026.
- **Direktorat Jenderal Anggaran (DJA):** Menyiapkan alokasi cadangan fiskal jika realisasi berada di batas bawah (Rp 6,13 T) atau batas atas (Rp 12,42 T).
- **Ditjen Perimbangan Keuangan (DJPK):** Mengoordinasikan estimasi transfer DBH SDA dengan pemerintah daerah agar perencanaan APBD lebih terukur.
- **Ditjen Perbendaharaan (DJPb):** Memanfaatkan jadwal arus kas masuk bulanan ini untuk mengatur waktu penerbitan Surat Berharga Negara (SBN) secara efisien.

LAMPIRAN ALUR KERJA ORANGE DATA MINING

Seluruh alur kerja pemrosesan data, differencing, uji model, dan peramalan disusun secara visual pada kanvas Orange Data Mining dalam file Workflow_Kelompok4.ows:



**Gambar Lampiran 1. Tangkapan Layar Kanvas Orange Data Mining
(Workflow_Kelompok4.ows)**

Tabel Lampiran 1. Rincian dan Peran Setiap Widget pada Kanvas Orange Data Mining

Node	Nama Widget	Label di Kanvas	Fungsi Utama Widget
0	OWFile	File - PNPB SDA	Membaca file data mentah K4_pnpb_sda.csv
1	OWTableToTimeseries	Form Timeseries	Mengatur kolom tanggal

			sebagai indeks waktu
2	OWTable	Data Table	Melihat tabel data historis
3	OWLineChart	Line Chart	Menampilkan grafik deret waktu asli
4	OWCorrelogram	Correlogram	Melihat grafik autokorelasi (ACF/PACF) data asli
5	OWDifference	Difference	Melakukan transformasi differencing ($d=1$)
6	OWCorrelogram	Correlogram - $d1$	Melihat ACF/PACF pasca differencing
15	OWARIMAModel	ARIMA(0,1,1)	Model pembanding Moving Average ordo 1
7	OWARIMAModel	ARIMA(1,1,0)	Model pembanding Autoregressive ordo 1
8	OWARIMAModel	ARIMA(1,1,1)	Model pembanding campuran ARMA ordo 1
9	OWARIMAModel	ARIMA(2,1,1) ★	Model terbaik untuk peramalan PNBPN SDA
10	OWModelEvaluation	Model Evaluation	Uji time series cross-validation 4 model
11	OWLineChart	Line Chart - Forecast	Grafik hasil ramalan 12 bulan dan selang 95% CI
12	OWLineChart	Line Chart - Residuals	Grafik deret sisaan model
13	OWCorrelogram	Correlogram - Residuals	Uji White Noise pada sisaan model
14	OWTable	Forecast 12 Periode	Tabel angka hasil ramalan bulanan tahun 2026