



## Evaluasi Komparatif Forecasting PNPB BLU Berbasis SARIMAX terhadap Target Renstra

Roberto\*, Abdul Hamid Arribathi

<sup>1</sup> Fakultas Sains dan Teknologi, Universitas Raharja, Tangerang, Indonesia

Email: <sup>1,\*</sup>[roberto@raharja.info](mailto:roberto@raharja.info), <sup>1</sup>[abdulhamid@raharja.info](mailto:abdulhamid@raharja.info)

Email Penulis Korespondensi: [roberto@raharja.info](mailto:roberto@raharja.info)

**Abstrak**-Penelitian ini mengevaluasi metode forecasting untuk memprediksi realisasi Penerimaan Negara Bukan Pajak (PNBP) BLU X dan menilai kesesuaiannya terhadap Target PNPB Renstra 2025-2029. Permasalahan utama penelitian adalah perlunya pendekatan peramalan yang mampu menguji realisme target penerimaan pada BLU yang memiliki struktur layanan heterogen. Data yang digunakan berupa transaksi PNPB bulanan periode Januari 2021 sampai April 2026 yang diagregasi pada level bulan, Chart of Account (COA), dan departemen. Empat pendekatan dibandingkan, yaitu Holt-Winters, SARIMAX, XGBoost, dan bottom-up forecasting berbasis kelompok COA dominan. Evaluasi dilakukan pada data uji Januari 2025-April 2026 menggunakan Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), dan Mean Absolute Percentage Error (MAPE). Hasil penelitian menunjukkan bahwa SARIMAX(1,1,1)x(0,0,0,0) memberikan kinerja terbaik dengan MAPE 17,97%, lebih rendah dibandingkan XGBoost 19,86%, bottom-up forecasting 20,06%, dan Holt-Winters 32,40%. Model terbaik kemudian digunakan untuk menyusun proyeksi sampai Desember 2029. Hasil perbandingan menunjukkan gap tipis terhadap target pada 2025-2026, sedangkan proyeksi 2027-2029 berada sedikit di atas target. Kontribusi penelitian ini terletak pada integrasi evaluasi komparatif metode statistik, machine learning, dan bottom-up forecasting dengan perbandingan hasil proyeksi terhadap target Renstra jangka menengah pada konteks PNPB BLU.

**Kata Kunci:** PNPB, BLU, SARIMAX, forecasting, Target Renstra, evaluasi komparatif

**Abstract**-This study evaluates forecasting methods for predicting BLU X non-tax state revenue and examining its alignment with the 2025-2029 strategic plan targets. The main problem addressed is the need for a forecasting approach that can assess the realism of revenue targets in a public service agency with heterogeneous service structures. The dataset consists of monthly PNPB transactions from January 2021 to April 2026 aggregated by month, Chart of Account (COA), and department. Four approaches are compared: Holt-Winters, SARIMAX, XGBoost, and bottom-up forecasting based on dominant COA groups. Model performance is assessed on the January 2025-April 2026 test period using Mean Absolute Error, Root Mean Squared Error, and Mean Absolute Percentage Error. The results indicate that SARIMAX(1,1,1)x(0,0,0,0) performs best with a MAPE of 17.97%, outperforming XGBoost at 19.86%, bottom-up forecasting at 20.06%, and Holt-Winters at 32.40%. The selected model is then applied to forecast revenue through December 2029. The comparison with strategic plan targets reveals a narrow gap in 2025-2026, while 2027-2029 projections are slightly above the target. The contribution of this study lies in integrating comparative evaluation of statistical, machine learning, and bottom-up forecasting methods with strategic target realism assessment in the context of BLU revenue planning.

**Keywords:** non-tax revenue, public service agency, SARIMAX, forecasting, strategic plan target, comparative evaluation

### 1. PENDAHULUAN

Penerimaan Negara Bukan Pajak (PNBP) memiliki posisi strategis dalam pengelolaan keuangan sektor publik karena penerimaan ini menjadi salah satu sumber pendanaan layanan negara di luar perpajakan. Dalam kerangka regulasi nasional, PNPB dipahami sebagai seluruh penerimaan pemerintah pusat yang tidak berasal dari penerimaan perpajakan [1]. Pengelolannya menuntut tata kelola yang tertib, akuntabel, dan dapat dipertanggungjawabkan, mulai dari perencanaan, penetapan target, pemungutan, penyetoran, hingga pelaporan [2]. Bagi satuan kerja yang menerapkan pola Badan Layanan Umum (BLU), PNPB tidak hanya merepresentasikan capaian penerimaan, tetapi juga berkaitan dengan keberlanjutan layanan, fleksibilitas pengelolaan keuangan, dan kemampuan organisasi untuk menjaga mutu pelayanan publik [3], [4]. Oleh karena itu, perencanaan target PNPB perlu didukung dengan pendekatan analitis yang dapat membaca pola historis, risiko ketidaktercapaian, dan potensi penerimaan pada periode mendatang.

Dalam praktik perencanaan anggaran, target penerimaan sering disusun berdasarkan kombinasi kebutuhan organisasi, tren tahun sebelumnya, proyeksi pertumbuhan, serta arah kebijakan jangka menengah. Pendekatan tersebut penting, tetapi dapat menimbulkan dua risiko apabila tidak diuji menggunakan data historis. Pertama, target yang terlalu optimistis dapat menimbulkan tekanan pelaksanaan anggaran karena realisasi penerimaan tidak cukup untuk mendukung rencana layanan. Kedua, target yang terlalu konservatif dapat mengurangi dorongan organisasi untuk mengoptimalkan potensi penerimaan. Risiko tersebut semakin besar ketika struktur penerimaan berasal dari banyak layanan dengan karakter yang berbeda. Sebagian layanan bersifat rutin dan relatif stabil, sedangkan sebagian lain sangat dipengaruhi oleh transaksi bernilai besar, kebijakan layanan, momentum ekonomi, atau kejadian non-rutin. Pada konteks ini, forecasting diperlukan sebagai

perangkat analitis untuk membantu menguji realisme target dan menyediakan dasar pembaruan proyeksi secara berkala [5], [6].

BLU X merupakan objek kajian yang relevan karena struktur PNBPNya berasal dari sejumlah layanan utama, antara lain pengelolaan lahan, kepelabuhanan, rumah sakit, air, serta layanan kerja sama tertentu. Sumber penerimaan tersebut tidak homogen. Pendapatan yang terkait dengan pengelolaan lahan dapat dipengaruhi oleh transaksi tertentu yang tidak selalu berulang setiap bulan, sedangkan jasa kepelabuhanan dan layanan rumah sakit cenderung berhubungan dengan volume aktivitas layanan. Kondisi ini menyebabkan pemodelan pada level total penerimaan saja sering belum cukup untuk menjelaskan sumber variasi penerimaan. Analisis perlu menghubungkan hasil forecasting dengan struktur Chart of Account (COA) dan departemen agar temuan statistik dapat diterjemahkan menjadi informasi manajerial. Dengan demikian, model yang akurat belum tentu memadai apabila tidak dapat menjelaskan layanan mana yang paling berkontribusi terhadap risiko atau peluang pencapaian target.

Penelitian terdahulu menunjukkan bahwa metode deret waktu klasik seperti exponential smoothing, ARIMA, dan perluasannya masih banyak digunakan karena relatif mudah ditafsirkan dan efektif pada data runtut waktu yang memiliki pola tren atau musiman [7], [8], [9], [10]. Di sisi lain, pendekatan machine learning seperti XGBoost mampu memanfaatkan fitur lag, kalender, dan statistik bergerak untuk menangkap pola nonlinier [11]. Perkembangan kompetisi dan kajian forecasting modern memperlihatkan bahwa tidak ada satu metode yang selalu unggul untuk semua jenis data. Hal ini karena kinerja model dipengaruhi oleh panjang data historis, granularitas, musiman, volatilitas, dan kualitas fitur, serta konteks penggunaan hasil prediksi [12], [13], [14], [15]. Karena itu, evaluasi komparatif antar-metode menjadi penting sebelum satu model dipilih sebagai dasar proyeksi. Selain mengejar akurasi, pemilihan model juga perlu mempertimbangkan kemudahan pembaruan, keterbacaan hasil, dan keterkaitannya dengan proses perencanaan.

Penelitian terdahulu pada peramalan PNBPN BLU pendidikan menunjukkan bahwa Grey-Markov dapat digunakan pada data historis terbatas dan berpola horizontal dengan fluktuasi rendah [16]. Namun, kajian tersebut belum mengevaluasi beberapa pendekatan forecasting secara komparatif pada data PNBPN bulanan yang lebih panjang dan heterogen menurut COA serta departemen. Selain itu, penelitian sebelumnya belum secara eksplisit mengaitkan hasil forecasting dengan pengujian realisme target Renstra jangka menengah. Gap tersebut menjadi dasar penelitian ini untuk membandingkan pendekatan statistik, machine learning, dan bottom-up forecasting dalam memprediksi realisasi PNBPN BLU serta menilai kesesuaiannya terhadap Target Renstra 2025-2029.

Berdasarkan kebutuhan tersebut, penelitian ini menyusun evaluasi forecasting PNBPN BLU X menggunakan data transaksi bulanan Januari 2021 sampai April 2026. Rentang ini menghasilkan 64 observasi bulanan yang lebih memadai dibandingkan penggunaan data dua atau tiga tahun terakhir saja. Penelitian tidak berhenti pada evaluasi akurasi model, tetapi juga membandingkan hasil proyeksi terhadap Target PNBPN dalam Renstra BLU X 2025-2029. Target tersebut menjadi tolok ukur jangka menengah, yaitu Rp1,99 triliun pada 2025, Rp2,44 triliun pada 2026, Rp2,64 triliun pada 2027, Rp2,84 triliun pada 2028, dan Rp3,07 triliun pada 2029 [17]. Kebaruan penelitian ini terletak pada penggunaan data PNBPN bulanan yang lebih rinci, evaluasi komparatif lintas pendekatan, serta pengaitan hasil forecast dengan realisme Target Renstra.

Rumusan masalah penelitian ini mencakup tiga aspek. Pertama, metode forecasting apa yang paling relevan untuk data PNBPN BLU X berdasarkan ukuran kesalahan prediksi. Kedua, bagaimana struktur COA dan departemen membentuk pola penerimaan yang perlu diperhatikan dalam interpretasi hasil forecasting. Ketiga, sejauh mana hasil proyeksi realisasi PNBPN sejalan dengan Target PNBPN Renstra 2025-2029. Kontribusi penelitian ini terletak pada integrasi antara evaluasi model statistik, machine learning, dan pendekatan struktural bottom-up, serta pemanfaatan hasil forecast sebagai alat bantu pengujian target jangka menengah. Pendekatan tersebut diharapkan dapat mendukung perencanaan anggaran yang lebih berbasis bukti, meningkatkan kualitas monitoring penerimaan, dan menyediakan dasar bagi pembaruan proyeksi yang dapat dilakukan secara berkala.


## **2. METODOLOGI PENELITIAN**

### **2.1 Desain Penelitian dan Sumber Data**

Penelitian ini menggunakan pendekatan kuantitatif dengan fokus pada forecasting deret waktu. Unit analisis utama adalah realisasi PNBPN bulanan BLU X. Data operasional berasal dari rincian transaksi PNBPN periode Januari 2021 sampai April 2026. Dalam dataset operasional, kolom IDR\_AMT merepresentasikan jumlah realisasi PNBPN dalam rupiah, sedangkan kolom SYS\_AMT merepresentasikan nilai target PNBPN pada data operasional. Selain itu, penelitian menggunakan Target PNBPN tahunan dalam Renstra BLU X 2025-2029 sebagai pembanding pada horizon proyeksi jangka menengah [17]. Tahapan penelitian dirancang agar proses analisis tidak hanya menghasilkan angka prediksi, tetapi juga menjelaskan struktur penerimaan dan implikasi pencapaian target.

Data transaksi dibersihkan sebelum proses pemodelan. Pembersihan dilakukan dengan memastikan periode transaksi valid, nilai penerimaan dapat diagregasi, dan kode COA serta departemen tetap dipertahankan untuk analisis struktural. Setelah pembersihan, data diagregasi ke level bulanan. Agregasi ini diperlukan karena target Renstra tersedia pada tingkat tahunan, sedangkan evaluasi model membutuhkan data runtut waktu yang cukup panjang dan konsisten. Pada tahap interpretasi, data juga dikelompokkan menurut COA dan departemen untuk mengidentifikasi layanan yang memberikan

kontribusi terbesar terhadap total PNBPN. Alur tahapan penelitian yang digunakan dalam proses pembersihan data, pemodelan, evaluasi, dan perbandingan terhadap target Renstra ditunjukkan pada Gambar 1.



**Gambar 1.** Tahapan penelitian forecasting PNBPN

Berdasarkan Gambar 1, penelitian dimulai dari pengumpulan data PNBPN, pembersihan dan agregasi bulanan, pemodelan menggunakan empat pendekatan, evaluasi model berdasarkan ukuran kesalahan, penyusunan forecast sampai 2029, serta perbandingan hasil proyeksi terhadap Target Renstra.

## 2.2 Definisi Variabel dan Pengolahan Data

COA atau Chart of Account dalam penelitian ini dipahami sebagai klasifikasi akun yang menggambarkan jenis layanan atau sumber penerimaan. Contohnya adalah Pendapatan UWTO, Pendapatan UWT Perpanjangan, Pendapatan Jasa Labuh, Registrasi Rawat Inap, dan KSO Pengolahan Air Bersih. Definisi ini penting karena COA tidak hanya berfungsi sebagai kode akuntansi, tetapi juga sebagai pintu masuk untuk memahami perilaku layanan yang membentuk total PNBPN. Dengan membaca COA dominan, organisasi dapat mengetahui komponen mana yang paling menentukan variasi realisasi penerimaan.

Target Renstra tahunan dikonversi menjadi variabel perbandingan dan, pada model SARIMAX, digunakan sebagai variabel eksogen. Karena target tersedia pada level tahunan, alokasi bulanan dilakukan dengan pendekatan proporsi musiman historis. Pendekatan ini menjaga agar target bulanan tetap konsisten dengan total target tahunan, tetapi juga memperhatikan pola distribusi realisasi antarbulanan pada data historis. Dengan demikian, variabel target tidak diperlakukan sebagai angka datar setiap bulan, melainkan sebagai representasi kebijakan penerimaan yang disesuaikan dengan pola musiman data.

## 2.3 Metode Forecasting yang Dibandingkan

Pemilihan metode forecasting dalam penelitian ini mempertimbangkan jumlah observasi, pola data, tingkat fluktuasi, serta kebutuhan interpretasi hasil terhadap target perencanaan. Dalam praktik forecasting, pemilihan metode perlu disesuaikan dengan karakteristik data, tujuan prediksi, ketersediaan informasi pendukung, dan konteks pengambilan keputusan [15]. Penelitian sebelumnya pada peramalan PNBPN BLU pendidikan yang jenis layanannya lebih homogen menunjukkan bahwa Grey-Markov dapat digunakan ketika data historis terbatas dan pola data cenderung horizontal dengan fluktuasi rendah [16]. Namun, karakteristik data dalam penelitian ini berbeda karena menggunakan observasi bulanan yang lebih panjang, heterogen menurut COA dan departemen, serta memiliki variasi penerimaan yang lebih kompleks. Oleh karena itu, penelitian ini mengevaluasi empat pendekatan, yaitu Holt-Winters, SARIMAX, XGBoost, dan bottom-up forecasting.

Holt-Winters dipilih sebagai baseline karena metode ini sederhana, mudah ditafsirkan, dan umum digunakan pada data deret waktu yang mengandung level, tren, dan musiman [8], [9], [10]. Pada data dengan pola musiman yang lebih kompleks, pengembangan metode exponential smoothing juga dapat digunakan untuk menangkap variasi musiman yang tidak sederhana [18]. SARIMAX dipilih karena mampu menangkap hubungan autoregressive dan moving average pada data historis, serta memungkinkan penggunaan variabel eksogen berupa target bulanan hasil distribusi Target Renstra [6], [19]. XGBoost dipilih untuk mewakili pendekatan machine learning karena dapat memanfaatkan fitur waktu, lag, dan rolling statistics untuk menangkap pola nonlinier [11], [20], [21]. Sementara itu, bottom-up forecasting dipilih karena struktur PNBPN BLU X bersifat heterogen dan terkonsentrasi pada beberapa COA dominan, sehingga prediksi total perlu dibandingkan dengan pendekatan yang membangun forecast dari komponen penyusunnya [22].

Parameter dan fitur pemodelan disusun agar penelitian dapat direplikasi. SARIMAX dievaluasi menggunakan kombinasi orde yang menghasilkan performa terbaik pada periode uji. XGBoost menggunakan fitur waktu, bulan, lag realisasi, dan rolling statistics. Pada bottom-up forecasting, lima COA dominan dimodelkan sebagai komponen utama, sedangkan COA lainnya dikelompokkan sebagai kategori lain-lain; hasil prediksi setiap komponen kemudian dijumlahkan menjadi total forecast. Perbandingan keempat metode tersebut dilakukan pada data uji yang sama agar hasil evaluasi dapat dibaca secara adil.

## 2.4 Skema Evaluasi Model

Skema evaluasi dibagi menjadi data latih Januari 2021 sampai Desember 2024 dan data uji Januari 2025 sampai April 2026. Pembagian ini dipilih agar evaluasi model dilakukan pada periode yang dekat dengan horizon Renstra, sehingga hasilnya relevan untuk menilai kinerja prediksi pada fase awal target 2025-2029. Setelah model terbaik ditentukan, model tersebut diestimasi ulang menggunakan seluruh data historis Januari 2021 sampai April 2026, kemudian digunakan untuk memproyeksikan realisasi PNBPN Mei 2026 sampai Desember 2029.

Ukuran kesalahan yang digunakan adalah Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), dan Mean Absolute Percentage Error (MAPE). MAE memberikan informasi rata-rata kesalahan absolut, RMSE memberi penalti lebih besar terhadap kesalahan ekstrem, sedangkan MAPE memudahkan pembacaan kesalahan dalam bentuk persentase [23]. Model utama dipilih berdasarkan MAPE terendah karena indikator ini mudah dikomunikasikan dalam konteks manajerial. Namun demikian, MAE dan RMSE tetap digunakan untuk melihat besaran kesalahan dalam satuan rupiah dan sensitivitas terhadap deviasi besar.

Rumus evaluasi yang digunakan dalam penelitian ini meliputi Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), dan Mean Absolute Percentage Error (MAPE), sebagaimana ditunjukkan pada persamaan berikut :

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t|$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2}$$

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right|$$

Dalam rumus tersebut,  $y_t$  adalah nilai aktual,  $\hat{y}_t$  adalah nilai prediksi, dan  $n$  adalah jumlah observasi pada periode pengujian. Untuk pendekatan bottom-up, total forecast dihitung sebagai berikut :

$$\hat{Y}_t = \sum_{i=1}^k \hat{Y}_{i,t}$$

yaitu penjumlahan prediksi setiap kelompok COA ke- $i$  pada periode  $t$ .

### 3. HASIL DAN PEMBAHASAN


#### 3.1 Gambaran Umum Data dan Struktur Penerimaan

Setelah proses penggabungan dan pembersihan, penelitian ini menggunakan 74.686 baris transaksi valid dengan 64 observasi bulanan. Total realisasi PNBPN periode Januari 2021 sampai April 2026 mencapai Rp9,92 triliun. Bulan dengan realisasi tertinggi terjadi pada April 2024 sebesar Rp427,57 miliar, sedangkan bulan terendah terjadi pada Mei 2021 sebesar Rp84,08 miliar. Rentang nilai tersebut menunjukkan bahwa data memiliki volatilitas yang cukup jelas. Variasi ini perlu diperhatikan karena model yang terlalu sederhana berpotensi gagal menangkap lonjakan atau penurunan penerimaan yang dipengaruhi transaksi besar dan dinamika layanan.

Struktur penerimaan memperlihatkan konsentrasi pada beberapa COA utama. Lima COA dengan kontribusi terbesar adalah Pendapatan UWTO, KSO Pengolahan Air Bersih, Pendapatan UWT Perpanjangan, Pendapatan UWT Alokasi Baru, dan Pendapatan Jasa Labuh. Kelima COA tersebut menunjukkan bahwa sumber penerimaan BLU X tidak tersebar merata, melainkan ditopang oleh sejumlah layanan kunci. Kondisi ini memiliki implikasi penting terhadap interpretasi forecast. Ketika model memprediksi pencapaian target, organisasi perlu melihat apakah prediksi tersebut didukung oleh kinerja layanan dominan atau hanya terbantu oleh agregasi total. Rincian lima COA dengan kontribusi terbesar terhadap total realisasi PNBPN ditampilkan pada Tabel 1, sedangkan visualisasi kontribusinya disajikan pada Gambar 2.

Tabel 1. Lima COA dengan kontribusi terbesar terhadap realisasi PNBPN

| COA      | Nama COA                    | Realisasi PNBPN | Kontribusi |
|----------|-----------------------------|-----------------|------------|
| 41110101 | Pendapatan UWTO             | Rp1,69 triliun  | 17,08%     |
| 44120101 | KSO Pengolahan Air Bersih   | Rp1,29 triliun  | 12,97%     |
| 41110109 | Pendapatan UWT Perpanjangan | Rp0,93 triliun  | 9,40%      |
| 41110110 | Pendapatan UWT Alokasi Baru | Rp0,76 triliun  | 7,61%      |
| 41310101 | Pendapatan Jasa Labuh       | Rp0,53 triliun  | 5,37%      |



Gambar 2. Kontribusi lima COA dominan terhadap realisasi PNBPN

Berdasarkan Tabel 1 dan Gambar 2, Pendapatan UWTO menjadi kontributor terbesar dengan nilai Rp1,69 triliun atau 17,08% dari total realisasi PNBPN. Kontribusi berikutnya berasal dari KSO Pengolahan Air Bersih, Pendapatan UWT Perpanjangan, Pendapatan UWT Alokasi Baru, dan Pendapatan Jasa Labuh. Pola ini menunjukkan bahwa realisasi PNBPN BLU X terkonsentrasi pada beberapa COA dominan, sehingga monitoring target tidak cukup dilakukan hanya pada level total penerimaan. Apabila satu atau dua layanan utama mengalami perlambatan, dampaknya dapat terlihat langsung pada total PNBPN. Sebaliknya, perbaikan tata kelola layanan dominan, penguatan penagihan, atau optimalisasi pemanfaatan layanan dapat memberikan efek besar terhadap pencapaian target. Oleh karena itu, penggunaan forecasting perlu dikombinasikan dengan dashboard monitoring yang mampu menampilkan kontribusi dan deviasi setiap COA kunci.

### 3.2 Perspektif Departemen dan Layanan Dominan

Analisis berikut melihat PNBPN dari sudut pandang departemen dan layanan. Pendekatan ini diperlukan agar forecasting tidak dibaca semata sebagai hasil statistik, tetapi juga sebagai refleksi dari sumber penerimaan di lapangan. Lima departemen dengan kontribusi terbesar menjadi fokus karena secara agregat merepresentasikan porsi dominan dari total PNBPN BLU X. Pada level departemen, pola penerimaan menunjukkan bahwa beberapa unit memiliki ketergantungan tinggi terhadap COA tertentu.

Tabel 2. Layanan dominan pada departemen dengan kontribusi PNBPN terbesar

| Departemen                                 | COA      | Layanan dominan                        | Realisasi         | Kontribusi internal |
|--------------------------------------------|----------|----------------------------------------|-------------------|---------------------|
| Direktorat Pengelolaan Lahan               | 41110101 | Pendapatan UWTO                        | Rp1.694,59 miliar | 47,35%              |
| Direktorat Pengelolaan Lahan               | 41110109 | Pendapatan UWT Perpanjangan            | Rp932,95 miliar   | 26,07%              |
| Direktorat Pengelolaan Kepelabuhanan       | 41310101 | Pendapatan Jasa Labuh                  | Rp533,13 miliar   | 26,19%              |
| Direktorat Pengelolaan Kepelabuhanan       | 41310110 | Pendapatan Jasa Bongkar Muat           | Rp270,30 miliar   | 13,28%              |
| Badan Usaha SPAM, Fasilitas dan Lingkungan | 44120101 | KSO Pengolahan Air Bersih              | Rp986,53 miliar   | 67,90%              |
| Badan Usaha SPAM, Fasilitas dan Lingkungan | 41520101 | Pendapatan Air Baku                    | Rp194,85 miliar   | 13,41%              |
| Badan Usaha Rumah Sakit                    | 41410101 | Registrasi Rawat Inap                  | Rp347,68 miliar   | 38,13%              |
| Badan Usaha Rumah Sakit                    | 41480101 | Pendapatan BPJS Kesehatan - Rawat Inap | Rp116,72 miliar   | 12,80%              |
| Badan Usaha SPAM, Fasilitas dan Lingkungan | 44120101 | KSO Pengolahan Air Bersih              | Rp300,19 miliar   | 56,40%              |
| Badan Usaha SPAM, Fasilitas dan Lingkungan | 44110401 | Pendapatan Hasil Kerjasama/KSO         | Rp78,46 miliar    | 14,74%              |

Berdasarkan Tabel 2, terlihat bahwa setiap departemen utama memiliki layanan dominan yang berbeda dan berkontribusi besar terhadap total penerimaan internalnya. Direktorat Pengelolaan Lahan ditopang terutama oleh UWTO, UWT Perpanjangan, dan UWT Alokasi Baru. Direktorat Pengelolaan Kepelabuhanan bertumpu pada jasa labuh, jasa bongkar muat, dan jasa tambat. Sementara itu, kelompok layanan air dan kerja sama pengelolaan air mendominasi departemen yang terkait dengan pengelolaan air. Pada Badan Usaha Rumah Sakit, layanan rawat inap dan rawat jalan menjadi penggerak utama. Temuan ini penting untuk interpretasi forecast, karena risiko ketidaktercapaian target kemungkinan besar akan dipengaruhi oleh beberapa layanan utama tersebut, bukan oleh seluruh layanan secara merata.

Kualitas data menjadi faktor penting dalam penelitian ini karena hasil forecasting sangat dipengaruhi oleh konsistensi data historis yang digunakan. Oleh karena itu, proses pengolahan data dilakukan dengan memastikan validitas periode transaksi, kesesuaian nilai realisasi PNBPN, konsistensi klasifikasi COA, serta keterhubungan data dengan departemen atau unit layanan terkait. Penguatan kualitas data tersebut diperlukan agar hasil analisis tidak hanya akurat secara numerik, tetapi juga dapat ditelusuri kembali ke sumber penerimaan yang relevan.


### 3.3 Evaluasi Komparatif Metode Forecasting

Evaluasi model dilakukan pada periode uji Januari 2025 sampai April 2026. Hasil perbandingan menunjukkan bahwa SARIMAX(1,1,1)x(0,0,0,0) memberikan kinerja terbaik dengan MAPE 17,97%. Model ini juga menghasilkan MAE Rp26,78 miliar dan RMSE Rp35,97 miliar. XGBoost berada pada posisi kedua dengan MAPE 19,86%, sedangkan bottom-up forecasting memiliki MAPE 20,06%. Holt-Winters menjadi baseline dengan MAPE 32,40%. Pola ini menunjukkan bahwa model yang memadukan komponen deret waktu dengan variabel target sebagai eksogen lebih sesuai untuk data PNPB BLU X dibandingkan baseline tren-musiman sederhana.

Rincian hasil evaluasi setiap metode berdasarkan MAE, RMSE, dan MAPE ditampilkan pada Tabel 3, sedangkan perbandingan nilai MAPE antar-metode divisualisasikan pada Gambar 3.

Tabel 3. Hasil evaluasi metode forecasting pada periode uji Januari 2025-April 2026

| Metode                   | MAE            | RMSE           | MAPE   |
|--------------------------|----------------|----------------|--------|
| SARIMAX(1,1,1)x(0,0,0,0) | Rp26,78 miliar | Rp35,97 miliar | 17,97% |
| XGBoost                  | Rp33,33 miliar | Rp43,50 miliar | 19,86% |
| Bottom-up Forecasting    | Rp29,53 miliar | Rp40,46 miliar | 20,06% |
| Holt-Winters             | Rp46,99 miliar | Rp56,79 miliar | 32,40% |



Gambar 3. Perbandingan MAPE antar-metode forecasting

Berdasarkan Tabel 3 dan Gambar 3, SARIMAX memiliki nilai MAPE paling rendah, yaitu 17,97%, sehingga menjadi model dengan performa terbaik pada periode uji. Gambar 3 juga memperlihatkan bahwa selisih performa antara SARIMAX, XGBoost, dan bottom-up forecasting relatif tidak terlalu jauh, sedangkan Holt-Winters memiliki kesalahan prediksi paling besar. Hal ini menunjukkan bahwa metode baseline tren-musiman sederhana kurang mampu menangkap kompleksitas data PNPB BLU X.

Keunggulan SARIMAX dapat dijelaskan dari dua sisi. Pertama, data PNPB memiliki komponen runtut waktu yang masih dapat ditangkap oleh struktur autoregressive dan moving average. Kedua, penggunaan target sebagai variabel eksogen membantu model membaca konteks kebijakan penerimaan yang memang memengaruhi proses perencanaan anggaran. Dengan kata lain, model tidak hanya mengandalkan memori historis, tetapi juga memasukkan informasi target yang menjadi bagian dari arah organisasi. Pendekatan ini sejalan dengan prinsip forecasting yang menekankan pentingnya mengombinasikan pola historis dan informasi kontekstual ketika tersedia [5], [6]. Temuan ini memperkuat argumen bahwa informasi kebijakan dapat menjadi variabel kontekstual yang berguna ketika data historis memiliki hubungan dengan target perencanaan organisasi.

XGBoost menunjukkan hasil kompetitif dengan MAPE 19,86%. Hal ini mengindikasikan bahwa fitur waktu, lag, dan rolling statistics dapat membantu menangkap pola nonlinier pada data PNPB. Namun, pada dataset dengan 64 observasi bulanan, ruang pembelajaran machine learning relatif terbatas. Model seperti XGBoost biasanya membutuhkan fitur yang kaya dan jumlah observasi yang memadai agar kelebihanannya terlihat optimal [11], [20]. Oleh karena itu, kinerja XGBoost yang sedikit di bawah SARIMAX tidak berarti pendekatan machine learning tidak relevan, melainkan menunjukkan bahwa untuk data bulanan yang relatif pendek, model statistik yang tepat masih sangat kuat.

Bottom-up forecasting menghasilkan MAPE 20,06%, sedikit lebih tinggi dibandingkan XGBoost. Walaupun belum menjadi model paling akurat, pendekatan ini memiliki nilai manajerial yang besar karena mendekatkan proses prediksi dengan struktur penerimaan. Pemisahan lima COA dominan dan kelompok lainnya membuat organisasi dapat melihat kontribusi komponen terhadap total forecast. Dalam konteks pengambilan keputusan, pendekatan bottom-up dapat digunakan sebagai pelengkap SARIMAX untuk menjelaskan sumber perubahan, menyusun skenario layanan, dan mengidentifikasi COA yang perlu dipantau lebih rapat.


Holt-Winters memiliki MAPE terbesar, yaitu 32,40%. Hasil ini menunjukkan bahwa pola PNBPN BLU X lebih kompleks dibandingkan pola tren-musiman reguler. Meskipun demikian, pendekatan exponential smoothing tetap relevan sebagai baseline dan dapat dikembangkan melalui dekomposisi STL, transformasi Box-Cox, serta teknik bagging untuk meningkatkan stabilitas prediksi pada data musiman [24]. Fluktuasi penerimaan yang dipengaruhi transaksi besar, layanan heterogen, serta perubahan komposisi penerimaan membuat baseline exponential smoothing kurang mampu mengikuti dinamika data. Namun, Holt-Winters tetap berguna sebagai pembandingan karena menyediakan titik awal evaluasi. Model utama seharusnya tidak hanya dibandingkan dengan metode yang kompleks, tetapi juga dengan baseline yang mudah dipahami agar peningkatan kinerja dapat diukur secara jelas [7], [23].

### 3.4 Forecast Sampai 2029 dan Pembandingan dengan Target Renstra

Model terbaik kemudian diestimasi ulang menggunakan seluruh data historis Januari 2021 sampai April 2026. Hasilnya dipakai untuk menyusun forecast Mei 2026 sampai Desember 2029. Karena target Renstra bersifat tahunan, pembandingan utama dilakukan pada level agregat tahunan. Untuk tahun 2026, nilai yang dibandingkan merupakan gabungan realisasi Januari-April dan forecast Mei-Desember. Dengan cara ini, tahun 2026 tetap dapat dibaca sebagai estimasi capaian penuh tahun berjalan.

Tabel 4. Perbandingan realisasi/forecast dengan Target PNBPN Renstra 2025-2029

| Tahun | Status                            | Realisasi/Forecast | Target Renstra | Selisih         | Rasio   |
|-------|-----------------------------------|--------------------|----------------|-----------------|---------|
| 2025  | Aktual                            | Rp1,93 triliun     | Rp1,99 triliun | Rp-0,06 triliun | 96,81%  |
| 2026  | Aktual Jan-Apr + Forecast Mei-Des | Rp2,37 triliun     | Rp2,44 triliun | Rp-0,07 triliun | 97,12%  |
| 2027  | Forecast                          | Rp2,68 triliun     | Rp2,64 triliun | Rp0,04 triliun  | 101,58% |
| 2028  | Forecast                          | Rp2,91 triliun     | Rp2,84 triliun | Rp0,07 triliun  | 102,61% |
| 2029  | Forecast                          | Rp3,18 triliun     | Rp3,07 triliun | Rp0,11 triliun  | 103,64% |



Gambar 4. Perbandingan realisasi/forecast dengan Target PNBPN Renstra

Berdasarkan Tabel 4 dan Gambar 4, realisasi tahun 2025 mencapai sekitar 96,81% dari target. Untuk 2026, gabungan realisasi Januari-April dan forecast Mei-Desember berada pada kisaran 97,12% dari target. Dengan demikian, dua tahun awal horizon Renstra menunjukkan gap tipis. Gap ini tidak terlalu besar, tetapi tetap perlu diperhatikan karena dapat memengaruhi ruang fiskal layanan apabila tidak ditutup melalui penguatan kinerja penerimaan. Pada 2027 sampai 2029, proyeksi berada sedikit di atas target, yaitu 101,58%, 102,61%, dan 103,64%. Sementara itu, Gambar 4 memperlihatkan pola visual perbandingan antara nilai realisasi/forecast dan Target Renstra dalam satuan triliun rupiah. Grafik tersebut menunjukkan bahwa jarak antara garis realisasi/forecast dan garis target relatif dekat sepanjang periode 2025–2029, dengan posisi realisasi/forecast sedikit di bawah target pada 2025–2026 dan sedikit di atas target pada 2027–2029. Temuan ini memberi sinyal bahwa target jangka menengah secara umum masih realistis berdasarkan pola historis dan asumsi model.

Interpretasi hasil forecast perlu dilakukan secara hati-hati. Proyeksi yang berada di atas target pada 2027-2029 tidak berarti target pasti tercapai, karena model tetap bergantung pada pola data historis dan asumsi bahwa tidak terjadi perubahan struktural besar. Perubahan regulasi layanan, kebijakan tarif, kondisi ekonomi, proyek besar, atau gangguan operasional dapat mengubah pola penerimaan. Oleh karena itu, forecasting sebaiknya diposisikan sebagai alat monitoring dinamis, bukan angka tetap yang tidak perlu diperbarui. Pembaruan model secara berkala, misalnya triwulanan atau semesteran, dapat membantu organisasi membaca deviasi lebih awal dan menyesuaikan strategi pencapaian target.

Secara manajerial, terdapat tiga implikasi utama. Pertama, monitoring target sebaiknya dilakukan pada level layanan kunci, bukan hanya total PNBPN. Layanan seperti UWTO, UWT Perpanjangan, KSO Pengolahan Air Bersih, dan Jasa Labuh perlu memperoleh perhatian khusus karena kontribusinya besar. Kedua, hasil forecast dapat digunakan untuk menilai realisme target sebelum target disahkan atau saat dilakukan revisi rencana kerja. Apabila proyeksi menunjukkan



deviasi besar, organisasi dapat menyusun skenario mitigasi lebih awal. Ketiga, kualitas data master perlu diperkuat, terutama konsistensi nama departemen, klasifikasi COA, dan dokumentasi sumber data. Kualitas data yang baik akan meningkatkan akurasi analisis dan memudahkan penelusuran penyebab deviasi.

Hasil penelitian juga menunjukkan bahwa integrasi antara model statistik dan informasi kebijakan dapat memberikan nilai tambah. SARIMAX unggul karena mampu menggabungkan pola historis dan variabel target. Namun, model ini sebaiknya tidak digunakan sendiri. Pendekatan bottom-up tetap diperlukan untuk menjelaskan komponen pembentuk forecast, sedangkan XGBoost dapat dikembangkan lebih lanjut apabila data historis bertambah dan fitur eksternal tersedia. Fitur eksternal yang dapat dipertimbangkan antara lain volume layanan, jumlah kunjungan kapal, transaksi lahan, indikator ekonomi wilayah, dan indikator operasional rumah sakit. Dengan fitur yang lebih kaya, pemodelan dapat bergerak dari prediksi agregat menuju prediksi berbasis penggerak penerimaan.

Keterbatasan penting dalam penelitian ini adalah belum dimasukkannya variabel eksogen operasional dan kebijakan yang secara langsung dapat memengaruhi peningkatan PNPB secara signifikan, seperti volume layanan, perubahan tarif, aktivitas pelabuhan, transaksi lahan, indikator layanan kesehatan, indikator ekonomi wilayah, serta program optimalisasi penerimaan. Oleh karena itu, hasil forecast dalam penelitian ini lebih tepat dipahami sebagai baseline proyeksi berbasis data historis dan target Renstra, bukan sebagai simulasi dampak kebijakan. Jika pimpinan BLU menetapkan target yang lebih optimistik daripada hasil proyeksi historis, maka target tersebut perlu didukung oleh intervensi kebijakan, strategi peningkatan layanan, dan indikator penggerak penerimaan yang terukur.

Dari sisi kontribusi akademik, penelitian ini menegaskan pentingnya evaluasi komparatif pada data sektor publik karena pemilihan metode forecasting tidak dapat hanya didasarkan pada popularitas metode, tetapi perlu diuji berdasarkan karakteristik data dan tujuan penggunaan hasil prediksi. Perbandingan antara Holt-Winters, SARIMAX, XGBoost, dan bottom-up forecasting menunjukkan bahwa metode terbaik harus dipilih berdasarkan bukti empiris pada data uji. Dari sisi praktis, penelitian ini menyediakan kerangka kerja yang dapat direplikasi untuk penerimaan BLU lain, mulai dari pembersihan data transaksi, agregasi bulanan, evaluasi beberapa metode, interpretasi struktur COA dan departemen, sampai perbandingan hasil proyeksi terhadap target jangka menengah.

#### 4. KESIMPULAN

Penelitian ini menunjukkan bahwa data PNPB BLU X periode Januari 2021 sampai April 2026 dapat digunakan untuk mengevaluasi beberapa metode forecasting dan menyusun proyeksi jangka menengah. Dari empat pendekatan yang dibandingkan, SARIMAX(1,1,1)x(0,0,0,0) menjadi metode paling relevan untuk dataset ini karena menghasilkan MAPE terendah sebesar 17,97%, lebih baik dibandingkan XGBoost, bottom-up forecasting, dan Holt-Winters. Keunggulan SARIMAX terutama terlihat karena model mampu membaca pola historis sekaligus memanfaatkan informasi target sebagai variabel eksogen. Meskipun demikian, XGBoost dan bottom-up forecasting tetap memiliki nilai tambah, yaitu XGBoost relevan untuk pengembangan berikutnya ketika fitur dan observasi bertambah, sedangkan bottom-up forecasting membantu menjelaskan struktur penerimaan berdasarkan COA dominan. Dari sisi substansi, hasil forecast sampai 2029 menunjukkan bahwa Target PNPB Renstra BLU X 2025–2029 masih berada pada rentang yang realistis, dengan capaian 2025 dan 2026 menunjukkan gap tipis terhadap target, masing-masing sekitar 96,81% dan 97,12%, sedangkan 2027 sampai 2029 diproyeksikan sedikit di atas target. Temuan ini mengindikasikan bahwa tantangan utama berada pada fase awal horizon Renstra dan perlu ditangani melalui monitoring layanan dominan, penguatan penagihan, serta pembaruan proyeksi secara berkala. Oleh karena itu, penelitian ini merekomendasikan agar forecasting dijadikan bagian dari siklus perencanaan dan pengendalian anggaran, bukan hanya analisis satu kali. Pengembangan lanjutan dapat menambahkan variabel eksternal seperti volume layanan, indikator ekonomi, transaksi lahan, aktivitas pelabuhan, dan indikator operasional unit layanan agar model menjadi lebih informatif dan dapat mendukung skenario kebijakan secara lebih rinci.

#### UCAPAN TERIMA KASIH

Penulis menyampaikan terima kasih kepada pihak-pihak yang telah mendukung penyediaan data dan proses penyusunan penelitian ini. Ucapan terima kasih juga disampaikan kepada unit kerja terkait yang berperan dalam pengelolaan data PNPB dan perencanaan anggaran.

#### REFERENSI

- [1] *Undang-Undang Republik Indonesia Nomor 9 Tahun 2018 tentang Penerimaan Negara Bukan Pajak*. Republik Indonesia, 2018.
- [2] *Peraturan Pemerintah Republik Indonesia Nomor 58 Tahun 2020 tentang Pengelolaan Penerimaan Negara Bukan Pajak*. Republik Indonesia, 2020.



- [3] Peraturan Pemerintah Republik Indonesia Nomor 23 Tahun 2005 tentang Pengelolaan Keuangan Badan Layanan Umum. Republik Indonesia, 2005.
- [4] K. K. R. Indonesia, *Peraturan Menteri Keuangan Nomor 129/PMK.05/2020 tentang Pedoman Pengelolaan Badan Layanan Umum*. Kementerian Keuangan Republik Indonesia, 2020.
- [5] R. J. Hyndman and G. Athanasopoulos, *Forecasting: Principles and Practice*, 3rd ed. Melbourne, Australia: OTexts, 2021.
- [6] G. E. P. Box, G. M. Jenkins, G. C. Reinsel, and G. M. Ljung, *Time Series Analysis: Forecasting and Control*, 5th ed. Hoboken, NJ, USA: Wiley, 2015.
- [7] C. Chatfield, *Time-Series Forecasting*. Boca Raton, FL, USA: Chapman and Hall/CRC, 2000.
- [8] E. S. Gardner, "Exponential smoothing: The state of the art," *J. Forecast.*, vol. 4, no. 1, pp. 1–28, 1985.
- [9] C. C. Holt, "Forecasting seasonals and trends by exponentially weighted moving averages," *Int. J. Forecast.*, vol. 20, no. 1, pp. 5–10, 2004.
- [10] P. R. Winters, "Forecasting sales by exponentially weighted moving averages," *Manage. Sci.*, vol. 6, no. 3, pp. 324–342, 1960.
- [11] T. Chen and C. Guestrin, "XGBoost: A scalable tree boosting system," in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2016, pp. 785–794.
- [12] S. Makridakis, E. Spiliotis, and V. Assimakopoulos, "Statistical and machine learning forecasting methods: Concerns and ways forward," *PLoS One*, vol. 13, no. 3, pp. 1–26, 2018.
- [13] S. Makridakis, E. Spiliotis, and V. Assimakopoulos, "The M4 competition: 100,000 time series and 61 forecasting methods," *Int. J. Forecast.*, vol. 36, no. 1, pp. 54–74, 2020.
- [14] S. Makridakis, E. Spiliotis, and V. Assimakopoulos, "M5 accuracy competition: Results, findings, and conclusions," *Int. J. Forecast.*, vol. 38, no. 4, pp. 1346–1364, 2022.
- [15] F. Petropoulos *et al.*, "Forecasting : theory and practice," *Int. J. Forecast.*, vol. 38, no. 3, pp. 705–871, 2022, doi: 10.1016/j.ijforecast.2021.11.001.
- [16] I. D. N. A. Manuaba, I. B. G. Manuaba, and M. Sudarma, "Komparasi Metode Peramalan Grey dan Grey-Markov untuk mengetahui Peramalan PNBPN di Universitas Udayana," *Maj. Ilm. Teknol. Elektro*, vol. 21, no. 1, p. 83, 2022, doi: 10.24843/mite.2022.v21i01.p12.
- [17] X. BLU, "Rencana Strategis BLU X 2025-2029," BLU X, Batam, 2025.
- [18] A. M. De Livera, R. J. Hyndman, and R. D. Snyder, "Forecasting time series with complex seasonal patterns using exponential smoothing," *J. Am. Stat. Assoc.*, vol. 106, no. 496, pp. 1513–1527, 2011.
- [19] J. D. Hamilton, *Time Series Analysis*. Princeton, NJ, USA: Princeton University Press, 1994.
- [20] L. Breiman, "Random forests," *Mach. Learn.*, vol. 45, no. 1, pp. 5–32, 2001.
- [21] H. Hewamalage, C. Bergmeir, and K. Bandara, "Recurrent neural networks for time series forecasting: Current status and future directions," *Int. J. Forecast.*, vol. 37, no. 1, pp. 388–427, 2021, doi: 10.1016/j.ijforecast.2020.06.008.
- [22] S. L. Wickramasuriya, G. Athanasopoulos, and R. J. Hyndman, "Optimal forecast reconciliation for hierarchical and grouped time series through trace minimization," *J. Am. Stat. Assoc.*, vol. 114, no. 526, pp. 804–819, 2019, doi: 10.1080/01621459.2018.1448825.
- [23] R. J. Hyndman and A. B. Koehler, "Another look at measures of forecast accuracy," *Int. J. Forecast.*, vol. 22, no. 4, pp. 679–688, 2006.
- [24] C. Bergmeir, R. J. Hyndman, and J. M. Benitez, "Bagging exponential smoothing methods using STL decomposition and Box-Cox transformation," *Int. J. Forecast.*, vol. 32, no. 2, pp. 303–312, 2016.