

Implementation of Temporal Fusion Transformer (TFT) for Short-Term Sales Prediction of Telkomsel Data Packages in East Java

Muhammad Azkiya Akmal^{1*)}, Trimono²⁾, Alfian Rizaldy Pratama³⁾

¹⁾²⁾³⁾Sains Data, Ilmu Komputer, UPN “Veteran” Jawa Timur

*)Correspondence author: Muhammad Azkiya Akmal, 22083010084@student.upnjatim.ac.id,
Jawa Timur, Indonesia

DOI : <https://doi.org/10.37012/jtik.v12i1.3268>

Abstract

The development of the cellular telecommunications industry has driven an increasing demand for fast, stable, and affordable data services. Accurate forecasting of data package sales is a significant challenge for telecommunications operators due to high demand fluctuations and the complexity of time series patterns. This study aims to implement a Temporal Fusion Transformer (TFT) model based on Seasonal-Trend Decomposition using Loess (STL) to predict short-term sales of Telkomsel data packages in East Java. The data used are sales transactions with hourly time resolution from January to June 2024, focusing on the five data packages with the highest transaction volume. The STL method is applied in the pre-processing stage to separate the trend, seasonal, and residual components, which are then used as additional features in the TFT modeling. Model performance is evaluated using Mean Absolute Error (MAE) and Quantile Risk (q-Risk). The results show that the TFT model is able to produce accurate predictions with an MAE value of 3.6941 and an average q-Risk of 0.0808. Furthermore, interpretability analysis revealed that historical sales variables, seasonal components, and calendar variables significantly contributed to the prediction results. These findings indicate that the STL-based TFT approach is effective for short-term sales forecasting and has the potential to support data-driven operational decision-making in the telecommunications sector.

Keywords: Time Series Forecasting, Temporal Fusion Transformer, STL Decomposition, Data Package Sales, Deep Learning

Abstrak

Perkembangan industri telekomunikasi seluler mendorong peningkatan kebutuhan akan layanan data yang cepat, stabil, dan terjangkau. Peramalan penjualan paket data yang akurat menjadi tantangan penting bagi operator telekomunikasi akibat tingginya fluktuasi permintaan dan kompleksitas pola deret waktu. Penelitian ini bertujuan mengimplementasikan model Temporal Fusion Transformer (TFT) berbasis Seasonal-Trend Decomposition using Loess (STL) untuk memprediksi penjualan jangka pendek paket data Telkomsel di wilayah Jawa Timur. Data yang digunakan berupa transaksi penjualan dengan resolusi waktu per jam pada periode Januari hingga Juni 2024, dengan fokus pada lima paket data dengan volume transaksi tertinggi. Metode STL diterapkan pada tahap pra-pemrosesan untuk memisahkan komponen tren, musiman, dan residual, yang selanjutnya digunakan sebagai fitur tambahan dalam pemodelan TFT. Kinerja model dievaluasi menggunakan Mean Absolute Error (MAE) dan Quantile Risk (q-Risk). Hasil penelitian menunjukkan bahwa model TFT mampu menghasilkan prediksi yang akurat dengan nilai MAE sebesar 3,6941 dan q-Risk rata-rata sebesar 0,0808. Selain itu, analisis interpretabilitas mengungkap bahwa variabel historis penjualan, komponen musiman, serta variabel kalender memiliki kontribusi dominan terhadap hasil prediksi. Temuan ini menunjukkan bahwa pendekatan TFT berbasis STL efektif untuk peramalan penjualan jangka pendek dan berpotensi mendukung pengambilan keputusan operasional berbasis data pada sektor telekomunikasi.

Kata Kunci : Peramalan Deret Waktu, Temporal Fusion Transformer, STL, Penjualan Paket Data, Deep Learning

PENDAHULUAN

Perkembangan industri telekomunikasi seluler mendorong peningkatan kebutuhan akan layanan data yang cepat, stabil, dan terjangkau. Paket data menjadi salah satu produk utama yang menentukan tingkat kepuasan pelanggan serta pendapatan operator telekomunikasi (Andi Dwi Riyanto, 2024). Kemampuan dalam memprediksi penjualan paket data secara akurat menjadi faktor penting dalam mendukung perencanaan stok, strategi distribusi, dan pengambilan keputusan operasional berbasis data (APJII, 2023).

Namun demikian, peramalan penjualan paket data bukanlah tugas yang sederhana. Data penjualan umumnya berbentuk deret waktu yang bersifat fluktuatif, nonlinier, dan dipengaruhi oleh berbagai faktor temporal seperti jam, hari, dan pola musiman (Baradie et al., 2022; Indonesia, 2024). Pendekatan peramalan konvensional berbasis metode statistik, seperti ARIMA dan exponential smoothing, memiliki keterbatasan dalam menangkap pola kompleks dan ketergantungan jangka panjang pada data dengan dinamika tinggi (Aditya Nugroho, 2023; Thomas Mola, 2025).

Seiring dengan perkembangan teknologi komputasi, pendekatan machine learning dan deep learning mulai banyak digunakan dalam peramalan deret waktu karena kemampuannya dalam memodelkan hubungan nonlinier (Bihan Mokodompit, 2025). Model berbasis Recurrent Neural Network (RNN), khususnya Long Short-Term Memory (LSTM), telah menunjukkan kinerja yang lebih baik dibandingkan metode statistik dalam berbagai studi peramalan (Choirul Anam, 2024; Izzul Wafa, 2025). Meskipun demikian, model LSTM konvensional masih memiliki keterbatasan dalam hal interpretabilitas serta kesulitan dalam mengintegrasikan variabel eksogen secara sistematis (Amtul Wahab et al., 2024).

Sebagai pengembangan lebih lanjut, Temporal Fusion Transformer (TFT) diperkenalkan sebagai arsitektur deep learning yang dirancang khusus untuk peramalan multihorizon dengan tingkat interpretabilitas yang tinggi (Türkmen et al., 2021). Model ini mengombinasikan mekanisme sequence modeling dengan attention mechanism serta Variable Selection Network yang memungkinkan identifikasi variabel paling berpengaruh


terhadap hasil prediksi (Suharno, 2025). Keunggulan ini menjadikan TFT lebih sesuai untuk aplikasi peramalan yang membutuhkan akurasi sekaligus transparansi model (Vishwakarma & Solanki, 2022).

Metode Seasonal-Trend Decomposition using Loess (STL) merupakan teknik dekomposisi deret waktu yang efektif dalam memisahkan komponen tren, musiman, dan residual (Deretić et al., 2022). Penggunaan STL pada tahap pra-pemrosesan telah terbukti mampu memperjelas struktur temporal data dan meningkatkan performa model peramalan berbasis pembelajaran mesin (Sirisha et al., 2022).

Untuk mengisi celah dari penelitian terdahulu dan menonjolkan kebaruan, penelitian ini membandingkan performa model usulan dengan metode konvensional ARIMA (SARIMAX) sebagai baseline peramalan. Kontribusi utama dari penelitian ini mencakup integrasi metode STL sebagai feature engineering pada arsitektur TFT untuk memperkuat ekstraksi pola temporal yang kompleks, serta evaluasi kinerja model secara probabilistik menggunakan metrik q-Risk guna mengukur ketidakpastian prediksi di samping evaluasi akurasi titik.

METODE PENELITIAN

Penelitian ini merupakan penelitian kuantitatif dengan pendekatan eksperimental yang bertujuan mengembangkan dan mengevaluasi model prediksi penjualan jangka pendek paket data menggunakan arsitektur deep learning. Tahapan penelitian meliputi pengumpulan data, pra-pemrosesan, pemodelan menggunakan Temporal Fusion Transformer (TFT), serta evaluasi kinerja model berdasarkan metrik kesalahan prediksi.



Gambar 1. Alur Penelitian

Jenis dan Sumber Data

Data yang digunakan dalam penelitian ini merupakan data sekunder berupa log transaksi penjualan paket data Telkomsel yang diperoleh dari aplikasi Digipos Aja! sebagai kanal distribusi ritel resmi Telkomsel. Data mencakup periode Januari hingga Juni 2024 dengan resolusi waktu per jam.

Objek penelitian difokuskan pada lima jenis paket data dengan volume transaksi tertinggi (Top 5 Products) di wilayah Jawa Timur. Pembatasan ini dilakukan untuk menghindari permasalahan sparse count process pada paket dengan volume penjualan rendah yang dapat mengganggu proses pembelajaran model. Variabel target dalam penelitian ini adalah jumlah transaksi penjualan paket data per jam.

Pra-Pemrosesan Data

Tahap pra-pemrosesan bertujuan meningkatkan kualitas dan struktur data sebelum digunakan dalam pemodelan. Data transaksi terlebih dahulu diagregasi ke dalam interval waktu per jam dan dilakukan pengecekan terhadap nilai hilang.

Selanjutnya, metode Seasonal-Trend Decomposition using Loess (STL) diterapkan pada variabel target untuk memisahkan komponen tren, musiman, dan residual. Dekomposisi ini bertujuan memperjelas struktur temporal data sehingga pola utama deret waktu dapat dipelajari secara lebih efektif oleh model prediksi. Ketiga komponen hasil dekomposisi tersebut kemudian digunakan sebagai fitur tambahan dalam proses pemodelan.

Variabel Penelitian dan Kategorisasi Input

Data dibagi secara time-based split ke dalam data pelatihan (training) dan pengujian (testing) untuk menjaga konsistensi temporal. Model dilatih dengan meminimalkan fungsi Quantile Loss pada beberapa nilai kuantil.

Kinerja model dievaluasi menggunakan metrik Quantile Risk (q-Risk) serta Mean Absolute Error (MAE) untuk menilai akurasi prediksi. Selain evaluasi numerik, analisis interpretabilitas dilakukan dengan mengamati bobot seleksi variabel dan pola attention yang

dihasilkan oleh model, sehingga faktor-faktor temporal yang dominan dapat diidentifikasi dan dianalisis secara kualitatif.

Arsitektur Temporal Fusion Transformer

Model prediksi yang digunakan dalam penelitian ini adalah Temporal Fusion Transformer (TFT), yang dirancang untuk peramalan multihorizon dengan tingkat interpretabilitas tinggi. Arsitektur TFT mengombinasikan Long Short-Term Memory (LSTM) sebagai pemroses sekuensial dengan mekanisme self-attention untuk menangkap ketergantungan temporal jangka panjang.

Komponen utama dalam arsitektur TFT meliputi Variable Selection Network untuk menentukan tingkat kepentingan masing-masing variabel, LSTM encoder-decoder untuk pemodelan sekuens, static enrichment untuk mengintegrasikan informasi statis, serta interpretable multi-head attention yang memungkinkan analisis kontribusi timestep historis terhadap hasil prediksi. Output model dihasilkan melalui quantile regression layer sehingga mampu memodelkan ketidakpastian prediksi secara probabilistik.

Skema Pelatihan dan Evaluasi Model

Data dibagi secara time-based split ke dalam data pelatihan (training) dan pengujian (testing) untuk menjaga konsistensi temporal. Model dilatih dengan meminimalkan fungsi Quantile Loss (QL) pada kuantil $q \in (0, 1)$, yang dirumuskan sebagai berikut:

$$QL_q(y, \hat{y}) = \max(q(y - \hat{y}), (q - 1)(y - \hat{y}))$$

Kinerja model dievaluasi menggunakan metrik Quantile Risk (q-Risk) serta Mean Absolute Error (MAE) untuk menilai akurasi prediksi. MAE digunakan untuk mengevaluasi akurasi titik dengan mengukur rata-rata selisih absolut antara nilai prediksi dan nilai aktual:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

Di mana y_i adalah nilai aktual penjualan paket data, $\hat{y}_i$ adalah nilai prediksi dari model, dan n adalah jumlah observasi. Sementara itu, untuk mengevaluasi rentang

ketidakpastian prediksi, Quantile Loss dinormalisasi menjadi metrik q-Risk agar dapat diinterpretasikan secara relatif terhadap total volume aktual penjualan:

$$q - Risk = \frac{2 \sum_i QL_q(y_i, \hat{y}_i)}{\sum_i |y_i|}$$

Selain evaluasi numerik, analisis interpretabilitas dilakukan dengan mengamati bobot seleksi variabel dan pola attention yang dihasilkan oleh model, sehingga faktor-faktor temporal yang dominan dapat diidentifikasi dan dianalisis secara kualitatif.

Metode pembandingan ARIMA

Sebagai pembandingan metode konvensional, penelitian ini menggunakan ARIMA musiman yang diimplementasikan melalui SARIMAX. Model baseline dibangun secara terpisah untuk setiap deret waktu sehingga karakteristik tiap series tetap terwakili pada proses pemodelan. Evaluasi baseline dilakukan menggunakan skema time-series cross-validation yang konsisten dengan skema evaluasi penelitian, agar tidak terjadi data leakage dan setiap fold tetap merepresentasikan prediksi terhadap data masa depan. Kinerja baseline diukur menggunakan Mean Absolute Error (MAE), kemudian performa dilaporkan dalam bentuk rata-rata MAE antar fold serta variasinya untuk menggambarkan stabilitas model.

Skema time-series cross-validation digunakan untuk memberikan gambaran stabilitas performa model pada berbagai periode pengujian. Hasil cross-validation pada baseline konvensional (ARIMA/SARIMAX) digunakan sebagai acuan pembandingan untuk menilai kelayakan pendekatan yang diusulkan. Dengan demikian, klaim efektivitas dan kelayakan metode usulan tidak hanya didasarkan pada satu kali pembagian data, tetapi juga mempertimbangkan variasi performa baseline pada beberapa fold evaluasi.


HASIL DAN PEMBAHASAN

Karakteristik Data Penjualan

Data yang digunakan dalam penelitian ini merupakan data transaksi penjualan paket data Telkomsel di wilayah Jawa Timur dengan periode pengamatan Januari hingga Juni 2024 dan resolusi waktu per jam. Fokus penelitian diarahkan pada lima jenis paket data dengan

volume transaksi tertinggi untuk memastikan kestabilan pola deret waktu dan menghindari permasalahan data yang terlalu jarang.

Analisis awal terhadap data menunjukkan bahwa pola penjualan bersifat fluktuatif dengan variasi yang signifikan pada skala harian dan mingguan. Lonjakan transaksi umumnya terjadi pada jam-jam tertentu serta pada akhir pekan, yang mengindikasikan adanya pola musiman yang kuat. Karakteristik ini menunjukkan bahwa pendekatan peramalan yang mampu menangkap dinamika temporal kompleks diperlukan.



Gambar 2. Visualisasi deret waktu penjualan per jam

Hasil Pra-Pemrosesan dan Dekomposisi STL

Tahap pra-pemrosesan dilakukan untuk meningkatkan kualitas data sebelum digunakan dalam proses pemodelan. Setelah agregasi data dan penanganan nilai hilang, metode Seasonal-Trend Decomposition using Loess (STL) diterapkan pada variabel target penjualan.

Tabel 1. Hasil dekomposisi STL

Date	Observed	Trend	Seasonal	Residual
2024-01-01 00:00:00	0	27,85	-27,98	0,13
2024-01-01 01:00:00	5	27,96	-30,74	7,77
2024-01-01 02:00:00	1	28,07	-28,57	1,50
2024-01-01 03:00:00	1	28,17	-27,81	0,63
2024-01-01 04:00:00	0	28,28	-27,89	-0,39

Hasil dekomposisi STL menunjukkan pemisahan yang jelas antara komponen tren, musiman, dan residual. Komponen tren menggambarkan kecenderungan umum penjualan selama periode observasi, sementara komponen musiman menunjukkan pola berulang yang konsisten pada interval harian dan mingguan. Komponen residual merepresentasikan variasi acak yang tidak dapat dijelaskan oleh tren maupun musiman.

Pemisahan ini membantu memperjelas struktur temporal data dan memberikan representasi fitur yang lebih informatif bagi model Temporal Fusion Transformer, sehingga diharapkan dapat meningkatkan akurasi prediksi.

Kinerja Model Temporal Fusion Transformer

Model Temporal Fusion Transformer dilatih menggunakan data latih dengan skema pembagian data berbasis waktu (time-based split). Evaluasi kinerja model dilakukan menggunakan metrik Mean Absolute Error (MAE) dan Quantile Risk (q-Risk) untuk mengukur akurasi serta kemampuan model dalam memprediksi ketidakpastian.

Tabel 2. Hasil evaluasi kinerja model TFT

MAE (<i>Mean Absolute Error</i>)	3.6941
Quantile Loss (<i>Average</i>)	1.2425
q-Risk (P10)	0.0595
q-Risk (P50 - Median)	0.1201
q-Risk (P90)	0.0627
q-Risk (<i>Average All</i>)	0.0808

Hasil evaluasi menunjukkan bahwa model TFT mampu menghasilkan prediksi penjualan jangka pendek dengan tingkat kesalahan yang relatif rendah. Nilai MAE sebesar 3.6941 dan q-Risk sebesar 0.0808 mengindikasikan bahwa model mampu mengikuti pola fluktuasi penjualan secara konsisten.

Perbandingan dengan Baseline ARIMA (SARIMAX)

Hasil evaluasi baseline ARIMA (SARIMAX) pada skema time-series cross-validation ditunjukkan pada Tabel 3 dan Tabel 4. Pada 8 fold evaluasi, baseline ARIMA menghasilkan MAE rata-rata sebesar 5,694 dengan standar deviasi 5,737 yang ditunjukkan pada Tabel 3.

Tabel 3. Ringkasan performa baseline ARIMA (SARIMAX)

Model	MAE mean	MAE std	N folds
ARIMA(SARIMAX)	5,694	5,737	8

Nilai deviasi yang relatif besar menunjukkan bahwa performa ARIMA tidak sepenuhnya stabil pada seluruh periode evaluasi. Hal ini terlihat pada Tabel 4, di mana fold pertama menghasilkan MAE 19,875013, jauh lebih tinggi dibanding fold lainnya yang berada pada kisaran sekitar 3,109 hingga 4,039. Variasi error antar fold ini mengindikasikan bahwa metode konvensional cenderung sensitif terhadap perubahan pola penjualan pada periode tertentu, sehingga kurang robust untuk dinamika penjualan yang fluktuatif.

Tabel 4. Nilai MAE baseline ARIMA (SARIMAX)

Model	fold	MAE
ARIMA(SARIMAX)	1	19,875013
ARIMA(SARIMAX)	2	3,664932
ARIMA(SARIMAX)	3	3,109245
ARIMA(SARIMAX)	4	3,748000
ARIMA(SARIMAX)	5	4,039820
ARIMA(SARIMAX)	6	3,956091
ARIMA(SARIMAX)	7	3,769517
ARIMA(SARIMAX)	8	3,395377

Untuk melihat konsistensi baseline pada kondisi data panel multi-klastrer, dilakukan analisis MAE baseline ARIMA per cluster seperti yang ditunjukkan pada Tabel 5. Hasil menunjukkan adanya perbedaan tingkat kesalahan antar wilayah. Cluster dengan MAE rata-rata terendah adalah BANYUWANGI (2,893), sedangkan MAE rata-rata tertinggi terdapat pada PONOROGO TRENGGALEK (9,116).

Selain perbedaan rerata, beberapa cluster juga menunjukkan variasi yang cukup besar antar fold, misalnya PONOROGO TRENGGALEK (12,385), MADURA (10,696), dan MADIUN (10,501). Temuan ini memperlihatkan bahwa performa ARIMA tidak seragam pada berbagai karakteristik cluster, sehingga baseline konvensional kurang robust untuk skenario peramalan penjualan yang heterogen antar wilayah.


Tabel 5. Ringkasan MAE baseline ARIMA (SARIMAX) per cluster

Cluster	MAE mean	MAE std	N folds
Banyuwangi	2.893638	2.343316	8
Situbondowoso	3.831729	3.584363	8
Tuban Bojonegoro	3.920426	3.843630	8
Jombang Mojokerto	4.035364	3.804563	8
Tulungagung	4.277606	4.537973	8
Kota Surabaya	4.758759	4.163286	8
Lamongan Gresik	4.852200	5.482484	8
Kota Probolinggo	5.432797	6.170117	8
Kediri	6.082722	6.629417	8
Malang	6.110580	4.819171	8
Sidoarjo Pasuruan	6.254406	6.776441	8
Madiun	7.652896	10.501220	8
Jember	7.983747	3.213163	8
Madura	8.217666	10.696009	8

Berdasarkan hasil baseline, ARIMA menunjukkan variasi error yang cukup besar antar periode evaluasi dan antar cluster. Kondisi ini menegaskan keterbatasan pendekatan konvensional dalam menangkap dinamika penjualan yang fluktuatif dan heterogen, terutama ketika pola dipengaruhi oleh komponen musiman, tren, dan faktor kalender. Variasi MAE baseline ARIMA antar fold menunjukkan bahwa metode konvensional memiliki sensitivitas terhadap perubahan pola pada periode tertentu. Oleh karena itu, ketika metode usulan menghasilkan error yang lebih rendah pada skenario evaluasi yang sama, hasil tersebut dapat dipandang sebagai indikasi bahwa pendekatan berbasis model modern lebih relevan dan layak diterapkan untuk peramalan penjualan pada data panel multi-klaster.

Analisis Prediksi terhadap Data Aktual

Perbandingan antara hasil prediksi model dengan data aktual menunjukkan bahwa model Temporal Fusion Transformer mampu menangkap pola penjualan secara akurat, baik pada periode normal maupun pada periode dengan lonjakan transaksi. Pola naik dan turun penjualan dapat diikuti dengan baik oleh model, meskipun pada beberapa titik ekstrem masih terdapat deviasi kecil.



Gambar 3. Perbandingan nilai aktual dan hasil prediksi penjualan

Hasil ini menunjukkan bahwa integrasi informasi historis, variabel temporal, serta komponen hasil dekomposisi STL memberikan kontribusi positif dalam meningkatkan kemampuan model dalam memprediksi dinamika penjualan jangka pendek.

Analisis Interpretabilitas Model

Salah satu keunggulan utama Temporal Fusion Transformer adalah kemampuannya dalam menyediakan interpretabilitas model. Analisis variable importance menunjukkan bahwa variabel historis penjualan serta komponen musiman hasil dekomposisi STL memiliki kontribusi terbesar terhadap hasil prediksi. Variabel kalender seperti jam dan hari dalam minggu juga memberikan pengaruh signifikan terhadap pembentukan prediksi.

Tabel 6. Bobot seleksi variabel dan attention model TFT

Nama Variabel	Skor Importance	Kontribusi (%)
cluster	21.322042	14.21
jumlah_terjual_center	20.496000	13.66
jumlah_terjual_scale	17.708147	11.81
jumlah_terjual	16.692118	11.13
relative_time_idx	12.726393	8.48
trend_stl	12.678770	8.45
hour	12.658747	8.44
ML4	11.459095	7.64
residual_stl	6.564823	4.38
time_idx	4.441592	2.96
day_of_week	4.139474	2.76
encoder_length	4.014716	2.68
seasonal_stl	2.801109	1.87

Selain itu, mekanisme attention pada model menunjukkan bahwa timestep historis tertentu memiliki pengaruh yang lebih dominan terhadap prediksi, khususnya pada periode dengan pola penjualan yang berulang. Hasil ini mengindikasikan bahwa model mampu mempelajari ketergantungan temporal jangka pendek secara efektif.

Hasil penelitian menunjukkan bahwa kombinasi metode STL dan Temporal Fusion Transformer efektif dalam memodelkan deret waktu penjualan paket data yang bersifat fluktuatif dan nonlinier. Dekomposisi STL membantu memisahkan struktur dasar data sehingga memudahkan model dalam mempelajari pola utama, sementara arsitektur TFT memungkinkan pemodelan multihorizon dengan tingkat interpretabilitas yang tinggi.

Dibandingkan dengan pendekatan statistik konvensional yang umumnya terbatas dalam menangkap pola kompleks, pendekatan ini lebih adaptif terhadap variasi temporal dan mampu memberikan wawasan tambahan terkait faktor-faktor yang memengaruhi penjualan. Dengan demikian, model yang diusulkan memiliki potensi untuk mendukung perencanaan dan pengambilan keputusan operasional berbasis data pada sektor telekomunikasi.

KESIMPULAN DAN REKOMENDASI

Penelitian ini berhasil mengimplementasikan model Temporal Fusion Transformer (TFT) berbasis Seasonal-Trend Decomposition using Loess (STL) untuk memprediksi penjualan jangka pendek paket data Telkomsel di wilayah Jawa Timur. Integrasi metode STL pada tahap pra-pemrosesan terbukti mampu memperjelas struktur temporal data melalui pemisahan komponen tren, musiman, dan residual, sehingga memperkaya representasi fitur yang digunakan dalam pemodelan.

Hasil evaluasi menunjukkan bahwa model TFT memiliki kinerja prediksi yang baik dengan nilai Mean Absolute Error (MAE) sebesar 3,6941 dan nilai Quantile Risk rata-rata sebesar 0,0808, yang mengindikasikan kemampuan model dalam menangkap fluktuasi penjualan secara akurat serta memodelkan ketidakpastian prediksi. Analisis visual antara data aktual dan hasil prediksi juga menunjukkan kesesuaian pola yang konsisten, baik pada periode normal maupun pada saat terjadi lonjakan transaksi.

Selain akurasi, keunggulan utama pendekatan ini terletak pada aspek interpretabilitas. Analisis variable importance dan mekanisme attention mengungkap bahwa variabel historis penjualan, komponen hasil dekomposisi STL, serta variabel kalender seperti jam dan hari dalam minggu merupakan faktor dominan yang memengaruhi hasil prediksi. Temuan ini memberikan wawasan yang bernilai bagi pengambil keputusan dalam memahami pola permintaan pelanggan.

Berdasarkan hasil evaluasi dan perbandingan terhadap baseline konvensional yang diuji menggunakan time-series cross-validation, pendekatan yang diusulkan menunjukkan potensi yang lebih baik untuk peramalan penjualan pada data panel multi-klaster. Dengan demikian, metode ini layak dipertimbangkan untuk digunakan pada skenario operasional.

REFERENSI

- Aditya Nugroho. (2023, September 11). DigiposAja! Sudah Dipakai 670 Ribu Reseller Telkomsel. RM.Id. <https://rm.id/baca-berita/ekonomi-bisnis/196299/sabet-penghargaan-best-in-future-of-customer-experience-digiposaja-sudah-dipakai-670-ribu-reseller-telkomsel>
- Amtul Wahab, Iffath Unnisa Begum, Baspally Babitha, Durgeshwari, Etlapur Renuka, & Rozeena Tahmeena. (2024). A Study on Inventory Management at D Mart. International Journal of Engineering Technology and Management Sciences, 8(2), 354–358. <https://doi.org/10.46647/ijetms.2024.v08i02.045>
- Andi Dwi Riyanto. (2024, February 21). Hootsuite (We are Social): Data Digital Indonesia 2024. <https://data.goodstats.id/statistic/4-provider-seluler-ri-dengan-pengguna-terbanyak-1Ne6i>
- APJII. (2023). Laporan Survei Internet APJII 2023. <https://apjii.or.id/berita/d/apjii-jumlah-pengguna-internet-indonesia-tembus-221-juta-orang>
- Baradie, S., Reddy, R., Lipps, C., & Schotten, H. D. (2022). Managing the Fifth Generation (5G) Wireless Mobile Communication: A Machine Learning Approach for Network Traffic Prediction. Mobile Communication - Technologies and Applications; 26th ITG-Symposium, 1–6.

- Bihan Mokodompit. (2025, August 24). Penetrasi Internet Jawa Timur Ada di Angka 82,19 Persen, Diskominfo Ingatkan Ancaman Serius Judi Online. <https://radartuban.jawapos.com/nasional/866474482/penetrasi-internet-jawa-timur-ada-di-angka-8219-persen-diskominfo-ingatkan-ancaman-serius-judi-online?page=2>
- Choirul Anam. (2024, April 1). Trafik Data Telkomsel dan Smartfren di Jatim, Bali, Nusa Tenggara Diproyeksi Naik Signifikan. Bisnis Indonesia. <https://surabaya.bisnis.com/read/20240401/531/1754512/trafik-data-telkomsel-dan-smartfren-di-jatim-bali-nusa-tenggara-diproyeksi-naik-signifikan>
- Deretić, N., Stanimirović, D., Al Awadh, M., Vujanović, N., & Djukić, A. (2022). SARIMA Modelling Approach for Forecasting of Traffic Accidents. Sustainability (Switzerland), 14(8). <https://doi.org/10.3390/su14084403>
- Indonesia, T. (2024). Laporan Keuangan Konsolidasian 2024. https://www.telkom.co.id/sites/hubungan-investor/id_ID/page/laporan-1025
- Izzul Wafa. (2025, August 15). Penetrasi Internet Indonesia Konsisten Naik, Tembus 80% pada 2025. GoodStats. <https://data.goodstats.id/statistic/penetrasi-internet-indonesia-konsisten-naik-tembus-80-pada-2025-jSGpJ>
- Sirisha, U. M., Belavagi, M. C., & Attigeri, G. (2022). Profit Prediction Using ARIMA, SARIMA and LSTM Models in Time Series Forecasting: A Comparison. IEEE Access, 10, 124715–124727. <https://doi.org/10.1109/ACCESS.2022.3224938>
- Suharno. (2025, August 11). ARPU Telkomsel dan Indosat Melambat di Semester I 2025. Selular.ID. <https://selular.id/2025/08/arpu-telkomsel-dan-indosat-melambat-di-semester-i-2025>
- Thomas Mola. (2025). Perbandingan ARPU dan Pelanggan Telkomsel vs Indosat. Bisnis.Com.<https://teknologi.bisnis.com/read/20250506/101/1874829/perbandingan-arpu-dan-pelanggan-telkomsel-vs-indosat>
- Türkmen, A. C., Januschowski, T., Wang, Y., & Cemgil, A. T. (2021). Forecasting intermittent and sparse time series: A unified probabilistic framework via deep

renewal processes. PLOS ONE, 16(11), e0259764.

<https://doi.org/10.1371/journal.pone.0259764>

Vishwakarma, S., & Solanki, Dr. S. C. (2022). Predicting sales during COVID using Machine Learning Techniques. International Journal for Research in Applied Science and Engineering Technology, 10(4), 2481–2489.
<https://doi.org/10.22214/ijraset.2022.41822>