

Peramalan Penjualan Kartu Layanan Internet Menggunakan Model Seq2Seq LSTM

Muhammad Rusydi Athaillah Akbar^{*1}, Dwi Arman Prasetya², Andri Fauzan Adziima³

¹²³Universitas Pembangunan Nasional “Veteran” Jawa Timur

¹²³Surabaya, Indonesia

Email: ¹22083010054@student.upnjatim.ac.id,

²arman.prasetya.sada@upnjatim.ac.id, ³andri.fauzan.fasilkom@upnjatim.ac.id

Abstract

This study proposes a sales forecasting model for internet service SIM card products using a Sequence-to-Sequence Long Short-Term Memory (Seq2Seq LSTM) architecture enhanced with an attention mechanism. The dataset used in this study consists of 144 monthly sales records spanning from January 2013 to December 2024. The research stages include data preprocessing, normalization, and splitting the dataset into training, validation, and testing sets. The model is trained using the AdamW optimizer and evaluated using RMSE, MAE, and MAPE metrics. The results show that the model achieves an RMSE of 47.65, MAE of 37.72, and MAPE of 8.79%, indicating accurate and stable predictive performance. The three-month forecasting results reveal an upward sales trend, demonstrating the model's ability to capture market patterns realistically. These findings provide valuable implications for the telecommunications industry, particularly in supporting strategic decision-making related to network capacity planning, sales target determination, and marketing campaign management.

Keywords: Deep learning, LSTM, Sales forecasting, Seq2Seq

Abstraksi

Penelitian ini mengusulkan model peramalan penjualan produk kartu layanan internet menggunakan arsitektur Sequence-to-Sequence Long Short-Term Memory (Seq2Seq LSTM) yang dilengkapi dengan attention mechanism. Dataset yang digunakan dalam penelitian ini berjumlah 144 data penjualan bulanan dengan rentang waktu dari Januari 2013 hingga Desember 2024. Tahapan meliputi pemrosesan data, normalisasi, serta pembagian data menjadi data latih, validasi, dan uji. Model dilatih menggunakan optimizer AdamW dan dievaluasi menggunakan metrik RMSE, MAE, dan MAPE. Hasil menunjukkan bahwa model memperoleh nilai RMSE sebesar 47.65, MAE sebesar 37.72, dan MAPE sebesar 8.79%, yang menandakan performa prediksi yang akurat dan stabil. Hasil peramalan tiga bulan ke depan menunjukkan tren peningkatan penjualan, mengindikasikan kemampuan model dalam menangkap pola pasar secara realistis. Temuan ini memberikan dampak bagi industri telekomunikasi, khususnya dalam mendukung pengambilan keputusan strategis terkait perencanaan kapasitas jaringan, penentuan target penjualan, dan pengelolaan kampanye pemasaran.

Kata Kunci: Deep learning, LSTM, Peramalan penjualan, Seq2Seq

1. PENDAHULUAN

Penjualan merupakan aspek penting dalam menjaga stabilitas dan pertumbuhan perusahaan, terutama pada industri layanan digital seperti penyedia internet. Persaingan yang semakin ketat, perubahan perilaku pelanggan, serta kebijakan promosi yang dinamis menyebabkan pola penjualan di sektor ini menjadi sangat fluktuatif dan sulit diprediksi. Kondisi tersebut menuntut perusahaan untuk memiliki kemampuan peramalan penjualan yang akurat guna mendukung strategi pemasaran, manajemen operasional, dan perencanaan pendapatan [1]. Berdasarkan data pada jurnal [2], jumlah pengguna internet di Indonesia mencapai 221,5 juta orang pada tahun 2024, menunjukkan besarnya potensi pasar layanan digital. Pertumbuhan pengguna internet yang signifikan ini semakin menegaskan pentingnya perusahaan memahami pola permintaan secara tepat agar tetap kompetitif dan responsif terhadap dinamika pasar.

Dalam industri penyedia layanan internet, prediksi penjualan memiliki peran strategis dalam menjaga efisiensi operasional dan mendukung pengambilan keputusan bisnis. Ketidakakuratan dalam memperkirakan permintaan dapat menyebabkan kelebihan kapasitas jaringan yang meningkatkan biaya operasional, atau sebaliknya, kekurangan kapasitas yang menurunkan kualitas layanan dan kepuasan pelanggan [3]. Selain itu, perencanaan stok kartu perdana, pengelolaan langganan pascabayar, serta strategi promosi juga sangat bergantung pada prediksi penjualan yang akurat.

Metode peramalan tradisional seperti *moving average*, analisis tren, dan regresi linier masih sering digunakan karena sederhana dan mudah diterapkan [4]. Namun, metode tersebut memiliki keterbatasan dalam menangkap pola non-linear dan dinamika kompleks pada data penjualan layanan internet, sehingga sering menghasilkan prediksi yang kurang akurat [5]. Pendekatan *machine learning* dan *deep learning* menjadi alternatif yang lebih adaptif karena mampu mengenali pola tersembunyi serta ketergantungan jangka panjang pada data deret waktu [6]. Salah satu arsitektur yang populer adalah *Long Short-Term Memory* (LSTM), yang memiliki kemampuan mempertahankan informasi historis melalui mekanisme memori internal [7]. LSTM telah terbukti menghasilkan performa lebih baik dibandingkan metode statistik klasik seperti ARIMA dalam berbagai kasus prediksi penjualan dan permintaan [8].

Namun demikian, model LSTM konvensional memiliki keterbatasan untuk melakukan *multi-step forecasting*, karena model sering menggunakan hasil prediksi sebelumnya sebagai input berikutnya, yang dapat menyebabkan akumulasi kesalahan. Untuk mengatasi hal tersebut, dikembangkan arsitektur *Sequence-to-Sequence* (Seq2Seq) berbasis LSTM yang terdiri dari dua komponen utama, yaitu *encoder* dan *decoder* [9]. Arsitektur ini mampu memetakan input dan output sequence dengan panjang yang berbeda, sehingga lebih efektif untuk peramalan multi-periode dengan pola data yang kompleks. Selain itu, integrasi mekanisme *attention* pada model Seq2Seq terbukti meningkatkan kemampuan model dalam menyoroti informasi penting dari data historis dan memperbaiki akurasi prediksi [10].

Model prediksi yang andal memungkinkan perusahaan untuk mengoptimalkan sumber daya dan merespons dinamika pasar dengan lebih cepat. Oleh karena itu, penerapan arsitektur Seq2Seq berbasis LSTM menjadi relevan karena mampu menangkap pola non-linear yang kompleks pada data penjualan dan menghasilkan peramalan multi-periode yang lebih stabil. Dengan demikian, penelitian ini memiliki urgensi tinggi dalam membantu provider internet untuk menyusun strategi penjualan yang tepat sasaran, serta mendukung pengambilan keputusan berbasis data.

2. TINJAUAN PUSTAKA

Bab ini membahas sejumlah teori dan penelitian terkait yang mendasari pelaksanaan penelitian ini. Teori dan penelitian terkait tersebut menjadi pijakan dalam memahami serta menganalisis permasalahan yang diteliti, sekaligus menjadi acuan dalam merancang metode yang digunakan.

2.1. Landasan Teori

Penjualan merupakan kegiatan pertukaran barang atau jasa antara pihak penjual dan pembeli dengan imbalan tertentu [11]. Aktivitas ini berperan penting dalam distribusi produk dari produsen ke konsumen serta menjadi sumber utama pendapatan perusahaan [12].

Dalam konteks penjualan, metode *deep learning* seperti *Long Short-Term Memory* (LSTM) memiliki kemampuan kuat dalam peramalan penjualan karena mampu mempelajari pola dan hubungan jangka panjang pada data deret waktu [13]. Untuk meningkatkan akurasi prediksi, arsitektur *Sequence-to-Sequence* (Seq2Seq) sering dikombinasikan dengan LSTM, di mana model memetakan urutan *input* menjadi urutan *output* yang fleksibel dan dapat menangani pola data yang kompleks [10]. Kombinasi LSTM Seq2Seq ini menjadikannya efektif dalam menghasilkan prediksi penjualan yang lebih adaptif dan akurat.

Pada penelitian ini, arsitektur Seq2Seq dibangun menggunakan LSTM pada bagian *encoder* dan *decoder* karena kemampuannya mempertahankan informasi jangka panjang serta mengatasi masalah *vanishing gradient* melalui mekanisme *cell state* dan *gate*. Pendekatan ini memungkinkan model memahami pola historis penjualan secara lebih mendalam dan menghasilkan prediksi yang lebih akurat.

2.2. Penelitian Terkait

Beberapa penelitian terdahulu telah mengembangkan model peramalan berbasis Seq2Seq LSTM untuk meningkatkan akurasi prediksi deret waktu. Tabel 1 merangkum penelitian-penelitian terkait yang memanfaatkan arsitektur Seq2Seq LSTM, termasuk studi yang berfokus pada peramalan penjualan maupun penelitian lain yang menggunakan pendekatan LSTM dalam pemodelan deret waktu.

Tabel 1. Penelitian terkait

No.	Profil Pustaka	Metode dan Temuan
1.	<p><i>A Multi-Step Time-Series Clustering-Based Seq2Seq LSTM Learning for a Single Household Electricity Load Forecasting</i> [14]</p> <p>Penulis: Zaki Masood, Rahma Gantassi, Ardiansyah, Yonghoon Choi</p> <p>Identitas artikel: Energies 2022, 15(7), 2623 https://doi.org/10.3390/en15072623</p>	<p>Penelitian ini menerapkan pendekatan <i>multi-step time-series</i> berbasis Seq2Seq LSTM yang dikombinasikan dengan K-means <i>clustering</i> menggunakan dataset ENERTALK, dengan fokus pada 2,1 juta sampel konsumsi listrik dari satu rumah tangga yang telah dipreproses dan di-<i>downsample</i> menjadi data per menit. Kinerja model dievaluasi menggunakan MAE, MAPE, dan RMSE serta dibandingkan dengan LSTM, GRU, RNN, dan BiLSTM. Hasil terbaik dicapai model Seq2Seq LSTM dengan <i>lookback</i> 60 langkah, menghasilkan MAE 35,1, MAPE 10,93%, dan RMSE 82,75. Penelitian ini masih terbatas pada pendekatan univariat dan hanya menggunakan data dari satu rumah tangga, sehingga peluang pengembangan mencakup perluasan ke data multivariat dan lingkup yang lebih besar.</p>
2.	<p><i>Short-time Series Load Forecasting By Seq2seqLSTM Model</i> [15]</p> <p>Penulis: Yongchao Cui, Bo Yin, Ruixue Li, Zehua Du, Mingquan Ding</p> <p>Identitas artikel: ITAIC 2020, 517-521, 10.1109/ITAIC49862.2020.9339110</p>	<p>Penelitian ini mengembangkan model peramalan beban jangka pendek menggunakan arsitektur Seq2Seq-LSTM yang dilengkapi residual LSTM, SDP <i>Attention</i>, dan FFNN untuk meningkatkan pemahaman konteks historis. Dataset ENTSO-E yang berisi 9.630 data beban listrik diproses melalui koreksi <i>bad</i> data, normalisasi, serta pembagian 80% data latih dan 20% data uji. Evaluasi menggunakan MSE, MAE, MAPE, dan RMSE menunjukkan bahwa model Seq2Seq-LSTM dengan residual dan SDP <i>Attention</i> mencapai performa terbaik, dengan peningkatan akurasi RMSE dibanding DBN, ANN, dan LSTM standar masing-masing sebesar 13.73%, 17.53%, dan 11.29%. Namun, model masih terbatas pada ketergantungan fitur cuaca dan kalender serta memiliki kompleksitas tinggi, sehingga pengembangan model yang lebih efisien dan generalis masih diperlukan.</p>
3.	<p><i>Sales Forecasting Based on Transformer-LSTM Model</i> [16]</p> <p>Penulis: Yi Liu</p> <p>Identitas artikel: CSIC 2023, 777-782, volume 85</p>	<p>Penelitian ini mengusulkan model peramalan penjualan berbasis Transformer-LSTM. Dataset berasal dari transaksi harian sebuah <i>bakery</i> di Kaggle (234.005 entri), yang diolah melalui agregasi harian, <i>first-order differencing</i>, normalisasi, dan <i>sliding window</i> empat hari. Evaluasi menggunakan RMSE menunjukkan bahwa Transformer-LSTM menjadi model terbaik dengan RMSE 0.091, jauh mengungguli LSTM dan regresi linier. Namun, penelitian ini masih terbatas pada fitur univariat, ukuran data yang relatif kecil, serta prediksi satu langkah, sehingga diperlukan pengembangan lebih lanjut untuk mendukung data <i>multifeature</i> dan peramalan <i>multi-step</i>.</p>
4.	<p>Prediksi Belanja Pemerintah Indonesia Menggunakan <i>Long</i></p>	<p>Penelitian ini menerapkan metode LSTM untuk memprediksi realisasi belanja pemerintah Indonesia dan membandingkannya dengan model ARIMA. Dataset yang digunakan berupa data</p>

Short-Term Memory (LSTM) [17] Penulis: Sabar Sautomo, Hilman Ferdinandus Pardede Identitas artikel: Jurnal Rekayasa Sistem dan Teknologi Informasi Vol. 5 No. 1 (2021) 99 - 106	historis harian selama 721 hari, yang melalui proses <i>cleaning</i> , <i>reduction</i> , normalisasi, serta pemilihan atribut berbasis <i>correlation coefficient</i> . Evaluasi menggunakan MSE, RMSE, MAE, dan MAPE menunjukkan bahwa LSTM dengan tiga <i>hidden layer</i> dan <i>selected attributes</i> menghasilkan performa terbaik (MSE 0.2325; RMSE 0.4820; MAE 0.3292; MAPE 0.4214), melampaui ARIMA. Keterbatasan penelitian ini terletak pada penggunaan data univariat dan tidak disertakannya faktor eksternal, sehingga pengembangan model multivariat dan penambahan variabel pendukung menjadi peluang penelitian lanjutan.
--	--

Berdasarkan penelitian-penelitian terkait pada Tabel 1, metode *deep learning* seperti Seq2Seq LSTM dan Transformer-LSTM terbukti mampu meningkatkan akurasi peramalan di berbagai domain. Namun, meskipun pendekatan *deep learning*, khususnya Seq2Seq LSTM, telah diterapkan pada peramalan beban listrik [14] dan sejumlah sektor lain [15], penerapannya pada penjualan kartu layanan internet yang memiliki karakteristik fluktuasi tinggi akibat promosi, perilaku pelanggan, dan dinamika kompetisi pasar masih sangat terbatas. Oleh karena itu, penelitian ini bertujuan untuk: (1) mengembangkan model Seq2Seq LSTM dengan *attention mechanism* untuk peramalan penjualan kartu layanan internet, (2) mengevaluasi akurasi model menggunakan metrik RMSE, MAE, dan MAPE, dan (3) melakukan peramalan penjualan tiga bulan ke depan. Dengan demikian, penelitian ini menempati posisi penting sebagai upaya memperluas penerapan Seq2Seq LSTM ke ranah penjualan layanan internet yang kompleks, sekaligus memberikan kontribusi empiris terhadap pengembangan model peramalan yang lebih adaptif dan akurat di industri telekomunikasi.

3. METODE PENELITIAN

Penelitian ini mengikuti serangkaian tahapan yang dirancang agar prosesnya berjalan secara sistematis dan terstruktur. Diagram alir yang ditampilkan pada Gambar 1 menggambarkan langkah-langkah analisis yang digunakan dalam penelitian ini.



Gambar 1. Diagram Alir Penelitian

1. Data Collecting

Tahap pertama yang dilakukan adalah pengumpulan data, yang menjadi dasar penting dalam proses analisis dan pembangunan model prediksi. Penelitian ini menggunakan data historis penjualan bulanan kartu layanan internet dari suatu perusahaan telekomunikasi mencakup 144 data dari Januari 2013 hingga Desember 2024. Data ini merepresentasikan karakteristik deret waktu (*time series*) yang sesuai untuk pemodelan berbasis urutan seperti LSTM. Kualitas data sangat menentukan kinerja

model, sehingga perlu dipastikan bebas dari kesalahan pencatatan, duplikasi, maupun nilai kosong sebelum memasuki tahap *preprocessing*.

2. Data Preprocessing

Tahap *preprocessing* data dilakukan setelah pengumpulan data untuk menyiapkan dataset agar siap digunakan dalam pelatihan dan pengujian model. Langkah utamanya adalah normalisasi data menggunakan *MinMaxScaler* yang mengubah nilai penjualan bulanan ke rentang 0–1 agar model LSTM dapat belajar lebih stabil dan efisien. Sebelum normalisasi, kolom “Date” dikonversi ke format *datetime* agar informasi waktu dapat diproses secara konsisten. Tahap ini penting untuk memastikan data bersih, terstruktur, dan siap digunakan dalam proses pemodelan berikutnya.

Selain *preprocessing*, dilakukan pula eksplorasi data awal (*Exploratory Data Analysis* / EDA) untuk memahami karakteristik dasar dari data penjualan. Eksplorasi data diawali dengan melakukan analisis statistik deskriptif untuk melihat distribusi nilai, rentang penjualan, serta kecenderungan umum selama periode observasi. Rata-rata penjualan bulanan juga dihitung untuk mengidentifikasi bulan dengan performa tertinggi maupun terendah, sehingga memberikan gambaran awal mengenai dinamika pasar sebelum data digunakan dalam proses pemodelan.

3. Data Splitting

Tahap *split* data dilakukan untuk membagi dataset menjadi beberapa bagian guna menilai kemampuan generalisasi model. Pada penelitian ini, data dibagi menjadi 70% data latih, 10% data validasi, dan 20% data uji. Pembagian 70:10:20 dipilih berdasarkan rekomendasi [18] untuk data *time series* dengan ukuran medium. Model LSTM dilatih menggunakan data penjualan dari periode sebelumnya, divalidasi untuk mengoptimalkan parameter, dan diuji pada periode selanjutnya untuk mengevaluasi performanya secara realistis. Langkah ini juga mencegah data *leakage*, sehingga hasil evaluasi benar-benar mencerminkan kemampuan prediktif model di kondisi nyata.

4. Model Building

Arsitektur LSTM memiliki tiga mekanisme utama, yaitu *forget gate*, *input gate*, dan *output gate*, yang mengatur aliran informasi melalui *cell state* sehingga model dapat menyimpan dan memperbarui informasi penting secara selektif, menjadikannya unggul dalam analisis deret waktu dan mampu mempelajari pola jangka panjang termasuk fluktuasi penjualan [13]. Untuk meningkatkan akurasi prediksi, LSTM sering dikombinasikan dengan arsitektur Seq2Seq, yaitu model *deep learning* yang memetakan urutan *input* menjadi urutan *output* dengan panjang berbeda [10]. Dalam alur kerjanya, Seq2Seq terdiri dari *encoder* yang menghasilkan *context vector* sebagai representasi ringkas dari seluruh urutan, dan *decoder* yang menggunakan *context vector* tersebut sebagai *initial state* untuk menghasilkan urutan *output* secara bertahap, memungkinkan model menangkap hubungan kompleks antar elemen data yang tidak mudah ditangani oleh metode tradisional.

Pada tahap Building Model, penelitian ini melatih arsitektur Seq2Seq LSTM yang dilengkapi *attention mechanism* menggunakan data penjualan bulanan yang telah dinormalisasi. Mekanisme *attention* berfungsi memfokuskan model pada bagian-bagian penting dari urutan *input*, sehingga proses peramalan menjadi lebih akurat dan stabil. Selama pelatihan, parameter seperti *epochs*, *batch size*, dan *loss function* disesuaikan untuk mencapai performa optimal, sementara *optimizer AdamW* digunakan untuk meningkatkan efisiensi pembelajaran dan membantu mengatasi permasalahan *vanishing gradient* [19]. Nilai *loss* dipantau secara berkala untuk mencegah *overfitting*, dan setelah model mencapai kinerja terbaik, bobot pelatihan disimpan agar dapat digunakan kembali pada proses peramalan tanpa perlu melakukan pelatihan ulang. Dengan alur kerja ini, sistem mampu menghasilkan prediksi penjualan yang lebih adaptif dan reliabel dalam konteks pasar layanan internet yang dinamis.

5. Model Evaluasi

Tahap akhir penelitian ini adalah evaluasi model untuk menilai kinerja prediksi terhadap data penjualan yang diuji. Evaluasi dilakukan menggunakan metrik MSE, RMSE, dan MAPE guna mengukur seberapa jauh hasil prediksi dari nilai aktual. Nilai yang lebih kecil pada ketiga metrik tersebut menunjukkan performa model yang lebih baik dan akurat. Tahap ini memastikan model yang dibangun mampu memberikan prediksi yang andal dan representatif terhadap data sebenarnya.

4. HASIL DAN PEMBAHASAN

4.1. Hasil Pembangunan Model

Berdasarkan proses pembangunan model yang telah dijelaskan sebelumnya, menghasilkan pembentukan arsitektur Seq2Seq LSTM dengan mekanisme *Attention* yang menjadi inti dari sistem peramalan penjualan ini. Arsitektur ini dirancang untuk mempelajari pola jangka panjang dari data historis penjualan kartu provider dan menghasilkan prediksi multi-step yang lebih akurat. Model menggabungkan kemampuan LSTM dalam menangkap ketergantungan temporal dengan keunggulan *Attention* yang memungkinkan fokus pada informasi penting di setiap langkah waktu [20]. Struktur detail model yang dibangun dapat dilihat pada Gambar 2.

Model: "functional_2"

Layer (type)	Output Shape	Param #	Connected to
input_layer_2 (InputLayer)	(None, 12, 4)	0	-
lstm_6 (LSTM)	(None, 12, 96)	38,784	input_layer_2[0]-
dropout_2 (Dropout)	(None, 12, 96)	0	lstm_6[0][0]
lstm_7 (LSTM)	(None, 96)	74,112	dropout_2[0][0]
repeat_vector_2 (RepeatVector)	(None, 3, 96)	0	lstm_7[0][0]
lstm_8 (LSTM)	(None, 3, 96)	74,112	repeat_vector_2[-
attention_2 (Attention)	(None, 3, 96)	0	dropout_2[0][0], lstm_8[0][0]
concatenate_2 (Concatenate)	(None, 3, 192)	0	lstm_8[0][0], attention_2[0][0]
time_distributed_2 (TimeDistributed)	(None, 3, 1)	193	concatenate_2[0]-

Total params: 187,201 (731.25 KB)
Trainable params: 187,201 (731.25 KB)
Non-trainable params: 0 (0.00 B)

Gambar 2. Struktur Model

Berdasarkan Gambar 2, arsitektur yang digunakan adalah model Seq2Seq LSTM dengan *attention mechanism*. Model menerima *input* berbentuk (12, 4), kemudian diproses oleh dua lapisan LSTM berisi 96 neuron yang mengekstraksi pola temporal, disertai *dropout* untuk mencegah *overfitting* dan *RepeatVector* untuk menyesuaikan representasi konteks bagi *decoder*. Pada bagian *decoder*, LSTM ketiga dengan 96 neuron menghasilkan urutan keluaran yang kemudian diperkuat oleh *Attention layer* agar model dapat fokus pada langkah waktu yang paling relevan. Hasil *attention* dan keluaran *decoder* digabungkan melalui *Concatenate*, menghasilkan representasi (3, 192), sebelum akhirnya diproyeksikan menjadi keluaran akhir melalui *TimeDistributed Dense*. Secara keseluruhan, model memiliki 187.201 parameter *trainable*, dengan kompleksitas yang dirancang untuk menangkap pola jangka panjang dan dinamika data penjualan, sehingga efektif untuk peramalan deret waktu *multi-step* seperti prediksi penjualan kartu layanan internet.

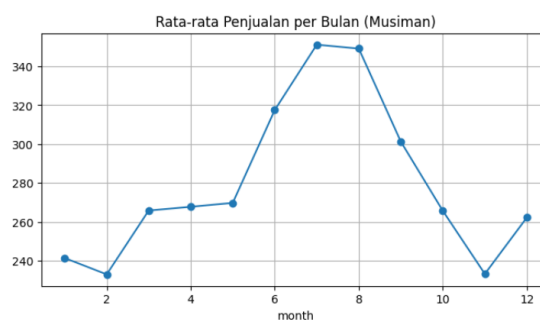
4.2. Hasil Eksplorasi Data/EDA

Pada tahap ini dijelaskan hasil eksplorasi data dengan menghitung statistik deskriptif serta rata-rata penjualan bulanan untuk mengidentifikasi pola musiman. Analisis ini bertujuan memberikan gambaran awal mengenai distribusi data, kecenderungan penjualan, serta fluktuasi yang terjadi setiap bulan, sehingga dapat membantu memahami karakteristik dasar dataset sebelum memasuki proses pemodelan. Hasil eksplorasi data dapat dilihat pada Tabel 2 dan Gambar 3.

Tabel 2. Hasil Statistika Deskripsi

Count	144.000000
Mean	279.819444
Standar Deviasi	120.332154
Min	103.000000
25%	180.500000
50%	269.500000
75%	352.250000
Max	637.000000

Berdasarkan Tabel 2, terdapat 144 data penjualan dengan nilai rata-rata sebesar 279,82 unit per bulan. Nilai standar deviasi yang cukup tinggi, yaitu 120,33, menunjukkan bahwa penjualan mengalami variasi yang signifikan antarperiode. Nilai minimum sebesar 103 dan maksimum mencapai 637 mencerminkan rentang penjualan yang cukup lebar. Sementara itu, nilai kuartil pertama (180,5), median atau kuartil kedua (269,5), dan kuartil ketiga (352,25) menunjukkan bahwa sebagian besar data berada dalam rentang tersebut, dengan kecenderungan penjualan cenderung meningkat pada kuartil atas. Secara keseluruhan, statistik ini menunjukkan bahwa pola penjualan bersifat fluktuatif dan memiliki dinamika yang cukup tinggi, sehingga relevan untuk dianalisis lebih lanjut menggunakan model peramalan deret waktu.



Gambar 3. Hasil Visualisasi Pola Musiman Bulanan

Berdasarkan Gambar 3, terlihat adanya pola musiman yang cukup jelas sepanjang tahun. Penjualan cenderung berada pada tingkat yang lebih rendah pada awal tahun, khususnya pada bulan Februari. Memasuki bulan Maret hingga Juni, penjualan mulai meningkat secara bertahap, kemudian mencapai puncaknya pada bulan Juli dan Agustus sebagai periode dengan rata-rata penjualan tertinggi. Setelah itu, terjadi penurunan yang cukup signifikan mulai bulan September hingga mencapai titik terendah kembali pada November, sebelum naik kembali pada Desember. Pola ini menunjukkan bahwa penjualan memiliki siklus musiman yang kuat, dengan periode pertengahan tahun sebagai fase puncak dan akhir tahun sebagai fase penurunan.

4.3. Hasil Evaluasi Model

Evaluasi model dilakukan untuk mengukur performa dan kemampuan generalisasi model yang telah dibangun. Gambar 3 menampilkan hasil *training* yang menunjukkan penurunan nilai *loss* pada data pelatihan dan validasi sebagai indikator kestabilan dan akurasi model Seq2Seq LSTM dalam memprediksi penjualan kartu provider.

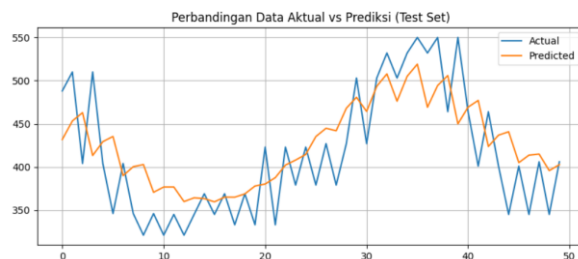
Gambar 4. Grafik *Training Loss* dan *Validasi Loss*

Gambar 3 menunjukkan grafik *Training Loss* dan *Validation Loss* selama proses pelatihan model Seq2Seq LSTM dengan mekanisme *Attention*. Berdasarkan grafik tersebut, terlihat bahwa nilai *loss* pada data pelatihan (*Train Loss*) dan data validasi (*Val Loss*) mengalami penurunan yang signifikan seiring bertambahnya *epoch*, terutama pada tahap awal pelatihan. Setelah sekitar *epoch* ke-10, kedua kurva mulai stabil dan mendekati nilai yang sangat kecil, menandakan bahwa model telah mencapai konvergensi dan mampu belajar pola data dengan baik. Nilai *validation loss* yang mengikuti pola *training loss* tanpa menunjukkan peningkatan berarti juga mengindikasikan bahwa model tidak mengalami *overfitting*. Secara keseluruhan, hasil ini menunjukkan bahwa model yang dibangun memiliki performa pelatihan yang baik, stabil, dan mampu melakukan generalisasi dengan efektif terhadap data yang belum pernah dilihat sebelumnya.

Tabel 3. Hasil Evaluasi Matriks

RMSE	47.65
MAE	37.72
MAPE	8.79%

Berdasarkan Tabel 1, hasil evaluasi menunjukkan bahwa model Seq2Seq LSTM memiliki nilai RMSE sebesar 47.65, MAE sebesar 37.72, dan MAPE sebesar 8.79%. Nilai RMSE dan MAE yang relatif kecil menunjukkan bahwa selisih antara nilai prediksi dan nilai aktual cukup rendah, menandakan model mampu menghasilkan prediksi yang mendekati data sebenarnya. Sementara itu, nilai MAPE di bawah 10% mengindikasikan tingkat akurasi yang tinggi, karena kesalahan rata-rata prediksi terhadap nilai aktual tergolong kecil [21]. Secara keseluruhan, hasil ini membuktikan bahwa model mampu mempelajari pola penjualan dengan baik dan memiliki performa prediksi yang stabil serta andal. Hal ini juga dapat dilihat pada Gambar 4 yang menunjukkan grafik perbedaan nilai prediksi dan aktual.



Gambar 5. Grafik Perbandingan Nilai Aktual dan Prediksi

Gambar 5 menunjukkan perbandingan antara data aktual dan hasil prediksi model pada data uji (*test set*). Terlihat bahwa garis prediksi (warna oranye) mengikuti pola data aktual (warna biru) dengan cukup baik, terutama pada tren naik dan turun yang signifikan. Meskipun terdapat sedikit deviasi pada beberapa titik, secara keseluruhan model mampu menangkap pola fluktuasi penjualan dengan akurat. Hal ini menunjukkan bahwa model Seq2Seq LSTM yang dibangun memiliki kemampuan generalisasi yang baik dalam memprediksi penjualan berdasarkan data historis, dengan kesalahan prediksi yang relatif kecil dan pergerakan yang konsisten terhadap nilai sebenarnya.

4.4. Hasil Prediksi Model

Setelah model dievaluasi dan menunjukkan performa yang baik, model tersebut digunakan untuk melakukan peramalan (*forecasting*) penjualan untuk tiga bulan ke depan. Proses prediksi ini dimulai dengan menggunakan data penjualan dari 12 bulan terakhir yang tersedia dalam dataset sebagai *input* awal. Gambar 5 menampilkan hasil prediksi model dalam bentuk grafik.



Gambar 6. Hasil Prediksi dalam Bentuk Grafik

Gambar 6 menunjukkan hasil prediksi penjualan kartu layanan internet untuk tiga bulan ke depan menggunakan model Seq2Seq LSTM, di mana garis biru merepresentasikan data historis 24 bulan terakhir dan titik oranye menunjukkan proyeksi untuk Januari hingga Maret 2025. Model berhasil memperkirakan adanya tren peningkatan yang konsisten setelah penurunan pada akhir 2024, dengan prediksi sekitar 452 unit pada Januari, meningkat menjadi 474 unit pada Februari, dan mencapai 497 unit pada Maret 2025. Tren kenaikan ini menunjukkan potensi pertumbuhan positif pada awal tahun dan mencerminkan kemampuan model dalam menangkap dinamika musiman serta pola jangka pendek secara akurat. Hasil ini sekaligus menegaskan bahwa model Seq2Seq

LSTM mampu memberikan proyeksi penjualan yang realistis dan dapat menjadi acuan dalam perencanaan strategi perusahaan.

5. KESIMPULAN

Penelitian ini berhasil mengembangkan model Seq2Seq LSTM dengan *attention mechanism* untuk peramalan penjualan kartu layanan internet dan mencapai akurasi tinggi dengan nilai RMSE 47.65, MAE 37.72, dan MAPE 8.79%, menunjukkan kemampuan model dalam menangkap pola kompleks serta menghasilkan *forecasting* tiga bulan ke depan dengan tren yang realistis. Kontribusi penelitian ini mencakup penerapan arsitektur Seq2Seq LSTM dengan *attention* pada domain penjualan kartu layanan internet yang masih jarang dieksplorasi, validasi performa model yang dapat dijadikan pembandingan bagi metode *baseline*, serta penyusunan *framework* peramalan yang berpotensi diimplementasikan sebagai *decision support system* bagi perusahaan telekomunikasi. Meskipun demikian, penelitian ini memiliki keterbatasan karena hanya menggunakan variabel tunggal sehingga belum mempertimbangkan faktor eksternal seperti promosi atau dinamika pasar yang dapat memengaruhi penjualan. Oleh karena itu, penelitian selanjutnya disarankan mengembangkan model multivariat dengan memasukkan variabel eksternal serta mengeksplorasi arsitektur lain seperti Transformer atau Temporal Fusion Transformer untuk meningkatkan akurasi prediksi.

DAFTAR PUSTAKA

- [1] F. Wang and J. Aviles, "Enhancing Operational Efficiency : Integrating Machine Learning Predictive Capabilities in Business Intelligence for Informed Decision - Making," vol. 9, no. 1, pp. 1–5, 2023.
- [2] N. Maisaroh, U. Raden Intan Lampung, A. Habibi, and M. Iqbal, "Growth Trends of Internet Users and E-commerce in Increasing Economic Growth in Indonesia," *J. Ekon. Pembang.*, vol. 13, no. 3, pp. 41–50, 2024, [Online]. Available: <https://jurnal.feb.unila.ac.id/index.php/jep/article/view/3868>
- [3] P. Nga Tran, B. Dwi Cahyanto, and A. Timm-Giel, "Network planning for stochastic traffic demands," *Lect. Notes Inst. Comput. Sci. Soc. Telecommun. Eng. LNICST*, vol. 125 LNICST, pp. 216–227, 2013, doi: 10.1007/978-3-319-04277-0_17.
- [4] F. R. N Zardi, Rasyidah, "Perbandingan Metode Single Exponential Smoothing dan Single Moving Average Dalam Memprediksi Kebutuhan Persediaan Barang," *J. Comput.*, vol. 4, no. 3, pp. 265–273, 2024.
- [5] B. Laksma Pradana, "Time Series Forecasting of LQ45 Stock Index Using ARIMA: Insights and Implications," *J. Manag. Account. Bus. Res.*, vol. 1, no. 1, pp. 27–40, 2025, doi: 10.51170/jmabr.v4i.1.160.
- [6] G. Ciaburro and G. Iannace, "Machine learning-based algorithms to knowledge extraction from time series data: A review," *Data*, vol. 6, no. 6, 2021, doi: 10.3390/data6060055.
- [7] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," *Neural Comput.*,

- vol. 9, no. 8, pp. 1735–1780, 1997, doi: 10.1162/neco.1997.9.8.1735.
- [8] Y. Angraini *et al.*, “Comparative Analysis of ARIMA and LSTM Methods for Sea Surface Temperature Forecasting in the Sunda Strait,” *J. Mat. Stat. dan Komputasi*, vol. 21, no. 3, pp. 868–885, 2025, doi: 10.20956/j.v21i3.42565.
- [9] I. Sutskever, O. Vinyals, and Q. V. Le, “Sequence to sequence learning with neural networks,” *Adv. Neural Inf. Process. Syst.*, vol. 4, no. January, pp. 3104–3112, 2014.
- [10] K. Kondo, “Sequence to Sequence with Attention for Influenza Prevalence Prediction using Google Trends,” pp. 2–8.
- [11] D. Tr. Resti Misra Aini, “Analisis Sistem Informasi Akuntansi Penjualan Dalam Menunjang Efektivitas Pengendalian Internal Pada Cv. Surya Kuantan Singingi,” *Anal. Sist. Inf. Akunt. Penjualan Dalammenunjang Ef. Pengendali. Intern. Pada Cv. Surya Kuantan Singingi*, vol. Vol. 8, no. No. 1, p. h. 193-207, 2019, [Online]. Available: <http://www.ejournal.uniks.ac.id/index.php/PERAK/article/view/584>
- [12] F. Djoharam, “Analisis Sistem Informasi Akuntansi Penerimaan Kas dan Pengeluaran Kas,” *J. EMBA*, vol. 9, no. 2, pp. 668–667, 2021.
- [13] A. I. Sari, D. P. Hapsari, H. F. R. Wibowo, C. N. Putri, G. V. F. Lande, and E. B. Aldero, “Implementasi Algoritma Pengklasifikasi Long Short–Term Memory (LSTM) untuk Data Time Series,” *Pros. Semin. Nas. Tek. Elektro, Sist. Informasi, dan Tek. Inform. V*, vol. 5, pp. 653–666, 2025, doi: 10.31284/p.snestik.2025.7034.
- [14] Z. Masood and R. Gantassi, “Learning for a Single Household Electricity Load Forecasting,” 2022.
- [15] Y. Cui, B. Yin, R. Li, Z. Du, and M. Ding, “Short-time Series Load Forecasting By Seq2seq- LSTM Model,” vol. 2020, pp. 517–521, 2020.
- [16] Y. Liu, “Sales Forecasting Based on Transformer-LSTM Model,” *Highlights Sci. Eng. Technol.*, vol. 85, pp. 776–782, 2024, doi: 10.54097/qdavzg31.
- [17] S. Sautomo and H. F. Pardede, “Prediksi Belanja Pemerintah Indonesia Menggunakan Long Short-Term Memory (LSTM),” *J. RESTI*, vol. 5, no. 1, pp. 99–106, 2021, doi: 10.29207/resti.v5i1.2815.
- [18] V. K. Yalavarthi, R. Scholz, S. Born, and L. Schmidt-Thieme, “Probabilistic Forecasting of Irregular Time Series via Conditional Flows,” 2024, [Online]. Available: <http://arxiv.org/abs/2402.06293>
- [19] I. Loshchilov and F. Hutter, “Decoupled weight decay regularization,” *7th Int. Conf. Learn. Represent. ICLR 2019*, 2019.
- [20] D. Bahdanau, K. H. Cho, and Y. Bengio, “Neural machine translation by jointly learning to align and translate,” *3rd Int. Conf. Learn. Represent. ICLR 2015 - Conf. Track Proc.*, pp. 1–15, 2015.
- [21] M. Azman Maricar, “Analisa Perbandingan Nilai Akurasi Moving Average dan Exponential Smoothing untuk Sistem Peramalan Pendapatan pada Perusahaan XYZ,” *J. Sist. dan Inform.*, pp. 1–10, 2019.