

Penerapan Long Short-Term Memory (LSTM) untuk Peramalan Keuntungan Usaha PT. Air Suci Pragaan Kabupaten Sumenep

Abd Kafi Al Madani¹, Masdukil Makruf², Bakir³

^{1,2,3}Teknik Informatika, Fakultas Teknik, Universitas Islam Madura (UIM)

kafialmadany@gmail.com, masdukil.makruf@uim.ac.id, bakir.madura@gmail.com

ABSTRAK

Penelitian ini bertujuan untuk memprediksi keuntungan usaha PT. Air Suci Pragaan di Kabupaten Sumenep dengan menerapkan metode Long Short-Term Memory (LSTM), salah satu teknik deep learning yang efektif dalam mengolah data deret waktu. Data penelitian mencakup variabel penjualan, produksi, distribusi, dan biaya pada periode 2023–2024. Proses penelitian meliputi tahap praproses data, perhitungan keuntungan, normalisasi, serta pemisahan data menjadi set pelatihan dan pengujian. Arsitektur model LSTM yang digunakan terdiri atas dua lapisan tersembunyi dan satu lapisan keluaran, yang dilatih dengan dataset terolah. Evaluasi model menghasilkan tingkat kesalahan yang relatif rendah (MAE: 0,3307) serta prediksi keuntungan untuk 12 bulan mendatang yang menunjukkan variasi namun tetap masuk akal. Temuan ini mengindikasikan bahwa LSTM berpotensi menjadi metode yang andal dalam memproyeksikan kondisi finansial perusahaan serta mendukung pengambilan keputusan bisnis berbasis data historis.

Kata kunci: LSTM, forecasting keuntungan usaha, deep learning, analisis deret waktu, PT. Air Suci Pragaan

ABSTRACT

This study aims to forecast the business profit of PT. Air Suci Pragaan in Sumenep Regency using the Long Short-Term Memory (LSTM) method, a deep learning technique well-suited for time series data analysis. The dataset includes variables of sales, production, distribution, and costs during the period of 2023–2024. The research procedure involved data preprocessing, profit calculation, normalization, and splitting into training and testing sets. The LSTM model employed consists of two hidden layers and one output layer, trained on the processed dataset. Model evaluation demonstrated a relatively low error rate (MAE: 0.3307), while the profit forecast for the next 12 months showed diverse yet realistic results. These findings indicate that LSTM can serve as a reliable tool for predicting a company's financial condition and support data-driven business decision-making.

Keywords: LSTM, profit prediction, deep learning, time series, PT. Air Suci Pragaan

PENDAHULUAN

Perusahaan merupakan suatu bentuk usaha yang didirikan dengan tujuan menghasilkan produk atau menyediakan layanan. Orientasi utamanya adalah memenuhi kebutuhan konsumen, memperoleh keuntungan, serta memberikan nilai tambah bagi masyarakat [1]. Agar tetap berkembang dan beroperasi secara optimal, perusahaan perlu melakukan analisis yang efektif dalam pengelolaan operasional serta memanfaatkan peluang yang ada [2]. Kemajuan teknologi informasi yang terus berkembang juga memberikan pengaruh

signifikan terhadap berbagai aspek kehidupan, termasuk dalam hal pengelolaan pendapatan dan pengeluaran usaha [3]. Oleh karena itu, perencanaan keuangan perusahaan membutuhkan peramalan yang akurat agar arus keluar-masuk dana dapat berjalan dengan baik [4].

Pada era teknologi modern saat ini, pengelolaan keuangan semakin kompleks, sebagaimana yang terjadi pada data keuangan PT. Air Suci Pragaan di Kabupaten Sumenep. Kondisi tersebut menuntut adanya metode yang mumpuni untuk menganalisis sekaligus

meramalkan arus keuangan dengan lebih tepat [5]. Salah satu pendekatan yang sering digunakan dalam peramalan adalah metode time series, karena hasil prediksinya dinilai cukup handal dalam mendukung pengambilan keputusan. Di antara berbagai metode, deep learning menjadi populer berkat kemampuannya dalam mengenali pola data yang kompleks. Salah satu algoritma deep learning yang terbukti efektif adalah Long Short-Term Memory (LSTM) [6].


Penelitian terdahulu telah banyak membahas penerapan LSTM dalam berbagai bidang. Misalnya, Agus Triyadi et al, (2024) [7]. menunjukkan bahwa model LSTM mampu memprediksi harga bawang merah kering di Wonosobo dengan tingkat akurasi yang baik. Namun, M. Imam Budi Laksamana et al. (2021) [8]. melaporkan bahwa LSTM memiliki keterbatasan akurasi dalam memprediksi jumlah kunjungan wisata di Kabupaten Lombok Barat. Sementara itu, Puteri et al. (2024) [9]. membandingkan metode Decision Tree dengan deep learning. pada prediksi nilai akademik, dan hasilnya menunjukkan bahwa Decision Tree memberikan performa yang lebih unggul dalam konteks tersebut.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengimplementasikan metode deep learning LSTM berbasis time series dalam menganalisis serta memprediksi pendapatan dan pengeluaran PT. Air Suci Pragaan [10]. Hasil penelitian diharapkan tidak hanya mendukung pengelolaan keuangan perusahaan, tetapi juga memberikan kontribusi terhadap pengembangan teknologi dan ilmu pengetahuan, khususnya dalam bidang analisis keuangan di Indonesia. Penerapan teknologi deep learning diyakini mampu meningkatkan efisiensi, akurasi, dan kecepatan dalam pengambilan keputusan, yang pada akhirnya berpotensi mendorong pertumbuhan ekonomi secara lebih luas.

METODOLOGI PENELITIAN

Penelitian ini menerapkan pendekatan “eksperimen kuantitatif” dalam pengembangan model peramalan pendapatan dan pengeluaran usaha dengan memanfaatkan metode Deep Learning Long Short-Term Memory (LSTM).

Metode LSTM termasuk salah satu teknik yang digunakan dalam klasifikasi pada bidang data mining. Tahapan penelitian yang dilakukan dapat dilihat pada Gambar 1 berikut.



Gambar 1. Tahapan Penelitian

2.1. Pengumpulan Data

Penelitian ini dilaksanakan melalui beberapa tahapan, dimulai dengan proses pengumpulan data. Pada tahap awal, data diperoleh dari laporan keuangan PT. Air Suci. Selanjutnya, data tersebut diubah ke dalam format XLSX (Microsoft Excel), yaitu format digital yang memudahkan pengolahan serta analisis data secara lebih efektif menggunakan bahasa pemrograman Python. Konversi ini dilakukan untuk meningkatkan efisiensi sekaligus menyederhanakan proses analisis terhadap data keuangan yang tersedia [3].

2.2. Pemrosesan Data

Setelah seluruh data berhasil dikumpulkan dan diidentifikasi, tahap selanjutnya adalah melakukan proses pengolahan data. Langkah ini memiliki peran krusial dalam pembangunan model LSTM, sebab kualitas hasil peramalan sangat dipengaruhi oleh bagaimana data diproses. Pada tahap awal, dilakukan pembersihan data dari kesalahan maupun kekosongan, penyeragaman skala nilai agar konsisten, serta konversi format data supaya lebih mudah dianalisis [10].

2.2.1. Pembersihan Data

Proses pembersihan data dilakukan untuk memastikan bahwa data yang digunakan benar-benar relevan dan memiliki kualitas yang baik. Pada tahap ini, data diperiksa dan diperbaiki dari berbagai permasalahan, seperti adanya nilai yang hilang (missing value), data kosong (null value), maupun ketidakkonsistenan (noise) [4].

2.2.2. Transformasi Data

Pada tahap ini, data yang telah dikumpulkan dihitung nilai keuntungannya berdasarkan selisih antara hasil produksi dan biaya, sehingga data yang diperoleh sesuai dengan kebutuhan pemrosesan oleh model LSTM. Selanjutnya, data dilakukan proses normalisasi agar berada pada skala atau rentang yang seragam, sehingga memudahkan model dalam mempelajari pola dengan lebih efektif dan akurat.

Metode normalisasi yang diterapkan dalam penelitian ini adalah Min-Max Scaling, dengan memanfaatkan library Python, yaitu scikit-learn melalui fungsi MinMaxScaler. Perubahan nilai pada Min-Max Scaling dapat ditentukan menggunakan persamaan berikut:

$$X' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Keterangan:

x' = nilai hasil normalisasi
 x = nilai asli yang akan dinormalisasi
 x_{min} = nilai minimum dari suatu variabel
 x_{max} = nilai maksimum dari suatu variabel

Dengan demikian, x' merupakan nilai baru yang diperoleh dari proses normalisasi, sementara x adalah data mentah sebelum dinormalisasi. Adapun x_{max} dan x_{min} masing-masing merepresentasikan nilai tertinggi dan terendah dari keseluruhan data yang digunakan [9].

2.2.3. Pembagian Dataset Pelatihan dan Pengujian

Setelah data selesai diproses, tahap berikutnya adalah melakukan pemisahan dataset menjadi dua kelompok, yaitu data pelatihan (training data) dan data pengujian (testing data). Pembagian ini bertujuan untuk memastikan model dapat dilatih secara optimal sekaligus dievaluasi tingkat akurasi. Dalam penelitian ini, dataset berjumlah 24 data yang dibagi menjadi dua proporsi, yakni 80% untuk pelatihan dan 20% untuk pengujian. Artinya, dari total 24 data, sebanyak 19 data digunakan dalam proses pelatihan model, sedangkan 5 data sisanya dipakai sebagai data pengujian [6].

2.3. Pemilihan Atribut

Untuk memperoleh hasil peramalan yang akurat, salah satu tahap krusial adalah pemilihan atribut (variabel atau fitur) yang relevan serta memiliki pengaruh signifikan terhadap proses prediksi. Pemilihan atribut yang tepat dapat meningkatkan performa model dengan cara mengurangi noise serta memusatkan perhatian pada variabel yang benar-benar berkontribusi terhadap hasil yang dituju. Pada penelitian ini, dataset mencakup lima atribut utama, yakni Produksi, Distribusi, Penjualan, dan Biaya pada periode 2023–2024. Atribut-atribut tersebut dipilih karena dianggap memiliki keterkaitan langsung dengan tujuan peramalan [11]. Pemilihan yang cermat ini dilakukan agar model tidak hanya memproses informasi yang kurang relevan, tetapi juga mampu mengoptimalkan hasil prediksi dengan memanfaatkan atribut yang paling berpengaruh terhadap variabel target.

2.4. Long Short-Term Memory (LSTM)

Dalam penelitian ini digunakan model jaringan saraf Long Short-Term Memory (LSTM) untuk memprediksi keuntungan bulanan berdasarkan data pendapatan. Setiap komponen pendapatan dianalisis secara terpisah. Data pendapatan bulanan yang telah dikumpulkan kemudian dihitung selisih antar bulannya, sehingga dapat diproses lebih lanjut menggunakan model LSTM.

2.5. Evaluasi Model

Proses peramalan dilakukan pada data uji (testing), kemudian hasil prediksi dibandingkan dengan data aktual untuk mengukur tingkat kesalahan model. Evaluasi performa dilakukan menggunakan tiga metrik utama, yaitu Mean Absolute Error (MAE) [10].

2.5.1. Mean Absolute Error (MAE)

Mean Absolute Error (MAE) berfungsi untuk mengetahui rata-rata perbedaan antara hasil prediksi dengan data aktual. Metode ini mengukur tingkat kesalahan tanpa memperhatikan arah deviasi (baik positif maupun negatif), karena seluruh selisih dikonversi menjadi nilai absolut. Rumus perhitungannya dapat dituliskan sebagai berikut:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2)$$

Keterangan:

n = jumlah data keseluruhan

y_i = nilai aktual

\hat{y}_i = nilai prediksi

Pada persamaan MAE, n menunjukkan total data yang digunakan, y_i merepresentasikan nilai sebenarnya, sedangkan \hat{y}_i menggambarkan nilai hasil prediksi. Nilai MAE yang semakin kecil menandakan bahwa model memiliki kemampuan peramalan yang lebih baik [4].

2.6. Tools

Dalam penelitian ini, digunakan beberapa alat bantu untuk memudahkan dalam membangun model LSTM. Berikut ini adalah penjelasan dari masing-masing alat yang digunakan.

HASIL DAN PEMBAHASAN

3.1 Pengumpulan Data

Dataset yang digunakan dalam penelitian ini terdiri dari empat variabel utama, yaitu penjualan, produksi, distribusi, serta biaya (pengeluaran) pada periode tahun 2023 hingga 2024, dengan jumlah total 24 entri data. Ilustrasi dataset dapat dilihat pada Gambar 2. Selanjutnya, data tersebut akan melalui tahap preprocessing agar diperoleh informasi berupa keuntungan yang berasal dari penjualan, produksi, distribusi, dan biaya selama periode 2023–2024.

	Jumlah	Bulan	Tahun	Produksi	Distribusi	Penjualan	Biaya
0	Total	1	2023	13122	13868	166312000	133876362
1	Total	2	2023	12029	8880	125271000	112627836
2	Total	3	2023	13239	10503	168764600	189013906
3	Total	4	2023	8354	10426	131780500	99530536
4	Total	5	2023	21941	21541	233037000	239829322
5	Total	6	2023	19529	18704	196839200	211091296
6	Total	7	2023	23608	23165	257588000	266280272
7	Total	8	2023	19109	20389	197612000	194789368
8	Total	9	2023	22487	21250	238977000	265030678
9	Total	10	2023	25588	27216	330050000	276001510
10	Total	11	2023	24039	24870	280303000	389677335
11	Total	12	2023	24507	23762	245615500	184160700
12	Total	1	2024	27425	27113	297311500	247852460
13	Total	2	2024	25461	26165	308662900	355736582

Gambar 2. Semua Data

3.2. Pemrosesan Data

Proses preprocessing memegang peranan penting dalam penelitian ini. Data yang telah dikumpulkan terlebih dahulu disiapkan secara optimal agar dapat diolah dengan lebih efektif melalui serangkaian langkah berikutnya.

3.2.1. Pembersihan Data

Langkah awal dalam preprocessing adalah pembersihan data. Pada tahap ini, data yang duplikat dihapus, data kosong (missing values) ditangani, serta data yang menyimpang (outlier) diperiksa dan disesuaikan. Selain itu, data difokuskan hanya pada keuntungan yang berasal dari penjualan, produksi, distribusi, dan biaya selama periode 2023 hingga 2024. Proses ini dilakukan dengan memanfaatkan library Pandas.

3.2.2. Transformasi Data

Pada tahap ini, data yang telah dikumpulkan diolah dengan menghitung keuntungan yang diperoleh dari selisih antara total penjualan, produksi, distribusi, dan biaya. Hasil pengolahan data tersebut ditampilkan pada Gambar 3 berikut.

	Jumlah	Bulan	Tahun	Produksi	Distribusi	Penjualan	Biaya
0	Total	1	2023	13122	13868	166312000	133876362
1	Total	2	2023	12029	8880	125271000	112627836
2	Total	3	2023	13239	10503	168764600	189013906
3	Total	4	2023	8354	10426	131780500	99530536
4	Total	5	2023	21941	21541	233037000	239829322
5	Total	6	2023	19529	18704	196839200	211091296
6	Total	7	2023	23608	23165	257588000	266280272
7	Total	8	2023	19109	20389	197612000	194789368
8	Total	9	2023	22487	21250	238977000	265030678
9	Total	10	2023	25588	27216	330050000	276001510
10	Total	11	2023	24039	24870	280303000	389677335
11	Total	12	2023	24507	23762	245615500	184160700
12	Total	1	2024	27425	27113	297311500	247852460
13	Total	2	2024	25461	26165	308662900	355736582

Gambar 3. Hasil Tranformasi Data

Pada periode 2023 hingga 2024, keuntungan perusahaan mengalami fluktuasi setiap bulannya. Nilai keuntungan diperoleh dari selisih antara pendapatan penjualan dan total biaya. Tingginya angka penjualan tidak selalu berbanding lurus dengan besarnya keuntungan apabila biaya yang dikeluarkan juga tinggi. Misalnya, pada Desember 2024 perusahaan memperoleh keuntungan besar karena penjualan tinggi dengan biaya yang relatif rendah. Sebaliknya, pada November 2023 terjadi kerugian karena biaya lebih tinggi daripada hasil penjualan. Selain itu, faktor distribusi dan produksi turut memengaruhi total biaya. Jika biaya distribusi maupun produksi meningkat tanpa diimbangi kenaikan penjualan, maka keuntungan akan menurun bahkan dapat berujung pada kerugian. Oleh karena itu, untuk memperoleh laba optimal, perusahaan perlu meningkatkan volume penjualan sekaligus menekan biaya, termasuk biaya distribusi dan produksi.

Selanjutnya, data keuntungan dinormalisasi menggunakan metode Min-Max Scaling agar nilai berada dalam rentang [0, 1]. Proses normalisasi ini dilakukan untuk memastikan model LSTM dapat bekerja lebih optimal tanpa dipengaruhi perbedaan skala antar variabel. Rumus perhitungannya ditunjukkan pada persamaan (1) di bagian metodologi, sedangkan hasil normalisasi divisualisasikan pada Gambar 4.

	Keuntungan (Asli)	Keuntungan (Ternormalisasi)
0	32435638	0.313786
1	12643164	0.269991
2	-20249306	0.197209
3	32249964	0.313375
4	-6792322	0.226985
5	-14252096	0.210479
6	-8692272	0.222781
7	2822632	0.248261
8	-26053678	0.184365
9	54048490	0.361609
10	-109374335	0.000000

Gambar 4. Normalisasi Data

Model LSTM memerlukan data yang tersusun dalam urutan tertentu. Oleh karena itu, data keuntungan dipecah menjadi beberapa segmen berurutan agar jaringan dapat mengenali pola perubahan antar waktu. Data yang telah melalui proses windowing kemudian diubah ke dalam format tiga dimensi: (samples, time_steps, features), sesuai dengan kebutuhan arsitektur LSTM. Setelah model menghasilkan prediksi, hasil peramalan yang awalnya berada pada rentang 0–1 dikonversi kembali ke skala aslinya (misalnya dalam satuan Rupiah) menggunakan proses inverse transform.

3.2.3. Pembagian Data Latih dan Uji

Setelah tahap preprocessing selesai, dataset dibagi menjadi dua kelompok: 80% digunakan sebagai data pelatihan (training) dan 20% sebagai data pengujian (testing). Rincian pembagian tersebut dapat dilihat pada Tabel 1 berikut:

Dataset	Dimensi Input (X)	Dimensi Target (y)
Data Latih	(9, 12, 1)	(9, 1)
Data Uji	(3, 12, 1)	(3, 1)

Table 1. Pembagian Data

Dalam tabel tersebut, angka pertama (9) merepresentasikan jumlah sampel, angka kedua (12) menunjukkan panjang urutan data deret waktu (12 bulan), sedangkan angka ketiga (1) menggambarkan jumlah fitur pada setiap langkah waktu, yaitu keuntungan. Data pelatihan digunakan untuk membangun dan menyesuaikan model, sementara data pengujian berfungsi untuk mengevaluasi kinerja model.

3.4. Pengembangan Model LSTM

Pada tahap ini, dilakukan pembangunan model LSTM yang kemudian dilatih menggunakan data yang telah melalui proses preprocessing. Variabel yang digunakan dalam pelatihan meliputi keuntungan dari penjualan, produksi, distribusi, serta biaya.

Setelah tahapan preprocessing selesai, model LSTM dikembangkan dengan arsitektur berlapis. Konfigurasi model tersebut ditampilkan pada Gambar 5.

```
model = Sequential()
model.add(LSTM(64, return_sequences=True, input_shape=(time_step, 1)))
model.add(LSTM(32))
model.add(Dense(1))
model.compile(optimizer='adam', loss='mse')
```

Gambar 5. Model LSTM

Lapisan awal LSTM terdiri dari 64 unit memori yang menghasilkan keluaran dari keseluruhan urutan data untuk kemudian diteruskan ke lapisan berikutnya (lihat persamaan (1) pada bagian metodologi). Lapisan kedua berisi 32 unit memori yang hanya memproses hasil akhir dari rangkaian data (lihat persamaan (2) pada bagian metodologi). Pada tahap akhir, terdapat lapisan output (Dense(1)) yang berfungsi menghasilkan satu nilai prediksi, yaitu estimasi keuntungan pada periode selanjutnya (lihat persamaan (3) pada bagian metodologi).

Model kemudian dikompilasi menggunakan fungsi loss Mean Squared Error (MSE) sebagai ukuran selisih antara hasil prediksi dan nilai aktual. Untuk mengoptimalkan proses pelatihan, digunakan algoritma Adam, yang mampu menyesuaikan laju pembelajaran secara adaptif sehingga model dapat mencapai performa terbaik dengan lebih cepat dan efisien.

Pelatihan model dilakukan dalam beberapa skenario, yakni 3 epoch, 50 epoch, 30 epoch, dan 20 epoch dengan ukuran batch sebesar 4, menggunakan data pelatihan (X_train, y_train). Selama proses training, data validasi (X_test, y_test) juga digunakan untuk mengevaluasi kemampuan model pada data baru. Hasil pelatihan tersimpan dalam objek history, yang mencatat perkembangan nilai loss dan validation loss, dan divisualisasikan pada Gambar 6.

```
[18] model.fit(X_train, y_train, epochs=20, batch_size=4, validation_data=(X_test, y_test), verbose=1)
Epoch 15/20 3/3 0s 37ms/step - loss: 0.0652 - val_loss: 0.1205
Epoch 16/20 3/3 0s 38ms/step - loss: 0.0835 - val_loss: 0.1139
Epoch 17/20 3/3 0s 38ms/step - loss: 0.0702 - val_loss: 0.1101
Epoch 18/20 3/3 0s 38ms/step - loss: 0.0579 - val_loss: 0.1070
Epoch 19/20 3/3 0s 39ms/step - loss: 0.0857 - val_loss: 0.0988
Epoch 20/20 3/3 0s 37ms/step - loss: 0.0678 - val_loss: 0.0975
<keras.src.callbacks.history.History at 0x7ff4f8c12090>

[19] model.fit(X_train, y_train, epochs=30, batch_size=4, validation_data=(X_test, y_test), verbose=1)
Epoch 25/30 3/3 0s 39ms/step - loss: 0.0903 - val_loss: 0.1383
Epoch 26/30 3/3 0s 38ms/step - loss: 0.0593 - val_loss: 0.1333
Epoch 27/30 3/3 0s 62ms/step - loss: 0.0929 - val_loss: 0.1328
Epoch 28/30 3/3 0s 44ms/step - loss: 0.0831 - val_loss: 0.1366
Epoch 29/30 3/3 0s 59ms/step - loss: 0.0491 - val_loss: 0.1415
Epoch 30/30 3/3 0s 45ms/step - loss: 0.0488 - val_loss: 0.1275
<keras.src.callbacks.history.History at 0x7ff5604a3bd0>

model.fit(X_train, y_train, epochs=50, batch_size=4, validation_data=(X_test, y_test), verbose=1)
Epoch 41/50 3/3 0s 41ms/step - loss: 0.0569 - val_loss: 0.1203
Epoch 42/50 3/3 0s 38ms/step - loss: 0.0823 - val_loss: 0.1284
Epoch 43/50 3/3 0s 39ms/step - loss: 0.0591 - val_loss: 0.1319
Epoch 44/50 3/3 0s 35ms/step - loss: 0.0657 - val_loss: 0.1321
Epoch 45/50 3/3 0s 34ms/step - loss: 0.0628 - val_loss: 0.1297
Epoch 46/50 3/3 0s 35ms/step - loss: 0.0884 - val_loss: 0.1224
Epoch 47/50 3/3 0s 40ms/step - loss: 0.0841 - val_loss: 0.1202
Epoch 48/50 3/3 0s 40ms/step - loss: 0.0593 - val_loss: 0.1201
Epoch 49/50 3/3 0s 37ms/step - loss: 0.0661 - val_loss: 0.1116
Epoch 50/50 3/3 0s 35ms/step - loss: 0.0848 - val_loss: 0.1066
<keras.src.callbacks.history.History at 0x7c33fe95f010>
```

Gambar 7. Hasil Tiga Epoch

3.5. Evaluasi Model


Pada tahap evaluasi, model yang telah dibangun diuji menggunakan tiga ukuran kinerja, salah satunya MAE (Mean Absolute Error) yang digunakan untuk menilai sejauh mana tingkat akurasi prediksi dari model deep learning yang dikembangkan. Hasil evaluasi tersebut dapat dilihat pada Tabel 2.

Metrik Evaluasi	Nilai
MAE (Mean Absolute Error)	0.3307

Mean Absolute Error (MAE)

MAE digunakan untuk menghitung rata-rata selisih absolut antara hasil prediksi dengan nilai aktual. Pada penelitian ini, nilai MAE sebesar 0.3307, yang berarti rata-rata deviasi prediksi keuntungan berada sekitar 0.3307 dari nilai sebenarnya. Karena tidak menggunakan kuadrat pada selisih error, metrik ini cenderung tidak terlalu terpengaruh oleh keberadaan data ekstrem (outlier), sehingga mampu memberikan gambaran umum mengenai akurasi model secara keseluruhan. Rumus perhitungannya dapat dilihat pada persamaan (2) di bagian metodologi.

Visualisasi hasil prediksi keuntungan usaha untuk periode tahun berikutnya ditampilkan pada Gambar 7.



Gambar 7. Hasil Peramalan Bulan Mendatang

Gambar ini menampilkan hasil prediksi keuntungan PT. Air Suci Pragaan untuk 12 bulan mendatang dengan menggunakan model LSTM. Garis berwarna biru merepresentasikan data keuntungan asli pada periode 2023–2024 yang dipakai dalam proses pelatihan model. Garis oranye menggambarkan hasil prediksi keuntungan setelah data aktual berakhir, sementara garis merah putus-putus menunjukkan pemisah antara data historis dan titik awal peramalan. Dari grafik dapat diamati bahwa model cukup mampu mengikuti pola keuntungan dari waktu ke waktu. Hasil peramalan tampak stabil serta realistis, meskipun terdapat sedikit kenaikan di awal yang kemudian cenderung menurun. Hal ini mencerminkan kecenderungan model untuk menjaga prediksi tetap konservatif, terutama ketika jumlah data terbatas dan fluktuatif. Grafik ini memberikan gambaran penting bagi manajemen dalam memperkirakan keuntungan di masa depan, sehingga dapat dijadikan dasar dalam merumuskan strategi pengelolaan usaha yang lebih tepat.

KESIMPULAN

Penelitian ini bertujuan untuk meramalkan keuntungan usaha PT. Air Suci Pragaan dengan memanfaatkan metode Long Short-Term Memory (LSTM), yang termasuk dalam teknologi deep learning. Data yang digunakan mencakup penjualan, produksi, distribusi, serta biaya operasional sepanjang tahun 2023 hingga 2024. Proses analisis dilakukan melalui beberapa tahap, mulai dari pembersihan data, perhitungan keuntungan, normalisasi, hingga pemisahan data latih dan data uji. Model LSTM yang dirancang terdiri dari dua lapisan tersembunyi dan satu lapisan keluaran.

Hasil evaluasi memperlihatkan bahwa model memiliki tingkat kesalahan yang relatif rendah dengan nilai MAE sebesar 0.3307. Hal ini menunjukkan bahwa model mampu mempelajari pola keuntungan secara cukup baik dan menghasilkan prediksi yang akurat. Peramalan keuntungan selama 12 bulan mendatang menampilkan pola yang stabil dan realistis, dengan beberapa bulan memperlihatkan peningkatan, sementara bulan lainnya menunjukkan penurunan, sesuai tren historis yang ada. Informasi ini dapat dimanfaatkan perusahaan sebagai dasar dalam merencanakan strategi keuangan serta mendukung pengambilan keputusan bisnis di masa depan.

Secara umum, metode LSTM terbukti efektif sebagai alat bantu peramalan berbasis data historis. Penelitian ini masih dapat ditingkatkan, misalnya dengan menambahkan variabel eksternal (seperti faktor musiman atau kondisi pasar) dan memperluas cakupan data historis untuk menghasilkan prediksi yang lebih akurat dan komprehensif.

Untuk pengembangan lebih lanjut, terdapat beberapa rekomendasi yang dapat dipertimbangkan:

Menambahkan variabel lain yang berpotensi memengaruhi keuntungan, seperti tren pasar, musim, atau kondisi perekonomian.

Menggunakan data dengan rentang waktu yang lebih panjang, atau memperbarui dataset secara berkala agar hasil peramalan tetap akurat dan relevan dengan kondisi terbaru.

DAFTAR PUSTAKA

- [1] A. Z. Prediksi Kebangrutan Dengan Menggunakan Metode *et al.*, “Analysis of Bankruptcy Predictions Using the Z Score Method on Pt. Mega Perintis,Tbk 2017-2021 Period),” *Res. Account. J.*, vol. 4, no. 1, pp. 36–44, 2019, [Online]. Available: <http://journal.yrpiiku.com/index.php/ra>
- [2] L. Tangdialla, A. Parerungan, and A. L. Matasik, “Analisis Kondisi Keuangan dengan Menggunakan Metode Altman Z-Score pada PT. Toba Pulp Lestari Tbk,” *J. Pendidik. Tambusai*, vol. 7, no. 1, pp. 3100–3110, 2023, [Online]. Available: www.idx.co.id
- [3] A. Maulandharu and F. Taufik, “Implementasi Metode Moving Average Untuk Memprediksi Pengeluaran Biaya Produksi,” vol. 3, no. September, pp. 748–754, 2024.
- [4] Sabar Sautomo and Hilman Ferdinandus Pardede, “Prediksi Belanja Pemerintah Indonesia Menggunakan Long Short-Term Memory (LSTM),” *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 5, no. 1, pp. 99–106, 2021, doi: 10.29207/resti.v5i1.2815.
- [5] R. D. Sanjaya and B. A. Sekti, “Studi Implementasi Aplikasi Keuangan Android dengan Analisis Data,” pp. 433–437.
- [6] M. Toyib, T. Decky, K. Pratama, and I. Aqil, “Prediksi Kondisi Cuaca di Kabupaten Bayuwangi Menggunakan Metode LSTM,” *J. Ilm. Sains dan Teknol.*, vol. 2, no. 7, pp. 78–84, 2024, [Online]. Available: <http://dataonline.bmkg.go.id>
- [7] Agus Triyadi, Adi Suwondo, Dian Asmarajati, Nur Hasanah, and Muhamad Fuat Asnawi, “Prediksi Harga Bawang Merah Kering Di Wonosobo Menggunakan Metode Long Short Term Memory,” *STORAGE J. Ilm. Tek. dan Ilmu Komput.*, vol. 3, no. 2, pp. 133–138, 2024, doi: 10.55123/storage.v3i2.3601.

-
- [8] M. Imam Budi Laksamana, Ema Utami, and Hanif Al Fatta, "Prediksi Jumlah Kunjungan Wisatawan Kabupaten Lombok Barat Menggunakan Algoritma Long Short Term Memory," *Tafaqquh*, vol. 6, no. 2, pp. 81–95, 2021, doi: 10.70032/4k3jrv73.
- [9] D. W. Puteri, P. W. Buana, and I. M. Sukarsa, "Komparasi Metode Decision Tree dan Deep Learning dalam Meramalkan Jumlah Mahasiswa Drop Out Berdasarkan Nilai Akademik," *J. Internet Softw. Eng.*, vol. 1, no. 2, p. 12, 2024, doi: 10.47134/pjise.v1i2.2327.
- [10] A. Santoso, A. Irma Purnamasari, and Irfan Ali, "Prediksi Harga Beras Menggunakan Metode Recurrent Neural Network Dan Long Short-Term Memory," *PROSISKO J. Pengemb. Ris. dan Obs. Sist. Komput.*, vol. 11, no. 1, pp. 128–136, 2024, doi: 10.30656/prosisko.v11i1.7921.
- [11] A. Kurniadi Hermawan, A. Nugroho, and Edora, "Analisa Data Mining Untuk Prediksi Penyakit Ginjal Kronik Dengan Algoritma Regresi Linier," *Bull. Inf. Technol.*, vol. 4, no. 1, pp. 37–48, 2023, doi: 10.47065/bit.v4i1.475.