

IMPLEMENTASI *NEURAL NETWORK* DENGAN METODE LSTM UNTUK PREDIKSI PENJUALAN CHINTARI CAKE AND COOKIES

Suranti¹, Sunarsan Sitohang²

¹Program Studi Teknik Informatika, Universitas Putera Batam

²Program Studi Teknik Informatika, Universitas Putera Batam
email: pb210210035@upbatam.ac.id

ABSTRACT

In the competitive food and beverage industry sector, the ability to accurately predict demand is crucial to supporting effective production and marketing strategies. Chintari Cake and Cookies, a small and medium-sized enterprise (SME) specializing in homemade cakes and cookies, faces challenges in dealing with unpredictable demand fluctuations. This study aims to forecast daily sales using the Long Short-Term Memory (LSTM) algorithm, a type of Recurrent Neural Network (RNN) known for its effectiveness in processing sequential data and recognizing long-term patterns. LSTM was chosen due to its advantages over conventional statistical methods such as ARIMA, particularly in terms of prediction accuracy. Five years of historical sales data were used as model input, which was then processed through preprocessing stages before training the LSTM model. The prediction results were evaluated using RMSE (Root Mean Square Error) and MAPE (Mean Absolute Percentage Error) metrics. The results showed an RMSE value of 6.752 and a MAPE value of 6.792, indicating a low prediction error rate. These findings demonstrate that the LSTM algorithm can serve as an effective solution for SMEs in improving the accuracy of production planning and inventory management based on historical data patterns.

Keywords: *Historical data; LSTM; MAPE; Recurrent Neural Network; Sales prediction*

PENDAHULUAN

Dalam era digital yang terus berkembang, kemampuan untuk memprediksi tren penjualan secara akurat telah menjadi kebutuhan krusial bagi para pelaku usaha, khususnya di sektor industri makanan dan minuman yang sangat dinamis dan kompetitif. Chintari Cake and Cookies, sebagai salah satu UMKM yang bergerak di bidang produksi serta penjualan kue dan cookies rumahan, menghadapi tantangan dalam merencanakan strategi produksi dan pemasaran akibat fluktuasi permintaan konsumen yang tidak menentu. Untuk menjawab tantangan ini, penerapan

metode prediksi berbasis teknologi menjadi pendekatan yang relevan guna mendukung pengambilan keputusan bisnis yang lebih tepat sasaran dan efisien.

Salah satu pendekatan yang terbukti efektif dalam memodelkan data deret waktu (time series) adalah metode *Long Short-Term Memory* (LSTM), yaitu varian dari jaringan saraf tiruan (Artificial Neural Network) yang dirancang khusus untuk menangani data sekuensial. LSTM memiliki keunggulan dalam mengenali pola jangka panjang dan mengatasi permasalahan vanishing gradient yang

umum terjadi pada *Recurrent Neural Network* (RNN) konvensional. Teknologi ini telah banyak diterapkan dalam berbagai bidang, seperti keuangan, peramalan cuaca, dan *e-commerce*, serta terbukti lebih unggul dibandingkan metode statistik tradisional seperti ARIMA dan regresi linier dalam hal akurasi prediksi penjualan (Brownlee, 2018).

Sebuah penelitian oleh Putri & Sadikin (2021) pada perusahaan makanan frozen food di Indonesia membandingkan performa model LSTM dengan ARIMA. Hasilnya menunjukkan bahwa LSTM menghasilkan nilai RMSE sebesar 0,22 dan MAPE sebesar 29,6%, jauh lebih rendah dibandingkan ARIMA yang menghasilkan RMSE sebesar 60,21 dan MAPE mencapai 73%. Temuan ini memperkuat bukti bahwa LSTM dapat memberikan hasil prediksi yang lebih presisi dalam konteks bisnis makanan. Oleh karena itu, eksplorasi lebih lanjut terhadap implementasi LSTM pada skala UMKM, seperti Chintari Cake and Cookies, menjadi penting guna mendukung efisiensi dalam perencanaan produksi serta strategi pemasaran yang berbasis data.

KAJIAN TEORI

2.1. Prediksi Penjualan Pada UMKM

UMKM kerap dihadapkan pada ketidakpastian permintaan yang signifikan, yang jika tidak dikelola dapat menyebabkan pemborosan atau kekurangan stok. Sebuah studi oleh Yogi dkk. (2024) tentang prediksi harga cabai merah besar di Malang menemukan bahwa model LSTM unggul dibanding ARIMA, dengan nilai MAPE hanya 3,65% vs ARIMA 3,80%, serta RMSE LSTM

sebesar 2,326—menunjukkan bahwa LSTM mampu menangani fluktuasi permintaan komoditas pangan secara efektif (Indrawan et al., 2025). Temuan ini menegaskan bahwa teknologi prediksi berbasis LSTM dapat meningkatkan efisiensi operasional dan mengurangi risiko stok pada bisnis skala kecil seperti Chintari Cake and Cookies.

2.2. Time Series (Deret Waktu)


Data deret waktu (time series) merupakan kumpulan observasi yang tercatat secara berurutan mengikuti waktu. Karakteristik utama mencakup trend (arah jangka panjang), *seasonality* (pola musiman), dan noise (fluktuasi acak). Hanke & Wichern (2005) menyatakan bahwa “secara umum terdapat empat macam pola data time series, yaitu horizontal, trend, musiman, dan siklus” (Ruhiat & Dan Effendi, 2018). Pengamatan pada data penjualan harian, mingguan, atau bulanan biasanya mengandung komponen–komponen tersebut, sehingga memungkinkan pengembangan model peramalan yang mampu memproyeksikan nilai masa depan berdasarkan pola historis.

2.3. Knowledge Discovery in Database (KDD)

Knowledge Discovery in Database (KDD) diartikan sebagai proses menemukan informasi yang bersifat potensial, tersembunyi, dan sebelumnya tidak diketahui dari suatu himpunan data (Putra & Chan, 2018). proses KDD yang terdiri dari tahapan berikut:

1. Selection dengan Memilih data awal yang relevan.
2. Preprocessing adalah Membersihkan dan mempersiapkan data.
3. Transformation Mengubah data ke format yang sesuai untuk analisis.

4. Data Mining Menerapkan metode analisis untuk menemukan pola atau model.
5. Interpretation/Evaluation
Menafsirkan hasil untuk menghasilkan pengetahuan yang bermanfaat.



Gambar 1 Knowledge Discovery in Database

(Sumber: Data Penelitian, 2025)

2.4. Data mining

Data mining merupakan proses iteratif dan interaktif untuk menemukan pola atau model baru yang sempurna, bermanfaat dan dapat dimengerti dalam suatu database yang sangat besar (Delima Sikumbang, 2018). Proses ini melibatkan teknik statistik, pembelajaran mesin (machine learning), dan basis data untuk mengidentifikasi pola, hubungan, atau tren dalam data. Tujuannya adalah mendukung pengambilan keputusan berdasarkan data.

2.5.RNN

Recurrent Neural Network (RNN) adalah salah satu jenis jaringan saraf tiruan (Artificial Neural Network) yang dirancang khusus untuk memproses data yang bersifat sekuensial atau berurutan, seperti teks, data waktu (time series), atau sinyal. Tidak seperti jaringan saraf feedforward biasa, Pada RNN masih

terdapat sebuah masalah *vanishing gradient* seiring bertambah panjang data berurutan yang ingin di training (Selle et al., 2022). Namun, RNN standar memiliki keterbatasan dalam mengingat informasi dalam urutan yang panjang karena masalah *vanishing gradient* saat pelatihan di mana nilai gradien menjadi sangat kecil sehingga pembelajaran berhenti. Untuk mengatasi kelemahan ini, dikembangkan varian seperti *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) yang memiliki mekanisme memori lebih kompleks dan stabil untuk pembelajaran jangka panjang.

2.5.LSTM

LSTM merupakan varian dari RNN yang dikembangkan oleh Hochreiter dan Schmidhuber pada tahun 1997 untuk memperbaiki kelemahan dalam mengingat informasi jangka panjang pada RNN standar. LSTM menggunakan mekanisme khusus berupa cell state dan tiga gerbang utama: *forget gate*, *input gate*, dan *output gate*. Struktur ini memungkinkan LSTM untuk menyimpan informasi penting sepanjang pelatihan dan membuang informasi yang tidak relevan. Sebagaimana dijelaskan dalam penelitian penggunaan LSTM untuk prediksi harga kopi, "LSTM merupakan jenis pemrosesan untuk RNN yang dirancang khusus untuk mengatasi dalam pembelajaran jangka panjang pada data sekuensial" serta memiliki "efektivitas dalam memprediksi data deret waktu dan kemampuannya memproses data nonlinier dalam jumlah besar secara efisien" (Muhammad & Nurhaida, 2025). Dengan demikian, LSTM mampu menangani hubungan jangka panjang dalam data seperti penjualan produk, cuaca, dan harga saham secara lebih andal dibanding RNN konvensional.

2.6. Prediksi

Tahap prediksi merupakan langkah lanjutan setelah model LSTM selesai dilatih dengan data historis penjualan. Pada tahap ini, model yang telah terbentuk digunakan untuk memperkirakan nilai penjualan di masa depan dengan mengacu pada pola-pola yang telah dipelajari sebelumnya. Input yang diberikan berupa data time series yang telah dinormalisasi dan dipersiapkan melalui tahapan pemodelan, lalu model akan menghasilkan output berupa hasil prediksi penjualan untuk periode berikutnya.

Keunggulan utama dari model LSTM dalam melakukan prediksi terletak pada kemampuannya dalam mempertahankan informasi jangka panjang pada data sekuensial. Hal ini sangat bermanfaat terutama untuk data penjualan yang kerap menunjukkan pola musiman atau tren berulang. Dalam hal ini, LSTM mampu mengidentifikasi perubahan tren, lonjakan permintaan, serta anomali yang mungkin muncul, sehingga dapat memberikan proyeksi yang lebih akurat terhadap data penjualan di masa mendatang.

2.7. Evaluasi Model

Setelah proses pelatihan dan prediksi selesai dilakukan, langkah selanjutnya adalah mengevaluasi performa model untuk mengetahui sejauh mana akurasi hasil prediksi yang dihasilkan. Evaluasi ini dilakukan dengan menggunakan dua metrik utama, yaitu *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). Kedua metrik ini digunakan untuk mengukur tingkat kesalahan prediksi antara nilai aktual dan nilai hasil prediksi dari model.

RMSE merupakan ukuran kesalahan prediksi yang dihitung dari akar kuadrat


rata-rata selisih kuadrat antara nilai aktual dan nilai prediksi. Metrik ini sensitif terhadap outlier karena penalti yang diberikan lebih besar untuk kesalahan yang besar (Nurdin et al., 2025). Semakin kecil nilai RMSE, maka semakin baik kinerja model. MAPE mengukur rata-rata kesalahan absolut dalam bentuk persentase terhadap nilai aktual. Keunggulan dari MAPE adalah interpretasinya yang mudah dipahami karena menggunakan satuan persen. Nilai MAPE yang rendah menunjukkan bahwa model memiliki tingkat kesalahan prediksi yang kecil.

METODE PENELITIAN

3.1 Desain Penelitian

Penelitian ini menggunakan metode Long Short-Term Memory untuk meramalkan penjualan Chintari *Cake and Cookies*. Tahapan pertama dimulai dari identifikasi masalah, yaitu memahami fluktuasi penjualan dan pentingnya prediksi permintaan. Setelah itu, dilakukan perumusan masalah yang bertujuan memprediksi penjualan secara akurat menggunakan model LSTM. Tahap selanjutnya adalah pengumpulan data penjualan historis dari toko tersebut. Data kemudian melalui proses preprocessing, seperti pembersihan data, normalisasi, dan transformasi menjadi format time series. Model LSTM diterapkan karena kemampuannya dalam menangani data berurutan dan mengingat pola jangka panjang, sehingga cocok untuk data penjualan yang bersifat temporal. Setelah pelatihan model, diperoleh hasil prediksi penjualan untuk periode mendatang. Akhirnya, dilakukan evaluasi hasil menggunakan metrik seperti RMSE, atau MAPE guna menilai keakuratan prediksi dan efektivitas model.

dalam membantu perencanaan produksi dan penjualan.



Gambar 2 Desain Penelitian
(Sumber: Data Penelitian, 2025)


3.2 Teknik Pengumpulan Data

Dalam penelitian ini, wawancara dilakukan dengan pemilik toko Chintari Cake and Cookies, Utriya Puspita Sari, guna memperoleh pemahaman mendalam mengenai faktor-faktor yang memengaruhi penjualan, seperti strategi promosi, tren musiman, dan preferensi pelanggan. Informasi dari wawancara ini digunakan untuk melengkapi data historis yang dibutuhkan dalam pelatihan model LSTM guna meramalkan penjualan. Selain itu, dilakukan observasi tidak langsung dengan menganalisis data penjualan

terdahulu untuk mengidentifikasi pola yang dapat dijadikan acuan dalam memprediksi permintaan produk di masa depan, sekaligus mendukung pengambilan keputusan dalam perencanaan produksi dan pemasaran. Penelitian ini juga diperkuat dengan studi literatur melalui penelusuran berbagai sumber ilmiah, seperti jurnal dan hasil penelitian terdahulu, yang membahas tentang pemodelan deret waktu dan penerapan algoritma *Long Short-Term Memory* dalam prediksi penjualan, sehingga memberikan dasar teoritis yang solid dan mendukung pemilihan metode yang tepat dalam penelitian ini.

3.3 kerangka pemikiran

Kerangka pemikiran pada penelitian ini dimulai dari input berupa data penjualan berbentuk time series selama periode 2020 hingga 2024. Data ini menjadi dasar untuk mempelajari pola dan tren penjualan historis. Selanjutnya, data tersebut diproses menggunakan algoritma Long Short-Term Memory (LSTM) yang diimplementasikan dalam bahasa pemrograman Python. LSTM dipilih karena kemampuannya dalam mengenali pola jangka panjang pada data sekuensial. Proses ini menghasilkan output berupa prediksi tingkat penjualan yang diklasifikasikan ke dalam tiga kategori, yaitu rendah, sedang, dan tinggi, yang nantinya dapat dimanfaatkan untuk mendukung pengambilan keputusan strategis dalam perencanaan produksi dan manajemen persediaan.



Gambar 3 kerangka pemikiran
(Sumber: Data Penelitian, 2025)

HASIL DAN PEMBAHASAN

Penelitian ini bertujuan untuk memprediksi penjualan produk kue menggunakan metode *Long Short-Term Memory* (LSTM). Data yang digunakan dalam penelitian ini merupakan data historis penjualan yang mencakup rentang waktu selama lima tahun, yaitu dari tanggal 1 Januari 2020 hingga 31 Desember 2024, dengan total sebanyak 1.874 entri. Sebelum dilakukan pelatihan model, data terlebih dahulu melalui tahap *data cleaning* untuk memastikan kualitas dan konsistensi data. Proses ini mencakup pemilihan atribut-atribut yang relevan dan signifikan dalam mendukung proses prediksi, serta penghapusan data duplikat atau nilai yang tidak valid. Tahap pembersihan data ini sangat penting untuk meningkatkan akurasi model dan menghindari gangguan akibat noise dalam data. Data yang telah dibersihkan kemudian diproses lebih lanjut pada tahap *preprocessing* untuk disesuaikan dengan format time series yang sesuai dengan karakteristik model LSTM

4.1. Data cleaning

Proses pembersihan data dilakukan dengan menyeleksi kolom-kolom yang dianggap penting, yaitu Tanggal, Waktu, dan Jumlah Terjual, sementara kolom lain yang tidak berkaitan diabaikan. Selanjutnya, kolom Tanggal dan Waktu digabung menjadi satu kolom baru yang dinamakan Datetime, kemudian dikonversi ke dalam format waktu yang sesuai agar data dapat diurutkan secara kronologis.

Tabel 1. Cleaning Data

No	Datetime	Jumlah Terjual
1	2020-01-02 09:34:00	77
2	2020-01-02 11:33:00	56
3	2020-01-02 12:46:00	93
4	2020-01-03 10:24:00	100
5	2020-01-05 09:19:00	70
:	:	:
1871	2024-12-25 12:06:00	68
1872	2024-12-25 12:31:00	118
1873	2024-12-28 11:05:00	63
1874	2024-12-28 13:15:00	62
1875	2024-12-28 18:24:00	121

(Sumber: Data Penelitian, 2025)

1. Normalisasi

Penggunaan *Min-Max Scaling* adalah untuk memastikan bahwa setiap fitur dalam dataset memiliki skala yang setara. Ini penting karena algoritma seperti LSTM sensitif terhadap perbedaan skala antar fitur. Jika skala tidak beragam, fitur dengan rentang nilai besar dapat mendominasi proses pelatihan dan menyebabkan bias pada hasil prediksi. Berikut ini adalah rumusnya:

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}}$$

Rumus 1 min-max Normalization

Rumus ini bekerja dengan cara mengurangi setiap nilai data (x) dengan nilai terkecil dalam dataset $X_{\min}$, lalu membaginya dengan selisih antara nilai maksimum ($X_{\max}$) dan minimum ($X_{\min}$). Hasil akhirnya X_{Norm} adalah nilai yang telah dinormalisasi dan berada dalam

rentang 0 hingga 1, sehingga seluruh data berada pada skala yang seragam.

Dengan menerapkan *Min-Max Scaling*, model dapat mempelajari pola data secara lebih efektif dan konvergen lebih cepat selama proses pelatihan. Metode *Min-Max* dilakukan dengan menentukan *safety stock* untuk mencegah resiko kekurangan persediaan, menentukan kapan pemesanan kembali harus dilakukan, dan menentukan jumlah maksimum persediaan yang diperbolehkan untuk disimpan (Rachmawati & Lentari, 2022).

Tabel 2 Normalisasi

No	Jumlah Terjual	Jumlah Terjual setelah Normalisasi
1	93	0,575757576
2	56	0,015151515
3	77	0,333333333
⋮	⋮	⋮
18	118	0,954545455
18		
74	62	0,106060606
18		
75	63	0,121212121

(Sumber: Data Penelitian, 2025)

2. Sliding window

Teknik *sliding window* berfungsi untuk mengonversi data deret waktu satu dimensi menjadi pasangan input-output berbentuk sekuensial, sehingga dapat dimanfaatkan dalam pelatihan model prediktif. Dalam hal ini, data penjualan harian dipotong menjadi segmen-segmen berdurasi tetap, di mana setiap segmen (*window*) terdiri atas sejumlah data historis tertentu (*time step*) yang akan

digunakan sebagai acuan untuk memprediksi nilai selanjutnya.

Pemilihan *time step* sebanyak 15 didasari oleh pola musiman serta kecenderungan harian yang sering ditemukan dalam aktivitas penjualan ritel, seperti lonjakan permintaan di akhir pekan atau hari-hari tertentu. Dengan memanfaatkan 15 data sebelumnya, model LSTM mampu mengenali pola mingguan secara menyeluruh sekaligus tetap adaptif terhadap perubahan tren terkini, tanpa terlalu terpengaruh oleh data lama yang kurang relevan.

Proses ini menjadi kunci dalam pelatihan model LSTM karena membantu model dalam mengenali pola berurutan secara lebih efektif dan menghasilkan prediksi yang lebih presisi. Secara keseluruhan, pendekatan *sliding window* menyusun data historis menjadi bentuk yang lebih sesuai untuk pemodelan sekuensial, di mana *time step* yang disesuaikan dengan karakteristik data berperan penting dalam meningkatkan performa prediksi model.

No	x-35	x-34	x-33	x-32	x-31	x-30	x-29	x-28	x-27	x-26	x-25	x-24	x-23	x-22	x-21	Target
1	0,37976	0,01515	0,33333	0,88182	0,22727	0,03030	0,37879	0,06061	0,74242	0,37879	0,63636	0,95455	0,65152	0,80303	0,88182	0,12121
2	0,01515	0,33333	0,88182	0,22727	0,03030	0,37879	0,06061	0,74242	0,37879	0,63636	0,95455	0,65152	0,80303	0,88182	0,12121	0,54545
3	0,33333	0,88182	0,22727	0,03030	0,37879	0,06061	0,74242	0,37879	0,63636	0,95455	0,65152	0,80303	0,88182	0,12121	0,54545	0,22727
4	0,88182	0,22727	0,03030	0,37879	0,06061	0,74242	0,37879	0,63636	0,95455	0,65152	0,80303	0,88182	0,12121	0,54545	0,22727	0,03030
5	0,22727	0,03030	0,37879	0,06061	0,74242	0,37879	0,63636	0,95455	0,65152	0,80303	0,88182	0,12121	0,54545	0,22727	0,03030	0,37879
6	0,03030	0,37879	0,06061	0,74242	0,37879	0,63636	0,95455	0,65152	0,80303	0,88182	0,12121	0,54545	0,22727	0,03030	0,37879	0,06061
7	0,37879	0,06061	0,74242	0,37879	0,63636	0,95455	0,65152	0,80303	0,88182	0,12121	0,54545	0,22727	0,03030	0,37879	0,06061	0,74242
8	0,06061	0,74242	0,37879	0,63636	0,95455	0,65152	0,80303	0,88182	0,12121	0,54545	0,22727	0,03030	0,37879	0,06061	0,74242	0,37879
9	0,74242	0,37879	0,63636	0,95455	0,65152	0,80303	0,88182	0,12121	0,54545	0,22727	0,03030	0,37879	0,06061	0,74242	0,37879	0,63636
10	0,37879	0,63636	0,95455	0,65152	0,80303	0,88182	0,12121	0,54545	0,22727	0,03030	0,37879	0,06061	0,74242	0,37879	0,63636	0,95455
11	0,63636	0,95455	0,65152	0,80303	0,88182	0,12121	0,54545	0,22727	0,03030	0,37879	0,06061	0,74242	0,37879	0,63636	0,95455	0,65152
12	0,95455	0,65152	0,80303	0,88182	0,12121	0,54545	0,22727	0,03030	0,37879	0,06061	0,74242	0,37879	0,63636	0,95455	0,65152	0,80303
13	0,65152	0,80303	0,88182	0,12121	0,54545	0,22727	0,03030	0,37879	0,06061	0,74242	0,37879	0,63636	0,95455	0,65152	0,80303	0,88182
14	0,80303	0,88182	0,12121	0,54545	0,22727	0,03030	0,37879	0,06061	0,74242	0,37879	0,63636	0,95455	0,65152	0,80303	0,88182	0,12121
15	0,88182	0,12121	0,54545	0,22727	0,03030	0,37879	0,06061	0,74242	0,37879	0,63636	0,95455	0,65152	0,80303	0,88182	0,12121	0,54545
16	0,12121	0,54545	0,22727	0,03030	0,37879	0,06061	0,74242	0,37879	0,63636	0,95455	0,65152	0,80303	0,88182	0,12121	0,54545	0,22727

Gambar 4 sequens time step
(Sumber: Data Penelitian, 2025)

3. Data splitting

Data dibagi menjadi dua bagian, yaitu data pelatihan (*training*) dan data pengujian (*testing*), dengan proporsi yang bervariasi: 50:50, 60:40, dan 70:30. Sementara itu, data pengujian berfungsi untuk menilai seberapa akurat model dalam melakukan prediksi terhadap data

yang belum pernah dilihat. Variasi dalam rasio pembagian ini dimaksudkan untuk mengamati sejauh mana jumlah data pelatihan mempengaruhi performa model secara keseluruhan.

Tabel 3 Splitting Data

Data training	Data testing
50% (936 data)	50% (936 data)
60% (1.123 data)	40% (749 data)
70% (1.310 data)	30% (562 data)

(Sumber: Data Penelitian, 2025)

4. Arsitektur LSTM

Model LSTM dibangun dari beberapa lapisan (*layer*) yang saling terhubung. pengaturan jumlah unit pada tiap layer memiliki peran penting dalam meminimalkan risiko terjadinya underfitting maupun overfitting pada model.

Rancangan arsitektur jaringan LSTM yang digunakan dalam penelitian ini dijelaskan sebagai berikut

- Sequential*: Menyusun layer secara berurutan.
- Layer LSTM pertama dengan 50 unit, mengembalikan urutan output ke LSTM berikutnya.
- Dropout: Menurunkan overfitting.
- Layer LSTM kedua yang hanya mengembalikan output terakhir (untuk prediksi)
- Dense(1): Layer output untuk prediksi satu nilai (cocok untuk regresi).

```
# proses model LSTM
def build_lstm_model(input_shape):
    model = Sequential([
        LSTM(50, return_sequences=True, input_shape=input_shape),
        Dropout(0.2),
        LSTM(50, return_sequences=False),
        Dropout(0.2),
        Dense(25, activation='relu'),
        Dense(1)
    ])
    return model
```

Gambar 5 Arsitektur LSTM
(Sumber: Data Penelitian, 2025)

5. Evaluasi model

Tabel 4 evaluasi model menggambarkan performa model LSTM dalam memprediksi data penjualan berdasarkan tiga skenario pembagian data pelatihan dan pengujian, yaitu 50:50, 60:40, dan 70:30, dengan menggunakan metrik RMSE dan MAPE sebagai ukuran akurasi.

Tabel 4 Hasil Evaluasi Model

Rasio Train/Test	Hasil Evaluasi Model	
	RMSE	MAPE
50% / 50%	6.777683	6.770951
60% / 40%	6.834423	6.854112
70% / 30%	6.752371	6.792212

(Sumber: Data Penelitian, 2025)

Dari hasil yang diperoleh, pembagian data dengan rasio 70% pelatihan dan 30% pengujian memberikan hasil terbaik, ditunjukkan oleh nilai RMSE sebesar 6.752 dan MAPE sebesar 6.792, yang merupakan nilai paling rendah dibandingkan dua skenario lainnya. Hasil ini menunjukkan bahwa semakin besar porsi data pelatihan, model memiliki kesempatan lebih besar untuk belajar dari pola historis penjualan, sehingga mampu

menghasi akurasi ini penting karena memungkinkan sistem memberikan estimasi jumlah penjualan yang mendekati kondisi sebenarnya, yang pada akhirnya dapat membantu pelaku usaha dalam perencanaan produksi dan pengambilan keputusan yang lebih tepat sasaran.

SIMPULAN

Hasil penelitian menunjukkan bahwa penerapan algoritma LSTM pada data historis penjualan selama lima tahun di Chintari *Cake and Cookies* mampu menghasilkan prediksi penjualan harian yang akurat. memberikan hasil terbaik dengan RMSE 6,752 dan MAPE 6,792, menandakan kesalahan prediksi yang rendah. Dengan demikian, model LSTM terbukti efektif untuk kebutuhan peramalan penjualan, terutama bagi UMKM dalam mendukung perencanaan produksi dan manajemen stok.

DAFTAR PUSTAKA

- Brownlee, J. (2018). *Deep learning for time series forecasting: predict the future with MLPs, CNNs and LSTMs in Python*. Machine Learning Mastery.
- Delima Sikumbang. (2018). Penerapan Data Mining Penjualan Sepatu Menggunakan Metode Algoritma Apriori. *Jurnal Teknik Komputer*, 4(1).
- Indrawan, Y. F., Larasati, A., Purnama, A. R., & Sholikhah, N. (2025). *Comparative Analysis of Large Red Chili Price Forecasting Models in Malang Regency Using Long Short-Term Memory (LSTM) and Autoregressive Integrated Moving Average (ARIMA)*. 07, 2025. <https://doi.org/10.52985/insyst.v7i1.419>
- Muhammad, R., & Nurhaida, I. (2025). Penerapan LSTM Dalam Deep Learning Untuk Prediksi Harga Kopi Jangka Pendek Dan Jangka Panjang. *JUPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 10(1), 554–564. <https://doi.org/10.29100/jupi.v10i1.5904>
- Nurdin, Suarna, N., & Prihartono, W. (2025). ALGORITMA REGRESI LINIER SEDERHANA UNTUK PREDIKSI PENGGUNAAN VOLUME AIR BERDASARKAN JENIS PELANGGAN PDAM. *Jurnal Kecerdasan Buatan Dan Teknologi Informasi*, 4(1), 43–52. <https://doi.org/10.69916/jkbt.v4i1.187>
- Putra, P. P., & Chan, A. S. (2018). Pengembangan Aplikasi Perhitungan Prediksi Stock Motor Menggunakan Algoritma C 4.5 Sebagai Bagian dari Sistem Pengambilan Keputusan (Studi Kasus di Saudara Motor). *INOVTEK Polbeng - Seri Informatika*, 3(1), 24. <https://doi.org/10.35314/isi.v3i1.296>
- Putri, E. S., & Sadikin, M. (2021). Prediksi Penjualan Produk Untuk Mengestimasi Kebutuhan Bahan Baku Menggunakan Perbandingan Algoritma LSTM dan ARIMA. In *Universitas Mercu Buana Alamat Jl. Raya*.
- Rachmawati, N. L., & Lentari, M. (2022). Penerapan Metode Min-Max untuk Minimasi Stockout dan Overstock Persediaan Bahan Baku. *Jurnal INTECH Teknik Industri Universitas Serang Raya*, 8(2), 143–148.

<https://doi.org/10.30656/intech.v8i2.4735>

Ruhat, C., & Dan Effendi, D. (2018). Pengaruh Faktor Musiman pada Pemodelan Deret Waktu untuk Peramalan Debit Sungai dengan Metode Sarima. In *Teorema: Teori dan Riset Matematika* (Vol. 2, Issue 2).

Selle, N., Yudistira, N., & Dewi, C. (2022). *PERBANDINGAN PREDIKSI PENGGUNAAN LISTRIK DENGAN MENGGUNAKAN METODE LONG SHORT TERM MEMORY (LSTM) DAN RECURRENT NEURAL NETWORK (RNN)*. 9(1), 155–162. <https://doi.org/10.25126/jtiik.202295585>

	Biodata Penulis Pertama Suranti merupakan mahasiswa Prodi teknik informatika Universitas Putera Batam.
	Biodata Penulis kedua Sunarsan Sitohang, S.Kom., M.TI., merupakan Dosen Prodi Teknik Informatika Universitas Putera Batam.