

# PERAMALAN PENJUALAN DAN JUMLAH STOK AMAN ROTI MENGGUNAKAN *LONG SHORT-TERM MEMORY* (STUDI KASUS DI EFRATA BAKERY)

1<sup>st</sup> Dean Igo Wibowo  
Program Studi Teknologi Informasi  
Universitas Telkom  
Surabaya, Indonesia  
deanigowib@student.telkomuniversity.  
ac.id

2<sup>nd</sup> Yohanes Setiawan  
Program Studi Teknologi Informasi  
Universitas Telkom  
Surabaya, Indonesia  
yohanessetiawan@telkomuniversity.ac.  
id

3<sup>rd</sup> Farah Zakiyah Rahmanti  
Program Studi Teknologi Informasi  
Universitas Telkom  
Surabaya, Indonesia  
farahzakiyah@telkomuniversity.ac.id

**Abstrak** — Industri roti di Indonesia terus berkembang seiring meningkatnya permintaan roti sebagai alternatif makanan pokok. Namun, usaha roti skala kecil seperti Efrata Bakery kerap menghadapi tantangan dalam meramalkan penjualan akibat fluktuasi permintaan, faktor musiman, dan perubahan preferensi konsumen. Hal ini dapat menyebabkan ketidaktepatan perencanaan stok, risiko *overstock*, hingga menurunnya kualitas layanan. Penelitian ini mengembangkan sistem peramalan penjualan harian menggunakan metode *Long Short-Term Memory* (LSTM), teknik *deep learning* yang efektif untuk data *time-series*. Model dikembangkan secara univariate per jenis roti dan dilengkapi proses deteksi serta penanganan anomali pada data historis untuk meningkatkan akurasi. Hasil evaluasi menunjukkan rata-rata *Mean Absolute Percentage Error* (MAPE) sebesar 10.84%, menandakan performa prediksi yang baik. Sistem tidak hanya memprediksi penjualan H+1, tetapi juga merekomendasikan jumlah stok produksi harian dengan mempertimbangkan stok sisa. Pendekatan ini memungkinkan penyesuaian jumlah produksi secara adaptif untuk menghindari *overstock* maupun *stockout*. Sistem diimplementasikan dalam bentuk aplikasi web yang memudahkan pemilik toko dalam mengakses informasi prediksi dan rekomendasi stok. Dengan sistem ini, Efrata Bakery dapat mengoptimalkan perencanaan produksi dan meningkatkan kepuasan pelanggan.

**Kata kunci** Peramalan Penjualan, *Long Short-term Memory*, Industri roti, *time-series*, *deep learning*.

## I. PENDAHULUAN

Di Indonesia, industri roti merupakan bagian penting dari sektor makanan dan minuman yang terus berkembang, dan secara umum terbagi menjadi tiga jenis utama: industri rumahan (*home bakery*) yang menjual roti tanpa merek dalam jangkauan lokal, industri massal (*industrial*) yang memproduksi roti dalam skala besar untuk distribusi luas, serta *bakery boutique* yang memiliki fasilitas produksi dan penjualan di satu tempat [1]. Seiring perubahan gaya hidup dan meningkatnya kebutuhan akan makanan praktis, roti semakin diminati sebagai alternatif makanan pokok, yang mendorong pertumbuhan pesat usaha roti skala kecil hingga menengah, terutama dalam bentuk *bakery boutique* [2]. Namun demikian, Toko roti skala kecil-menengah masih menghadapi tantangan dalam meramalkan penjualan secara akurat. Fluktuasi permintaan musiman dan perubahan

preferensi konsumen kerap menyulitkan perencanaan produksi [3].

Hal ini turut dialami oleh *Efrata Bakery*, sebuah toko roti mandiri di Sidoarjo, Jawa Timur, yang masih mengandalkan estimasi manual untuk menentukan jumlah produksi harian. Ketidaktepatan dalam estimasi tersebut dapat menyebabkan *overstock* (kelebihan stok tidak terjual) maupun *understock* (kekurangan stok), yang pada akhirnya memengaruhi kualitas produk dan kepuasan pelanggan. Produk roti yang tidak menggunakan pengawet memiliki masa simpan yang terbatas, sehingga kesalahan dalam jumlah produksi dapat menyebabkan kerugian. Ketidaktepatan peramalan kerap disebabkan oleh penggunaan metode manual yang belum mengoptimalkan data historis secara menyeluruh. Untuk mengatasi permasalahan tersebut, diperlukan pendekatan prediktif yang lebih canggih dan presisi, salah satunya adalah *Long Short-Term Memory* (LSTM). LSTM merupakan bagian dari teknik *deep learning* yang efektif dalam menganalisis data runtun waktu, dengan kemampuan mengenali pola secara otomatis tanpa memerlukan proses ekstraksi fitur secara manual, melalui pemanfaatan jaringan saraf tiruan berlapis [4].

Penelitian terkait prediksi penjualan produk makanan, termasuk roti, telah banyak dilakukan sebelumnya dengan berbagai pendekatan dan hasil yang beragam. Penelitian [5] membandingkan metode ARIMA dan LSTM dalam memprediksi penjualan obat di Apotek Kimia Farma dan menemukan bahwa LSTM menghasilkan prediksi yang lebih akurat dalam menangkap pola nonlinier. Penelitian [1] menerapkan metode statistik seperti *Least Square* dan *Double Exponential Smoothing* dalam memprediksi penjualan kue kering, namun hasilnya masih kurang optimal saat menghadapi fluktuasi tajam. Penelitian [6] menggunakan LSTM untuk memprediksi penjualan laptop dan menunjukkan performa baik terutama pada kategori dengan pola stabil. Penelitian [7] menggunakan multivariate LSTM dengan tambahan variabel hari libur dan promosi untuk memprediksi penjualan di swalayan, dan berhasil menangkap pola musiman secara lebih akurat. Penelitian [8] menggunakan LSTM untuk memprediksi permintaan produk segar di sektor agrikultur, dengan tujuan mengurangi pemborosan dan mengoptimalkan stok.

Beberapa penelitian lainnya juga menunjukkan keberhasilan penggunaan LSTM dalam berbagai domain peramalan. Al Kiramy dkk. berhasil menerapkannya untuk memprediksi jumlah jamaah Umrah dengan akurasi lebih tinggi dibandingkan metode RNN [9]. Penelitian oleh Tamami dan Arifin juga menunjukkan bahwa LSTM efektif dalam memprediksi tren penjualan laptop, khususnya untuk kategori *mid-end* [10]. Penelitian oleh Azhari dan Haryanto membuktikan bahwa LSTM mampu memberikan prediksi harga bawang putih yang lebih akurat, sehingga dapat mendukung pengambilan keputusan strategis dalam bisnis [11]. Merespons berbagai temuan tersebut dan permasalahan konkret yang dihadapi oleh *Efrata Bakery*, penelitian ini mengembangkan dan mengevaluasi model peramalan penjualan roti harian menggunakan metode LSTM berbasis data *time series*, serta membangun sistem prediksi dan rekomendasi stok dalam bentuk aplikasi yang mudah diakses oleh pengguna toko roti. Sistem ini dirancang untuk menentukan jumlah produksi optimal berdasarkan hasil prediksi. Tujuan dari model yang dikembangkan adalah untuk meningkatkan akurasi prediksi penjualan, mengurangi risiko kelebihan maupun kekurangan stok, serta mendukung perencanaan produksi yang lebih efisien dan adaptif, sehingga dapat memberikan solusi praktis bagi pelaku usaha roti berskala kecil hingga menengah.

## II. KAJIAN TEORI

### A. Peramalan Penjualan

Peramalan atau *forecasting* merupakan pendekatan kuantitatif yang bertujuan memperkirakan kejadian di masa depan berdasarkan pola data historis. Salah satu manfaat utama dari peramalan penjualan adalah kemampuannya dalam memperkirakan jumlah penjualan secara akurat dari waktu ke waktu, sehingga proses perencanaan produksi dapat disesuaikan dengan estimasi tersebut [12]. Perusahaan menggunakan hasil peramalan penjualan untuk menentukan jumlah produk yang harus disiapkan guna memenuhi permintaan di masa mendatang, dengan tujuan mencegah kelebihan stok akibat produk tidak terjual, sekaligus mengantisipasi kekurangan stok saat terjadi peningkatan permintaan konsumen [13]. Informasi dari peramalan penjualan juga berperan penting dalam perencanaan produksi agar perusahaan dapat menghindari pemborosan akibat kelebihan produksi maupun kehilangan peluang penjualan akibat kekurangan produksi [12].

### B. Analisis Metode *Time Series*

*Time series* merupakan kumpulan data yang dicatat secara berurutan berdasarkan waktu, di mana pola masa lalu digunakan untuk memprediksi kondisi masa depan. Metode ini menganalisis tren atau pola dari data historis, seperti penjualan atau produksi, yang tercatat dalam periode tertentu (mingguan, bulanan, dll.). Dalam konteks bisnis, analisis *time series* berguna untuk memperkirakan kinerja di masa mendatang berdasarkan tren sebelumnya [14]; [15].

### C. Deep Learning

Deep learning merupakan cabang dari machine learning yang menggunakan jaringan saraf tiruan berlapis-lapis (*deep neural networks*) untuk mempelajari

representasi data yang kompleks secara otomatis, tanpa perlu proses ekstraksi fitur manual [16]. Proses deep learning meliputi lima tahapan utama, yaitu: (1) merancang arsitektur jaringan yang terdiri dari input, hidden layer, dan output; (2) menyiapkan data untuk pelatihan dan pengujian; (3) menentukan cara implementasi kode, baik dari awal maupun menggunakan library; (4) menguji model dan struktur jaringan; serta (5) mengoptimalkan algoritma berdasarkan hasil evaluasi.

### D. Normalisasi Data

Penelitian ini menggunakan metode min-max normalization, yaitu proses mengubah nilai data ke dalam rentang tertentu, biasanya antara 0 hingga 1 [9]. Persamaan normalisasi ditunjukkan pada (1).

$$\hat{x} = \frac{X_i - x_{min}}{X_{max} - x_{min}} \quad (1)$$

Keterangan :

$\hat{x}$  = Nilai setelah proses normalisasi

$X_i$  = Nilai data yang akan diproses

$X_{min}$  = Nilai terkecil dari data asli

$X_{max}$  = Nilai terbesar dari data asli

### E. Penanganan Anomali

Penanganan anomali merupakan proses penting untuk mendeteksi data yang menyimpang dari pola umum. Anomali dapat disebabkan oleh kesalahan pencatatan, noise, atau kejadian luar biasa. Salah satu metode yang digunakan adalah IQR (Interquartile Range), yaitu selisih antara kuartil ketiga (Q3) dan kuartil pertama (Q1) [17]. Rumus IQR ditunjukkan pada (2).

$$\begin{aligned} IQR &= Q3 - Q1, \\ \text{Batas Bawah} &= Q1 - 1.5 \times IQR, \\ \text{Batas Atas} &= Q3 + 1.5 \times IQR \end{aligned} \quad (2)$$

Z-Score digunakan untuk mendeteksi anomali dengan mengukur seberapa jauh suatu nilai menyimpang dari rata-rata dalam satuan standar deviasi. Metode ini mengasumsikan distribusi data [17]. Persamaan Z-Score ditunjukkan pada (3).

$$Z = \frac{X - \mu}{\sigma} \quad (3)$$

Keterangan :

$x$  = nilai data yang diuji

$\mu$  = rata-rata mean dari dataset

$\sigma$  = standar deviasi dari dataset

$|Z| > 2$ : data dianggap sebagai outlier ringan

$|Z| > 3$ : data dianggap sebagai outlier yang signifikan.

*Adaptive threshold* merupakan metode deteksi anomali pada *time series* yang menggunakan ambang batas dinamis berdasarkan pola data terkini [18]. Perhitungannya ditampilkan pada (4).

$$\begin{aligned} \text{Upper} &= \mu_{\text{rolling}} + 1.5 \times \sigma_{\text{rolling}}, \\ \text{Lower} &= \mu_{\text{rolling}} - 1.5 \times \sigma_{\text{rolling}} \end{aligned} \quad (4)$$

Keterangan :

$\mu_{rolling}$  = rata-rata bergerak pada window lokal (mis. 5 data terakhir).

$\sigma_{rolling}$  = standar deviasi bergerak pada window yang sama.

1.5 = faktor sensitivitas; makin kecil  $\rightarrow$  makin sensitif mendeteksi anomali

## F. Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) adalah pengembangan dari RNN yang dirancang untuk mengatasi masalah hilangnya gradien dan mampu mempelajari ketergantungan jangka panjang, sehingga cocok untuk data time series [5]. LSTM menggunakan sel memori dan gerbang-gerbang khusus (input, forget, dan output) untuk mengatur informasi yang disimpan atau dilupakan [4]. Salah satu komponen utamanya adalah forget gate, yang menentukan informasi mana yang harus dibuang dari memori [19]. Persamaan untuk  $F_t$  adalah dapat dilihat pada (5).

$$F_t = \sigma(W_{Fx} \cdot X_t + W_{Fh} \cdot h_{t-1} + b_f) \quad (5)$$

Keterangan:

$F_t$  = Forget Gate

$\sigma$  = Fungsi Aktivasi Sigmoid

$x_t$  = Input pada waktu t

$W_f$  = Nilai bobot untuk forget gate

$h_{t-1}$  = Output dari lapisan tersembunyi sebelumnya

$b_f$  = Nilai bias pada forget gate

Gerbang Masukan (*Input Gate*) berfungsi mengatur seberapa banyak informasi baru yang akan disimpan ke dalam memori jangka panjang. Terdiri dari lapisan sigmoid yang menentukan nilai mana yang perlu diperbarui. Persamaan untuk  $i_t$  dapat dilihat pada (6).

$$\begin{aligned} i_t &= \sigma(W_{ix} \cdot X_t + W_{ih} \cdot h_{t-1} + b_i) \\ \tilde{C}_t &= \tanh(W_{cx} \cdot X_t + W_{ch} \cdot h_{t-1} + b_c) \end{aligned} \quad (6)$$

Keterangan:

$F_i$  = Input Gate

$\tilde{C}_t$  = Nilai baru yang dapat ditambahkan ke cell state

$\tan h$  = fungsi aktivasi tanh

$W_i$  = Nilai bobot untuk input gate

$W_c$  = Nilai bobot pada cell aktivasi

$b_i$  = Nilai bias pada input gate

$b_c$  = Nilai bias pada cell aktivasi

Pada tahap ini, *cell state* lama diperbarui dengan mempertimbangkan informasi yang perlu dilupakan dan informasi baru yang akan ditambahkan. Proses ini menjaga agar memori hanya menyimpan informasi penting dan relevan dari waktu ke waktu [5]. Persamaan untuk  $C_t$  dapat dilihat pada (7).

$$C_t = (f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t) \quad (7)$$

Keterangan:

$C_t$  = Cell State

$C_{t-1}$  = state pada waktu t-1

Gerbang keluaran (*Output Layer*), Gerbang ini menentukan informasi penting dari cell state yang akan dijadikan output, sesuai hasil pemrosesan memori saat ini [5]. Persamaan untuk  $O_t$  ditunjukkan pada (8).

$$O_t = \sigma(W_o \cdot [X_t, h_{t-1}] + b_o) \quad (8)$$

Keterangan:

$O_t$  = Output Gate

$W_o$  = nilai bobot untuk output gate

$b_o$  = nilai bias untuk output gate

$h_t$  = nilai output pada orde t

Lapisan Tersembunyi (*Hidden Layer*), Lapisan ini membantu memproses dan memahami pola dalam data yang bersifat berurutan [19]. Persamaan untuk  $h_t$  ditunjukkan pada (9).

$$h_t = (O_t \cdot \tanh(C_t)) \quad (9)$$

Keterangan:

$h_t$  = lapisan tersembunyi pada langkah waktu ke t .

## G. Evaluasi Model

### 1) Root Mean Square Error (RMSE)

RMSE mengukur selisih antara nilai prediksi dan nilai aktual; semakin kecil nilainya, semakin akurat hasil peramalan [5]. Persamaannya ditunjukkan pada (10).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_t - f_t)^2}{n}} \quad (10)$$

Keterangan:

$X_t$  = nilai data aktual

$F_t$  = nilai hasil peramalan

$n$  = banyaknya data

$\Sigma$  = jumlah keseluruhan nilai

### 2) Mean Absolute Percentage Error (MAPE)

merupakan metode evaluasi yang mengukur rata-rata kesalahan relatif antara nilai prediksi dan nilai aktual dalam bentuk persentase ([20]; [6]). Persamaannya ditunjukkan pada (11).

$$MAPE = \frac{100\%}{n} \Sigma \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (11)$$

Keterangan:

$\hat{y}$  = nilai peramalan dari data ke i

$y_i$  = nilai sebenarnya dari data ke i

$n$  = banyak data

## H. Denormalisasi

Setelah proses prediksi, denormalisasi perlu dilakukan untuk mengembalikan hasil ke skala asli sebelum evaluasi akurasi dapat dilakukan [4]. Persamaan denormalisasi disajikan pada (12).

$$x_i = \hat{x} (X_{max} - X_{min}) + X_{min} \quad (12)$$

## I. Safety Stock

Dalam menghadapi fluktuasi permintaan, perusahaan perlu menyediakan safety stock sebagai cadangan untuk mencegah kekurangan barang [21]. Safety stock dihitung dengan mempertimbangkan standar deviasi permintaan, tingkat keyakinan ( $Z$ -score), dan lead time produksi. Persamaan perhitungan safety stock ditunjukkan pada (13).

$$SS = \sigma_D \times Z \times \sqrt{L} \quad (13)$$

Keterangan :

$SS$  = safety stock

$\sigma_D$  = Standar deviasi (rata-rata dari prediksi penjualan)

$Z$  = Tingkat kepastian yang diinginkan

$L$  = Lead time

## J. Perhitungan Rekomendasi Stok

Rekomendasi stok merupakan jumlah stok yang disarankan untuk memenuhi permintaan selama lead time dan mengantisipasi ketidakpastian. Perhitungannya mencakup hasil prediksi penjualan dari model LSTM serta komponen safety stock yang mempertimbangkan  $Z$ -score, standar deviasi prediksi, dan lead time.

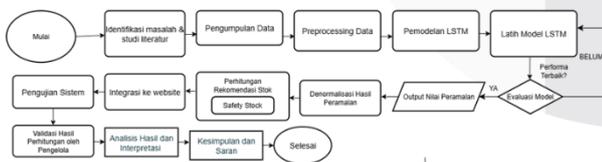
Setelah memperoleh nilai safety stock berdasarkan *rolling standard deviation* dari error prediksi, langkah selanjutnya adalah menghitung rekomendasi stok total (RT). Perhitungan ini juga mempertimbangkan stok sisa dari hari sebelumnya, sehingga menghasilkan rekomendasi stok yang bersifat adaptif terhadap kondisi aktual. Persamaan perhitungan dapat dilihat pada (14).

$$\text{Rekomendasi Total} = \text{Prediksi} + \text{Safety Stock} - \text{stok sisa} \quad (14)$$

## III. METODE

Penelitian ini menggunakan pendekatan kuantitatif dengan metode time series forecasting untuk memprediksi penjualan harian sebelas jenis roti. Model *Long Short-Term Memory* (LSTM) univariate dipilih karena mampu mengenali pola temporal dan memungkinkan pemodelan khusus per jenis roti.

### A. Prosedur Penelitian



GAMBAR 1.  
Alur Prosedur Penelitian

#### 1. Identifikasi Masalah dan Literatur

Penelitian diawali dengan mengidentifikasi permasalahan yang dihadapi oleh mitra usaha (Efrata Bakery), khususnya terkait fluktuasi permintaan dan ketidaktepatan dalam perencanaan produksi roti. Studi literatur dilakukan untuk memahami pendekatan peramalan berbasis time series, serta penerapan model LSTM dan metode safety stock dalam pengambilan keputusan stok.

#### 2. Pengumpulan Data

Data yang digunakan dalam penelitian ini merupakan data primer yang diperoleh langsung dari Efrata Bakery melalui sistem pencatatan penjualan internal. Dataset mencakup data historis penjualan harian selama 412 hari (1 Januari 2024 – 15 Februari 2025) untuk sebelas jenis roti. Informasi yang tersedia meliputi jumlah roti terjual, stok awal, dan sisa stok harian, seluruhnya dalam format digital.

#### 3. Preprocessing Data

Tahapan ini mencakup pembersihan data dari nilai kosong dan duplikat, seleksi jenis roti yang aktif terjual, serta normalisasi data agar sesuai untuk pemrosesan oleh model LSTM. Selain itu, dilakukan deteksi dan penanganan nilai-nilai ekstrem (anomali) menggunakan metode statistik seperti *IQR*, *Z-Score*, dan *rolling statistics*, yang diintegrasikan ke dalam proses ini guna meningkatkan akurasi prediksi.

#### 4. Pemodelan LSTM

Model LSTM univariate dibangun secara terpisah untuk masing-masing jenis roti, dengan struktur jaringan yang disesuaikan terhadap karakteristik pola penjualan. Pendekatan *sequence-to-vector* digunakan, di mana input model berupa urutan penjualan lima hari sebelumnya (timesteps = 5) untuk memprediksi penjualan satu hari ke depan (H+1). Horizon prediksi H+1 dipilih karena umur simpan roti yang pendek, sehingga peramalan harian lebih relevan untuk kebutuhan operasional harian dan mengurangi potensi pemborosan akibat stok berlebih.

#### 5. Pelatihan Model LSTM

Model dilatih menggunakan data historis yang telah melalui preprocessing. Proses pelatihan menggunakan teknik *early stopping* dan *learning rate scheduler* untuk mencegah *overfitting* dan mempercepat konvergensi. Evaluasi awal dilakukan menggunakan metrik *Mean Absolute Percentage Error* (MAPE).

#### 6. Evaluasi Model

Kinerja model diuji pada data test yang belum pernah dilihat sebelumnya. Jika MAPE masih tinggi atau tidak stabil, proses pelatihan diulang dengan tuning parameter (jumlah neuron, dropout, jumlah epoch, dsb.) sampai diperoleh model yang optimal.

#### 7. Output Nilai Peramalan dan Denormalisasi

Model terbaik menghasilkan output berupa prediksi penjualan harian untuk hari berikutnya (H+1). Nilai prediksi ini kemudian didenormalisasi agar kembali ke skala aslinya (jumlah unit roti).

#### 8. Perhitungan Rekomendasi Stok

Nilai hasil prediksi digunakan dalam perhitungan rekomendasi jumlah produksi menggunakan pendekatan *safety stock* yang adaptif terhadap fluktuasi residual dan kondisi stok sisa terakhir. Pertimbangan masa simpan roti juga diperhitungkan.

#### 9. Integrasi ke Website

Nilai hasil prediksi digunakan dalam perhitungan rekomendasi jumlah produksi menggunakan pendekatan *safety stock* yang adaptif terhadap

fluktuasi residual dan kondisi stok sisa terakhir. Pertimbangan masa simpan roti juga diperhitungkan.

### 10. Pengujian Sistem

Setelah integrasi selesai, sistem diuji secara menyeluruh untuk memastikan setiap fungsi berjalan dengan baik, termasuk input data, pemanggilan model, penghitungan stok, dan tampilan hasil di antarmuka pengguna.

### 11. Validasi Hasil Oleh Pengelola

Hasil rekomendasi stok dibandingkan dengan kebutuhan riil toko roti, berdasarkan penilaian subjektif dari pemilik toko terhadap kelayakan dan manfaat prediksi. Hal ini bertujuan untuk menilai penerapan sistem dalam konteks operasional sebenarnya.

### 12. Analisis Hasil dan Interpretasi

Peneliti melakukan analisis terhadap akurasi model dan efektivitas sistem rekomendasi berdasarkan data pengujian dan hasil validasi. Analisis ini menjadi dasar untuk menyusun simpulan dan saran pengembangan lebih lanjut.

## IV. HASIL DAN PEMBAHASAN

### A. Pengumpulan Dataset

TABEL 1.  
PENGUMPULAN DATASET

Tgl	Roti Manis Terjual	Roti Sausage Terjual	Roti Abon Terjual	...	Roti topping meses keju terjual	Roti Sisir terjual
01-01-24	18	7	9		6	5
02-01-24	45	9	15		6	6
03-01-24	16	10	7		5	6
...	..	...	...	...	...	...
13-02-25	12	5	5		1	2
14-02-25	6	3	2		2	3
15-02-25	18	4	4		4	0

Data yang digunakan dalam penelitian ini merupakan data primer yang diperoleh langsung dari Efrata Bakery melalui sistem pencatatan penjualan internal. Dataset mencakup data historis penjualan harian selama 412 hari (1 Januari 2024 – 15 Februari 2025) untuk sebelas jenis roti.

### B. Deteksi dan Penanganan Anomali

Deteksi dan penanganan anomali diterapkan pada data univariate untuk memastikan kualitas data penjualan. Tiga metode statistik digunakan, yaitu Interquartile Range, Z Score, dan adaptive threshold berbasis rolling mean dan standard deviation. Nilai anomali tidak dihapus, tetapi disesuaikan menggunakan median dari window sekitarnya (window size = 3), kemudian dilakukan smoothing dengan moving average agar pola tetap stabil tanpa mengganggu urutan waktu. Hasil deteksi menunjukkan jumlah data anomali yang relatif kecil dibanding total 412 data penjualan pada masing-masing jenis roti.

TABEL 2.  
DETEKSI DAN PENANGANAN ANOMALI

Jenis Roti	Jumlah Data Anomali	Jenis roti	Jumlah Data Anomali
Roti Manis	30	RS 3 Rasa	10
Roti Sausage	55	Topping Abon10rb	31
Roti Abon	22	Topping meses10rb	15
Roti Tawar	39	Topping meju10rb	18
Moccabun	23	Roti Sisir	57
Garlic Bread	16		

### C. Pembagian Data

Dataset penjualan yang terdiri dari 412 data dibagi menjadi tiga bagian utama. Sebanyak 329 data pertama digunakan sebagai data pelatihan untuk membangun model dan mengenali pola historis. Selanjutnya, 41 data berikutnya digunakan sebagai data validasi untuk membantu proses tuning parameter dan mencegah overfitting. Terakhir, 42 data paling akhir dimanfaatkan sebagai data pengujian untuk mengevaluasi performa model terhadap data yang belum pernah dilihat sebelumnya.

### D. Normalisasi Data

Data penjualan dari 11 jenis roti di-normalisasi menggunakan teknik Min-Max Scaling agar berada dalam rentang yang sama. Ini dilakukan untuk memastikan bahwa model LSTM dapat memproses data dengan lebih efektif dan cepat, menghindari masalah akibat perbedaan skala antar fitur.

### E. Pembuatan Sequence untuk input LSTM

Dalam pendekatan univariate, setiap model hanya memproses satu jenis roti secara terpisah. Untuk memprediksi penjualan pada hari berikutnya (H+1), digunakan data penjualan lima hari sebelumnya (H-5 hingga H-1) sebagai input. Dengan demikian, input LSTM terdiri atas lima *timesteps*, masing-masing berisi satu nilai penjualan dari roti terkait. Sebagai contoh, untuk memprediksi penjualan tanggal 16 Februari 2025, model akan menggunakan data penjualan roti yang sama pada tanggal 11 hingga 15 Februari 2025. Pendekatan ini memungkinkan model untuk mengenali pola temporal spesifik dari masing-masing jenis roti.

### F. Pemodelan dan Pelatihan Model LSTM

Proses tuning hyperparameter dilakukan secara iteratif sebanyak empat kali untuk memperoleh konfigurasi model LSTM yang paling optimal. Setiap jenis roti diuji secara terpisah, dan hasil pengamatan menunjukkan bahwa karakteristik pola penjualan antar roti berbeda-beda, sehingga diperlukan penyesuaian parameter yang spesifik untuk masing-masing jenis. Oleh karena itu, kombinasi hyperparameter terbaik ditentukan secara individual. Dalam penulisan ini, hanya disajikan hasil akhir tuning dalam bentuk tabel untuk menunjukkan konfigurasi optimal yang digunakan pada tiap model. Tabel berikut menyajikan hasil akhir tuning hyperparameter untuk masing-masing jenis roti.

TABEL 3.  
TUNING HYPERPARAMETER LSTM

Jenis Roti	Tuning Terbaik	LSTM Layer	Dropout Layer	Regularizers	Learning Rate	Batch Size	Epochs	Val Loss
1	1	64	0.2	-	0.001	8	150	0.0047
2	3	48	0.25	-	0.0001	4	300	0.0041
3	1	32	0.3	0.0005	0.0005	6	400	0.0077
4	2	48	0.15	0.0001	0.0008	6	200	0.0165
5	1	64	0.2	-	0.0005	8	300	0.0079
6	2	64	0.25	L1 L2 (L1 = 0.001, L2 = 0.001)	0.001	4	250	0.0179
7	2	32	0.3	0.0005	0.0005	2	100	0.1938
8	2	64	0.4	0.001	0.0003	4	300	0.0095
9	1	32	0.25	0.001	0.0001	4	350	0.0059
10	1	32	0.3	0.001	0.001	4	300	0.0106
11	1	32	0.15	-	0.002	8	180	0.0095

### G. Validasi Model

Setelah proses pelatihan model LSTM diselesaikan, evaluasi dilakukan menggunakan metrik MAPE untuk mengukur akurasi prediksi. Sebelumnya, data penjualan telah melalui tahapan prapemrosesan yang disesuaikan dengan karakteristik masing-masing jenis roti. Rangkuman konfigurasi preprocessing dan hasil evaluasi model ditampilkan pada tabel berikut.

TABEL 4.  
VALIDASI MODEL DENGAN PENANGANAN ANOMALI

Jenis roti	MAPE (%)	Penanganan Anomali
1	6.43%	-
2	6.35%	-
3	12.88%	IQR multiplier = 2.5 Z-score threshold = 2.8 Anomaly threshold = 30 Extreme outlier > 45 Smoothing $\alpha = 0.4$
4	9.68%	IQR multiplier = 1.4 Z-score threshold = 1.9 Anomaly threshold = 1.4
5	20.23%	-
6	16.80%	-
7	9.46%	IQR multiplier = 1.5 Z-score threshold = 2.0 Anomaly threshold = 1.5
8	12.34%	Anomaly threshold = 2.5
9	2.93%	IQR multiplier = 1.8 Z-score threshold = 2.2 Anomaly threshold = 2.2 Smoothing $\alpha = 0.3$
10	8.87%	IQR multiplier = 1.5 Z-score threshold = 2.0 Anomaly threshold = 2.0 Smoothing $\alpha = 0.25$
11	13.29%	-

Tabel 4 menunjukkan bahwa tidak semua jenis roti memerlukan penanganan anomali. Roti 1 dan roti 2 memiliki pola penjualan yang stabil dengan nilai MAPE dan val loss yang rendah meskipun tanpa deteksi outlier, sehingga proses *smoothing* dianggap tidak memberikan perbaikan signifikan. Hal serupa terjadi pada roti 6 dan roti 11, di mana hasil prediksi cukup akurat tanpa pembersihan data ekstrem. Pada kasus seperti roti 5, meskipun MAPE tinggi akibat *noise*, penerapan deteksi anomali tidak memperbaiki performa model. Oleh karena itu, keputusan untuk tidak melakukan penanganan anomali pada beberapa jenis roti didasarkan pada evaluasi yang menunjukkan bahwa deteksi outlier tidak secara signifikan meningkatkan akurasi, dan dalam beberapa kasus justru menurunkan performa prediksi.

### H. Peramalan Penjualan H+1

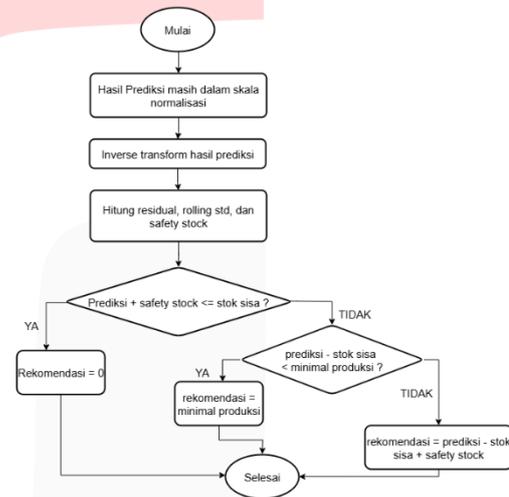
TABEL 5.  
HASIL PERAMALAN H+1

Jenis Roti	Tanggal	Prediksi
1	16 - 02 -2025	17
2	16 - 02 -2025	4

3	16 - 02 -2025	4
4	16 - 02 -2025	5
5	16 - 02 -2025	34
6	16 - 02 -2025	3
7	16 - 02 -2025	2
8	16 - 02 -2025	4
9	16 - 02 -2025	3
10	16 - 02 -2025	3
11	16 - 02 -2025	2

Tabel 5 menunjukkan hasil prediksi penjualan untuk tanggal 16 Februari 2025 (H+1) dari sebelas jenis roti yang dianalisis. Setiap nilai prediksi dihasilkan dari model LSTM univariate yang telah dilatih khusus untuk masing-masing jenis roti. Prediksi ini digunakan sebagai dasar dalam sistem rekomendasi stok harian, dengan mempertimbangkan sisa stok aktual dan kebutuhan produksi. Hasil prediksi bervariasi sesuai karakteristik penjualan masing-masing produk, seperti terlihat pada Roti 5 dengan prediksi tertinggi (34 buah), dan beberapa jenis lainnya seperti Roti Sisir dan RS Topping 10 yang hanya diprediksi sebanyak 2 buah.

### I. Perhitungan Safety Stock dan Rekomendasi Stok



GAMBAR 2.

Flowchart Perhitungan Safety Stock dan Rekomendasi Stok

Nilai safety stock dihitung secara adaptif berdasarkan deviasi error dari hasil prediksi sebelumnya, sehingga dapat menyesuaikan dengan fluktuasi data historis. Rekomendasi produksi dihitung dari prediksi ditambah safety stock. Jika stok sisa mencukupi, maka tidak disarankan produksi. Namun jika stok tidak cukup, sistem menghitung kekurangannya, dan bila kebutuhan lebih kecil dari batas produksi minimum, maka produksi disesuaikan ke batas tersebut. Pendekatan ini menggabungkan prediksi H+1, stok sisa roti, dan safety stock adaptif untuk menjaga efisiensi produksi sekaligus memastikan ketersediaan stok. Berikut ini hasil perhitungan rekomendasi stok yang terdapat dalam tabel 6.

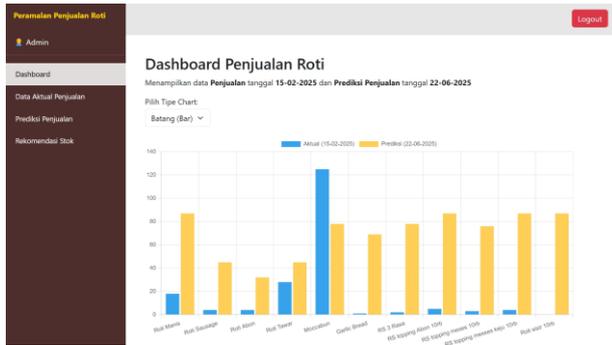
TABEL 6.  
HASIL PERHITUNGAN REKOMENDASI STOK

Jenis Roti	Prediksi H+1	Stok Sisa	Safety Stock	Rekomendasi Stok
1	17	2	1	16
2	4	3	1	2
3	4	4	1	5
4	5	4	1	5
5	34	5	1	30
6	3	6	1	0
7	2	2	1	5

8	4	3	1	5
9	3	0	0	5
10	3	3	1	5
11	2	2	1	5

## J. Tampilan Website

Sistem peramalan penjualan roti diimplementasikan dalam bentuk aplikasi web berbasis React.js untuk frontend dan Python Flask untuk backend. Implementasi ini bertujuan untuk menyediakan antarmuka yang user-friendly bagi pengguna dalam melakukan peramalan penjualan. Implementasi sistem dapat dilihat melalui beberapa tampilan antarmuka berikut:



GAMBAR 3.

Dashboard Penjualan Roti Aktual vs Peramalan

Pada gambar 3 menampilkan data aktual dan data hasil prediksi penjualan roti yang ditampilkan pada dashboard

Nama Roti	Prediksi	Sisa Stok (15-02-2025)	Rekomendasi Produksi
Roti Manis	18	2	20
Roti Saguage	4	3	6
Roti Alben	4	4	6
Roti Tamar	3	4	5
Maccabun	31	5	33
Garlic Bread	3	6	5
RS 3 Rata	3	2	5
RS topping Alben 10lb	4	3	6
RS topping meses 10lb	3	0	5
RS topping meses keju 10lb	3	3	5
Roti sate 10lb	2	2	4

GAMBAR 4.

Halaman Rekomendasi Stok Roti

Pada gambar 4 menampilkan pengguna bisa melihat rekomendasi stok berdasarkan hasil prediksi dengan mempertimbangkan stok sisa roti.

## K. Pengujian Black-Box

TABEL 7.  
PENGUJIAN BLACK-BLOCK

No	Skenario Pengujian	Hasil Yang di harapkan	Hasil
1	Login dengan email salah dan password valid	Sistem menampilkan pesan error "Email tidak terdaftar" dan user tetap di halaman login	Berhasil
2	Login dengan email valid dan password salah	Sistem menampilkan pesan error "Password salah" dan user tetap di halaman login	Berhasil
3	Login dengan email dan password yang benar	Sistem berhasil login dan Tampilan halaman beralih ke halaman dashboard.	Berhasil

4	Mengakses menu Dashboard setelah login berhasil	Halaman Dashboard tampil dengan grafik penjualan, navigasi menu	Berhasil
5	Mengakses menu "Data Penjualan Roti" dari dashboard	Tabel data penjualan roti historis ditampilkan dengan informasi lengkap	Berhasil
6	Mengisi form tambah data penjualan baru dan submit	Data baru tersimpan dalam database dan muncul notifikasi berhasil	Berhasil
7	Melakukan prediksi penjualan	Memproses data untuk melakukan prediksi lstm	Berhasil
8	Mengakses menu "Rekomendasi Stok Roti"	Tabel rekomendasi stok untuk setiap jenis roti ditampilkan dengan lengkap	Berhasil

Pada tabel 7 , menampilkan pengujian fungsional dengan metode black-box terhadap 11 skenario utama menunjukkan seluruh fitur sistem berjalan sesuai harapan. Uji coba dilakukan langsung oleh pemilik/pengelola Efrata Bakery dan tidak ditemukan bug. Sistem dinilai siap digunakan untuk mendukung prediksi permintaan dan rekomendasi stok roti.

## V. KESIMPULAN

Penelitian ini berhasil membangun sistem prediksi penjualan roti harian menggunakan model LSTM univariate dengan penanganan anomali, yang mampu meningkatkan akurasi prediksi. Penyesuaian data dilakukan melalui deteksi anomali menggunakan pendekatan statistik, sehingga model lebih andal dalam menangkap pola historis penjualan. Hasil evaluasi menunjukkan rata-rata MAPE sebesar 10.84%, dengan kinerja terbaik pada produk roti berpola stabil. Sistem juga menghasilkan rekomendasi stok berbasis prediksi H+1, stok sisa, dan safety stock adaptif, serta mempertimbangkan batas produksi minimum untuk efisiensi operasional. Aplikasi yang dikembangkan telah diuji dan siap digunakan sebagai alat bantu pengambilan keputusan dalam manajemen stok roti.

## REFERENSI

- [1] Q. A. Fuzaki, *Perbandingan Metode Double Exponential Smoothing dan Least Square untuk Prediksi Penjualan Kue*, Skripsi, Universitas Islam Negeri Maulana Malik Ibrahim Malang, 2022. [Online]. Tersedia: <http://etheses.uin-malang.ac.id/39078/1/17650117.pdf> [Diakses: 15 Nov. 2024].
- [2] E. P. Hartinningrum, S. Achmadi, dan Y. A. Pranoto, "Implementasi Metode Holt Winter's Exponential Smoothing sebagai Prediksi Penjualan Roti Agung Bakery (Studi Kasus: Cabang Kabupaten Kotabaru)," *Jurnal Mahasiswa Teknik Informatika*, vol. 8, no. 5, 2024
- [3] J. Cahyani, S. Mujahidin, dan T. P. Fiqar, "Implementasi Metode Long Short Term Memory (LSTM) untuk Memprediksi Harga Bahan Pokok Nasional," *J. Sistem Dan Teknologi Informasi (Justin)*, vol. 11, no. 2, hal. 346, 2023. [Online]. Tersedia: <https://doi.org/10.26418/justin.v11i2.57395> [Diakses: 11 Nov. 2024]
- [4] D. D. Pramesti, D. C. R. Novitasari, F. Setiawan, dan H. Khaulasari, "Long-Short Term Memory (LSTM) for Predicting Velocity and Direction Sea

- Surface Current on Bali Strait," BAREKENG: J. Ilmu Matematika dan Terapan, vol. 16, no. 2, hal. 451–462, 2022.[Online].Tersedia:<https://doi.org/10.30598/barekengvol16iss2pp451-462> [Diakses: 21 Okt. 2024].
- [5] A. Kurniawati, M. Sabri Ahmad, M. Fhadli, dan S. Lutfi, "Analisis Perbandingan Metode Time Series Forecasting untuk Prediksi Penjualan Obat di Apotek (Studi Kasus: Kimia Farma Apotek Takoma)," JATI (J. Jaringan dan Teknologi Informasi), vol. 3, no. 1, hal. 96–106, 2023. [Online]. Tersedia: <https://doi.org/10.33395/sinkron.v8i4.14057> [Diakses: 21 Okt. 2024].
- [6] F. C. Yulianto dan N. Latifah, Peramalan Penjualan Laptop Menggunakan Metode Long Short Term Memory (LSTM), 2024. [Online]. Tersedia: [https://github.com/C4AnN/Laptop\\_Lens/blob/main/M](https://github.com/C4AnN/Laptop_Lens/blob/main/M) [Diakses: 13 Des. 2024].
- [7] M. T. Tombeng dan Z. Ardian, "Prediksi Penjualan Supermarket Menggunakan Pendekatan Deep Learning," Cogito Smart J., vol. 7, no. 1, hal. 160, Jun. 2021. Fakultas Ilmu Komputer, Universitas Klabat. [Online].Tersedia:<https://cogito.unklab.ac.id/index.php/cogito/article/view/306/184> [Diakses: 21 Okt. 2024].
- [8] D. Meilasari, Implementasi Machine Learning dalam Memprediksi Permintaan Model Business to Business dengan Menggunakan Algoritma Autoregressive Integrated Moving Average (ARIMA) dan Long Short Term Memory (LSTM) Guna Mengurangi Food Waste (Studi Kasus: PT TaniHub Indonesia), Tugas Akhir, Program Studi Teknik Industri, Fakultas Teknologi Industri, Universitas Islam Indonesia, Yogyakarta, 2022. [Online]. Tersedia: <https://dspace.uui.ac.id/handle/123456789/40966> [Diakses: 31 Jul. 2025].
- [9] R. Al Kiramy, I. Permana, A. Marsal, M. R. Munzir, dan M. Megawati, "Perbandingan Performa Algoritma RNN dan LSTM dalam Prediksi Jumlah Jamaah Umrah pada PT. Hajar Aswad," MALCOM: Indonesian Journal of Machine Learning and Computer Science, vol. 4, no. 4, hal. 1224–1234, 2024. [Online].Tersedia:<https://doi.org/10.57152/malcom.v4i4.1373> [Diakses: 14 Nov. 2024].
- [10] G. Tamami dan M. Arifin, "Penggunaan LSTM dalam Membangun Prediksi Penjualan untuk Aplikasi Laptop Lens," J. Fasilkom, vol. 14, no. 2, hal. 301–308, 2024. [Online]. Tersedia: <https://www.kaggle.com/datasets/artakusuma/laptopen> [Diakses: 21 Okt. 2024].
- [11] I. C. Azhari dan T. Haryanto, "Modeling of Hyperparameter Tuned RNN-LSTM and Deep Learning for Garlic Price Forecasting in Indonesia," J. Informatics and Telecommunication Engineering, vol. 7, no. 2, hal. 502–513, 2024. [Online]. Tersedia: <https://doi.org/10.31289/jite.v7i2.10714> [Diakses: 17 Okt. 2024].
- [12] S. Rahayu dan D. H. Nurdiansyaha, "Analisis Peramalan Penjualan Produk Kaos Sablon (Studi Kasus: Home Industry Alva Cloth)," J. Ilmiah Wahana Pendidikan, vol. 8, no. 22, hal. 383–393, 2022. [Online].Tersedia:<https://doi.org/10.5281/zenodo.7349799> [Diakses: 14 Des. 2024].
- [13] I. S. Machfiroh dan C. A. Ramadhan, "Peramalan Penjualan Produk Cup 220 mL Menggunakan Metode Least Square pada PT. Panen Embun Kemakmuran Tahun 2022," J. Matematika dan Statistika serta Aplikasinya, vol. 10, no. 2, 2022. [Online]. Tersedia: <https://journal3.uinalauddin.ac.id/index.php/msa/article/view/27870> [Diakses: 14 Des. 2024].
- [14] H. Jamaludin dan S. Sugiyanto, "Monthly Revenue Prediction for HeroGame Businesses Using Time Series Analysis," J. Media Pratama, vol. 17, no. 2, 2023. [Online]. [Diakses: 14 Des. 2024].
- [15] M. N. Ustadha, I. Kadek, dan D. Nuryana, "Model Peramalan Permintaan Sandal Wanita dalam Rantai Pasok UMKM Menggunakan Algoritma Regresi Linear: Studi Kasus pada UMKM Ann-D'Mello Sandals," 2024. [Online]. Tersedia: <https://digilib.unesa.ac.id/detail/NDcwODAyODAtN DVhZS0xMwVmlTk3NDQtYWl0ZmQyY2Q2Yjk2> [Diakses: 17 Des. 2024].
- [16] M. Tamba, Analisis dan Implementasi Teknologi Deep Learning dalam Pengolahan Citra Digital, 2024. [Online]. [Diakses: 15 Des. 2024].
- [17] A. S. Yaro, F. Maly, dan P. Prazak, "Outlier Detection in Time-Series Receive Signal Strength Observation Using Z-Score Method with Sn Scale Estimator for Indoor Localization," Appl. Sci. (Switzerland), vol. 13, no. 6, 2023. [Online]. Tersedia: <https://doi.org/10.3390/app13063900> [Diakses: 12 Jul. 2025].
- [18] E. R. H. P. Isaac dan A. Sharma, "Adaptive Thresholding Heuristic for KPI Anomaly Detection," arXiv preprint, arXiv:2308.10504, 2023. [Online]. Tersedia: <http://arxiv.org/abs/2308.10504> [Diakses: 12 Jul. 2025].
- [19] I. G. T. Suryawan, I. K. N. Putra, P. M. Meliana, dan I. G. I. Sudipa, "Performance Comparison of ARIMA, LSTM, and Prophet Methods in Sales Forecasting," Sinkron, vol. 8, no. 4, hal. 2410–2421, 2024.[Online].Tersedia:<https://doi.org/10.33395/sinkron.v8i4.14057> [Diakses: 12 Feb. 2025].
- [20] A. Sujjada dan F. Sembiring, "Prediksi Harga Bitcoin Menggunakan Algoritma Long Short-Term Memory," Jurnal Inovtek Polbeng – Seri Informatika, vol. 9, no. 1, hal. 1–10, 2024. [Diakses: 12 Feb. 2025].