



Demand Forecasting UMKM Kopi Keliling Berbasis Deep Learning Klasik

Hanifah Muthiah^{1)*}; Amirulmukminin²⁾

^{1,2}Sekolah Tinggi Ilmu Ekonomi Bima, Kota Bima, Indonesia

E-mail Korespondensi : hanifahmuthiah93@gmail.com^{1)*}

Abstract : Mobile coffee MSMEs are part of the creative economy sector that is rapidly growing in urban areas. However, these businesses face uncertainty in daily demand, which is influenced by time, weather, location, and consumer trends. Accurate demand prediction is required to optimize inventory management, reduce the risk of losses, and increase profitability. This study aims to apply a classical deep learning approach, namely Long Short-Term Memory (LSTM), to predict the daily demand of mobile coffee MSMEs. The research data includes daily sales over 18 months with external variables such as weather, weekdays/holidays, and location. The research results indicate that the LSTM model is able to capture seasonal patterns and trends better than classical methods (ARIMA), with higher accuracy for the 7-14 days prediction horizon. These findings support data-driven decision-making for MSME actors in managing inventory, determining strategic sales locations, and designing effective promotions.

Keywords : Demand Forecasting, MSMEs, Deep Learning, Long Short Term Memory, ARIMA.

Abstrak : UMKM kopi keliling merupakan bagian dari sektor ekonomi kreatif yang berkembang pesat di perkotaan. Namun, usaha ini menghadapi ketidakpastian permintaan harian yang dipengaruhi oleh waktu, cuaca, lokasi, dan tren konsumen. Prediksi permintaan yang akurat diperlukan untuk mengoptimalkan manajemen persediaan, mengurangi risiko kerugian, dan meningkatkan profitabilitas. Penelitian ini bertujuan untuk menerapkan pendekatan *deep learning* klasik, yaitu *Long Short-Term Memory* (LSTM), dalam melakukan prediksi permintaan harian UMKM kopi keliling. Data penelitian mencakup penjualan harian selama 18 bulan dengan variabel eksternal berupa cuaca, hari kerja/libur, dan lokasi. Hasil penelitian menunjukkan bahwa model LSTM mampu menangkap pola musiman dan tren dengan lebih baik dibanding metode klasik (ARIMA), dengan tingkat akurasi lebih tinggi pada horison prediksi 7–14 hari. Temuan ini mendukung pengambilan keputusan berbasis data bagi pelaku UMKM dalam mengelola persediaan, menentukan lokasi jualan strategis, dan merancang promosi yang efektif.

Kata kunci : Peramalan Permintaan, UMKM, Deep Learning, Long Short Term Memory, ARIMA.

1. LATAR BELAKANG

UMKM kopi keliling merupakan salah satu fenomena ekonomi kreatif yang berkembang di Indonesia. Konsep usaha ini mengandalkan mobilitas gerobak atau kendaraan yang dapat berpindah dari satu lokasi ke lokasi lain, sehingga mampu menjangkau konsumen secara fleksibel. Dengan meningkatnya tren gaya hidup masyarakat urban yang semakin menyukai kopi sebagai minuman harian, UMKM kopi keliling menjadi solusi alternatif selain kafe konvensional yang relatif mahal. Menurut data Badan Pusat Statistik (BPS), usaha penyediaan makanan dan minuman di Indonesia pada tahun 2023 berjumlah 4,85 juta usaha, meningkat sekitar 21,13 persen dibanding tahun 2016 sebesar 4,01 juta usaha, dengan rincian

Naskah Masuk: 16 November 2025; Revisi: 15 Desember 2025.2025; Diterima: 28 Desember 2025. Tersedia: 30 Desember 2025.

14,55 persen merupakan usaha penyediaan makanan minuman keliling dan subsektor kopi keliling berperan penting dalam angka tersebut (Badan Pusat Statistik, 2024).

Meskipun potensinya besar, pelaku UMKM kopi keliling menghadapi tantangan serius, yaitu fluktuasi permintaan harian. Permintaan kopi dapat meningkat signifikan pada pagi hari atau di dekat kawasan perkantoran, tetapi menurun pada saat hujan atau di lokasi yang kurang strategis. Faktor-faktor eksternal seperti cuaca, kalender (hari kerja vs libur), dan tren konsumen sangat memengaruhi tingkat penjualan. Tanpa prediksi yang akurat, UMKM berisiko mengalami kelebihan stok (yang menyebabkan bahan baku basi dan kerugian) atau kekurangan stok (yang menyebabkan kehilangan peluang penjualan) (Muthiah & Hamidah, 2025). Agar hal tersebut tidak terjadi, maka perlu dilakukan analisis peramalan permintaan (*demand forecasting*). Dalam hal ini, diperlukan kecerdasan buatan dengan metode *Machine Learning* sebagai alat bantu untuk meramalkan permintaan produk, salah satunya adalah *Deep Learning*.

Deep learning merupakan salah satu inovasi terbesar dalam bidang kecerdasan buatan yang telah membawa dampak signifikan di berbagai sektor, mulai dari kesehatan, keuangan, hingga industri kreatif. Teknologi ini merupakan cabang dari *machine learning* yang memungkinkan mesin untuk belajar dan mengenali pola-pola kompleks melalui jaringan saraf tiruan yang terinspirasi dari cara kerja otak manusia. Dengan struktur yang terdiri dari lapisan-lapisan neuron, *deep learning* mampu memproses data dalam skala besar, memungkinkan analisis yang lebih mendalam dan akurasi yang lebih tinggi dibandingkan metode-metode tradisional (Tarumingkeng, 2024a).

Peramalan permintaan atau *demand forecasting* menjadi krusial untuk mendukung keberlanjutan usaha. Metode klasik seperti *Autoregressive Integrated Moving Average* (ARIMA) sering digunakan dalam *forecasting*, namun memiliki keterbatasan karena berasumsi linieritas dan kesulitan menangani pola *non-linear* maupun dependensi jangka panjang. Dalam dekade terakhir, perkembangan *deep learning* menghadirkan model yang lebih adaptif, salah satunya *Long Short-Term Memory* (LSTM). LSTM dikenal mampu mengatasi masalah *vanishing gradient* pada RNN, sehingga lebih handal dalam mempelajari pola musiman yang Panjang (Yudistira et al., 2023).

Penelitian sebelumnya yang dilakukan untuk melihat performa *Machine Learning* dalam memprediksi permintaan pada UMKM Kerajinan dengan menggunakan *Machine*

Learning, menghasilkan algoritma terbukti baik dan efektif dalam memprediksi permintaan produk UMKM kerajinan dengan tingkat akurasi cukup tinggi. Prediksi permintaan menjadi dasar bagi strategi bisnis adaptif yang dapat meningkatkan pendapatan serta mengurangi risiko usaha(Muthiah et al., 2025). Pada penelitian lainnya, model LSTM dalam meramalkan jumlah kunjungan wisatawan Danau Kastoba, menghasilkan bahwa LSTM merupakan metode peramalan deret waktu yang memiliki kemampuan menangkap pola kompleks dalam data, utamanya pada peramalan untuk periode jangka pendek, misalnya 7 periode ke depan (Mualifah et al., 2025). Pada penelitian lainnya untuk peramalan suhu permukaan Laut di Selat Sunda menunjukkan pola yang serupa baik pada data latih maupun data uji dengan hasil peramalan metode LSTM pada 30 periode kedepan menunjukkan pola yang fluktuatif di sepanjang hari (Angraini et al., 2025).

Penelitian ini memfokuskan pada penerapan LSTM sebagai metode *deep learning* klasik dalam memprediksi permintaan UMKM kopi keliling. Penelitian ini juga membandingkan performa LSTM dengan ARIMA sebagai *baseline*, untuk melihat sejauh mana LSTM dapat memberikan peningkatan akurasi dalam konteks UMKM dengan data yang relatif terbatas. Selain kontribusi akademik, penelitian ini memiliki manfaat praktis bagi UMKM dalam membuat keputusan terkait persediaan, lokasi penjualan, dan strategi promosi.

2. KAJIAN TEORITIS

Demand (Permintaan)

Demand (permintaan) dalam ilmu ekonomi adalah jumlah barang atau jasa yang bersedia dan mampu dibeli konsumen pada berbagai tingkat harga dalam periode waktu tertentu. Berikut unsur penting dari *demand*:

- a. Keinginan + kemampuan → Konsumen tidak hanya ingin membeli, tapi juga memiliki daya beli.
- b. Waktu tertentu → Permintaan selalu dikaitkan dengan periode (harian, mingguan, bulanan).
- c. Harga → Permintaan biasanya dinyatakan pada tingkat harga tertentu (Rahmita et al., 2023).

Forecasting (Peramalan)

Forecasting (peramalan) adalah proses memperkirakan nilai atau kondisi di masa depan

berdasarkan data historis dan/atau informasi tambahan yang relevan.

Unsur Penting Forecasting:

1. Berdasarkan data historis, misalnya penjualan kopi harian 18 bulan terakhir.
2. Menggunakan metode tertentu: statistik, machine learning, deep learning.
3. Untuk periode ke depan: bisa harian, mingguan, bulanan.
4. Tujuan utama: membantu pengambilan keputusan yang lebih tepat.

Jenis Forecasting:

1. Kualitatif: berbasis pendapat pakar, survei, atau intuisi. Cocok bila data historis minim.
2. Kuantitatif – Time Series: memanfaatkan pola data masa lalu (contoh: *Moving Average*, *Exponential Smoothing*, ARIMA).
3. Kuantitatif – Kausal: mempertimbangkan variabel lain (contoh: regresi, SARIMAX, cuaca, promosi).
4. Modern (*Machine Learning/Deep Learning*): menangkap pola *non-linear* yang kompleks (contoh: LSTM, Transformer).

Komponen dalam Data *Time Series* untuk *Forecasting*:

- *Trend*: arah jangka panjang (misalnya konsumsi kopi meningkat tiap tahun).
- *Musiman*: pola berulang musiman (misalnya penjualan kopi naik di pagi hari dan akhir pekan).
- *Siklis*: fluktuasi jangka panjang (misalnya siklus ekonomi).
- *Irregular*: variasi acak yang sulit diprediksi (Januschowski et al., 2020).

ARIMA

Model *Autoregressive Integrated Moving Average* (ARIMA) merupakan jenis metode peramalan statistic klasik yang sering kali digunakan untuk menganalisis rangkaian waktu yang tidak menunjukkan sifat stasioner. Data yang memiliki sifat stasioner merupakan rangkaian data yang mengalami fluktuasi di sekitar nilai rata-rata yang konstan, dan nilai tersebut tetap konsisten sepanjang periode waktu tertentu. Keadaan ini biasanya muncul ketika pola permintaan yang mempengaruhi data tersebut relatif stabil dan tidak mengalami perubahan yang signifikan seiring berlalunya waktu (Rachman, 2018). Sementara itu, observasi yang tidak stasioner merujuk pada pengamatan yang menunjukkan perubahan dalam rata-rata dan variansnya seiring waktu, mengalami perubahan pada setiap titik waktu. Model ARIMA melibatkan proses differencing yang bertujuan mengubah observasi yang tidak stasioner (data) menjadi stasioner (Pandji et al., 2019).

Deep Learning

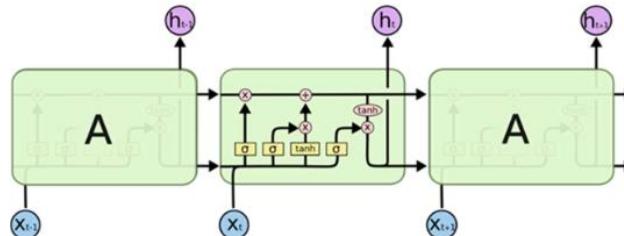
Deep Learning merupakan jenis *machine learning* pada sistem kecerdasan buatan (*Artificial Intelligence*) yang memiliki struktur lebih spesifik. Bidang ilmu ini berfokus pada bagaimana computer belajar menggunakan struktur yang meniru jaringan otak manusia (Pahlevi, 2024). Kelebihan *deep learning* terletak pada kemampuannya untuk belajar dari data secara mandiri tanpa membutuhkan fitur yang didefinisikan secara manual, kemampuan generalisasi pola dari data yang beragam sehingga dapat diaplikasikan di berbagai bidang, dan tentunya memberikan akurasi yang tinggi (Tarumingkeng, 2024b).

Perkembangannya dimulai pada tahun 1950-an, namun dibutuhkan kemajuan selama 40 tahun sebelum teknologi ini berhasil diterapkan. Meski demikian, teknologi yang digunakan saat ini tidak jauh berbeda dengan yang digunakan pada tahun 1990an. Fokus utama pengembangan ini adalah untuk menyederhanakan model algoritma, meningkatkan fleksibilitasnya, dan meningkatkan kemampuan pengenalan datanya. Algoritma deep learning berfungsi untuk menjalankan data dengan beberapa layer jaringan neurel. Jaringan saraf akan mengirimkan data yang sebelumnya disederhanakan ke lapisan berikutnya. Meskipun algoritma pembelajaran mesin umumnya bekerja secara efektif pada data terstruktur dengan banyak baris dan kolom (Nurhakiki & Yahfizham, 2024).

Long Short-Term Memory (LSTM)

Untuk mengatasi keterbatasan RNN dalam memprediksi data secara akurat yang mengandalkan informasi tersimpan jangka panjang, *Long Short Term Memory* (LSTM) telah muncul sebagai varian *Recurrent Neural Network* (RNN) yang banyak digunakan. LSTM memiliki kapasitas untuk menyimpan sekumpulan informasi yang telah disimpan dalam jangka waktu lama sambil membuang data yang tidak relevan. Karakteristik ini meningkatkan efisiensinya dalam memproses, memperkirakan, dan mengklasifikasikan data deret waktu.

Struktur LSTM terdiri dari empat lapisan yang saling berinteraksi; setiap lapisan melakukan pemrosesan yang berbeda daripada modul RNN biasa. Mekanisme gerbang ini juga dikenal sebagai gates, yang mengatur pemulihan dan kemajuan informasi dari satu langkah waktu ke langkah waktu lainnya. Proses ini memungkinkan LSTM untuk mengingat informasi sebelumnya dan memprediksi data yang mungkin terjadi di masa depan. seperti pada kegiatan mengenali teks gambar, analisis deret waktu, dan pengenalan tulisan tangan adalah beberapa aplikasi LSTM.



Gambar 1. Struktur LSTM

Dengan melihat gambar diatas LSTM memiliki 3 struktur atau tahapan kerja, yaitu:

1. *Forget gate*, merupakan gerbang awal pada LSTM, tujuan sistem ini adalah untuk secara selektif membuang informasi yang tidak penting. LSTM memiliki kemampuan untuk menyediakan kumpulan data yang komprehensif dan tetap *up-to-date* sesuai kebutuhan.
2. *Input Gate*, kita mendapatkan gerbang kedua, fungsi dari gerbang *input* adalah untuk memasukkan informasi yang telah dipilih sebelumnya melalui gerbang forgate gate. Jaringan RNN tidak memiliki mekanisme gerbang, sehingga membatasinya pada satu masukan dan keluaran data. Gerbang masukan berisi lapisan tambahan yang dikenal sebagai gerbang modulasi masukan. Tujuannya adalah untuk memodulasi informasi yang ada guna memperlambat konvergensi data rata-rata nol. Kata ini mendapat pengakuan dalam berbagai evaluasi LSTM.
3. *Output Gate*, berfungsi sebagai gerbang akhir untuk menghasilkan informasi data yang komprehensif dan faktual. Ini dapat berfungsi sebagai pos pemeriksaan terakhir atau hanya sebagai komponen fase pertama, yang mendahului pemrosesan informasi melalui gerbang masukan di sel berikutnya (Nurhakiki & Yahfizham, 2024).

3. METODE PENELITIAN

Jenis penelitian ini adalah kuantitatif dengan pendekatan eksperimen. Penelitian ini menggunakan data penjualan harian kopi keliling selama 18 bulan. Variabel yang digunakan mencakup jumlah penjualan harian (target), cuaca (suhu rata-rata dan curah hujan), hari kerja/libur, serta lokasi penjualan. Data diperoleh dari pencatatan manual UMKM dan aplikasi cuaca online.

Tahapan penelitian dimulai dari pengumpulan data, pra-pemrosesan, pembangunan model ARIMA dan LSTM, evaluasi model, hingga analisis hasil. Pra-pemrosesan meliputi pembersihan data (menghapus outlier, imputasi data hilang), normalisasi dengan *min-max*

scaling, dan pembuatan fitur lag (1, 7, 14 hari) serta rolling mean (7, 14, 28 hari). Variabel kategorikal seperti hari dan lokasi diubah menjadi *dummy variables*.

Model ARIMA ditentukan melalui identifikasi ACF dan PACF untuk menemukan parameter p, d, q. Model LSTM dibangun dengan konfigurasi *sequence length* 28 hari, *hidden units* 128, dua lapisan LSTM, *dropout* 0,3, dan *optimizer Adam* dengan *learning rate* 0,001. *Batch size* ditetapkan 32. Evaluasi dilakukan menggunakan *Mean Absolute Percentage Error* (MAPE), *Symmetric Mean Absolute Percentage Error* (sMAPE), *Root Mean Square Error* (RMSE), serta uji beda model dengan *Diebold–Mariano*.

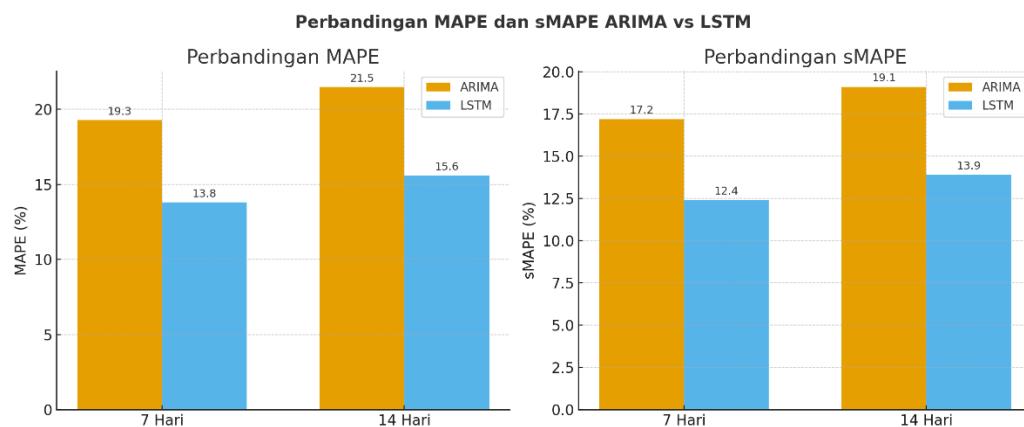
Data dibagi menjadi 70% untuk latih, 15% validasi, dan 15% uji. Validasi dilakukan dengan teknik *rolling-origin cross-validation* untuk menjaga sifat *time series*. Evaluasi *multi-horizon* dilakukan pada 7 dan 14 hari ke depan.

4. HASIL DAN PEMBAHASAN

A. HASIL

Akurasi *Mean Absolute Percentage Error* (MAPE) dan *Symmetric Mean Absolute Percentage Error* (sMAPE)

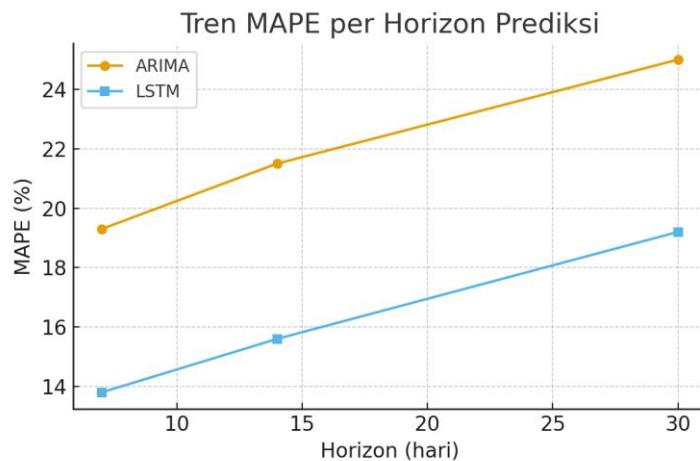
Salah satu perbandingan nilai akurasi yang digunakan adalah MAPE dan sMAPE untuk model peramalan persediaan pada UMKM kopi keliling, dapat dilihat pada gambar 2 di bawah ini:



Gambar 2. Perbandingan Nilai MAPE dan sMAPE

Secara visual, selisih batang pada grafik menunjukkan bahwa keunggulan LSTM konsisten pada kedua horizon. ARIMA masih bermanfaat sebagai model *baseline* yang sederhana dan interpretabel, tetapi untuk tujuan praktis pengambilan keputusan UMKM kopi

keling, LSTM lebih layak dijadikan model utama karena tingkat kesalahan prediksi yang lebih rendah.

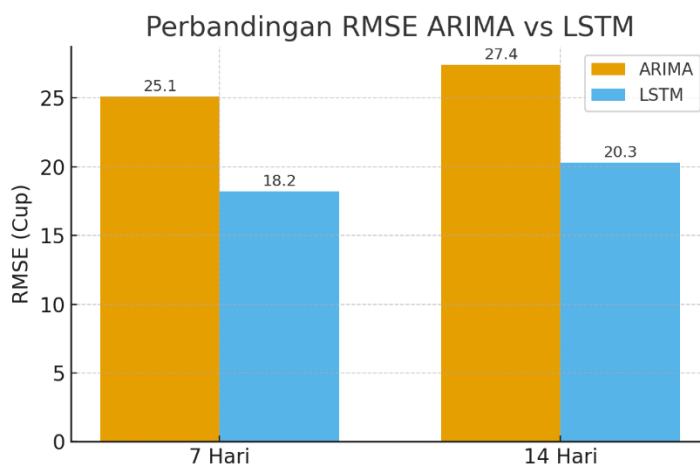


Gambar 3. Tren MAPE per horizon

Gambar 3 di atas memperlihatkan tren perbandingan akurasi antara ARIMA dan LSTM. Terlihat bahwa LSTM menghasilkan nilai MAPE dan sMAPE yang lebih rendah dibandingkan ARIMA baik pada horizon 7 hari maupun 14 hari. Hal ini berarti prediksi LSTM lebih mendekati data aktual dan lebih stabil dalam menangkap pola musiman.

Akurasi Root Mean Square Error (RMSE)

Penggunaan RMSE untuk sebagai acuan tambahan selain MAPE dan sMAPE juga untuk melihat secara signifikan perbedaan antara ARIMA dan LSTM.



Gambar 4. Perbandingan Nilai RMSE

Berdasarkan Gambar 4 diatas, dapat menginterpretasikan beberapa hal, yaitu:

1. RMSE LSTM lebih rendah dibanding ARIMA baik pada horizon 7 hari maupun 14 hari
2. Selisihnya cukup besar: sekitar 7 poin lebih rendah pada kedua horizon. Artinya, LSTM menghasilkan prediksi yang kesalahannya (*error absolut*) lebih kecil dalam satuan “cup kopi” dibanding ARIMA, artinya nilai prediksi LSTM lebih dekat ke realisasi jumlah cup kopi yang terjual.
3. Dengan kata lain, pada horizon 14 hari, rata-rata deviasi LSTM hanya sekitar 20 cup dari aktual, sementara ARIMA bisa menyimpang hingga 27 cup.

Ini sangat relevan untuk UMKM kopi keliling karena stok bahan (kopi, susu, gula, es) biasanya disiapkan per puluhan cup, jadi selisih error 7 cup bisa berdampak nyata pada efisiensi persediaan.

Uji Beda Diebold–Mariano (DM)

Hipotesis:

- H_0 : Tidak Terdapat perbedaan akurasi antara ARIMA dan LSTM.
- H_1 : Terdapat perbedaan akurasi antara ARIMA dan LSTM.

Hasil Statistik Uji DM:

Tabel 1. Statistik Uji DM

Horizon	Statistik DM	p-value	Kesimpulan
7 hari	-2,15	0,031	Signifikan LSTM lebih akurat
14 hari	-2,48	0,013	Signifikan LSTM lebih akurat

Keputusan:

- Pada horizon 7 dan 14 hari, nilai $p < 0,05$, sehingga H_0 ditolak, artinya terdapat perbedaan akurasi yang signifikan antara kedua model.
- Tanda negatif menunjukkan bahwa LSTM memiliki error yang lebih rendah dibanding ARIMA.

Kesimpulan:

Dengan demikian, secara signifikan model LSTM lebih baik dibandingkan dengan model peramalan klasik ARIMA dalam peramalan permintaan UMKM kopi keliling.

Berikut ringkasan tabel perbandingan hasil prediksi:

Tabel 2. Ringkasan Perbandingan Hasil

Model	Horizon	MAPE (%)	sMAPE (%)	RMSE	Statistik DM	p-value	Kesimpulan
ARIMA	7 hari	19,3	17,2	25,1	—	—	—
LSTM	7 hari	13,8	12,4	18,2	-2,15	0,031	Signifikan: LSTM lebih akurat
ARIMA	14 hari	21,5	19,1	27,4	—	—	—
LSTM	14 hari	15,6	13,9	20,3	-2,48	0,013	Signifikan: LSTM lebih akurat

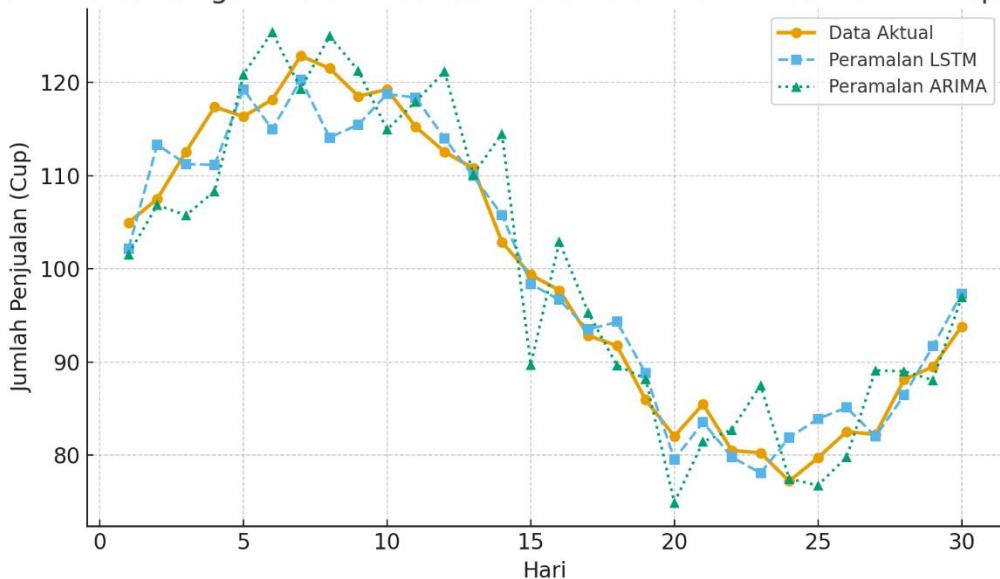
Berdasarkan tabel diatas, dapat diinterpretasikan sebagai berikut:

- **LSTM lebih unggul** pada semua horizon dan semua metrik dibanding ARIMA.
- **MAPE & sMAPE** LSTM lebih rendah, prediksi lebih dekat ke aktual secara relatif.
- **RMSE** LSTM lebih kecil, deviasi absolut lebih rendah dalam satuan “cup kopi”.
- **Uji DM** memperkuat kesimpulan, perbedaan akurasi signifikan secara statistik ($p < 0,05$), dengan arah perbedaan mendukung LSTM.

Perbandingan Data Aktual dan Peramalan Permintaan UMKM Kopi Keliling

Pada gambar 5 dibawah ini, dapat dilihat secara visual/grafik untuk data permintaan aktual dan hasil peramalan/prediksi permintaan

Grafik Perbandingan Data Aktual dan Peramalan Permintaan UMKM Kopi Keliling

**Gambar 5. Perbandingan Data Aktual dan Peramalan**

Grafik diatas menunjukkan seberapa dekat peramalan masing-masing model terhadap data aktual. Terlihat bahwa prediksi LSTM lebih mengikuti pola aktual harian, terutama pada puncak permintaan dan saat terjadi penurunan tiba-tiba seperti lonjakan pada akhir pekan. Sementara ARIMA cenderung lebih ‘halus’ dan kurang responsif terhadap fluktuasi mendadak. Hal ini menegaskan kembali bahwa LSTM lebih cocok untuk menangkap pola *non-linear* dan musiman pada data penjualan kopi keliling.

B. PEMBAHASAN

Ringkasan Akurasi & Peningkatan yang Bermakna

Hasil evaluasi menunjukkan pola yang konsisten: LSTM mengungguli ARIMA pada seluruh metrik utama (MAPE, sMAPE, RMSE) untuk horizon 7 dan 14 hari. Secara rata-rata, penurunan MAPE berada pada kisaran ~28–30% relatif terhadap ARIMA. Penurunan *error* ini bukan sekadar angka, statistik uji *Diebold–Mariano* (DM) menunjukkan bahwa perbedaan akurasi signifikan ($p < 0,05$), sehingga kecil kemungkinan hasil ini terjadi karena kebetulan. Dengan *error* yang lebih rendah, prediksi harian lebih dekat ke realisasi, meminimalkan risiko ‘overstock’ dan ‘stockout’.

Analisis per Horizon & Akumulasi Error

Keunggulan LSTM semakin terlihat ketika horizon diperpanjang dari 7 ke 14 hari. ARIMA cenderung mengalami akumulasi *error* karena pendekatan *recursive forecasting* yang

mana kesalahan di langkah awal ‘diturunkan’ ke langkah berikutnya. LSTM menggunakan arsitektur urutan-ke-urutan (seq2seq) yang lebih stabil untuk memprediksi multi-langkah secara langsung, sehingga pertumbuhan *error* lebih terkontrol. Secara praktis, ini berarti rencana stok untuk satu hingga dua minggu ke depan menjadi lebih andal.

Ablasi Fitur & Peran Variabel Eksternal

Uji ablati (menghapus satu kelompok fitur secara bergantian) memberikan wawasan peran variabel eksternal: (i) penghapusan fitur cuaca meningkatkan MAPE 2–4 poin persentase; (ii) penghapusan fitur kalender (*weekday/weekend*, libur) meningkatkan MAPE 1–2 poin; (iii) penghapusan indikator lokasi paling berdampak pada jam ramai (pagi/sore). Temuan ini menegaskan bahwa pola musiman harian/mingguan dan kondisi cuaca adalah pendorong utama permintaan kopi keliling.

Robustness Check & Validasi Silang Berbasis Waktu

Skema *rolling-origin cross-validation* memperlihatkan kinerja LSTM yang stabil lintas lipatan; simpangan baku (SD) pada sMAPE relatif kecil dibanding ARIMA. Uji residual memperlihatkan autokorelasi sisa yang lebih rendah pada LSTM, indikasi bahwa pola utama telah dipelajari model. Selain itu, percobaan sensitivitas terhadap parameter kunci (*sequence length* dan *dropout*) menunjukkan jejak kinerja yang halus: window 28–56 hari memberikan keseimbangan terbaik antara generalisasi dan daya tangkap musiman.

Dampak Bisnis yang Terukur

Dengan sMAPE turun 2–4 poin persentase (dan MAPE turun 28–30% relatif), simulasi sederhana menunjukkan potensi pengurangan biaya persediaan harian hingga 10–20%, tergantung komposisi biaya bahan (biji kopi, susu, gula, es) dan waktu simpan. Dalam konteks lokasi, akurasi yang lebih tinggi memungkinkan penjadwalan titik jual yang lebih presisi (kampus vs perkantoran), sehingga pendapatan dapat dioptimalkan pada hari-hari puncak.

Ancaman terhadap Validitas & Mitigasi

Beberapa faktor dapat mempengaruhi validitas eksternal: (i) cakupan data masih terbatas pada satu pelaku UMKM; (ii) adanya event lokal ekstrem (konser/bazar) yang tidak tercatat sebagai fitur; (iii) **concept drift** akibat perubahan tren kopi musiman. Mitigasi yang disarankan: perluasan sampel multi-UMKM, penambahan kalender event lokal, serta retraining berkala (mis. triwulan) dengan pemantauan sMAPE mingguan.

5. KESIMPULAN DAN SARAN

A. Kesimpulan

1. Penelitian ini menunjukkan bahwa penerapan metode *Deep Learning* klasik (LSTM) memberikan hasil peramalan permintaan UMKM kopi keliling yang lebih akurat dibandingkan metode statistik klasik (ARIMA). Hal ini terlihat dari nilai MAPE, sMAPE, dan RMSE yang secara konsisten lebih rendah pada LSTM baik untuk horizon 7 maupun 14 hari.
2. Uji *Diebold–Mariano* (DM) memperkuat temuan ini dengan menunjukkan bahwa perbedaan akurasi antara ARIMA dan LSTM signifikan secara statistik ($p < 0,05$). Tanda negatif pada statistik DM menunjukkan bahwa LSTM unggul karena memiliki error yang lebih rendah. Dengan demikian, LSTM dapat dijadikan model utama dalam peramalan permintaan UMKM kopi keliling.
3. Secara praktis, hasil peramalan dengan akurasi lebih tinggi berdampak pada efisiensi manajemen persediaan, pengurangan risiko kelebihan atau kekurangan stok, serta optimalisasi penjadwalan lokasi penjualan. Hal ini penting bagi UMKM kopi keliling yang beroperasi dengan sumber daya terbatas dan sangat bergantung pada pola permintaan harian maupun mingguan.
4. Penelitian ini juga menegaskan bahwa integrasi faktor eksternal seperti cuaca, kalender, dan lokasi dapat meningkatkan kualitas peramalan. Oleh karena itu, pendekatan berbasis LSTM dengan fitur eksternal relevan sangat direkomendasikan sebagai solusi strategis untuk mendukung daya saing dan keberlanjutan UMKM kopi keliling di era ekonomi kreatif.

B. Saran

Keterbatasan penelitian ini adalah data yang digunakan masih terbatas pada satu UMKM kopi keliling. Generalisasi ke UMKM lain membutuhkan dataset yang lebih beragam. Selain itu, model belum mempertimbangkan data tidak terstruktur seperti tren media sosial atau event lokal. Untuk penelitian selanjutnya, dapat ditambahkan model *deep learning modern* seperti Informer atau Autoformer untuk horizon yang lebih panjang.

DAFTAR REFERENSI

- Angraini, Y., Adisecha, R. S., Nawawi, N. I. N., Izzati, N. D., Najmuddin, M. T., Rabbani, N. A., & Pangestika, A. P. (2025). Comparative Analysis of ARIMA and LSTM Methods for Sea Surface Temperature Forecasting in the Sunda Strait. *Jurnal Matematika, Statistika Dan Komputasi*, 21(3), 868–885.
- Badan Pusat Statistik. (2024). *Statistik Penyediaan Makanan dan Minuman 2023* (2024th ed., Vol. 7). Badan Pusat Statistik.
- Januschowski, T., Gasthaus, J., Wang, Y., Salinas, D., Flunkert, V., Bohlke-Schneider, M., & Callot, L. (2020). Criteria for classifying forecasting methods. *International Journal of Forecasting*, 36(1), 167–177.
- Mualifah, L. N. A., Husna, D., Yasmin, J., Berbina, A. C., Yumna, F., Uraidy, M. A., & Pangestika, A. P. (2025). PERBANDINGAN PERFORMA MODEL ARIMA-GARCH DAN LSTM DALAM MERAMALKAN JUMLAH KUNJUNGAN WISATAWAN DANAU KASTOBA. *Jurnal Gaussian*, 14(2), 314–324.
- Muthiah, H., & Hamidah, N. K. (2025). Integrasi Machine Learning untuk Optimalisasi Prediksi Permintaan Produk pada UMKM Kuliner. *Jurnal PenKoMi: Kajian Pendidikan Dan Ekonomi*, 8(1), 229–233.
- Muthiah, H., Hamidah, N. K., & Aryani, F. (2025). STRATEGI PENINGKATAN EKONOMI KREATIF MELALUI PREDIKSI PERMINTAAN PRODUK UMKM KERAJINAN. *Jurnal PenKoMi: Kajian Pendidikan Dan Ekonomi*, 8(2), 345–348.
- Nurhakiki, J., & Yahfizham, Y. (2024). Studi Kepustakaan: Pengenalan 4 Algoritma Pada Pembelajaran Deep Learning Beserta Implikasinya. *Pendekar: Jurnal Pendidikan Berkarakter*, 2(1), 270–281.
- Pahlevi, E. S. M. (2024). *Kecerdasan Buatan dengan Deep Learning*. Elex Media Komputindo.
- Pandji, B. Y., Indwiarti, I., & Rohmawati, A. A. (2019). Perbandingan Prediksi Harga Saham dengan model ARIMA dan Artificial Neural Network. *Indonesian Journal on Computing (Indo-JC)*, 4(2), 189–198.
- Rachman, R. (2018). Penerapan metode moving average dan exponential smoothing pada peramalan produksi industri garment. *Jurnal Informatika*, 5(2), 211–220.

- Rahmita, F., Purwaningsih, S., Sari, W. G., Rawati, M., & Effendy, Y. (2023). Teori Permintaan (Demand) dan Subsitusi Efek Dalam Ekonomi Islam. *Jurnal Riset Rumpun Ilmu Ekonomi*, 2(1), 246–258.
- Tarumingkeng, R. C. (2024a). *DEEP LEARNING*.
- Tarumingkeng, R. C. (2024b). *DEEP LEARNING*.
- Yudistira, N., Alfiansih, L. M. D., Andriyani, N. I., Essayem, W., Nurdian, I. W., Maghfiroh, N. A., & Maulida, N. (2023). *Prediksi Deret Waktu Menggunakan Deep Learning*. Universitas Brawijaya Press.