

BAB I

PENDAHULUAN

1.1. Latar Belakang

Perkembangan teknologi dan informasi di era globalisasi telah mendorong inovasi dalam berbagai sektor, termasuk dunia bisnis. Persaingan yang ketat menuntut perusahaan untuk terus beradaptasi dan meningkatkan efisiensi operasional (Martini, Avif, & Izzudin, 2021). Salah satu inovasi yang berkembang di bidang penjualan adalah penggunaan *vending machine* sebagai solusi otomatisasi yang dapat beroperasi mandiri tanpa interaksi manusia (Anwar, Adikara, Setiyati, Satria, & Satriawan, 2021). Namun, keunggulan tersebut sering kali terhambat oleh kurangnya pemantauan permintaan produk harian, yang mengakibatkan masalah seperti penumpukan produk yang kurang diminati atau kekurangan produk yang sangat dibutuhkan (Frira Sesilia, Viktor Handrianus Pranatawijaya, & Ressa Priskila, 2024). Hal tersebut berdampak pada kepuasan pelanggan dan potensi keuntungan bagi pengelola *vending machine*. Oleh karena itu, pemantauan permintaan produk menjadi suatu kebutuhan penting untuk mendukung pengelolaan *vending machine* secara optimal (Taufik Hidayat, Suarna, & Rahaningsih, 2023).

Penelitian sebelumnya telah mengkaji prediksi permintaan produk dengan berbagai metode. Pendekatan konvensional seperti *Economic Order Quantity* (EOQ) digunakan untuk menentukan jumlah pemesanan yang optimal guna meminimalkan biaya persediaan, meliputi biaya pemesanan dan penyimpanan (Achmad & Dedgo, 2023). Meskipun efektif untuk pola permintaan yang stabil,

metode ini kurang adaptif terhadap perubahan permintaan yang fluktuatif dan dinamis seperti pada sistem vending machine (Deraz, 2023).

Selain pendekatan konvensional, metode machine learning klasik seperti *Autoregressive Integrated Moving Average* (ARIMA) dan *Support Vector Regression* (SVR) juga telah diterapkan dalam memprediksi permintaan produk. ARIMA mampu mengidentifikasi pola linier dan musiman, namun kesulitan dalam menangani variasi nonlinier pada data yang bersifat dinamis. Di sisi lain, SVR memiliki performa yang baik pada pola data sederhana, tetapi tidak mampu mempelajari ketergantungan jangka panjang pada data deret waktu yang kompleks (Mehmood, Broderick, Davies, Bashir, & Rabie, 2024).

Perkembangan *deep learning* menawarkan pendekatan alternatif yang lebih komprehensif. Arsitektur *Long Short-Term Memory* (LSTM) terbukti efektif dalam menangkap pola deret waktu yang kompleks dibandingkan metode tradisional (Kilimci et al., 2019). Namun, implementasi LSTM memerlukan jumlah data yang besar serta sumber daya komputasi yang memadai, sehingga menimbulkan tantangan tersendiri dalam penerapannya (Azis, Zy, & Sunge, 2024).

Permasalahan lain yang muncul dalam penelitian sebelumnya adalah keterbatasan jenis data yang digunakan. Sebagian besar penelitian hanya berfokus pada data penjualan dan belum mengintegrasikan variabel lain yang memengaruhi permintaan, serta belum memetakan karakteristik data secara menyeluruh (Feizabadi, 2022). Proses *Exploratory Data Analysis* (EDA) seharusnya dilakukan untuk memahami distribusi, tren, anomali, dan pola data sebelum membangun model prediksi. Namun, proses ini belum banyak dimanfaatkan secara

komprehensif, sehingga model yang dibangun kurang mampu menggambarkan dinamika permintaan yang fluktuatif secara akurat (Riza, 2022).

Berdasarkan penelitian (Mehmood, Bashir, Rabie, Broderick, & Davies, 2023) telah menerapkan *machine learning* untuk memprediksi permintaan produk pada *vending machine* dengan mempertimbangkan variabel eksternal. Namun, model tersebut masih terbatas dalam menangkap pola jangka panjang. Kondisi ini menimbulkan kesenjangan penelitian, yaitu belum adanya pendekatan yang secara simultan mengintegrasikan EDA secara komprehensif dan memanfaatkan arsitektur LSTM untuk mempelajari pola permintaan produk *vending machine* secara lebih adaptif dan berkelanjutan. (Azis et al., 2024) Selain mampu mempelajari urutan data historis secara mendalam, LSTM juga berpotensi menghasilkan prediksi yang lebih akurat dengan mempertimbangkan dinamika waktu dan tren permintaan. (Khan et al., 2020).

Penelitian ini bertujuan untuk membangun model prediksi permintaan produk pada *vending machine* dengan menggunakan algoritma *Long Short-Term Memory* (LSTM), sebagai solusi atas tantangan fluktuasi permintaan. Model ini dirancang untuk mengenali pola penjualan berdasarkan data historis, sehingga model dapat menyesuaikan jumlah permintaan produk secara tepat dan responsif terhadap permintaan aktual. Selain itu, penelitian ini juga mengevaluasi performa model LSTM dalam menganalisis tren permintaan dan akurasi prediksinya.

1.2. Rumusan Masalah

Berdasarkan uraian latar belakang di atas maka di dapatlah beberapa rumusan masalah sebagai berikut:

1. Bagaimana mengatasi permintaan produk pada vending machine untuk mencegah kekurangan dan penumpukan produk dengan menggunakan model LSTM?
2. Bagaimana model LSTM dapat meningkatkan performa model prediksi permintaan produk pada vending machine dalam menganalisis pola penjualan?

1.3. Tujuan Penelitian

Berdasarkan uraian rumusan masalah di atas maka di dapatlah tujuan yang ingin dicapai sebagai berikut:

1. Menerapkan model *Long Short-Term Memory* (LSTM) untuk memprediksi permintaan produk pada *vending machine* guna mencegah terjadinya kekurangan dan penumpukan stok produk.
2. Mengevaluasi performa model LSTM dalam meningkatkan akurasi prediksi permintaan produk pada vending machine berdasarkan analisis pola penjualan.

1.4. Manfaat Penelitian

Adapun manfaat dari penelitian ini diharapkan sebagai berikut:

1. Model prediksi memberikan wawasan berbasis data yang memungkinkan pengelola untuk membuat keputusan yang lebih tepat terkait permintaan produk.
2. Model prediksi dapat membantu mengoptimalkan pengelolaan stok, mengurangi pemborosan dan kekurangan produk, serta meningkatkan efisiensi operasional *vending machine*.
3. Prediksi yang tepat memastikan produk yang diinginkan pelanggan selalu tersedia, meningkatkan kepuasan dan loyalitas pelanggan.

4. Model ini dapat digunakan sebagai referensi dalam pengembangan teknologi manajemen stok dan prediksi permintaan, tidak hanya untuk *vending machine*, tetapi juga untuk sektor ritel dan distribusi lainnya.

1.5. Batasan Penelitian

Adapun yang menjadi Batasan dalam penelitian ini sebagai berikut:

1. Dataset yang digunakan merupakan data transaksi penjualan harian *vending machine* tahun 2022 yang berasal dari dataset public yaitu Kaggle <https://www.kaggle.com/datasets/awesomeasingh/vending-machine-sales>
2. Variabel yang digunakan dalam dataset untuk penelitian ini meliputi waktu dan data penjualan.
3. Penelitian ini berfokus pada penerapan algoritma LSTM untuk memprediksi penyediaan produk berdasarkan pola temporal dalam data penjualan.
4. Evaluasi model LSTM dilakukan menggunakan MAE, MSE, dan RMSE dengan data terbatas pada periode tertentu tanpa simulasi atau uji coba di luar dataset.

1.6. Sistematika Penulisan

Sistematika penulisan dalam penelitian ini mencakup uraian isi dari setiap bab yang disusun secara runtut dan terstruktur sebagai berikut:

BAB I PENDAHULUAN

Bab ini memuat latar belakang penelitian, rumusan masalah penelitian, tujuan penelitian, manfaat penelitian, batasan masalah, serta sistematika penulisan.

BAB II LANDASAN TEORI

Bab ini berisi teori-teori dasar yang mendukung penelitian, seperti konsep, metode, dan algoritma yang digunakan.

BAB III METODE PENELITIAN

Bab ini menjelaskan langkah-langkah yang dilakukan dalam pelaksanaan penelitian, meliputi tahapan teknis dan prosedur yang digunakan untuk mencapai tujuan penelitian.

BAB IV HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil yang diperoleh dari proses penelitian serta pembahasan yang berkaitan dengan temuan tersebut.

BAB V KESIMPULAN

Bab ini memuat kesimpulan dari hasil penelitian dan saran yang dapat dijadikan bahan pertimbangan untuk penelitian selanjutnya.