

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Yang Relevan

Penelitian menyimpulkan bahwa metode *Recurrent Neural Network* (RNN) dan *Long Short-Term Memory* (LSTM) dapat digunakan secara efektif untuk memprediksi harga beras di Indonesia. Dalam penelitiannya, mereka memanfaatkan data dari Badan Pusat Statistik (BPS) berupa harga rata-rata beras tingkat penggilingan pada periode tahun 2013 hingga 2023 yang disajikan setiap bulan. Hasil penelitian menunjukkan bahwa model RNN menghasilkan nilai RMSE terkecil sebesar 0.73 pada beras kualitas medium, sedangkan model LSTM menghasilkan nilai MAE terkecil sebesar 2.31 pada beras luar kualitas. Penelitian ini memiliki relevansi yang kuat dengan penelitian penulis karena sama-sama membahas prediksi harga beras menggunakan pendekatan deep learning, meskipun penelitian penulis lebih fokus pada penggunaan GRU untuk memprediksi harga beras premium pada periode tahun 2026–2027 (Santoso et al., 2024).

Penelitian menyimpulkan bahwa metode *Double Exponential Smoothing* mampu memberikan hasil prediksi yang baik untuk harga beras kualitas premium di tingkat nasional. Penelitian ini menggunakan data dari BPS mulai Januari 2018 hingga Februari 2022. Hasil penelitian menunjukkan nilai MAPE sebesar 1,00097% dengan hasil prediksi harga beras pada periode Maret hingga Desember 2022 berada pada kisaran Rp 9.836 sampai Rp 9.919. Temuan ini menunjukkan bahwa harga beras cenderung stabil dengan adanya kenaikan secara bertahap. Meskipun metode ini efektif untuk kondisi harga yang relatif stabil, namun model GRU dinilai lebih sesuai untuk data time series yang bersifat dinamis dan dipengaruhi oleh berbagai faktor eksternal seperti kondisi cuaca (Ilmananda & Alfianty, 2022).

Penelitian menyimpulkan bahwa metode *K-Nearest Neighbor* (KNN) dapat digunakan untuk memprediksi harga beras premium dengan cukup baik. Penelitian ini memanfaatkan data dari BPS Kota Bandung dan BMKG Kota Bandung pada periode tahun 2014 hingga 2019. Berdasarkan hasil pengujian, nilai $K = 2$ memberikan performa terbaik dengan nilai RMSE sebesar 0.044 pada data yang telah dinormalisasi. Walaupun KNN terbukti mampu memberikan prediksi yang baik, namun penelitian ini juga

menunjukkan bahwa metode ini masih memiliki keterbatasan dalam mengelola data deret waktu yang kompleks jika dibandingkan dengan model GRU (Mukhlisin et al., 2019).

Penelitian menyimpulkan bahwa metode *Stacked LSTM* dapat digunakan untuk memodelkan prediksi harga beras medium di wilayah Jawa Timur. Penelitian ini menggunakan data mingguan tahun 2023 dari Siskaperbapo dan memanfaatkan algoritma Adamax yang menghasilkan nilai RMSE terbaik sebesar 10.912. Namun, penelitian ini juga menemukan adanya gejala *overfitting* pada model sehingga diperlukan proses optimasi lebih lanjut untuk meningkatkan akurasi. Hal ini menjadi alasan penulis memilih menggunakan GRU karena dinilai lebih stabil dalam menghadapi fluktuasi harga beras yang dinamis dan tidak mudah mengalami *overfitting* (Sukmaningtiyas et al., 2023).

Penelitian menyimpulkan bahwa metode *Gradient Boosted Trees Regression* (GBTR) efektif digunakan untuk memprediksi harga beras premium di Indonesia. Penelitian ini menggunakan data BPS periode Januari 2013 hingga Februari 2024. Hasil penelitian menunjukkan nilai RMSE sebesar 0.0473, nilai *R-Squared* sebesar 0.9047, dan nilai MAPE sebesar 0.1241. Nilai-nilai tersebut menunjukkan bahwa model GBTR memiliki tingkat akurasi yang sangat baik. Meskipun demikian, penelitian penulis tetap memilih menggunakan model GRU karena memiliki kelebihan dalam menangani perubahan harga beras yang dinamis di tingkat provinsi (Andriyani et al., 2024).

Penelitian menyimpulkan bahwa model *Gated Recurrent Unit* (GRU) sangat akurat dalam memprediksi harga beras multivariat yang dipengaruhi oleh berbagai faktor seperti kondisi cuaca, ekonomi, dan kesehatan. Hasil penelitian menunjukkan nilai MAPE sebesar 0.964% pada data training dan 2.628% pada data testing. Hal ini menunjukkan bahwa GRU memiliki kemampuan prediksi yang baik. Penelitian ini sangat relevan dengan penelitian penulis karena sama-sama menggunakan model GRU, meskipun penelitian penulis lebih berfokus pada prediksi berdasarkan provinsi (Ananda, 2023).

Penelitian menyimpulkan bahwa model GRU mampu memberikan prediksi yang sangat akurat terhadap harga pangan, termasuk harga beras di Kota Bandung. Data penelitian diperoleh dari Pusat Informasi Harga Pangan Strategis Nasional (PIHPS) dengan periode Januari 2018 hingga Februari 2023. Hasil penelitian menunjukkan bahwa GRU mampu menangani data yang bersifat dinamis dan tidak stabil dengan tingkat error

yang rendah. Hal ini mendukung pemilihan GRU dalam penelitian penulis (Oni et al., 2023).

Penelitian menyimpulkan bahwa algoritma GRU mampu digunakan untuk menganalisis tren dan memprediksi harga beras secara akurat menggunakan data harian periode Januari 2022 hingga April 2025. Hasil penelitian menunjukkan nilai MAPE yang rendah pada berbagai jenis beras sehingga membuktikan bahwa GRU efektif untuk prediksi jangka panjang. Hasil ini semakin memperkuat alasan penulis menggunakan GRU sebagai model utama dalam penelitian ini (Serenita et al., 2025).

Penelitian menyimpulkan bahwa metode *Long Short-Term Memory* (LSTM) lebih akurat dibandingkan *Multilayer Perceptron* (MLP) dalam memprediksi harga beras di Indonesia. Penelitian ini menggunakan data dari PT Food Station periode Januari 2016 hingga Januari 2020 dengan total 1429 data yang dibagi menjadi 1245 data latih dan 184 data uji. Hasil penelitian menunjukkan nilai RMSE sebesar 0.27 untuk model LSTM pada data uji, sedangkan MLP menghasilkan RMSE sebesar 39.32. Penelitian ini relevan dengan penelitian penulis karena sama-sama menggunakan jaringan saraf untuk prediksi harga beras, namun penelitian penulis lebih fokus pada prediksi harga di periode 2026–2027 (Sen et al., 2020).

2.2 Landasan Teori

Landasan teori membahas berbagai konsep dan teori yang digunakan dalam penelitian ini. Teori-teori tersebut diperoleh dari sumber-sumber yang terpercaya, termasuk buku, jurnal, dan artikel untuk mendukung dan menjadi acuan bagi penelitian ini.

2.2.1 Harga beras sebagai komoditas

Beras merupakan makanan pokok utama masyarakat Indonesia yang memiliki peran sangat penting, bukan hanya dari sisi sosial, tetapi dari sisi ekonomi dan politik juga. Lebih dari 90% penduduk Indonesia setiap hari mengonsumsi beras sebagai sumber energi utama. Karena itu ketersediaan beras dan stabilitas harga menjadi sangat berpengaruh di kehidupan masyarakat. Kenaikan harga beras yang signifikan akan langsung mempengaruhi daya beli masyarakat, khususnya masyarakat yang

berpenghasilan rendah, karena sebagian besar pengeluaran mereka digunakan untuk kebutuhan pangan (Pramanda & Priyatmono, 2025).

Dalam skala yang lebih luas, harga beras juga sangat mempengaruhi kondisi ekonomi nasional. Beras masuk kedalam kelompok bahan makanan yang berkontribusi dalam Indeks Harga Konsumen (IHK). Oleh karena itu, ketidakstabilan harga beras secara langsung sangat inflasi, baik tingkat kota maupun nasional. Penelitian (Pramanda & Priyatmono, 2025) menunjukkan bahwa perubahan harga beras menjadi salah satu pendorong utama inflasi di kota maupun nasional. Sementara faktor lain seperti cadangan beras atau stok relatif memiliki pengaruh lebih kecil terhadap laju inflasi.

Faktor-faktor yang membuat harga beras tidak seimbangan sangat beragam. Dari sisi produksi, hasil panen juga dipengaruhi oleh luasnya lahan, ketersediaan air, kondisi cuaca, hingga penerapan teknologi pertanian. Bencana alam seperti banjir dan kekeringan juga bisa menurunkan produksi sehingga harga beras naik. Dari sisi distribusi, masalah infrastruktur jalan yang kurang baik atau biaya logistik yang tinggi membuat harga beras jauh lebih mahal dibandingkan harga di tingkat petani atau penggilingan (Eliyah, 2020).

Kebijakan pemerintah sangat berperan penting dalam menjaga harga beras tetap stabil. Program operasi pasar, penerapan harga eceran tertinggi (HET), dan pengelolaan cadangan beras pemerintah biasanya digunakan untuk menahan melonjaknya harga beras. Namun, keberhasilan kebijakan ini sering dipengaruhi oleh kondisi pasar dan faktor eksternal, seperti harga beras internasional dan nilai tukar rupiah (Pramanda & Priyatmono, 2025)

Selain itu, permintaan beras juga bisa naik turun mengikuti musim. Misalnya, pada bulan ramadan dan menjelang Idul Fitri, konsumen beras biasanya meningkat sehingga harga ikut naik. Walaupun pemerintah terus mendorong diversifikasi pangan ke komoditas lain seperti jagung dan singkong, kenyataannya beras menjadi pilihan utama masyarakat Indonesia dan sangat sulit digantikan (Nurmeryteni, 2025).

Karena itu harga beras bisa dibilang sangat dinamis dan sulit diprediksi jika hanya menggunakan metode perhitungan sederhana. (Pramanda & Priyatmono, 2025). Menekankan bahwa pola harga beras lebih tepat dianalisis menggunakan pendekatan teknologi canggih seperti kecerdasan buatan. Metode *deep learning* dinilai sangat mampu

menangkap pola data yang kompleks sehingga hasil prediksi harga beras bisa lebih akurat dan berguna untuk pemerintah maupun pelaku pasar.

2.2.2 Kerangka Data Harga Beras Bulanan Berdasarkan Provinsi di Indonesia

Pengelolaan serta analisis data harga beras di Indonesia memerlukan struktur data yang jelas dan terorganisir agar hasil penelitian dapat dipertanggungjawabkan dengan baik. Dataset yang digunakan dalam penelitian ini bersumber dari data resmi yang disajikan oleh Badan Pusat Statistik (BPS), dengan harga beras bulanan yang tercatat berdasarkan wilayah administratif provinsi. Dataset ini tidak mencakup informasi per kota atau kabupaten, melainkan berfokus pada agregasi harga beras di tingkat provinsi. Pendekatan agregasi ini banyak digunakan dalam penelitian harga komoditas karena lebih stabil dan dapat menggambarkan secara umum dinamika pasar beras di tingkat yang lebih luas, serta relevan untuk analisis kebijakan pangan nasional yang lebih besar. Data yang digunakan dalam penelitian ini mencakup periode antara 2022 hingga 2025, yang mencerminkan kebijakan pangan jangka panjang yang diterapkan oleh pemerintah Indonesia untuk menjaga stabilitas harga beras. Periode tersebut sangat penting untuk merencanakan kebijakan pangan di masa depan, terutama dengan tantangan-tantangan yang dihadapi terkait perubahan iklim dan perkembangan sosial-ekonomi di Indonesia (Sukmaningtiyas et al., 2023).

Struktur dataset ini disusun untuk mendukung analisis deret waktu (time series), yang mengamati harga beras secara berkala setiap bulan. Setiap nilai harga yang tercatat mewakili rata-rata harga beras pada bulan tertentu di provinsi tersebut. Pendekatan deret waktu memungkinkan peneliti untuk mengidentifikasi pola-pola jangka panjang, fluktuasi musiman, dan perubahan harga yang terjadi secara periodik. Beberapa penelitian sebelumnya menunjukkan bahwa data harga beras bulanan memiliki karakteristik musiman yang sangat kuat, terutama terkait dengan siklus panen, distribusi, serta periode hari beras keagamaan. Dengan demikian, analisis menggunakan time series merupakan pendekatan yang tepat dalam memodelkan pola harga beras (Hasanudin, 2020).

Secara konseptual, kerangka data harga beras bulanan dapat di bagi ke dalam beberapa komponen utama, sebagaimana di sajikan dalam Tabel 2.1 berikut. Pembagian komponen ini bertujuan untuk memperjelas struktur data sekaligus memudahkan proses

pemodelan dan interpretasi hasil prediksi. Pengelompokan data berdasarkan dimensi wilayah, waktu, dan variabel utama merupakan praktik umum dalam penelitian peramalan harga komoditas berbasis data historis (Tussifah, 2023).

Tabel 2. 1 Kerangka Data Harga Beras Bulanan Berdasarkan Provinsi di Indonesia

No	Parameter	Satuan	Keterangan
Identitas Data			
1	Provinsi	–	Nama provinsi di Indonesia
2	Periode Data	Bulan	Januari 2022 sampai Desember 2025
Data Harga			
3	Harga Beras	Rp/kg	Harga beras bulanan pada masing-masing provinsi
4	Frekuensi Pencatatan	–	Data dicatat secara bulanan
5	Bentuk Data	–	Data runtun waktu (<i>time series</i>)
Struktur Dataset			
6	Struktur Tabel	–	Tabel lebar, satu baris mewakili satu provinsi
7	Jumlah Provinsi	–	Seluruh provinsi yang tercatat dalam dataset
8	Sumber Data	–	Dataset harga beras bulanan berdasarkan provinsi

2.2.3 Time Series

Data *time series* merupakan data yang dicatat secara berurutan berdasarkan waktu, misalnya data harian, mingguan, bulanan, dan tahunan. Dalam penelitian ini harga beras bulanan termasuk data time series, karena setiap hari harganya tercatat dan dari data bulanan bisa melihat pola dari waktu ke waktu (Supriadin et al., 2024).

Data *time series* punya beberapa karakteristik penting. Harga pada suatu periode biasanya di pengaruhi oleh harga sebelumnya, ada tren jangka panjang yang menggambarkan pergerakan harga secara umumnya, pola musim yang muncul secara berkala seperti harga beras yang naik menjelang Ramadan, siklus jangka panjang yang tidak selalu tepat waktunya, dan fluktuasi acak atau noise yang muncul akibat hal-hal yang sulit di prediksi seperti bencana alam atau gangguan distribusi (Tardini & Suharjito, 2024).

Pola harga beras, yang merupakan contoh dari data time series, cenderung memiliki kompleksitas yang tinggi dan tidak selalu bersifat linear. Sebagai data time series, harga beras dipengaruhi oleh nilai-nilai sebelumnya, menciptakan ketergantungan temporal antar periode yang harus diperhatikan dalam proses prediksi. Pendekatan modern menggunakan deep learning khususnya Recurrent Neural Networks (RNN) dan Gated Recurrent Unit (GRU) dapat menangani pola yang lebih kompleks dan non-linear yang terdapat dalam data time series, terutama ketika data menunjukkan hubungan jangka panjang yang tidak linier. Metode ini memungkinkan model untuk mempelajari hubungan yang lebih kompleks antar periode waktu dan mengidentifikasi pola-pola tersembunyi dalam data, menghasilkan prediksi harga beras yang lebih akurat dan relevan, yang penting untuk pengambilan keputusan oleh pemerintah maupun pedagang (Magh Heryan Tudaan, 2025).

2.2.4 Sliding Window

Sliding Window adalah sebuah teknik dalam analisis data sekuensial, seperti deret waktu (*time series*), yang digunakan untuk membagi dataset besar menjadi beberapa subset kecil yang lebih mudah dikelola dan dianalisis. Teknik ini sangat berguna dalam pembelajaran mesin, terutama dalam konteks peramalan, di mana model mempelajari pola data yang terjadi dalam periode waktu tertentu dan membuat prediksi berdasarkan informasi yang tersedia dalam rentang waktu tersebut. Dengan menggunakan sliding window, data dipecah menjadi *window* atau jendela yang memiliki panjang tetap, dan jendela ini digeser seiring dengan berjalannya waktu (Norwawi, 2021).

Pada teknik ini, panjang *window* (atau periode waktu) ditentukan terlebih dahulu sesuai dengan kebutuhan analisis. Misalnya, dalam analisis harga komoditas, panjang *window* dapat berupa data bulanan yang mencakup tiga bulan berturut-turut. Setiap *window* mencakup sekumpulan data yang digunakan untuk mempelajari pola dan hubungan antar data pada periode tersebut. Setelah model dilatih menggunakan data dalam *window* pertama, *window* akan digeser satu langkah ke depan, sehingga data baru yang datang akan digunakan untuk memperbarui model dan membuat prediksi untuk periode berikutnya. Proses ini berlanjut hingga seluruh data dalam deret waktu digunakan (Norwawi, 2021).

Keunggulan dari metode *sliding window* adalah kemampuannya untuk menangani data yang berubah secara dinamis. Dengan menggantikan data lama dengan data terbaru dalam setiap pergeseran *window*, model dapat memperbarui pemahamannya tentang pola dan tren dalam data sesuai dengan perubahan yang terjadi seiring waktu. Hal ini sangat berguna dalam kasus-kasus di mana pola dalam data dapat berubah atau memiliki ketergantungan jangka panjang yang perlu dipertahankan, seperti dalam peramalan harga beras yang dipengaruhi oleh faktor musiman atau kondisi pasar (Norwawi, 2021).

Selain itu, *sliding window* juga membantu mengatasi masalah *overfitting*, karena model hanya menggunakan subset data dalam jangka waktu tertentu untuk melatih dirinya, bukan seluruh dataset yang mungkin memiliki fluktuasi atau noise yang tidak relevan. Teknik ini meningkatkan generalisasi model, memungkinkan model untuk belajar pola-pola yang lebih relevan dan menghindari pengaruh dari data yang tidak signifikan atau tidak lagi relevan. Dengan demikian, *sliding window* adalah teknik yang efektif untuk analisis data deret waktu, terutama dalam aplikasi peramalan yang memerlukan pemahaman tentang perubahan pola yang terjadi secara berkelanjutan (Norwawi, 2021).

2.2.5 Pengaruh Cuaca Terhadap Harga Beras

Perubahan cuaca yang sering kali datang secara tiba-tiba dan tak terduga, ternyata memiliki dampak yang sangat besar terhadap pertanian, khususnya dalam produksi beras. Indonesia dengan iklim tropis yang terbagi menjadi dua musim utama, seringkali menghadapi cuaca ekstrim, baik hujan lebat yang tidak kunjung reda maupun kekeringan yang berlarut-larut. Ini bukan mengganggu keseharian masyarakat, tetapi menghambat kestabilan pasokan beras yang menjadi kebutuhan pokok semua masyarakat. Ketika cuaca mulai berubah secara drastis, dampaknya langsung terasa seperti penurunan hasil panen yang mengarah pada kelangkaan pasokan beras di pasaran (Fatmawati et al., 2024).

Hasil wawancara dengan para petani menunjukkan betapa besar pengaruh cuaca terhadap hasil panen mereka. Hujan yang terlalu banyak dapat membuat batang padi ambruk dan memengaruhi kualitas beras, yang pada akhirnya membuat beras sulit dijual dengan harga normal. Bahkan dalam kasus-kasus tertentu, petani mengalami gagal panen total akibat cuaca yang tidak menentu. Di musim kemarau yang berkempanjangan,

kekuarangan air menyebabkan padi tidak berkembang dengan baik, memperburuk ketahanan pangan, dan membuat harga beras melambung tinggi karena pasokan yang terbatas (Fatmawati et al., 2024).

Berdasarkan penelitian ini, sangat jelas bahwa peran pemerintah menjadi sangat penting untuk membantu petani bertahan dari cuaca ekstrim. Salah satu langkah yang bisa dilakukan adalah dengan memberikan subsidi pupuk KLC yang berguna untuk memperkuat batang padi agar tidak mudah roboh saat hujan lebat. Selin itu, pemerintah juga dapat menyediakann fasilitas sumur bor untuk memastikan petani tetap bisa mengairi sawah mereka saat musim kemarau datang. Dengan begitu diharapkan bukan hanya harga beras yang lebih stabil, tetapi juga kesejahteraan petani yang dapat meningkat meskipun mereka harus berhadapan dengan cuaca yang semakun tidak bisa di prediksi (Fatmawati et al., 2024).

2.2.6 Normalisasi Data

Data harga beras menunjukkan variasi yang signifikan antar provinsi dan bulan, di mana harga di satu provinsi dapat jauh lebih tinggi dibandingkan dengan provinsi lainnya. Variabilitas ini adalah hal yang wajar dalam konteks dunia nyata. Namun, apabila data yang memiliki skala yang sangat berbeda-beda dimasukkan langsung ke dalam jaringan saraf, proses pelatihan model dapat menjadi lebih lambat atau bahkan tidak stabil (Islamy et al., 2025).

Untuk mengatasi masalah tersebut, dilakukan normalisasi data menggunakan metode Min-Max Scaling, yang bertujuan untuk mengubah nilai-nilai data ke dalam rentang antara 0 dan 1. Proses ini sangat penting untuk meningkatkan efisiensi pelatihan model dan mencegah dominasi nilai-nilai tertentu yang dapat mempengaruhi kestabilan proses pembelajaran dalam jaringan saraf (Islamy et al., 2025). Persamaan untuk normalisasi data dirumuskan menggunakan Persamaan 1.

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

Berdasarkan Persamaan 1, X adalah nilai harga beras asli yang akan dinormalisasi, sementara X' adalah nilai harga beras setelah dilakukan normalisasi.

Nilai $X_{\min}$ dan $X_{\max}$ masing-masing merupakan harga beras terendah dan tertinggi dalam dataset yang digunakan (Islamy et al., 2025).

Proses normalisasi bertujuan untuk menyelaraskan rentang nilai data yang bervariasi menjadi skala yang konsisten, sehingga memudahkan model dalam mempelajari pola tanpa terpengaruh oleh perbedaan skala antar fitur. Secara ilmiah, normalisasi dengan Min-Max Scaling berfungsi untuk mengurangi ketidakcocokan skala antar fitur yang seringkali memperlambat atau mengganggu konvergensi model. Dengan normalisasi ini, harga beras yang paling tinggi akan didekatkan ke angka 1, sementara harga yang paling rendah akan mendekati angka 0. Seluruh nilai harga beras kemudian berada dalam rentang yang seragam, yakni $[0, 1]$, yang pada gilirannya meningkatkan kecepatan dan kestabilan proses pelatihan model deep learning.

Dengan adanya normalisasi, model dapat lebih mudah mengoptimalkan parameter tanpa terpengaruh oleh skala yang tidak konsisten pada data, sehingga meminimalisir potensi masalah yang muncul akibat perbedaan skala antar variabel input yang beragam (Islamy et al., 2025)..

2.2.7 Inverse Scaling

Setelah proses prediksi dilakukan menggunakan model GRU dan LSTM, nilai keluaran yang dihasilkan masih berada dalam bentuk data yang telah dinormalisasi. Artinya, nilai prediksi tersebut masih berada dalam rentang 0 hingga 1 dan belum mencerminkan harga beras yang sebenarnya dalam satuan rupiah. Oleh karena itu, diperlukan tahap lanjutan berupa inverse scaling untuk mengembalikan nilai prediksi ke skala asli (Wei et al., 2023).

Inverse scaling adalah proses untuk mengembalikan nilai prediksi dari skala normalisasi ke skala data asli. Proses ini dilakukan dengan menggunakan parameter minimum dan maksimum yang sama seperti saat proses normalisasi sebelumnya. Dengan cara ini, nilai hasil prediksi dapat dikonversi kembali sehingga merepresentasikan harga beras yang sesungguhnya (Wei et al., 2023). Rumus untuk inverse scaling dirumuskan menggunakan Persamaan 2.

$$X = X' \cdot (X_{\max} - X_{\min}) + X_{\min} \quad (2)$$

Berdasarkan Persamaan 2, X' merupakan nilai yang telah dinormalisasi, yang dihasilkan oleh model selama proses pelatihan dan prediksi. Nilai ini berada dalam rentang 0 hingga 1 dan belum mencerminkan harga beras yang sesungguhnya. X adalah nilai yang dikembalikan ke skala asli, yaitu harga beras dalam satuan rupiah yang sebenarnya, yang menjadi tujuan dari proses inverse scaling. Sementara itu, $X_{\min}$ dan $X_{\max}$ masing-masing merupakan nilai harga beras terendah dan tertinggi dalam dataset yang digunakan untuk normalisasi. Kedua nilai ini berfungsi sebagai parameter untuk mengubah skala prediksi yang berada di antara 0 dan 1 kembali ke rentang harga beras yang sesungguhnya (Wei et al., 2023).

Tahap inverse scaling ini memiliki peran yang sangat penting dalam proses evaluasi dan interpretasi hasil prediksi. Tanpa melakukan inverse scaling, hasil prediksi yang masih berada dalam skala normalisasi tidak bisa digunakan secara langsung untuk analisis lebih lanjut. Misalnya, tidak mungkin membandingkan prediksi harga beras yang dinormalisasi dengan harga beras aktual dalam satuan rupiah, baik dalam bentuk tabel maupun grafik. Selain itu, perhitungan nilai kesalahan, seperti Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), dan Mean Absolute Percentage Error (MAPE), harus dilakukan menggunakan data dalam skala asli agar hasil evaluasi yang diperoleh benar-benar mencerminkan akurasi model dalam konteks yang sesungguhnya. Dengan kata lain, inverse scaling memastikan bahwa hasil prediksi dapat diinterpretasikan dengan benar dan dapat dibandingkan secara langsung dengan data harga aktual, yang penting untuk mengevaluasi seberapa efektif model dalam memprediksi harga beras (Lstm, n.d.).

Dengan demikian, nilai hasil inverse scaling ini digunakan sebagai dasar dalam proses evaluasi kinerja model, serta dalam visualisasi perbandingan antara harga aktual dan harga hasil prediksi. Proses inverse scaling memastikan bahwa evaluasi model dan interpretasi hasil prediksi dilakukan dengan mempertimbangkan satuan data yang sesuai, yang dalam hal ini adalah harga beras dalam satuan rupiah (Lstm, n.d.).

2.2.8 Konsep *Machine Learning*

Machine Learning (ML) merupakan cabang dari kecerdasan buatan yang membuat komputer mampu belajar dari data untuk menghasilkan prediksi atau keputusan,

tanpa perlu diberi aturan yang sangat detail satu per satu. Sederhananya, model ML dilatih menggunakan data historis agar paham pola yang pernah terjadi, lalu pola tersebut dipakai untuk memperkirakan kondisi pada data baru (Schmid et al., 2025).

Dalam konteks peramalan harga, ML relevan karena harga komoditas biasanya membentuk pola yang berulang, misalnya tren naik-turun, fluktuasi musiman, atau perubahan yang dipengaruhi situasi tertentu. Dengan memanfaatkan data historis, ML membantu peneliti membangun model prediksi yang lebih sistematis dibanding sekadar perkiraan manual, karena keputusan model didasarkan pada pola yang dipelajari dari data (Schmid et al., 2025).

2.2.9 Konsep *Deep Learning*

Deep learning merupakan cabang dari machine learning yang memanfaatkan jaringan saraf tiruan (artificial neural networks, ANN) dengan struktur berlapis (layers), yang memungkinkan model untuk mempelajari representasi data yang lebih kompleks dan abstrak. Keunggulan utama dari pendekatan ini terletak pada kemampuannya untuk menangkap pola-pola yang tidak linier dan hubungan yang lebih rumit, yang sering ditemukan dalam data deret waktu (time series), seperti harga komoditas yang berfluktuasi setiap bulan. Dalam hal ini, deep learning memungkinkan model untuk mengenali pola tren jangka panjang serta pola musiman yang ada dalam data historis, serta beradaptasi terhadap perubahan pola tersebut seiring waktu (Manogna et al., 2025).

Perkembangan deep learning dapat ditelusuri melalui evolusi jaringan saraf tiruan (ANN), yang pertama kali diperkenalkan pada tahun 1950-an sebagai model komputasi yang terinspirasi dari cara kerja otak manusia. Namun, penerapan awal ANN terbatas oleh kendala kemampuan komputasi yang ada pada saat itu, serta kesulitan dalam melatih model yang lebih dalam. Kemudian, pada 1980-an, jaringan saraf berulang (Recurrent Neural Networks, RNN) diperkenalkan untuk mengatasi masalah pengolahan data sekuensial, seperti teks atau urutan waktu, dengan memberikan model kemampuan untuk mengingat informasi sebelumnya. Meskipun RNN menunjukkan kemajuan, jaringan ini masih menghadapi tantangan besar berupa vanishing gradient problem, yaitu hilangnya informasi penting saat melakukan backpropagation dalam pembaruan parameter model,

yang menghambat kemampuan model dalam mempelajari dependensi jangka panjang (Manogna et al., 2025).

Sebagai solusi atas permasalahan ini, *Long Short-Term Memory* (LSTM) diperkenalkan pada tahun 1997 oleh Sepp Hochreiter dan Jürgen Schmidhuber. LSTM mengatasi masalah vanishing gradient dengan memperkenalkan konsep sel memori yang memungkinkan informasi dipertahankan dalam jangka panjang. LSTM juga menggunakan tiga gerbang utama, yakni input gate, forget gate, dan output gate, yang berfungsi untuk mengatur aliran informasi masuk dan keluar dari sel memori, sehingga model dapat memelihara informasi yang relevan untuk waktu yang lebih lama. Pendekatan ini menjadikan LSTM sangat efektif dalam menangani data sekuensial yang memiliki ketergantungan jangka panjang, seperti dalam tugas peramalan harga komoditas dan penerjemahan bahasa (Manogna et al., 2025).

Meskipun LSTM sangat efektif dalam mengatasi masalah pengolahan data sekuensial, kompleksitas komputasi yang tinggi menjadi kendala, terutama pada data yang besar. Oleh karena itu, pada tahun 2014, *Gated Recurrent Unit* (GRU) diperkenalkan sebagai alternatif yang lebih sederhana namun tetap efektif. GRU menyederhanakan struktur LSTM dengan menggabungkan beberapa gerbang yang ada pada LSTM menjadi dua gerbang utama, yaitu update gate dan reset gate. Dengan mengurangi kompleksitas struktur, GRU menawarkan efisiensi komputasi yang lebih baik tanpa mengorbankan kemampuannya untuk memproses data sekuensial dan menangkap pola dalam urutan data historis. GRU cocok digunakan dalam berbagai aplikasi, termasuk peramalan harga komoditas, di mana data historis digunakan untuk memprediksi perubahan harga di masa depan (Manogna et al., 2025)(Aditya et al., 2024).

2.2.10 *Gated Recurrent Unit* (GRU)

GRU atau *Gated Recurrent Unit* bisa dibilang salah satu model turunan RNN yang dibuat supaya lebih ringan dan cepat dipakai. Jika LSTM punya tiga gerbang, GRU justru mempunyai dua gerbang utama yaitu gerbang update gate dan reset gate. Dua gerbang ini mempunyai fungsi untuk mengatur informasi mana yang penting untuk di simpan dan mana yang dibuang. Karena lebih sederhana, GRU butuh lebih sedikit

perhitungan, tapi hasilnya tetap bagus dan bisa membaca pola data yang rumit seperti naik turun harga beras (Sholeh, 2022).

Beberapa penelitian juga sudah membuktikan kalau GRU mampu menghasilkan prediksi yang akurat pada data harga cabai merah, dengan performa yang sebanding bahkan lebih baik dari model tradisional. Hal ini menunjukkan bahwa GRU sangat potensial digunakan untuk memprediksi harga beras yang memiliki pola musimam dan tren jangka panjang (Lim & Handhayani, 2025).

Secara matematis, perhitungan GRU pada waktu ke- t dapat dijelaskan melalui beberapa komponen utama, yaitu reset gate, update gate, kandidat hidden state, dan hidden state akhir.

Pada tahap pertama, perhitungan untuk reset gate dilakukan dengan Persamaan 3.

$$r_t = \sigma(W_r[h_{t-1}, x_t] + b_r) \quad (3)$$

Berdasarkan Persamaan 3, reset gate bertugas untuk menentukan seberapa besar informasi dari harga beras pada bulan sebelumnya, h_{t-1} , perlu dipertahankan atau dilupakan ketika memproses harga beras pada bulan ke- t , yaitu x_t . Dalam konteks peramalan harga beras bulanan, mekanisme reset gate ini sangat penting untuk mengurangi pengaruh fluktuasi harga jangka pendek yang mungkin tidak relevan terhadap pola harga jangka panjang. Dengan cara ini, model dapat mengidentifikasi dan memprioritaskan informasi yang lebih relevan untuk dipertimbangkan dalam peramalan harga yang akan datang (Lim & Handhayani, 2025).. Selanjutnya, update gate dihitung menggunakan Persamaan 4.

$$z_t = \sigma(W_z[h_{t-1}, x_t] + b_z) \quad (4)$$

Berdasarkan Persamaan 4, update gate berfungsi untuk menentukan apakah informasi sebelumnya masih perlu dipertahankan atau digantikan dengan informasi baru. Di sini, model mempertimbangkan data yang masuk saat ini, x_t , bersama dengan ingatan sebelumnya, h_{t-1} , dan menghasilkan nilai antara 0 dan 1. Jika nilai update gate ini

mendekati 1, maka informasi baru akan lebih dominan digunakan. Sebaliknya, jika nilai mendekati 0, maka informasi lama akan lebih dipertahankan. Mekanisme ini memungkinkan GRU untuk menyesuaikan diri dengan perubahan pola data harga dari waktu ke waktu, menjadikannya sangat efektif untuk menangani data yang memiliki dinamika musiman atau perubahan tren yang tajam (Sholeh, 2022). Setelah itu, kandidat hidden state dihitung dengan Persamaan 5.

$$\tilde{h}_t = \tanh(W_h[x_t, r_t \odot h_{t-1}] + b_h) \quad (5)$$

Berdasarkan Persamaan 5, Kandidat hidden state ini berfungsi untuk menggabungkan input saat ini, x_t , dengan informasi lama yang telah disaring oleh reset gate, r_t . Dalam rumus ini, $\odot$ menunjukkan operasi perkalian elemen per elemen antara reset gate dan hidden state sebelumnya, h_{t-1} . Fungsi aktivasi tanh digunakan untuk memastikan bahwa nilai yang dihasilkan tetap stabil dan tidak terlalu besar, sehingga calon ingatan baru yang dihasilkan tetap dalam rentang yang dapat diproses dengan baik oleh jaringan. Hasil dari proses ini adalah calon informasi yang siap dipilih untuk disimpan dalam hidden state akhir (Oni et al., 2023). Terakhir, perhitungan hidden state akhir dilakukan dengan Persamaan 6.

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (6)$$

Berdasarkan Persamaan 6, rumus ini menggambarkan bagaimana hidden state baru, h_t , merupakan gabungan antara ingatan lama, h_{t-1} , dan kandidat ingatan baru, $\tilde{h}_t$. Proses penggabungan ini dikendalikan oleh update gate, z_t , yang menentukan porsi masing-masing informasi. Jika z_t mendekati 1, maka kandidat hidden state baru, $\tilde{h}_t$, akan lebih dominan, sementara jika z_t mendekati 0, ingatan lama, h_{t-1} , akan lebih dipertahankan. Dengan mekanisme ini, GRU dapat secara efisien memproses informasi dari data urutan untuk membuat prediksi yang lebih akurat, seperti dalam kasus peramalan harga beras (Sholeh, 2022).

Secara keseluruhan, struktur GRU ini memungkinkan jaringan untuk menangani data sekuensial dengan cara yang efisien dan sederhana, namun tetap efektif

dalam menyimpan informasi penting untuk prediksi jangka panjang, yang pada akhirnya membuatnya sangat berguna dalam aplikasi peramalan harga komoditas (Sholeh, 2022).

2.2.11 Long Short-Term Memory (LSTM)

Long Short-term Memory (LSTM) adalah model otak buatan komputer yang bisa mengingat informasi data dalam jangka waktu yang panjang. LSTM berbeda dari model lain, LSTM memiliki tiga pintu yang membantu buat memilih mana data yang harus disimpan dan mana data yang harus dibuang. Hal ini yang bikin LSTM cocok buat prediksi harga barang yang sering berubah-ubah, seperti harga komoditas yang pola musiman (Haris et al., 2025).

Penelitian Tami dan Owda (2024) menunjukkan jika LSTM lebih cocok buat prediksi harga barang seperti minyak, susu, dan daging, jika dibanding dengan cara lama, hasilnya juga lebih akurat, dengan perbedaan prediksi dan kenyataan Cuma 3,04%. Begitu juga dengan penelitian Tardin dan Suharjito (2024), yang menggunakan LSTM buat prediksi harga CPO dan hasilnya akurat, MAPE nya di bawah 10%. Jadi, bisa dibilang LSTM memang akurat buat prediksi harga barang yang naik turun (Tardini & Suharjito, 2024)(Tami & Owda, 2024).

Secara matematis, perhitungan pada Long Short-Term Memory (LSTM) terdiri dari beberapa tahap yang melibatkan beberapa gerbang untuk mengontrol aliran informasi. Salah satu komponen utama dalam LSTM adalah forget gate, yang digunakan untuk menentukan bagian mana dari memori lama yang masih relevan dan perlu disimpan (Tami & Owda, 2024). Perhitungan forget gate dilakukan dengan Persamaan 7.

$$f_t = \sigma(W_f[x_t, h_{t-1}] + b_f) \quad (7)$$

Berdasarkan Persamaan 7, di sini, f_t adalah nilai forget gate yang dihitung menggunakan fungsi aktivasi sigmoid yang menghasilkan output antara 0 dan 1. Fungsi sigmoid ini berperan untuk mengatur apakah informasi dari memori lama, h_{t-1} , perlu dipertahankan atau dilupakan. Nilai f_t yang mendekati 0 berarti informasi lama akan dilupakan, sementara nilai yang mendekati 1 berarti informasi tersebut akan tetap disimpan. Mekanisme ini memungkinkan LSTM untuk mengurangi pengaruh data yang

sudah tidak relevan dalam proses pembelajaran, sehingga hanya informasi yang penting yang diteruskan (Tami & Owda, 2024).

Tahap berikutnya adalah perhitungan input gate, yang berfungsi untuk mengatur seberapa besar kontribusi informasi baru yang akan disimpan dalam cell state, berdasarkan input saat ini dan informasi yang diperoleh dari langkah sebelumnya (Sen et al., 2020). Perhitungan input gate dilakukan dengan menggunakan Persamaan 8.

$$i_t = \sigma(W_i[x_t, h_{t-1}] + b_i) \quad (8)$$

Berdasarkan Persamaan 8, dalam rumus ini, i_t merupakan nilai dari input gate yang berfungsi untuk mengatur proporsi informasi baru yang akan disertakan dalam pembaruan cell state. Input gate dihitung menggunakan fungsi aktivasi sigmoid, yang menghasilkan output dalam rentang 0 hingga 1. Nilai i_t ini mengendalikan seberapa banyak informasi baru, $\tilde{C}_t$, yang dapat diterima oleh sistem memori. Dengan nilai i_t yang mendekati 1, informasi baru sepenuhnya diterima, sementara nilai yang mendekati 0 menunjukkan bahwa informasi tersebut akan ditolak. Proses ini memungkinkan LSTM untuk secara selektif menyerap informasi relevan, mengoptimalkan penyimpanan memori jangka panjang dan meningkatkan efisiensi dalam pembelajaran sekuensial (Sen et al., 2020).

Tahap berikutnya adalah perhitungan kandidat cell state, yang digunakan untuk menghasilkan calon isi memori baru berdasarkan input saat ini dan informasi sebelumnya (Sen et al., 2020). Perhitungan kandidat cell state dilakukan dengan Persamaan 9.

$$\tilde{C}_t = \tanh(W_c[x_t, h_{t-1}] + b_c) \quad (9)$$

Berdasarkan Persamaan 9, fungsi aktivasi tanh digunakan untuk memastikan bahwa nilai yang dihasilkan tetap stabil dan tidak terlalu besar, yang dapat mengganggu proses pembelajaran model. Kandidat cell state ini menggambarkan calon ingatan baru yang akan dipertimbangkan untuk dimasukkan ke dalam memori (Sen et al., 2020).

Setelah kandidat cell state dihitung, tahap selanjutnya adalah memperbarui memori untuk menghasilkan cell state yang baru (Sen et al., 2020). Proses pembaruan memori ini digambarkan oleh Persamaan 10.

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (10)$$

Berdasarkan Persamaan 10, pada rumus ini, C_t adalah cell state baru yang merupakan gabungan antara memori lama yang masih dipertahankan, C_{t-1} , dan informasi baru yang diperbolehkan masuk, $\tilde{C}_t$. Nilai f_t mengontrol seberapa banyak memori lama yang dipertahankan, sedangkan i_t adalah input gate yang menentukan seberapa banyak informasi baru yang akan diterima. Dengan cara ini, LSTM dapat menyimpan informasi yang relevan dalam jangka panjang dan membuang yang tidak relevan (Sen et al., 2020).

Selanjutnya, output gate mengatur bagian mana dari memori yang akan dikeluarkan sebagai output (Tami & Owda, 2024). Perhitungan output gate dilakukan dengan Persamaan 11.

$$o_t = \sigma(W_o[x_t, h_{t-1}] + b_o) \quad (11)$$

Berdasarkan Persamaan 11, output gate ini menggunakan fungsi aktivasi sigmoid untuk menghasilkan nilai antara 0 dan 1, yang menentukan seberapa banyak informasi dari cell state yang akan diteruskan ke langkah berikutnya. Tidak semua informasi dalam memori akan digunakan langsung sebagai output; hanya informasi yang relevan yang akan diteruskan (Tami & Owda, 2024).

Akhirnya, hidden state LSTM dihitung untuk menghasilkan output akhir yang akan digunakan dalam prediksi atau sebagai input pada langkah waktu berikutnya (Cahyani et al., 2023). Hidden state dihitung dengan Persamaan 12.

$$h_t = o_t \odot \tanh(C_t) \quad (12)$$

Berdasarkan persamaan 12, hidden state ini merupakan hasil akhir dari proses LSTM yang menggambarkan informasi penting yang telah diproses dari data

sebelumnya. Nilai h_t akan digunakan baik untuk prediksi saat ini maupun sebagai input untuk langkah berikutnya dalam urutan data. Fungsi aktivasi tanh pada cell state, yang kemudian dikalikan dengan output gate o_t , memastikan bahwa hanya informasi yang relevan yang diteruskan dan diolah lebih lanjut (Cahyani et al., 2023).

Secara keseluruhan, perhitungan dalam LSTM melibatkan beberapa tahap yang mengontrol aliran informasi melalui gerbang-gerbang yang berbeda. Proses ini memungkinkan LSTM untuk mengingat pola jangka panjang dalam data sekuensial, sehingga cocok digunakan dalam aplikasi seperti peramalan harga komoditas, pengenalan suara, dan penerjemahan bahasa (Cahyani et al., 2023) (*Enhanced Violence Detection in CCTV Using LSTM*, 2025).

2.2.12 Evaluasi Model

Perbandingan kinerja model GRU dan LSTM menggunakan tiga metrik utama yaitu MAE, RMSE, dan MAPE. Ketiga metrik ini menjadi tolak ukur seberapa jauh prediksi model perbedaan dengan data aktual, serta memberikan gambaran mengenai akurasi model dalam menangkap pola temporal jangka panjang pada data harga beras yang dinamis (Tussifah, 2023).

Mean Absolute Error (MAE) adalah salah satu ukuran evaluasi kinerja model yang menggambarkan rata-rata selisih absolut antara nilai prediksi dan nilai sebenarnya. MAE memberikan gambaran yang sederhana dan mudah dipahami tentang seberapa besar rata-rata kesalahan yang terjadi dalam model prediksi (Tussifah, 2023). Secara matematis, MAE dihitung dengan Persamaan 13.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (13)$$

Berdasarkan persamaan 13, n adalah jumlah data, y_i adalah nilai aktual pada data ke- i , dan $\hat{y}_i$ adalah nilai prediksi pada data ke- i . MAE memberikan nilai rata-rata dari selisih antara nilai aktual dan nilai prediksi, dengan semakin kecil nilai MAE, semakin baik model dalam memprediksi data yang diberikan (Tussifah, 2023).

Selanjutnya, *Root Mean Squared Error* (RMSE) adalah ukuran evaluasi lainnya yang menghitung akar dari rata-rata kuadrat kesalahan. RMSE lebih sensitif terhadap

kesalahan besar, sehingga sangat berguna untuk mengukur model yang digunakan pada data dengan fluktuasi harga ekstrem, seperti harga komoditas yang sering mengalami lonjakan atau penurunan drastis (Cahyani et al., 2023). RMSE dihitung dengan persamaan 14.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (14)$$

Berdasarkan Persamaan 13, dalam rumus ini, y_i adalah nilai aktual pada data ke- i , $\hat{y}_i$ adalah nilai prediksi pada data ke- i , dan n adalah jumlah data. RMSE memberikan bobot yang lebih besar pada kesalahan yang lebih besar, sehingga model dengan RMSE yang rendah menunjukkan kemampuan yang lebih baik dalam menangani data dengan kesalahan besar (Cahyani et al., 2023)(Boosting, 2025).

Terakhir, *Mean Absolute Percentage Error* (MAPE) digunakan untuk mengukur kesalahan rata-rata dalam bentuk persentase. MAPE sering digunakan dalam penelitian harga komoditas karena hasilnya yang mudah dipahami dan memberikan gambaran langsung tentang seberapa besar perbedaan antara nilai prediksi dan nilai aktual (Sudirman et al., 2020). Rumus perhitungan MAPE Berdasarkan Persamaan 15.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (15)$$

Berdasarkan Persamaan 15, dalam rumus ini, y_i adalah nilai aktual pada data ke- i , $\hat{y}_i$ adalah nilai prediksi pada data ke- i , dan n adalah jumlah data. MAPE menghasilkan nilai dalam bentuk persentase, yang memudahkan pemahaman tentang seberapa besar kesalahan yang terjadi dalam prediksi model (Magh Heryan Tudaan, 2025).

Ketiga ukuran ini memberikan evaluasi kinerja yang lebih menyeluruh terhadap model prediksi. MAE lebih menekankan pada rata-rata kesalahan, RMSE memberikan perhatian lebih pada kesalahan besar, dan MAPE menyajikan hasil dalam bentuk persentase yang mudah dipahami. Kombinasi ketiganya sangat berguna dalam

memastikan bahwa model prediksi, seperti GRU, dapat diandalkan untuk memprediksi harga beras dengan akurat dan tepat (Tussifah, 2023).

2.2.13 Flowchart

Flowchart merupakan diagram yang menjelaskan alur proses sebuah program yang sangat penting saat membangun program karena membantu menjelaskan proses berjalannya program agar lebih mudah di mengerti (Fauzi, 2020).

	Flow Simbol yang digunakan untuk menggabungkan antara simbol yang satu dengan simbol yang lain. Simbol ini disebut juga dengan Connecting Line.		Input/output Simbol yang menyatakan proses input atau output tanpa tergantung peralatan.
	On-Page Reference Simbol untuk keluar - masuk atau penyambungan proses dalam lembar kerja yang sama.		Manual Operation Simbol yang menyatakan suatu proses yang tidak dilakukan oleh komputer.
	Off-Page Reference Simbol untuk keluar - masuk atau penyambungan proses dalam lembar kerja yang berbeda.		Document Simbol yang menyatakan bahwa input berasal dari dokumen dalam bentuk fisik, atau output yang perlu dicetak.
	Terminator Simbol yang menyatakan awal atau akhir suatu program.		Predefine Proses Simbol untuk pelaksanaan suatu bagian (sub-program) atau prosedur.
	Process Simbol yang menyatakan suatu proses yang dilakukan komputer.		Display Simbol yang menyatakan peralatan output yang digunakan.
	Decision Simbol yang menunjukan kondisi tertentu yang akan menghasilkan dua kemungkinan jawaban, yaitu ya dan tidak.		Preparation Simbol yang menyatakan penyediaan tempat penyimpanan suatu pengolahan untuk memberikan nilai awal.

Gambar 2. 1 Flowchart (Nathasya, 2024)

2.2.14 Python


Python merupakan bahasa pemrograman yang sangat digemari karena sintaksnya yang sederhana dan mudah digunakan, menjadikannya pilihan utama bagi pemula maupun pengembangan berpengalaman. Dikembangkan oleh Guido van Rossum pada tahun 1991, python terus berkembang pesat dan dan menjadi pilihan populer dalam dunia pengembangan perangkat lunak dan analisis data. Salah satu keunggulannya yaitu fleksibilitas, yang memungkinkan pengguna untuk memilih berbagai paradigma pemrograman seperti prosedural, berorientasi objek, atau fungsional, tergantung pada kebutuhan aplikasi yang dikembangkan (Mckinney, 2018).

Python juga dilengkapi dengan ekosistem pustaka yang sangat kaya, seperti pandas dan NumPy untuk analisis data, serta tensorFlow dan Pytorch untuk kecerdasan

buatan dan machine learning. Python juga dapat dijalankan di berbagai sistem operasi seperti windows, macOS, dan Linux tanpa memerlukan banyak penyesuaian kode yang menjadikan pilihan yang fleksibel untuk berbagai proyek, mulai dari pengembangan web hingga penelitian ilmiah (Mckinney, 2018).

2.3 Kerangka Pemikiran

Kerangka Pemikiran ini menggambarkan alur sistematis yang dilakukan untuk menganalisis dan memprediksi harga beras menggunakan algoritma deep learning, khususnya model *Gated Recurrent Unit* (GRU) dan *Long Short-Term Memory* (LSTM). Proses penelitian ini disusun dengan tujuan untuk memperoleh hasil prediksi yang valid dan akurat terhadap harga beras di tingkat provinsi. Dimulai dengan pengumpulan data harga beras bulanan, penelitian ini kemudian melalui beberapa tahapan pengolahan data yang meliputi pra-pemrosesan, normalisasi, dan pembentukan data time series, sebelum akhirnya dilakukan pelatihan model, evaluasi kinerja model, serta visualisasi dan interpretasi hasil. Langkah-langkah ini disusun dengan tujuan untuk menghasilkan model yang dapat memprediksi harga beras dengan ketepatan tinggi dan sesuai dengan karakteristik dinamika harga beras yang bervariasi antara provinsi. Berikut adalah flowchart yang menggambarkan langkah-langkah penelitian ini secara sistematis pada Gambar 2.2.



Gambar 2. 2 Kerangka Pemikiran

Gambar 2.2, menunjukkan tahapan-tahapan yang dilalui dalam penelitian ini. Tahap pertama adalah pengumpulan data harga beras dari berbagai provinsi di Indonesia, yang mencakup data harga beras bulanan dari tahun 2022 hingga 2025. Data yang terkumpul kemudian melalui tahap pra-pemrosesan, yang melibatkan pembersihan data dan penyusunan data agar siap untuk dianalisis lebih lanjut. Proses normalisasi data dilakukan untuk menyamakan skala nilai data, sehingga memudahkan pelatihan model dan meningkatkan efisiensi dalam proses pembelajaran.

Setelah data disiapkan, dilakukan pembentukan data time series dengan menggunakan teknik sliding window, yang memungkinkan model untuk mempelajari pola dalam data deret waktu berdasarkan periode tertentu. Selanjutnya, data dibagi menjadi dua bagian: data latih (untuk periode 2022-2024) dan data uji (untuk periode 2025), yang bertujuan untuk memastikan bahwa model diuji dengan data yang tidak digunakan selama pelatihan.

Model GRU dan LSTM kemudian dilatih menggunakan data latih yang telah dipersiapkan, dan hasil prediksi untuk tahun 2026 dan 2027 dievaluasi dengan menggunakan metrik Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), dan Mean Absolute Percentage Error (MAPE) untuk mengukur akurasi model dalam memprediksi harga beras. Tahap akhir dari penelitian ini adalah visualisasi dan interpretasi hasil, di mana hasil prediksi dibandingkan dengan data aktual untuk mengevaluasi efektivitas kedua model dalam memberikan prediksi yang akurat.

Dengan mengikuti tahapan yang terstruktur dan sistematis ini, penelitian ini bertujuan untuk menghasilkan model prediksi harga beras yang dapat diandalkan, serta memberikan kontribusi dalam pengambilan keputusan terkait kebijakan harga pangan di Indonesia.