



Multivariate Time Series Forecasting of Asphalt Prices Using the Gated Recurrent Unit Algorithm

Peramalan *Multivariate Time Series* Harga Aspal Menggunakan Algoritma *Gated Recurrent Unit*

Winaldi Putra Jaya¹, Puput Budi Wintoro², Trisya Septiana³, Yessi Mulyani⁴

^{1,2,3,4}Program Studi Teknik Informatika, Fakultas Teknik, Universitas Lampung, Indonesia

E-mail: winaldipj16@gmail.com¹, budi.wintoro@eng.unila.ac.id²,
trisya.septiana@eng.unila.ac.id³, yessi.mulyani@eng.unila.ac.id⁴

Received Jul 26th 2025; Revised Oct 04th 2025; Accepted Oct 20th 2025; Available Online Nov 05th 2025

Corresponding Author: Winaldi Putra Jaya

Copyright © 2025 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

Abstract

Global oil price fluctuations lead to high volatility in asphalt prices, creating uncertainty in business planning. This study develops a multivariate forecasting model for asphalt prices using the Gated Recurrent Unit (GRU) algorithm. The research process follows the stages of Business Understanding, Data Understanding, Data Preprocessing, Data Modeling, Evaluation, and Deployment. The data analyzed include asphalt prices (in low and high categories) and global oil prices (close to) for the period 2016–2023, with a total of 371 observations. The exploration results show that oil prices are the dominant predictor of changes in asphalt prices. Model evaluation reveals excellent GRU performance, with an average MAE value of 6.2441, an RMSE of 8.2880, and an R^2 of 96.05%, indicating the model's ability to accurately recognize time series patterns. However, the limitation of this study lies in the scope of data sourced from a single company with a limited time range, which has the potential to cause representative bias. Additionally, the GRU model is sensitive to training parameters and windowing sizes, which can impact the stability of results in data with extreme seasonal patterns. In practical implementation, integrating GRU into business systems also requires computing capacity and periodic model updates to keep prediction results adaptive to global market dynamics. The final model was implemented in an interactive Power BI-based dashboard to support price trend visualization and accelerate strategic decision-making in the infrastructure and asphalt distribution sectors.

Keyword: Asphalt Price, Forecasting, Gated Recurrent Unit, Multivariate Time Series

Abstrak

Fluktuasi harga minyak global menimbulkan volatilitas tinggi pada harga aspal dan menciptakan ketidakpastian dalam perencanaan bisnis. Penelitian ini mengembangkan model *multivariate forecasting* harga aspal menggunakan algoritma *Gated Recurrent Unit* (GRU). Proses penelitian mengikuti tahapan *Business Understanding*, *Data Understanding*, *Data Preprocessing*, *Data Modelling*, *Evaluation*, dan *Deployment*. Data yang dianalisis mencakup harga aspal (kategori *low* dan *high*) serta harga minyak global (*close*) periode 2016–2023, dengan total 371 observasi. Hasil eksplorasi menunjukkan bahwa harga minyak menjadi prediktor dominan terhadap perubahan harga aspal. Evaluasi model memperlihatkan kinerja GRU yang sangat baik dengan nilai rata-rata MAE 6,2441, RMSE 8,2880, dan R^2 sebesar 96,05%, yang menandakan kemampuan model dalam mengenali pola deret waktu secara akurat. Namun demikian, keterbatasan penelitian ini terletak pada cakupan data yang bersumber dari satu perusahaan dengan rentang waktu terbatas, sehingga berpotensi menimbulkan *bias representatif*. Selain itu, model GRU cenderung sensitif terhadap parameter pelatihan dan ukuran *windowing*, yang dapat mempengaruhi stabilitas hasil pada data dengan pola musiman ekstrem. Dalam implementasi praktis, integrasi GRU ke dalam sistem bisnis juga memerlukan kapasitas komputasi dan pembaruan model berkala agar hasil prediksi tetap adaptif terhadap dinamika pasar global. Model akhir diimplementasikan dalam *dashboard* interaktif berbasis Power BI untuk mendukung visualisasi tren harga dan mempercepat pengambilan keputusan strategis di sektor infrastruktur dan distribusi aspal.

Kata Kunci: Forecasting, Gated Recurrent Unit, Harga Aspal, Multivariate Time Series

1. PENDAHULUAN

Dengan pesatnya pembangunan yang melibatkan penggunaan aspal, maka permintaan aspal semakin meningkat yang menyebabkan terjadinya perubahan harga pada aspal yang semakin tidak terprediksi. Hal ini juga yang sedang dialami oleh salah satu perusahaan PT. XYZ yang merupakan salah satu penjual aspal di Indonesia. Oleh sebab itu, dalam menangani ketidakpastian harga aspal, maka salah satu solusi yang dapat menangannya adalah *timeseries forecasting*.

Timeseries forecasting memberikan gambaran dari perubahan tren yang melibatkan prediksi titik data masa depan berdasarkan pengamatan yang dilakukan masal lalu. Beberapa model tradisional yang memiliki kemampuan *forecasting* adalah *Auto Refressive*, *Moving Average*, dan *Auto Regressive Integrated Moving Average* (ARIMA) [1]. Meskipun terdapat beberapa model *forecasting* yang tersedia, beberapa diantaranya tidak cocok dalam menangani volitalitas sebuah data. Sehingga dalam menangani masalah ini, penggunaan *Artificial Intelligence* (AI) atau kecerdasan buatan denan memberikan sebuah pendekatan baru yang lebih akurat.

AI merupakan sebuah teknologi yang membuat komputer meniru perilaku kecerdasan manusia, di mana sebuah mesin belajar untuk menyelesaikan permasalahan secara mandiri menggunakan algoritma, terutama dalam tugas yang melibatkan persepsi serta kognisi yang belajar dari data [2]. Salah satu sub bidang dari AI adalah *machine learning*, yang merupakan kecerdasan buatan yang memungkinkan komputer dalam menyelesaikan masalah-masalah tanpa dilakukan program secara eksplisit. Terdapat beberapa pendekatan yang umum dalam *machine learning* diantaranya adalah *supervised learning*, *unsupervised learning*, dan *reinforcement learning* [3]. Dalam kasus *forecasting* maka pendekatan yang dapat digunakan adalah *supervised learning* dan regresi. Beberapa algoritma yang umum digunakan di dalamnya adalah *linear regression*, *random forest*, *support vector machine* (SVM) [4].

Deep Learning merupakan subbidang *machine learning* yang menggunakan jaringan saraf yang dapat mengetasi keterbatasan model tradisional, sehingga mesin dapat belajar dari data yang sangat kompleks, beberapa arsitektur yang terdapat dalam *deep learning* adalah *Convolutional Neural Network* (CNN) dan *Recurrent Neural Network* (RNN). CNN umumnya ditemukan dalam penyelesaian tugas yang melibatkan citra, sedangkan RNN dirancang dalam menyelesaikan tugas seperti *Natural Language Processing* (NLP), *Voice Recognition*, dan *timeseries forecasting* [5]. RNN merupakan jenis jaringan saraf tiruan yang dirancang dalam menyelesaikan pekerjaan pada data yang berurutan, sehingga memungkinkan informasi yang tersimpan dapat bertahan dari waktu ke waktu secara fleksibel. RNN memiliki beberapa keterbatasan, seperti masalah *vanishing gradient*, dan *exploding gradient* yang dapat menyebabkan bobot *neuron* menjadi sangat besar, sehingga pelatihan model menjadi tidak stabil [6].

GRU merupakan jenis *neural network* yang dirancang dalam menangani pemrosesan data sekuensial yang lebih efisien dan mengurangi beban komputasi dan waktu pelatihan dibanding dengan model RNN tradisional [7]. GRU memiliki dua gerbang utama yaitu *update gate* dan *reset gate*, sebagai penyaring informasi yang relevan dari masa lalu untuk selanjutnya diteruskan ke langkah selanjutnya. Selain itu GRU memiliki keunggulan dalam menangkap pola dengan ketergantungan jangka panjang dari data yang memiliki volitalitas tinggi. Hal ini memberikan GRU kemampuan yang cocok dalam mengatasi masalah yang terdapat dapat volitalitas di data harga aspal, yang salah satunya di pengaruhi oleh fluktuasi harga minyak dunia. GRU menawarkan pendekatan gerbang yang lebih sederhana dibandingkan LSTM, sehingga GRU mampu memberikan hasil prediksi yang akurat dan mengurangi risiko *overfitting* dan *vanishing gradient descent* dalam model, sehingga menjadi pilihan yang tepat dalam menangani *forecasting* harga aspal [7].

Berdasarkan hal-hal diatas, penelitian ini diharapkan menghasilkan model *forecasting* yang dapat memprediksi harga aspal dengan akurat yang mampu menangani volitalitas dalam harga aspal dan dapat diintegrasikan dalam *dashboard power BI* yang interaktif, sehingga dapat memudahkan *stakeholder* dalam melakukan analisis data dalam harga aspal dan pengambilan keputusan yang dilakukan secara cepat dan tepat.

2. KAJIAN TEORI

2.1. Aspal

Aspal bersifat plastis, viskos, dan elastis, sehingga mudah dibentuk, mengalir dengan baik, serta tahan terhadap tekanan. Pencampuran yang tepat, aspal menghasilkan permukaan jalan yang kuat, tahan lama, dan ramah lingkungan karena dapat didaur ulang, sehingga mendukung pembangunan berkelanjutan [8].

2.2. Forecasting

Forecasting adalah metode untuk menganalisis data historis guna memprediksi kondisi masa depan dengan mempertimbangkan berbagai faktor. Konsep kointegrasi digunakan untuk melihat hubungan jangka panjang antarvariabel. Komponen utamanya meliputi tren, pola musiman, pola siklis, dan fluktuasi acak yang sulit diprediksi [9]. Beberapa metode tradisional dalam *forecasting* antara lain *AutoRegressive* (AR) yang memprediksi data berdasarkan nilai sebelumnya [10], *Moving Average* (MA) yang menggunakan rata-rata nilai saat ini dan kesalahan prediksi sebelumnya [10], serta ARIMA yang menggabungkan konsep AR dan

MA dengan proses differencing untuk menjadikan data bersifat stasioner [10]. Model lain seperti *AutoRegressive Fractionally Integrated Moving Average* (ARFIMA) menambahkan konsep long memory [11], sedangkan *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH) digunakan untuk menganalisis volatilitas tinggi pada data keuangan [11]. Seiring perkembangan teknologi, pendekatan modern menggunakan *machine learning* dan *deep learning*, seperti *Gated Recurrent Unit* (GRU), yang mampu mempelajari pola data sekuensial dan mengenali hubungan jangka panjang secara lebih efektif tanpa memerlukan data stasioner [7].

2.3. *Artificial Intelligence*

AI adalah cabang ilmu komputer yang memungkinkan mesin melakukan tugas layaknya manusia, terutama yang berkaitan dengan kemampuan kognitif [2]. Penerapan AI meningkatkan efisiensi analisis data, mempercepat pengambilan keputusan, serta mengoptimalkan tugas berulang, sehingga lebih efektif dan hemat biaya dibanding metode manual [12]. Dalam penyelesaiannya, AI memiliki empat teknik utama: *searching*, *reasoning*, *planning*, dan *learning*. *Searching* berfungsi menemukan solusi optimal melalui berbagai jalur kemungkinan, seperti algoritma *Breadth-First Search* (BFS) dan *Depth-First Search* (DFS). *Reasoning* memungkinkan AI menarik kesimpulan logis dari fakta yang ada. *Planning* menyusun langkah-langkah strategis untuk mencapai tujuan secara efisien. Sedangkan *learning* membuat AI mampu memecahkan masalah dengan menganalisis pengalaman sebelumnya tanpa perlu pemrograman eksplisit [2].

2.4. *Machine Learning*

Machine Learning (ML) merupakan cabang dari AI yang memungkinkan komputer belajar dari data tanpa perlu pemrograman eksplisit [13]. Teknik ini bertujuan menganalisis pola dan membuat inferensi, sehingga sistem dapat meningkatkan akurasi dalam menyelesaikan berbagai tugas serta beradaptasi seiring bertambahnya data. Berdasarkan pendekatannya, ML terbagi menjadi *Supervised Learning*, *Unsupervised Learning*, dan *Reinforcement Learning* [3]. ML digunakan untuk tugas prediksi seperti klasifikasi, regresi, dan klusterisasi dengan beragam algoritma, antara lain SVM, *Linear Regression*, *Naive Bayes* (*Multinomial* dan *Gaussian*), serta *K-Nearest Neighbours* (KNN). Fleksibilitas ini membuat ML mampu menangani permasalahan kognitif dari tingkat sederhana hingga kompleks. Dalam industri, ML berperan penting dalam otomatisasi proses yang sebelumnya membutuhkan intervensi manual dan biaya besar, sehingga meningkatkan efisiensi serta menekan biaya operasional. Namun, ML juga memiliki keterbatasan, seperti ketergantungan pada kualitas data yang memerlukan proses preprocessing panjang sebelum pelatihan model. Banyaknya algoritma juga dapat menyulitkan pemilihan metode yang tepat, terutama bagi pengguna baru. Selain itu, proses pelatihan perlu pengawasan khusus untuk menghindari *overfitting* (model terlalu mengikuti data latih) dan *underfitting* (model terlalu sederhana). Untuk menangani data kompleks, digunakan pendekatan yang lebih lanjut yaitu *Deep Learning*, yang merupakan subbidang dari *Machine Learning* [14].

2.5. *Deep Learning*

Deep Learning adalah cabang dari *Machine Learning* yang berbasis Jaringan Syaraf Tiruan (JST) dan meniru cara kerja otak manusia dalam memproses informasi [5]. Berbeda dari metode tradisional, *Deep Learning* mampu mengenali dan mengekstraksi fitur penting secara otomatis, sehingga efektif untuk tugas kompleks seperti pengenalan gambar dan pemrosesan bahasa alami (NLP) [15]. Keterbatasan *Deep Learning* meliputi kebutuhan komputasi tinggi, waktu pelatihan lama, serta ketergantungan pada data besar dan berkualitas. Model ini juga sensitif terhadap noise dan outliers, serta kurang optimal untuk parallel processing [17]. Jenis utamanya meliputi CNN yang unggul dalam pengenalan pola visual, dan RNN yang efektif memproses data berurutan seperti bahasa alami dan forecasting [15].

2.6. *Recurrent Neural Network (RNN)*

RNN merupakan jenis *Artificial Neural Network* (ANN) yang dirancang untuk memproses data secara berurutan dengan kemampuan menyimpan informasi dari urutan sebelumnya melalui siklus terarah [18]. RNN banyak digunakan dalam forecasting analysis dan NLP karena kemampuannya menangani data berurutan secara efektif. RNN dapat mengingat informasi jangka pendek maupun panjang, sehingga mampu beradaptasi terhadap urutan variabel yang kompleks dan menghasilkan model yang lebih akurat dibandingkan metode tradisional. Namun, RNN memiliki keterbatasan seperti *vanishing gradient*, yang menyebabkan hilangnya informasi jangka panjang, serta *exploding gradient*, yang mengakibatkan pelatihan menjadi tidak stabil ketika bobot neuron terlalu besar. Untuk mengatasi masalah tersebut, dikembangkan varian yang lebih canggih, yaitu *Long Short-Term Memory* (LSTM) dan GRU [6].

2.7. *Gated Recurrent Unit (GRU)*

GRU dikembangkan untuk mengatasi masalah *vanishing gradient* dan *exploding gradient* yang sering muncul pada model RNN tradisional saat mempelajari ketergantungan jangka panjang dalam data sekuensial [7]. *Vanishing gradient* terjadi ketika nilai gradien sangat kecil sehingga pembaruan bobot tidak signifikan,

sedangkan *exploding gradient* muncul saat nilai gradien terlalu besar hingga membuat proses pelatihan tidak stabil. GRU merupakan versi penyederhanaan dari LSTM, di mana *forget gate* dan *input gate* digabung menjadi satu gerbang. Penyatuan ini meningkatkan efisiensi komputasi dan kemampuan model dalam mempertahankan informasi jangka panjang [7]. Sementara itu, LSTM sendiri memiliki tiga gerbang utama *forget gate*, *input gate*, dan *output gate* yang mengatur aliran informasi melalui mekanisme *cell state* dan *gated operations* [7].

2.8. Null Hypothesis

Null Hypothesis atau hipotesa nol merupakan pernyataan dalam uji statistika yang menyatakan tidak adanya efek dan hubungan antar variabel yang diuji, dalam pengujian, hipotesa nol sering dinyatakan dengan koefisien regresi yang sama dengan nol (tidak signifikan) [19]. Hipotesa nol, dapat dinyatakan dalam bentuk sebagai berikut. Tujuan utama dari banyak pengukuran statistik adalah untuk mengevaluasi apakah ada cukup bukti untuk menolak hipotesa nol [19].

2.9. Power BI

Microsoft Power BI adalah alat analisis data yang dikembangkan oleh Microsoft untuk mengolah, menganalisis, dan memvisualisasikan data dari berbagai sumber secara efektif dan mudah dipahami. Platform ini memungkinkan pembuatan *dashboard* interaktif yang kaya visual serta dapat diintegrasikan ke dalam situs web. Power BI mendukung berbagai sumber data, seperti CSV, Excel, *database*, *cloud service*, hingga *platform big data*. Keunggulan utamanya terletak pada kemampuan pembaruan data secara *real-time* dan tersedianya versi gratis, sehingga dapat dimanfaatkan untuk menampilkan hasil analisis maupun visualisasi model *machine learning* secara dinamis.

2.10. Standard Scaling Normalisasi

Standard scaling normalisasi adalah metode transformasi data yang mengubah nilai suatu fitur ke dalam distribusi normal dengan rata-rata nol dan standar deviasi satu, sehingga setiap fitur berada pada skala yang sebanding [20]. Namun, penelitian oleh Haque [21] menunjukkan bahwa dalam beberapa kasus, model yang dilatih tanpa normalisasi justru menghasilkan akurasi lebih tinggi dibandingkan dengan data yang dinormalisasi. Sementara itu, *Cross-Industry Standard Process for Data Mining* (CRISP-DM) merupakan metodologi pengembangan proyek berbasis data yang terdiri dari enam tahapan utama, yaitu *business understanding*, *data understanding*, *data preprocessing*, *modelling*, *evaluation*, dan *deployment*, yang digunakan secara berurutan selama proses pengembangan model [22].

2.11. Business Understanding

Tahapan ini berfungsi untuk menetapkan tujuan serta kebutuhan bisnis secara terarah dalam konteks organisasi. Prosesnya mencakup perumusan tujuan proyek dan persyaratan dalam bentuk yang sesuai dengan unit bisnis atau penelitian, penerjemahan tujuan tersebut ke dalam definisi masalah data mining, serta penyusunan strategi awal untuk mencapainya. Pada tahap ini, keselarasan pemahaman antar pihak yang terlibat menjadi sangat penting agar model yang dikembangkan tidak hanya unggul secara teknis, tetapi juga relevan dengan kebutuhan bisnis yang sebenarnya [22].

2.12. Describing Data

Merupakan tahapan yang digunakan untuk memahami struktur dalam data serta karakteristik dari data tersebut, termasuk memahami jumlah baris dan kolom, melihat tipe data (*numeric*, *string*, *float*) [23].

2.13. Exploring Data

Tahap ini mencakup pemahaman pola, karakteristik, dan hubungan yang terdapat didalam data, tahapan ini bertujuan untuk mengenali struktur yang terdapat didalam data [23].

2.14. Statistika Deskriptif

Statistika deskriptif merupakan cabang ilmu statistik yang memiliki fokus dalam mengumpulkan, menyajikan, dan meringkas informasi dalam data agar dapat dipahami dan dianalisis [24]

2.15. Analisis korelasi data

Analisis korelasi adalah metode statistik untuk menilai arah dan kekuatan hubungan antara dua variabel. Tiga jenis utama yaitu *Pearson* untuk data linear berdistribusi normal, serta *Spearman* dan *Kendall's Tau* (τ) untuk hubungan monotonik pada data non-linear atau ordinal [25].

2.16. Uji Granger Causality

Uji *granger causality* merupakan uji yang digunakan untuk menguji apakah suatu variabel dalam *timeseries* memiliki kemampuan prediktif terhadap variabel yang lain. Dalam regresi, variabel dikatakan

granger apabila nilai masa lalu atau beberapa waktu mempengaruhi secara signifikan nilai variabel yang lainnya.

2.17. Uji Augmented Dickey Fuller

Uji *Augmented Dickey–Fuller* (ADF) merupakan uji yang digunakan untuk mendeteksi suatu akar unit (*root*) dalam suatu *time series*, yaitu apakah suatu data bersifat *stationer* (kondisi suatu data tidak berubah sepanjang waktu) atau tidak. ADF mengatasi beberapa masalah autokorelasi pada residual dengan menambahkan lag dari perbedaan variabel [19].

2.18. Verifying Data Quality

Verifying data quality merupakan tahapan yang digunakan untuk memastikan bahwa data kualitas data yang digunakan didalam analisis bersih, konsisten, dan lengkap. Tujuan dari tahapan ini adalah melaporkan kualitas dalam data, yang ditemukan [23].

2.19. Deteksi missing values

Missing value adalah kondisi ketika satu atau lebih data tidak tersedia dalam *dataset*. Penanganannya penting karena dapat memengaruhi hasil prediksi, seperti dengan mengganti nilai hilang menggunakan konstanta, rata-rata, median, variabel acak, atau metode imputasi seperti KNNImputer [22].

2.20. Deteksi duplikasi

Deteksi duplikasi dilakukan untuk mengidentifikasi baris data yang muncul lebih dari satu kali secara tidak sengaja. Duplikasi seperti ini dapat menyebabkan distorsi dalam analisis karena memberikan bobot berlebih pada nilai yang sama. Contohnya, jika terdapat dua baris dengan ID yang sama persis, maka salah satunya perlu dihapus agar hasil analisis akurat. Namun, penting juga untuk mempertimbangkan konteks apakah kemiripan data tersebut benar-benar duplikat atau memang mewakili entitas berbeda yang sah [22].

2.21. Deteksi outliers

Outlier adalah nilai ekstrem yang menyimpang jauh dari sebagian besar data. Identifikasi *outlier* penting karena dapat menunjukkan kesalahan atau anomali dalam data. Meskipun tidak selalu salah, keberadaan *outlier* dapat memengaruhi kinerja model yang sensitif terhadapnya. Deteksi *outlier* dapat dilakukan melalui metode grafis seperti *histogram* dan *scatter plot*, atau metode numerik seperti *Z-Score* dan IQR [22].

2.22. Data Preprocessing

Tahap ini mencakup semua aktivitas untuk mempersiapkan *dataset final* yang akan digunakan dalam tahap *modeling*. Ini merupakan tahap yang harus mengubah data mentah menjadi format yang siap dianalisis. Kegiatan dalam tahap ini antara lain memilih kasus dan variabel yang relevan, melakukan transformasi pada beberapa variabel jika diperlukan, serta membersihkan data dari *noise*, *missing value*, atau inkonsistensi yang dapat mengganggu kinerja model [22].

2.23. Modelling

Tahap *modeling* mencakup penerapan teknik pemodelan pada data yang telah dipersiapkan melalui pemilihan metode, kalibrasi parameter, dan perbandingan beberapa pendekatan, serta dapat kembali ke tahap data *preparation* jika format data belum sesuai [22]. Beberapa komponen penting dalam tahap ini meliputi: *Loss Function*, yang mengukur selisih antara nilai prediksi dan aktual [26]; *Optimizer*, yang memperbarui bobot model berdasarkan fungsi loss [26]; *Learning Rate*, sebagai *hyperparameter* untuk mengatur besar langkah optimisasi [5]; *Epochs*, yaitu jumlah iterasi penuh selama proses pelatihan [26]; *Callbacks*, untuk menjalankan fungsi otomatis selama pelatihan; *Training* dan *Validation Data*, yang digunakan masing-masing untuk melatih dan menguji performa model [26]; serta *Metrics*, yang berfungsi mengevaluasi akurasi dan kinerja model selama pelatihan [26].

2.24. Mean Absolute Error

Mean Absolute Error (MAE) merupakan metrik yang mengukur kesalahan rata-rata absolut antara nilai aktual dan prediksi. MAE memberikan gambaran seberapa baik prediksi model dari nilai sebenarnya, semakin tinggi nilai MAE semakin tinggi tingkat kesalahannya dalam model [27].

2.25. R-Squared (R2 Score)

R-Squared atau koefisien determinasi merupakan metrik yang menunjukkan seberapa besar proporsi variasi dalam variabel target yang dapat dijelaskan oleh model, persamaan R-Squared dituliskan sebagai berikut. Nilai R-Squared diatas 0,8 atau 80% dapat dikategorikan sebagai hasil yang sangat baik [27].

2.26. Uji Residual dan Densitas

Residual merupakan selisih antar nilai aktual dengan nilai prediksi, dimana residual digunakan untuk merepresentasikan seberapa banyak kesalahan distribusi dari prediksi dengan memperhatikan pola dari hasil prediksi. Uji densitas digunakan untuk memahami pola sebaran error, apakah berbentuk simetris atau memiliki pola lain [19].

2.27. Deployment

Pada tahap deployment, model yang telah dibuat diterapkan ke lingkungan nyata. Deployment dapat berbentuk sederhana seperti menghasilkan laporan, atau lebih kompleks seperti mengintegrasikannya kedalam sistem penuh [22].

2.28. Penelitian Terkait

Berbagai penelitian telah membahas penerapan forecasting multivariat berbasis *deep learning*. Salah satunya dilakukan oleh Robertus Bagaskara Radite Putra (2022) yang meneliti multivariate time series forecasting pada penjualan barang ritel. Penelitian tersebut menggunakan metode RNN dengan tahapan meliputi identifikasi masalah, pengumpulan data, *preprocessing*, dan analisis data. Hasil penelitian menunjukkan bahwa penerapan RNN, khususnya model LSTM dan GRU, memberikan peningkatan akurasi yang signifikan dibandingkan metode statistik tradisional seperti Prophet [28]. Penelitian kedua dilakukan oleh Osvaldo Anacleto yang membahas tentang pengembangan model dalam *forecasting* arus lalu lintas, terutama jalan raya dan informasi seputar lalu lintas. Penelitian ini bertujuan untuk mengatasi dua masalah yaitu variasi dalam arus lalu lintas yang terkadang berubah tiap waktu dan penanganan terkait kesalahan pengumpulan data. Metode yang digunakan dalam penelitian ini adalah *Linear Multiregression Dynamic Model* (LMDM), yang kemudian divisualisasikan dengan grafis *timeseries* multivariate dengan model ruang keadaan. Hasil dari penelitian ini menunjukkan bahwa batas nilai *forecasting* yang digunakan dalam LMDM mendekati batas dari data nilai asli [29].

Penelitian oleh Pantelis R. Vlachas [30] membahas metode peramalan data berdimensi tinggi yang bersifat chaotic menggunakan LSTM. Hasilnya menunjukkan kemampuan model dalam memprediksi informasi jangka pendek secara akurat, serta peningkatan signifikan untuk prediksi jangka panjang melalui penggabungan dengan Mean Stochastic Model. Penelitian G. Peter Zhang [31] menggunakan pendekatan hybrid ARIMA dan ANN untuk peramalan data time series, dengan hasil menunjukkan akurasi lebih tinggi dibandingkan model tunggal. Sementara itu, Heng Shi [32] menerapkan *Pooling-based Deep Recurrent Neural Network* (PDRNN) untuk memprediksi beban listrik rumah tangga, dan hasilnya menunjukkan peningkatan akurasi signifikan serta kemampuan mengatasi *overfitting* lebih baik dibandingkan model tradisional seperti ARIMA.

3. METODE

3.1. Tahapan Penelitian

Penelitian ini menggunakan metode *Cross-Industry Standard Process for Data Mining* (CRIPS-DM). CRIPS-DM memberikan beberapa kerangka standar yang digunakan didalam pelaksanaan proyek yang melibatkan *data mining* dengan tahapan yang terstruktur dan jelas. Berikut beberapa tahapan utama dan penyesuaiannya didalam penyelesaian proyek yaitu *business understanding*, *data understanding*, *data preprocessing*, *data modelling*, *evaluation model*, dan *deployment*. Alur flowchart tahapan penelitian dapat digambarkan pada Gambar 1.

3.2. Tahap Business Understanding

Tahap ini menekankan pemahaman bisnis distribusi aspal yang harganya dipengaruhi faktor eksternal seperti harga minyak global, opini publik, dan kondisi ekonomi. Untuk mengatasi ketidakpastian tersebut, digunakan algoritma GRU guna memprediksi harga aspal mingguan berdasarkan hubungan dengan harga minyak. Pendekatan ini bertujuan meningkatkan akurasi peramalan, efisiensi anggaran, dan mendukung pengambilan keputusan strategis perusahaan.


3.3. Tahap Data Understanding

Pada penelitian ini, tahapan data *understanding* dibagi menjadi 4 tahapan utama, yaitu *gathering data*, *describing data*, *exploring data*, dan *verifying quality data*. Berikut beberapa penjelasan dari masing-masing tahapan utama yang dilakukan didalam penelitian.

1. *Gathering data*, data yang diambil merupakan data harga aspal periode rentang 2016-2023 dengan jumlah 371 baris. Data ini merupakan data asli serta merupakan data private yang tidak bersifat open source, sehingga hanya dapat diakses oleh pihak tertentu. Sumber data berasal dari PT. XYZ, yang merupakan salah satu perusahaan penjual aspal di Indonesia. Data selanjutnya adalah data harga minyak yang merupakan data dari harga Brent Crude Oil dari Google Finance yang diambil dari rentang 2016-2023 dengan jumlah 371 baris, dimana data bersifat open source dan data minyak

merupakan data asli. Penggunaan data minyak dalam forecasting direkomendasikan oleh salah satu staf dan stakeholder perusahaan PT. XYZ. Masing-masing data memiliki rentang yang sudah disesuaikan yaitu bersifat data mingguan, yang dimulai dari hari sabtu

2. *Describing data*, dalam tahapan ini akan dilakukan analisis awal untuk melihat beberapa informasi umum dalam data yang mencakup isi dalam data dan tipe data yang terdapat dimasing-masing kolom.
3. *Exploring data*, dalam tahapan ini akan dilakukan uji statistika deskriptif, analisis korelasi data, uji granger causality, dan uji augmented dickey fuller.
4. *Verifying quality data*, dalam tahapan ini akan dilakukan deteksi missing values, deteksi duplikasi data, dan deteksi outlier.



Gambar 1. Flowchart Tahapan Penelitian

3.4. Tahap Data Preprocessing

Pada tahap ini data yang digunakan sudah bersih dan tidak mengandung *outliers* serta *missing data value*, namun data belum dapat langsung digunakan dalam melakukan pembangunan model prediksi *time series*. Sehingga data masih memerlukan proses transformasi agar dapat diimplementasikan didalam model. Berdasarkan hal diatas, dalam penelitian ini dilakukan beberapa penyesuaian tahapan diantaranya sebagai berikut.

1. Formating Data

Tahapan ini mencakup transformasi data menjadi bentuk sekuensial, digunakan untuk memastikan data diubah ke dalam bentuk sekuensial menggunakan metode *window sliding*. Setiap windows memiliki ukuran yang konstan serta berfungsi sebagai *input* model, sedangkan nilai yang terdapat setelah rentang nilai *window* digunakan sebagai target *output*. Metode ini digunakan agar model GRU dalam *framework Tensorflow* dapat mempelajari pola berdasarkan rangkaian data historis yang telah ditentukan dalam *window*.

2. Selecting Data

Tahapan ini mencakup pembagian data menjadi data *training* dan data *testing*, hal ini untuk memastikan data yang sebelumnya sudah berbentuk sekuensial dibagi menjadi dua bagian, yaitu data *training* dan data *testing* dengan rasio perbandingan 4:1. Data *training* dipakai sebagai bahan pelatihan model dalam menangkap dan mempelajari pola dari data, sedangkan data *testing* digunakan untuk menguji performa yang terdapat didalam model yang telah dilatih, hal ini bertujuan sebagai bahan evaluasi model.

3.5. Tahap Data Modelling

Tahap ini melibatkan pembangunan model menggunakan dua algoritma GRU. GRU dipilih karena kemampuannya dalam menangkap pola informasi jangka panjang dan pola-pola kompleks yang lebih baik dalam *forecasting*, serta memiliki komputasi yang lebih ringan daripada LSTM. Selanjutnya model dilatih menggunakan data *training* yang sebelumnya telah dipersiapkan. Tahapan ini melibatkan penyesuaian model untuk pengoptimalan model GRU dalam memaksimalkan akurasi dari prediksi harga aspal, sehingga melibatkan proses *try and error*.

3.6. Tahap *Evaluation Model*

Model yang telah dilakukan *training*, selanjutnya dilakukan evaluasi menggunakan data *testing* untuk mengukur kemampuan dari performa model. Evaluasi yang akan dilakukan akan membandingkan nilai asli dan nilai hasil prediksi dari model. Metode evaluasi yang digunakan mencakup MAE, *Root Mean Squared Error* (RMSE), *R² Score*, Uji residual dan *density* model untuk mengukur kemampuan serta akurasi pada model.

3.7. Tahap *Deployment*

Pada tahap ini, hasil dari data prediksi dari model terbaik yang sebelumnya telah dilatih dan dievaluasi akan divisualisasikan melalui *dashboard* menggunakan platform Power BI. *Dashboard* ini dirancang sebagai hal yang mempermudah user dalam memahami tren prediksi data dari harga aspal, serta mengikutsertakan data histori harga aspal dan harga minyak. *Dashboard* yang dihasilkan diharapkan memiliki fitur interaktif seperti filter dalam pemilihan rentang waktu serta beberapa parameter lain yang memiliki keterkaitan

4. HASIL DAN PEMBAHASAN

4.1. Analisis Korelasi Data

Hasil dari output menunjukkan bahwa data aspal (*low*) dan aspal (*high*) memiliki korelasi yang sangat tinggi yang ditunjukkan dengan nilai yang mendekati 1. Sedangkan untuk korelasi antara data aspal dan data minyak memiliki korelasi yang tinggi dalam metode *pearson* dan *spearman* yaitu masing-masing 0.9 dan 0.89, serta dalam metode *kendall* 0.71, hal ini mengindikasikan bahwa fluktuasi harga aspal dipengaruhi oleh harga minyak. Dengan demikian, hasil dari uji ini dapat dijadikan landasan untuk menggunakan harga minyak dalam melakukan *forecasting* dan perancangan model dari harga aspal.

4.1.1. Uji *Granger Causality*

Hasil uji *granger causality* untuk minyak (*close*) terhadap data aspal (*low*) menunjukkan bahwa, lag 1 dan lag 2 memiliki *p-value* 0.000 yang menunjukkan nilai yang lebih kecil dari 0,05 yang berarti menolak hipotesa nol dan mengindikasikan bahwa data minyak (*close*) memiliki pengaruh yang signifikan dalam data harga aspal (*low*). Selanjutnya, untuk minyak (*close*) terhadap data aspal (*high*) menunjukkan bahwa, lag 1 dan lag 2 memiliki *p-value* 0.000 yang berarti menolak hipotesa nol dan mengindikasikan bahwa data minyak (*close*) mempengaruhi harga aspal (*high*).

4.1.2. Uji Stasioneritas Data

Hasil uji *Augmented Dickey-Fuller* (ADF) menunjukkan bahwa kolom harga minyak (*close*) memiliki nilai *adf-statistic* sebesar -1,63 dan *p-value* 0,46, kolom harga aspal (*low*) memiliki *adf-statistic* -2,81 dan *p-value* 0,055, sedangkan kolom harga aspal (*high*) menunjukkan *adf-statistic* -2,32 dengan *p-value* 0,16. Nilai *p-value* yang lebih besar dari 0,05 pada seluruh variabel menunjukkan bahwa ketiga deret waktu tersebut bersifat *non-stationer*. Kondisi ini berarti bahwa *varians* dan rata-rata data berubah sepanjang waktu, sehingga berpotensi menimbulkan fenomena *spurious regression* apabila dianalisis menggunakan model statistik klasik seperti ARIMA atau regresi linier, karena hubungan antarvariabel dapat muncul secara semu. Meskipun demikian, penelitian ini tetap menggunakan algoritma GRU karena pendekatan *deep learning* tersebut memiliki kemampuan menangkap pola temporal jangka panjang tanpa harus mensyaratkan data bersifat stasioner. Arsitektur GRU yang berbasis gerbang (*gated mechanism*) mampu menyesuaikan bobot internalnya terhadap tren dan fluktuasi data, sehingga dapat mempelajari representasi waktu yang kompleks secara adaptif. Oleh karena itu, proses transformasi data seperti *differencing* tidak dilakukan agar model tetap dapat mengenali pola musiman dan tren alami dalam data historis. Pendekatan ini sejalan dengan beberapa studi terkini yang menunjukkan bahwa model berbasis RNN dan GRU tetap dapat memberikan hasil prediksi yang akurat meskipun data input bersifat non-stasioner, asalkan pelatihan dilakukan secara bertahap dengan parameter yang dikontrol secara hati-hati.

4.2. Verifying Quality Data

4.2.1. Deteksi *Missing Values*

Hasil dari kode yang digunakan menunjukkan bahwa tidak terdapat *missing values* yang terdapat disetiap kolom, yang ditunjukkan pada Tabel 1.

Tabel 1. Jumlah Missing Data Value

Nama Kolom	<i>Missing Data Values</i>
Aspal (<i>Low</i>)	0
Aspal (<i>High</i>)	0
Minyak (<i>Close</i>)	0

Dalam Tabel 1 ditemukan bahwa semua kategori aspal (*low*), aspal (*high*), dan minyak (*close*) tidak memiliki nilai hilang, dengan jumlah 0 *missing values*. Hal ini memberikan gambaran bahwa data yang digunakan didalam pembangunan model memiliki kualitas yang baik, sehingga tidak diperlukan upaya lanjutan seperti penanganan *missing values*.

4.2.2. Deteksi Duplikasi Data

Berikut kode program yang digunakan untuk melihat nilai duplikasi yang terdapat dalam data dituliskan pada gambar dibawah ini. Hasil output yang dihasilkan dari kode program ini adalah 0, yang berarti tidak terdapat duplikasi data dalam *dataset*. Sehingga *dataset* bebas dari dupliasi dan memastikan bahwa analisis dan model tidak akan dipengaruhi nilai duplikasi yang dapat mengubah bobot dalam model.

4.2.3. Deteksi Outlier

Hasil *output* menunjukkan penyebaran data dalam kolom Minyak (*Close*) ditemukan satu *outlier* yang ditandai dengan satu *dot* diluar garis *whisker*. Namun, nilai *outlier* ini tidak signifikan dan tidak mempengaruhi karakteristik data secara keseluruhan. Selain itu dalam penyebaran data Aspal (*Low*) dan Aspal (*High*), tidak ditemukan *outlier* dalam data, sehingga penyebaran data kedua kolom tersebut dapat dikatakan normal dan semuanya berada di rentang *whisker*.

4.3. Data Preprocessing

Dalam penelitian ini, tahap *data preprocessing* dibagi menjadi dua yang dilakukan secara bertahap dan menyesuaikan kebutuhan dalam pembagunan model yaitu *forming* data dan *selecting* data.

4.3.1. Formatting Data

Tahap ini mencakup transformasi data menjadi bentuk sekuensial, yang menggunakan pendekatan berbasis *sliding window* yang memastikan potongan data dari beberapa periode sebelumnya digunakan untuk memprediksi periode berikutnya. Berikut tahapan-tahapan dalam transformasi data:

1. Konversi dataframe ke bentuk array (Numpy) digunakan untuk mempermudah proses manipulasi data.
2. Mengubah data harga aspal (*low*) menjadi sekuensial data.
3. Mengubah data harga aspal (*low*) menjadi sekuensial data.

Transformasi sekuensial ini memastikan bahwa data historis dapat dimanfaatkan sebagai input untuk model *machine learning* yang akan dibuat untuk memprediksi nilai pada periode berikutnya. Proses ini dilakukan secara konsisten baik pada data harga aspal kategori *low* maupun *high*, sehingga model dapat dilatih dengan pola data yang seragam.

Tabel 2. Perbandingan Model dengan Normalisasi dan Tanpa Normalisasi

Kategori	Normalisasi	Waktu Pelatihan (detik)	MAE	RMSE	R-Squared
Aspal	Ya	80,05	9,6047	11,7867	92,10%
(Low)	Tidak	78,54	5,9849	7,7458	96,59%
Aspal	Ya	77,14	9,8767	12,2727	90,84%
(High)	Tidak	74,80	7,1807	9,3453	95,01%

Tabel 2 merupakan perbandingan data yang telah dilakukan dormalisasi dan yang belum. Pada umumnya normalisasi dilakukan pada tahapan ini, namun pada penelitian ini normalisasi tidak dilakukan. Untuk membuktikan hal tersebut, dilakukan eksperimen data dengan normalisasi dan tidak dinormalisasi menggunakan model GRU dalam kategori Aspal (*Low*) dan Aspal (*High*).

4.3.2. Selecting Data

Data yang telah berbentuk sekuensial dibagi menjadi dua bagian, yaitu 80% untuk data *training* dan 20% untuk data *testing* dengan rasio 4:1. Pembagian ini bertujuan menjaga keseimbangan antara kebutuhan pelatihan dan evaluasi model, sehingga model dapat mempelajari pola historis dengan baik sekaligus diuji performanya secara memadai. Rasio 7:3 tidak digunakan karena data training yang lebih sedikit dapat menurunkan efektivitas pembelajaran model. Langkah-langkah yang digunakan untuk membagi data menjadi bentuk *training* dan *testing* adalah sebagai berikut:

1. Membagi data aspal (*low*) yang telah dalam bentuk sekuensial menjadi data *training* dan data *testing*. Pembagian dilakukan tanpa adanya pengacakan atau *shuffle* dalam data, karena urutan dalam data penting untuk menjaga bentuk data dan memastikan model dapat memprediksi masa depan.
2. Membagi data aspal (*high*) yang telah dalam bentuk sekuensial menjadi data *training* dan data *testing*, tahapan yang digunakan sama dengan pembagian data pada aspal (*low*).

4.4. Data Modelling

Model *time series forecasting* pada penelitian ini dibangun menggunakan arsitektur GRU yang dilatih dengan algoritma *backpropagation*. Dengan demikian, GRU bukan dijalankan terpisah dari *Backpropagation Neural Network* (BPNN), melainkan proses *backpropagation* digunakan sebagai mekanisme pembaruan bobot selama pelatihan model GRU. Arsitektur model terdiri atas beberapa lapisan utama, yaitu lapisan *input* untuk menerima data sekuensial, lapisan GRU sebagai inti jaringan yang bertugas menangkap pola temporal dan ketergantungan jangka panjang dalam data, lapisan *dense* untuk melakukan transformasi non-linear terhadap hasil keluaran GRU, serta lapisan *output* yang menghasilkan prediksi akhir berupa harga aspal (*low* dan *high*). Pendekatan ini memastikan bahwa proses pembelajaran model berlangsung adaptif, dengan setiap neuron memperbarui bobotnya berdasarkan *error gradient* yang dihitung melalui prosedur *backpropagation through time* (BPTT), sehingga pola historis dapat dikenali secara optimal..

4.4.1. Model GRU untuk Prediksi Harga Aspal (Low)

Model GRU (*Low*) yang dirancang untuk memprediksi harga aspal (*low*) menggunakan pendekatan GRU dan *deep learning* yang cocok untuk data *time series* karena keunggulannya menangkap pola-pola kompleks dan temporal dengan arsitektur ditampilkan Tabel 3.

Tabel 3. Arsitektur Model GRU (*Low*)

Lapisan	Output Shape	Trainable Parameters
Input layer	(None, 8, 2)	0
GRU layer	(None, 128)	50688
Dense layer	(None, 64)	8256
Output layer	(None, 2)	130

Dari Tabel 3, model GRU terdiri atas empat lapisan utama: lapisan input berdimensi (8,2) yang memproses delapan *timestep* data harga minyak dan aspal, lapisan GRU dengan 128 neuron dan aktivasi *tanh* untuk menangkap pola temporal kompleks, lapisan *dense* sebagai *hidden layer* untuk transformasi non-linear, dan lapisan output dengan dua hasil prediksi harga minyak dan aspal menggunakan aktivasi linear. Model dikonfigurasi dengan komponen pelatihan seperti *loss function*, *optimizer*, dan *learning rate* sesuai tabel konfigurasi (lihat Tabel 4).

Tabel 4. Konfigurasi Komponen Lingkungan Model GRU (*Low*)

Komponen	Deskripsi
<i>Loss Function</i>	<i>Mean Squared Error</i>
<i>Optimizer</i>	<i>Adam</i>
<i>Initial Learning Rate</i>	0.001
<i>Callbacks</i>	Tensorboard Reduce Learning Rate
<i>Epochs</i>	300
<i>Validation Data</i>	<i>x_low_test, y_low_test</i>
<i>Training Data</i>	<i>x_low_train, y_low_train</i>
<i>Metrics</i>	MAE, MSE

4.4.2. Model GRU untuk Prediksi Harga Aspal (High)

Model GRU (*High*) yang dirancang dalam memprediksi harga aspal (*high*) menggunakan pendekatan GRU dan *deep learning* yang cocok untuk data *time series* karena keunggulannya menangkap pola-pola kompleks dan temporal dengan arsitektur ditampilkan Tabel 5.

Tabel 5. Arsitektur Model GRU (*High*)

Lapisan	Output Shape	Trainable Parameters
Input layer	(None, 8, 2)	0
GRU layer	(None, 128)	50688
Dense layer	(None, 64)	8256
Output layer	(None, 2)	130

Model ini terdiri dari 4 lapisan utama, dimulai dengan lapisan input yang menerima data sekuensial berdimensi (8,2), yaitu 8 *timestep* dari data harga minyak (*close*) dan aspal (*high*). Lapisan GRU dengan 128 neuron menggunakan fungsi aktivasi *tanh* untuk menangkap pola temporal dalam data, serta regulasi kernel l2 untuk mengurangi *overfitting*. Lapisan *dense* dengan 64 neuron dan fungsi aktivasi ReLU membantu mempelajari pola yang lebih kompleks. Akhirnya, lapisan output menghasilkan 2 prediksi untuk harga minyak (*close*) dan aspal (*high*) menggunakan fungsi aktivasi linear. Dalam kode program tersebut, model

dikonfigurasi dengan lingkungan dan komponen-komponen yang digunakan selama pelatihan, yang ditampilkan pada Tabel 6.

Tabel 6. Konfigurasi Komponen Lingkungan Model GRU (*High*)

Komponen	Deskripsi
<i>Loss Function</i>	<i>Mean Squared Error</i>
<i>Optimizer</i>	<i>Adam</i>
<i>Initial Learning Rate</i>	0.001
<i>Callbacks</i>	Tensorboard Reduce Learning Rate
<i>Epochs</i>	300
<i>Validation Data</i>	<i>x_low_test, y_low_test</i>
<i>Training Data</i>	<i>x_low_train, y_low_train</i>
<i>Metrics</i>	MAE, MSE

4.5. Evaluation Model

Evaluasi model melibatkan 2 model yaitu model GRU untuk masing-masing kategori model aspal (*low*) dan model aspal (*high*) dengan beberapa metrik evaluasi yang dipakai. Metrik- metrik ini adalah MAE, *mean root mean squared error* (RMSE), dan R^2 Score (*R-Squared*).

4.5.1. Mean Absolute Error (MAE)

Pada penelitian ini, nilai MAE yang dihitung melibatkan kedua model yaitu model GRU aspal (*low*), model GRU aspal (*high*). Berikut hasil untuk perbandingan evaluasi metrik MAE untuk masing-masing model yang ditunjukkan pada Tabel 7.

Tabel 7. Nilai MAE Masing-Masing Model

Jenis Model	Nilai MAE
Model GRU Aspal (<i>Low</i>)	5,6693
Model GRU Aspal (<i>High</i>)	6,8189

4.5.2. Root Mean Absolute Error (RMSE)

Pada penelitian ini, perhitungan nilai RMSE yang dihitung melibatkan kedua model, yaitu model GRU Aspal (*Low*), model GRU Aspal (*High*) (lihat Tabel 8).

Tabel 8. Nilai RMSE Masing-Masing Model

Jenis Model	Nilai RMSE
Model GRU Aspal (<i>Low</i>)	7,5323
Model GRU Aspal (<i>High</i>)	9,0528

4.5.3. R^2 Score (*R-Squared*)

R^2 Score atau koefisien determinasi digunakan dalam mengukur seberapa baik model dalam mendekati nilai asli, sehingga nilai yang tinggi menunjukkan bahwa model dapat memprediksi dengan baik dan beradaptasi dengan variansi data. Nilai R^2 score masing-masing model dapat dilihat pada Tabel 9.

Tabel 9. Nilai R^2 Score Masing-Masing Model

Jenis Model	Nilai R^2 Score	Dalam Persen
Model GRU Aspal (<i>Low</i>)	0,9678	96,78%
Model GRU Aspal (<i>High</i>)	0,9532	95,32%

4.5.4. Perbandingan Prediksi dengan Aktual

Untuk mengevaluasi lebih lanjut performa model GRU dalam memprediksi harga aspal, dilakukan analisis perbandingan antara nilai prediksi dan nilai aktual. Analisis ini dilakukan untuk kedua kategori, yaitu harga aspal (*Low*) dan harga aspal (*High*), pada data uji (*test set*). Tujuannya adalah untuk mengetahui seberapa dekat nilai yang dihasilkan oleh model dengan nilai riil yang terjadi di lapangan. Tabel 10 dan Tabel 11 adalah tabel yang menyajikan perbandingan nilai prediksi dengan aktual.

4.6. Deployment

Pada penelitian ini, tahap *deployment* dilakukan menggunakan Microsoft Power BI untuk memvisualisasikan hasil dari *forecasting* harga aspal menggunakan model GRU yang sebelumnya sudah dipilih untuk selanjutnya menghasilkan bentuk *dashboard* sehingga dapat dipahami secara umum.

Pengembangan ini bertujuan untuk memberikan gambaran tentang harga aspal (*low* dan *high*), serta prediksi harga aspal diminggu berikutnya.

Tabel 10. Perbandingan Harga Aspal dan Prediksi Kategori (*Low*)


Tanggal	Prediksi (<i>Low</i>)	Aktual (<i>Low</i>)	Selisih
17 Desember 2022	491,2728	495	3,7272
24 Desember 2022	489,9606	495	5,0394
...	...	...	...
18 Februari 2023	496,0511	500	3,9488
25 Februari 2023	492,7733	495	2,2266
...	...	...	...
14 Oktober 2023	485,0091	489	3,9908
21 Oktober 2023	497,9115	490	7,9115
...	...	...	...
Rata-rata selisih			5,67

Tabel 11. Perbandingan Harga Aspal dan Prediksi Kategori (*High*)

Tanggal	Prediksi (<i>High</i>)	Aktual (<i>High</i>)	Selisih
12 November 2022	566,1878	565	1,1878
19 November 2022	562,9337	560	2,9337
...	...	...	...
29 April 2023	479,6630	487,8	8,1369
06 Mei 2023	479,9858	482,5	2,5141
...	...	...	...
23 Desember 2023	441,4078	435	6,4078
30 Desember 2023	433,1738	434,38	1,2062
Rata-rata selisih			6,82

4.6.1. Visualisasi Hasil Tampilan Power BI

Tahapan ini melibatkan pembuatan *dashboard* yang digunakan untuk memvisualisasikan hasil prediksi menggunakan Power BI, sehingga tampilan dapat dibuat interaktif dan dipakai secara umum. *Dashboard* yang ditampilkan mengandung beberapa informasi seperti harga aspal saat ini, prediksi harga aspal minggu depan, grafik perbandingan harga aspal dan minyak, grafik perbandingan prediksi dan aktual harga aspal, serta tabel perbandingan prediksi harga aspal.



Gambar 2. Dashboard Tampilan Harga Aspal

Dashboard pada Gambar 2 dirancang untuk mempermudah *user* dalam memahami tren dan pola perbandingan harga aspal di masa ini dan masa depan, dengan pendekatan visual yang informatif dan sederhana. Sehingga *user* dapat memantau perubahan harga dalam aspal serta mengantisipasi adanya kerugian. Berikut adalah beberapa penjelasan informasi yang terdapat didalam *dashboard*.

Model GRU menunjukkan performa yang sangat baik dengan nilai R^2 sebesar 96,05%, menandakan bahwa model mampu menjelaskan sekitar 96% variasi harga aspal aktual dengan tingkat kesalahan yang rendah (MAE 6,2441 dan RMSE 8,2880) [17]. Jika dibandingkan dengan penelitian sejenis, nilai tersebut tergolong sangat tinggi. Penelitian yang dilakukan oleh G. P. Zhang [31] menunjukkan bahwa model hybrid ARIMA–ANN mampu menghasilkan akurasi lebih baik dibandingkan model tunggal dengan nilai R^2 berkisar antara 85–90%. Sementara itu, penelitian oleh H. Shi et al. [32] menggunakan PDRNN untuk peramalan beban listrik rumah tangga memperoleh peningkatan akurasi signifikan dengan nilai R^2 sekitar 94–96%. Hasil serupa juga ditemukan dalam penelitian oleh P. R. Vlachas [30] yang menunjukkan bahwa model LSTM mampu mencapai nilai R^2 di atas 95% dalam prediksi sistem *chaotic* berdimensi tinggi. Oleh karena itu, capaian R^2 sebesar 96% pada penelitian ini tergolong sangat kompetitif dan menunjukkan kinerja model

yang kuat untuk memprediksi harga aspal yang bersifat volatil. Namun, karena penelitian ini belum menyertakan perbandingan langsung dengan model lain seperti LSTM, ARIMA, atau hybrid ARIMA-ANN pada *dataset* yang sama, hasil ini masih bersifat indikatif dan belum dapat dijadikan dasar konklusif atas keunggulan absolut model GRU dalam domain peramalan harga komoditas.

5. SIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, maka kesimpulan yang dapat diperoleh adalah Model sistem kecerdasan buatan menggunakan algoritma GRU berhasil dirancang untuk memprediksi harga aspal dengan sangat baik dan hasil prediksinya mendekati nilai aktual. Hal ini ditunjukkan melalui nilai MAE dan RMSE yang rendah, serta nilai R-Squared yang tinggi, yang menandakan bahwa error prediksi kecil dan variasi data aktual dapat dijelaskan dengan baik oleh kedua model. Secara rata-rata, model GRU memiliki nilai MAE sebesar 6,2441, RMSE sebesar 8,2880, dan *R-Squared* sebesar 96,05%. Berdasarkan perbandingan hasil prediksi dengan data aktual pada Tabel 10 dan 11. Model GRU mampu menangkap pola perubahan harga aspal dengan baik dan mendekati nilai aktual, dimana rata-rata selisih harga aspal kategori *low* adalah 5,67 dan selisih harga aspal kategori *high* 6,82. Hal ini menunjukkan bahwa model GRU dapat mengikuti arah tren dan fluktuasi harga dengan baik. Model GRU yang telah dibangun berhasil diterapkan dalam visualisasi Power BI, hasil ini memungkinkan pengguna untuk memantau dan menganalisis tren prediksi harga aspal (*Low* dan *High*) secara interaktif dan informatif, sehingga mendukung dalam pengambilan keputusan yang lebih baik.

REFERENSI

- [1] S. Khan and H. Alghulaiakh, "ARIMA Model for Accurate Time Series Stocs Forecasting," *International Journal of Advances Computer Science and Applications (IJACSA)*, vol. 11, no. 7, pp. 524-528, 2020.
- [2] S. Russell and P. Norvig, *Artificial Intelligence A Modern Approach Third Edition*, Upper Saddle River: Prentice Hall, 2010.
- [3] M. I. Jordan and T. M. Mitchell, "Machine Learning: Trends, Perspectives, and Prospects," *Science (AAAS)*, vol. 349, no. 6245, pp. 255-269, 2015.
- [4] R. P. Masini, M. C. Medeiros and E. F. Mendes, "Machine Learning Advances for Time Series Forecasting," *Journal of Economic Surveys*, vol. 37, no. 1, pp. 76-111, 2023.
- [5] I. Goodfellow, Y. Bengio and A. Courville, *Deep Learning*, Cambridge: The Mit Press, 2017.
- [6] K. Gajamannage, D. I. Jayatilake, Y. Park and E. M. Bollt, "Recurrent neural networks for dynamical systems: Applications to ordinary differential equations, collective motion, and hydrological modelling," *Chaos*, vol. 33, no. 1, pp. 1-18, 2023.
- [7] Furizal, A. B. Fawait, H. Maghfiroh, A. Ma'arif, A. A. Firdaus and I. Suwarno, "Long Short-Term Memory vs Gated Recurrent Unit: A Literature Review on the Performance of Deep Learning Methods in Temperature Time Series Forecasting," *International Journal of Robotics and Control Systems*, vol. 4, no. 3, pp. 1506-1526, 2024.
- [8] S. Sukirman, *Beton Aspal Campuran Panas*, Bandung: Institut Teknologi Bandung, 2016.
- [9] D. L. Hoffman and R. H. Rasche, "Assessing Forecast Performance In A Cointegrated System," *Journal of Applied Econometrics*, vol. 11, no. 5, pp. 495-517, 1996.
- [10] B. Abraham and J. Ledolter, "Forecasting Functions Implied by Autoregressive Integrated Moving Average Models and Other Related Forecast Procedures," *International Statistical Review*, vol. 54, no. 1, pp. 51- 66, 1986.
- [11] W. K. Li, S. Ling and M. McAleer, "Recent Theoretical Result For Time Series Models With Garch Errors," *Journal of Economic Surveys*, vol. 16, no. 3, pp. 245-269, 2002.
- [12] S. A. Oke, "A Literature Review on Artificial Intelligence," *International Journal of Information and Management Science*, vol. 19, no. 4, pp. 535-570, 2008.
- [13] S. S. Shwartz, *Understanding Machine Learning From Theory to Algorithms*, New York: Cambridge University Press, 2014.
- [14] I. H. Sarker, "Machine Learning: Algorithms, Real-World Applications and Research Directions," *SN Computer Science*, vol. 2, no. 3, p. 160, 2021.
- [15] Y. LeCun, Y. Bengio and G. Hinton, "Deep Learning," *Nature*, vol. 521, no. 7553, pp. 436-444, 2015.
- [16] S. Haykin, *Neural Network and Learning Machines Third Edition*, Upper Saddle River: Prentice Hall, 2009.
- [17] X. Glorot and Y. Bengio, "Understanding The Difficulty of Training Deep Feedforward Neural Network," *Journal of Machine Learning Research*, vol. 9, pp. 249-256, 2010.
- [18] A. M. Schafer and H.-G. Zimmermann, "Recurrent Neural Networks are Universal Approximators," *International Journal of Neural Systems*, vol. 17, no. 4, pp. 253-263, 2007.
- [19] W. H. Greene, *Fifth Edition Econometric Analysis*, Upper Saddle River: Prentice Hall, 2002.

- [20] A. A. Linkon, I. R. Noman, M. R. Islam, J. C. Bortty, K. K. Bishnu, A. Islam, R. Hasan and M. Abdullah, "Evaluation of Feature Transformation and Machine Learning Models on Early Detection of Diabetes Melitus," *IEEE Access*, vol. 12, pp. 165425-165440, 2024.
- [21] E. Haque, S. Tabassum and E. Hossain, "A Comparative Analysis of Deep Neural Networks for Hourly Temperature Foreceasting," *IEEE Access*, vol. 9, pp. 160646-160660, 2021.
- [22] D. T. Larose and C. D. Larose, *Data Mining and Predictive Analytics*, Hoboken: John Wiley & Sons, Inc., 2015.
- [23] M. S. Brown, *Data Mining For Dummies*, Hoboken: John Wiley & Sons, Inc., 2014.
- [24] D. S. Shafer and Z. Zhiyi, *Beginning Statistics*, Washington, D.C: 2011, 2011.
- [25] P. Y. Chen and P. M. Popovich, *Correlation Parametic and Nonparametic Measures`*, Thousand Oaks: Sage Publications, 2002.
- [26] F. Chollet, *Deep Learning with Python*, Shelter Islan: Manning Publications Co., 2018.
- [27] D. Chicco, M. J. Warrens and G. Jurman, "The Coefficient of Determination R-Squared is More Informative than SMAPE, MAE, MAPE, MSE, and RMSE in Regression Analysis Evaluation," *PeerJ Computer Science*, vol. 7, pp. 1-24, 2021.
- [28] R. B. R. Putra and H. , "Multivariate Time Series Forecasting pada Penjualan Barang Retail dengan Recurrent Neural Network," *Jurnal Inovtek Polbeng - Seri Informatika*, vol. 7, no. 1, pp. 71-82, 2022.
- [29] O. Anacleto, C. Queen and C. J. Albers, "Multivariate Forecasting of Road Traffic Flows in the Presence of Heteroscedasticity and Measurement Errors," *Journal of the Royal Statistical Society Series C: Applied Statistics*, vol. 63, no. 2, pp. 251-270, 2013.
- [30] P. R. Vlachas, W. Byeon, Z. Y. Wan, T. P. Sapsis and P. Koumoutsakos, "Data-Driven Forecasting of High-Dimnesional Chaotic Systems with Long- Short Term Memory Networks," *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Science*, vol. 474, no. 2213, 2018.
- [31] G. P. Zhang, "Time series forecasting using a hybrid ARIMA and neural network model," *Neurocomputing*, vol. 50, pp. 159-175, 2003.
- [32] H. Shi, M. Xu and R. Li, "Deep Learning for Household Load Forecasting - A Novel Pooling Deep RNN," *IEEE Transactions on Smart Grids*, vol. 9, no. 5, pp. 5271-5280, 2018.