

PREDIKSI DAN ANALISIS HARGA MINYAK DI PAPUA: PENDEKATAN BERBASIS GRU DAN LSTM

Carin Gunawan, Teny Handayani

Teknik Informatika, Universitas Tarumanagara
Jalan Letjen S. Parman No.1 Jakarta Barat, Indonesia
carin.535220056@stu.untar.ac.id

ABSTRAK

Penelitian Fluktuasi harga minyak goreng merupakan tantangan serius bagi stabilitas ekonomi rumah tangga di Indonesia, terutama di Provinsi Papua yang menghadapi kendala infrastruktur dan logistic sehingga harga di wilayah ini cenderung lebih tinggi dan tidak stabil. Kenaikan harga minyak goreng juga berkontribusi pada tekanan inflasi dan menurunnya daya beli masyarakat setempat. Penelitian ini bertujuan untuk membandingkan performa dua model prediktif, *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU), dalam memprediksi harga minyak goreng curah, minyak goreng kemasan bermerk 1, dan minyak goreng kemasan bermerk 2 di Papua. Model diuji pada dua skema pembagian data (80% latih–20% uji dan 70% latih–30% uji). Hasil menunjukkan bahwa model GRU menghasilkan nilai Mean Squared Error (MSE) dan Mean Absolute Error (MAE) yang lebih rendah dibandingkan LSTM—misalnya pada skenario 80%–20%, MSE GRU sebesar 229 454,2 dan MAE 226,89, lebih baik daripada MSE 339 310,6 dan MAE 270,69 pada LSTM. Selain itu, nilai R-squared (R^2) model GRU lebih tinggi, menandakan kemampuan yang lebih baik dalam menjelaskan variabilitas data. Tren harga minyak di Papua memperlihatkan puncak pada pertengahan 2022, diikuti penurunan signifikan hingga Maret 2023, kemudian stabil pada level harga rendah. Temuan ini mengindikasikan bahwa GRU lebih akurat dan efektif untuk prediksi harga minyak goreng di Papua, sehingga dapat membantu perumusan kebijakan penetapan harga dan strategi rantai pasok di daerah dengan tantangan logistic.

Kata kunci : LSTM, GRU, Prediksi, Harga Minyak

1. PENDAHULUAN

Ketersediaan bahan pokok semakin berkurang setiap tahun seiring dengan peningkatan populasi. Permintaan terhadap bahan pokok seperti makanan, air, dan energi terus meningkat. Beberapa bahan pokok mengalami kenaikan harga, salah satunya adalah minyak. Harga bahan pokok seperti beras, jagung, cabai, daging, dan minyak goreng adalah bahan pangan yang sering mengalami fluktuasi atau perubahan harga [1]. Perubahan pada harga bahan pokok tersebut tentunya pemicu terjadinya inflasi pada harga minyak yaitu suatu ketidakmampuan untuk menjangkau harga yang terus naik sehingga penurunan daya beli dapat menunjukkan peningkatan inflasi [2]. Salah satu sumber daya yang melimpah di Indonesia adalah minyak. Hal ini disebabkan karena Indonesia adalah produsen minyak dengan cadangan yang tersebar di seluruh daerah, namun seiring dengan peningkatan jumlah penduduk, membuat cadangan minyak yang tersebar semakin lama akan semakin berkurang. Dalam 10 tahun terakhir trend produksi minyak selalu mengalami penurunan, yang disebabkan sulitnya mencari cadangan minyak [3].

Salah satu kebutuhan masyarakat Indonesia adalah minyak goreng. Sumber terbesar dari minyak goreng di Indonesia berasal dari kelapa sawit, dengan posisinya sebagai negara produsen dan eksportir minyak sawit terbesar di dunia. Konsumsi minyak sawit lokal Indonesia pada tahun 2021 mencapai 18,42 juta ton, atau 36% dari produksi total, menurut data dari Gabungan Pengusaha Kelapa Sawit Indonesia (GAPKI) [4]. Minyak kelapa sawit berada di urutan

ketiga dari sepuluh komoditi ekspor utama Indonesia, menurut data dari Kementerian Perdagangan Indonesia. Penguasaan lahan Perkebunan kelapa sawit yang dikelola konglomerasi menyebabkan pergeseran konsumsi minyak sawit nasional. Minyak kelapa sawit mentah (*Crude Palm Oil*) yang disalurkan untuk produksi minyak goreng dialihkan untuk pembuatan biodiesel [5]. Hal tersebut tentunya menyebabkan penurunan produksi minyak goreng yang ada di Indonesia dan tentunya mempengaruhi harga pada minyak goreng. Kenaikan harga minyak goreng tentunya dapat mempengaruhi kenaikan harga barang lainnya [6]. Di Indonesia, minyak goreng sawit adalah yang paling banyak digunakan dan memiliki pangsa pasar terbesar dari semua jenis minyak goreng. Minyak goreng dipasarkan dalam 2 jenis, yaitu minyak goreng kemasan dan minyak goreng curah. Minyak goreng curah adalah jenis minyak yang dijual dalam bentuk tidak terkemas atau tanpa kemasan merek, sedangkan minyak goreng kemasan adalah jenis minyak goreng yang dijual dalam kemasan yang telah diisi atau disegel [7]. Harga minyak goreng kemasan lebih mahal daripada minyak curah.

Harga minyak di Papua sedikit lebih tinggi daripada di semua Provinsi Indonesia lainnya berdasarkan data dari Pusat Informasi Harga Pangan Strategis Nasional. Hal ini dikarenakan, di daerah Papua hanya sedikit sumber cadangan minyak dan belum ada produksi dan pengolahan minyak goreng di wilayah ini [8]. Infrastruktur di Papua yang masih terbatas, tantangan logistic membuat sulitnya untuk mendirikan pabrik minyak, sehingga ketersediaan

minyak di Papua lebih sedikit dan mengharuskan Provinsi Papua untuk mendapatkan distribusi minyak dari Provinsi lain, yang menyebabkan minyak goreng di wilayah ini lebih sulit dan mahal. Pada tahun 2022, harga minyak sawit global juga mengalami penurunan karena pengurangan konsumsi sawit oleh India dan China sebesar 4,8 juta ton per tahun. Ketua Umum DPP Asosiasi Petani Kelapa Sawit Indonesia menyampaikan penurunan global tersebut menyebabkan penurunan harga TDS (Tandan Buah Segar) pada kelapa sawit [9], faktor – faktor tersebut mempengaruhi harga dari minyak goreng sehingga terjadi fluktuasi harga.

Penelitian ini bertujuan untuk memprediksi dan menganalisis harga minyak goreng yang ada di Provinsi Papua. Metode *time series* terbagi menjadi dua yaitu metode *statistic* dan metode *machine learning* [10]. Algoritma yang dipakai pada analisis *time series* ini adalah Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU) [11]. Kedua algoritma tersebut adalah algoritma *deep learning* yang merupakan cabang dari *machine learning*. LSTM merupakan jenis jaringan saraf tiruan yang termasuk dalam kategori Recurrent Neural Network (RNN) [12]. LSTM memiliki beberapa *gate* pada setiap neuronnya, sehingga dapat mempelajari data mana saja yang harus disimpan dan dibuang. LSTM banyak digunakan untuk melakukan proses data *time series* [13] karena memiliki kemampuan untuk mengingat informasi dalam jangka waktu yang lama sehingga dapat mengenali pola dan tren kompleks untuk memprediksi harga, yang sering kali dipengaruhi oleh harga pada periode waktu sebelumnya [14], jenis RNN lainnya yang lebih sederhana untuk mengatasi beberapa kelemahan RNN konvensional seperti masalah *vanishing gradient*. Proses komputasi GRU sederhana namun memiliki akurasi yang cukup baik [15].

Penggunaan model LSTM sering digunakan untuk memprediksi harga seperti pada penelitian *Prediction and Early Warning Methods for Agricultural Commodity Price Based on SSA-LSTM* yang dilakukan oleh Dian Zhang, Yi-Qun Wang, dan Wen-Bai Chen [16] Model GRU juga banyak dilakukan dalam penelitian, seperti prediksi harga saham, harga komoditas, dan harga energi, seperti penelitian yang dilakukan oleh Clara Tanudy dengan judul *Prediksi Harga Emas di Indonesia Menggunakan Gated Recurrent Unit* [17].

2. TINJAUAN PUSTAKA

Penelitian prediksi harga minyak goreng di Papua menerapkan model *Long Short Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU). Model prediksi berbasis *deep learning* ini dipilih karena kemampuannya dalam menangani pola data deret waktu (*time series*) yang kompleks dan fluktuatif. Selain itu, model ini terbukti efektif dalam berbagai studi untuk memprediksi harga komoditas maupun pergerakan pasar keuangan

2.1. Long Short Term Memory (LSTM)

Salah satu jenis modifikasi arsitektur *Recurrent Neural Network* (RNN) adalah *Long Short-Term Memory Model* (LSTM). LSTM banyak digunakan untuk mengelola set data teks, video, atau deret waktu tertentu, dan memiliki kemampuan untuk mempelajari dan memprediksi data karena dapat mengingat informasi penting dalam jangka waktu yang Panjang [18]. LSTM terdiri dari beberapa komponen utama yaitu sel memori (*memory cell*), gerbang masukan (*input cell*), gerbang lupa (*forget cell*), dan gerbang keluaran (*output cell*).

2.2. Forget Gate

Forget gate menentukan informasi yang akan dibuang dari *memory cell*. Fungsi *sigmoid* akan mengatur pintu *forget* dan menghasilkan nilai antara 0 dan 1. Nilai 0 menunjukkan bahwa informasi sepenuhnya akan dihapus, sedangkan nilai 1 menunjukkan bahwa informasi sepenuhnya akan dipertahankan.

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

Nilai f_t adalah nilai *forget gate* pada waktu t , σ adalah fungsi sigmoid, W_f adalah bobot dari *forget gate*, h_{t-1} adalah keluaran dari unit LSTM pada waktu sebelumnya, x_t adalah input pada waktu t , b_f adalah bias *forget gate*.

2.3. Input Gate

Input gate menentukan informasi baru yang akan disimpan dalam sel memori. *Input gate* menggunakan fungsi sigmoid dan fungsi tanh untuk memperbarui sel memori. Nilai i_t adalah nilai *input gate* pada waktu t . $\tilde{C}_t$ adalah kandidat sel pada memori baru, C_t adalah nilai sel memori yang diperbarui. b_i b_C adalah bobot untuk *input gate* dan sel memori, *tanh* adalah bias *input gate* dan *memory cell*, dan adalah fungsi aktivasi tanh. Persamaan (2) menghitung *input gate* dengan mengombinasikan *hidden state* dan input saat ini kemudian memetakannya ke menggunakan sigmoid untuk menentukan seberapa besar informasi baru yang boleh masuk. Persamaan (3) membentuk *cell candidate* dengan melakukan transformasi linear. Persamaan (4) menggabungkan *forget gate* dan input gate untuk memperbarui memori dan mengatur seberapa banyak memori lama yang dipertahankan serta menentukan kontribusi kandidat baru dan menghasilkan status memori yang seimbang antara ingatan lama dan informasi baru.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (3)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (4)$$

2.4. Output Gate

Gerbang ini menentukan *output* dari *memory cell* ke lapisan berikutnya. *Output* akhir unit LSTM dihasilkan oleh *gate output* yang menggunakan tanh dan fungsi sigmoid. O_t adalah nilai *output gate* pada waktu t , h_t adalah keluaran dari unit LSTM pada

waktu t , W_o adalah bobot *output gate*, dan b_o adalah bias *output gate*.

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t * \tanh(C_t) \quad (6)$$

2.5. Gated Recurrent Unit (GRU)

Gated Recurrent Unit (GRU) diperkenalkan Kyunghyun cho et sebagai alternatif untuk LSTM (*Long Short Term Memory*) pada tahun 2014 karena arsitekturnya yang sederhana, dengan menggabungkan *cell state* dan *hidden state* menjadi satu dan mengurangi jumlah *gate* dari tiga menjadi dua, GRU memiliki arsitektur yang lebih sederhana dibandingkan dengan LSTM. GRU menunjukkan hasil yang baik dalam menangani masalah *vanishing gradient*. *Vanishing gradient* adalah masalah selama pelatihan jaringan saraf dalam, terutama pada jaringan saraf berulang, dan jaringan saraf konvolusional.

2.6. Reset Gate

Reset gate (r_t) adalah *gate* yang digunakan untuk menghitung seberapa banyak informasi dari masa lalu yang akan dilupakan. r_t merupakan output dari reset gate. W_r adalah matriks bobot untuk reset gate. h_{t-1} merupakan hidden state sebelumnya. x_t adalah input pada waktu t


$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) \quad (7)$$

2.7. Update Gate

Update gate (z_t) menentukan seberapa banyak informasi dari masa lalu yang akan dilupakan. r_t merupakan output dari reset gate. W_z adalah matriks bobot untuk reset gate. h_{t-1} merupakan hidden state sebelumnya. x_t adalah input pada waktu t .

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t]) \quad (8)$$

3. METODE PENELITIAN



Gambar 1. Diagram alur penelitian

Penelitian ini menggunakan pendekatan yang sistematis dengan menggunakan model pembelajaran

mesin. Metode yang digunakan melibatkan beberapa tahapan penting mulai dari pengumpulan data sampai interpretasi hasil. Diagram alur penelitian pada gambar 1 dibuat untuk menggambarkan langkah – langkah pada penelitian ini

3.1. Data Collection

Tahap pengumpulan data (*Data Collection*) dimulai dengan penentuan variabel dan ruang lingkup penelitian: harga minyak goreng curah, harga minyak kemasan (merek A dan B), serta harga bahan baku (*crude palm oil*) pada periode harian Januari 2022– Januari 2024 di Provinsi Papua. Data primer diunduh secara otomatis dari API Pusat Informasi Harga Pangan Strategis (PIHPS) menggunakan skrip Python yang memanggil endpoint resmi setiap hari. Untuk mempertahankan reproducibility, setiap panggilan API dicatat timestamp-nya dan disimpan dalam format CSV dengan penamaan terstandar (harga_minyak_YYYYMMDD.csv), serta diuji kesesuaian tipe data tanggal (YYYY-MM-DD) dan nilai numerik harga dalam satuan rupiah.

Setelah penarikan data, dilakukan validasi kelengkapan dan konsistensi format sebelum memasuki tahap pra-proses. Lengkapnya deret waktu dicek dengan memastikan tidak ada tanggal hilang selama rentang pengamatan, sedangkan nilai harga yang ekstrem di luar tiga kali simpangan baku ditandai untuk verifikasi manual. Semua file mentah kemudian diarsipkan di direktori data/raw/ dan dibackup ke repositori GitHub untuk menghindari kehilangan data. Dokumentasi metadata (sumber, metode pengunduhan, versi skrip) juga disimpan untuk mendukung transparansi dan memudahkan proses audit ataupun pengulangan penelitian.

3.2. Exploratory Data Analysis

Berdasarkan *dataset* harian harga minyak goreng di Papua yang disajikan pada Tabel deskripsi dataset (rentang 3 Januari 2022–1 Januari 2024), penulis pertama-tama melakukan perhitungan statistik deskriptif untuk setiap seri harga (minyak goreng curah, kemasan merek 1, kemasan merek 2, dan *crude palm oil*). Rata-rata, median, simpangan baku, serta rentang nilai minimum–maksimum dihitung untuk memahami sebaran dasar dan variabilitas tiap variabel. Selain itu, frekuensi dan pola nilai hilang (*missing values*) diperiksa—ditemukan kurang dari 1% data hilang—sehingga diputuskan untuk menggunakan imputasi forward fill pada langkah pra-proses berikutnya.

Visualisasi *univariat* dan *multivariat* dilakukan untuk mengungkap ciri-ciri penting data. *time series plot* memperlihatkan *tren* jangka panjang serta pola musiman; misalnya, terlihat lonjakan harga setiap akhir tahun dan penurunan selepas periode panen sawit. Sebuah *heatmap matriks korelasi* juga dibuat untuk menilai hubungan linier antar seri harga—hasilnya menunjukkan korelasi positif kuat ($\rho > 0,8$) antara *crude palm oil* dan keduanya minyak kemasan,

yang mengindikasikan bahwa fluktuasi harga bahan baku segera tercermin pada harga eceran. Dari langkah-langkah ini diperoleh wawasan penting untuk tahap rekayasa fitur: fitur lag ($t-1$, $t-7$) dipilih untuk menangkap efek *autokorelasi*. Semua temuan EDA ini kemudian menjadi dasar bagi proses normalisasi dan pembagian data sebelum memasuki pelatihan model GRU dan LSTM.

3.3. Feature Selection and Engineering

Pada tahap *feature selection*, evaluasi terhadap kontribusi dilakukan pada masing – masing variabel berdasar korelasi dan multikolinearitas. Semua fitur yang memiliki korelasi sangat tinggi ($\rho > 0,9$) dengan fitur lain dihapus untuk menghindari redundansi. Dari sisa fitur, diterapkan *recursive feature elimination* (RFE) menggunakan regresi berregularisasi L1 untuk memilih subset yang secara empiris paling menurunkan error pada data validasi. Proses ini menghasilkan delapan fitur teratas yang meliputi harga mentah (*crude palm oil*), harga minyak kemasan, serta beberapa turunan lag dan rata-rata bergerak. Semua fitur hasil rekayasa kemudian dinormalisasi ke rentang $[0, 1]$ sebelum digunakan sebagai input pada model GRU dan LSTM, sehingga setiap variabel memiliki skala yang seragam dan model dapat belajar dengan stabil.

3.4. Data Splitting

Pada penelitian ini diterapkan dua skema pembagian data deret waktu secara kronologis tanpa melakukan *shuffling*. Pada skema pertama (80:20), 80 % data awal (Januari 2022–Agustus 2023) digunakan sebagai *training set*, sedangkan 20 % data berikutnya (September 2023–Januari 2024) dijadikan *testing set*. *Training set* ini dipakai untuk proses fitting model (GRU dan LSTM) dan optimasi hyperparameter melalui *time-series cross-validation*, kemudian model dilatih ulang pada keseluruhan *training set* dengan konfigurasi terbaik. Setelah itu, *testing set* digunakan untuk evaluasi performa akhir menggunakan metrik MAE, RMSE, dan MAPE.

Skema kedua (70:30) membagi 70 % data pertama (Januari 2022–September 2023) sebagai *training set* dan 30 % data sisa (Oktober 2023–Januari 2024) sebagai *testing set*. Prosedur yang sama—*time-series cross-validation* pada *training set* untuk pemilihan hyperparameter, pelatihan akhir model, dan evaluasi pada *testing set* dengan MAE, RMSE, dan MAPE—dilakukan untuk mengukur kestabilan model terhadap variasi rasio pembagian data dan membandingkan hasil prediksi kedua skema.

3.5. Evaluation Process

Pada tahap evaluasi, performa model GRU dan LSTM diukur menggunakan metrik kuantitatif yang umum dalam peramalan deret waktu, yaitu MAE (Mean Absolute Error), RMSE (Root Mean Squared Error), dan MAPE (Mean Absolute Percentage Error). MAE memberikan gambaran rata-rata selisih

absolut antara nilai prediksi dan nilai aktual, sedangkan RMSE lebih sensitif terhadap outlier karena mengkuadratkan error. MAPE mengekspresikan error dalam persen sehingga memudahkan perbandingan antar seri dengan skala berbeda. Setiap model diuji pada *testing set* yang belum pernah dilihat selama pelatihan, dan hasil metriknya dibandingkan untuk menentukan model mana yang menghasilkan kesalahan paling kecil. Analisis juga mencakup visualisasi *residual plot* untuk memastikan distribusi kesalahan mendekati normal dan tidak terdapat pola tersisa yang sistematis.

Setelah menentukan model terbaik berdasarkan metrik di atas, masuklah ke tahap Prediksi di mana model tersebut dipakai untuk meramalkan harga minyak goreng di periode masa depan—misalnya bulan berikutnya atau kuartal mendatang. Prediksi dihasilkan dalam bentuk *point estimates*, yaitu nilai tunggal untuk setiap tanggal prediksi. Untuk aplikasi praktis, interval keyakinan (*confidence intervals*) 95 % juga dapat dihitung dengan asumsi distribusi residual normal, sehingga pengguna mengetahui rentang ketidakpastian prediksi. Hasil prediksi kemudian ditampilkan dalam grafik time series yang memplot nilai aktual dan nilai ramalan berdampingan, memudahkan interpretasi tren dan evaluasi visual performa model pada titik-titik kunci.

Secara keseluruhan, evaluasi yang teliti—menggunakan beberapa metrik dan analisis residual—membuktikan bahwa model terpilih mampu menangkap pola temporal dan musiman dengan baik, sedangkan tahap prediksi menyediakan output yang siap pakai untuk pengambilan keputusan harga. Dengan demikian penelitian ini tidak hanya menyajikan perbandingan GRU dan LSTM, tetapi juga menunjukkan proses end-to-end mulai dari pemodelan hingga penerapan prediksi dalam skenario dunia nyata.

4. HASIL DAN PEMBAHASAN

Prediksi harga minyak goreng di Papua menggunakan dataset dari Berdasarkan Daerah - PIHPS (bi.go.id), dataset memiliki rentang data mulai dari 3 Januari 2022 sampai 1 Januari 2024. Data berupa *timeseries* harian dan berisi harga – harga minyak yang ada di Papua. Tabel mengenai dataset dapat dilihat pada table 2. Dataset berisikan 5 atribut dengan atribut ‘Time’ yang berisi tentang waktu harian, dan atribut harga jenis – jenis minyak yang terdiri dari ‘Minyak’, ‘Minyak Goreng Curah’, ‘Minyak Goreng Kemasan Bermerk 1’, dan ‘Minyak Goreng Kemasan Bermerk 2’, setelah melakukan *data collection*, tahapan selanjutnya adalah melakukan *preprocessing* data.

Tabel 1. Dataset harga minyak di Papua

Time	Minyak	Curah	Kemasan 1	Kemasan 2
03/01/2022	20,400	19,400	21,350	20,450
04/01/2022	20,400	19,400	21,350	20,450
05/01/2022	20,400	19,400	21,350	20,450

Time	Minyak	Curah	Kemasan 1	Kemasan 2
06/01/2022	20,400	19,400	21,350	20,450
...	...	...	...	...
27/12/2022	19,700	16,650	21,850	20,600
28/12/2022	19,700	16,650	21,850	20,600
29/12/2022	19,700	16,650	21,850	20,600

4.1. Preprocessing Data

Tahapan *preprocessing* data dilakukan untuk menghilangkan *null values* pada setiap kolom. Pada tahapan ini, format atribut 'time' yang sebelumnya *object* akan diubah menjadi format *datetime*. Hal ini dilakukan untuk mempermudah untuk melakukan manipulasi, transformasi, dan juga pengurutan dalam penyortiran data. Semua atribut dalam dataset memiliki tipe data berupa *object*, setelah dilakukan *preprocessing data* dan *analysis*, tipe data akan berubah menjadi seperti pada table 2.

Tabel 2. Tipe data pada setiap atribut dataset

Atribut	Tipe Data
Time	datetime64 [ms]
Minyak	float64
Minyak Curah	float64
Minyak Kemasan Bermerk 1	float64
Minyak Kemasan Bermerk 2	float64

Pada Tahapan *preprocessing* data juga dilakukan normalisasi data, yang dilakukan untuk mengubah skala fitur ke rentang tertentu misalnya seperti [0,1] tanpa mengubah distribusi data. Metode yang digunakan adalah Min-MaxScaling dengan menggunakan rumus pada persamaan 11, dimana *scaled* adalah nilai yang telah dinormalisasi, *min* berarti nilai *minimum*, dan *max* adalah nilai *maximum*.

$$X_{scaled} = \frac{x - x_{min}}{x_{max} - x_{min}}$$

4.2. Normalisasi Data

Proses normalisasi dilakukan dengan mengambil harga minyak pada setiap kolom kemudian mengubahnya menjadi *array numpy* dengan satu kolom, dan menerapkan *scaler* pada data harga minyak untuk mengubah nilai – nilainya ke rentang [0,1]. *Dataset* akan dilakukan proses *splitting data*, data akan dipisah menjadi *data training* dan *data testing*, eksperimen dilakukan dengan data *training* 70%, 80% dan data *testing* sebanyak 30%, 20%, dengan timestep sebanyak 1,2, dan 3, serta *epoch* sebanyak 50, dengan kombinasi *batch size* sebanyak 8 seperti ditunjukkan pada table 5.

Tabel 3. Inisialisasi *training data*

Data Training	Data Testing	Batch Size
80%	20%	[16],[32],[64], [16,32], [32,64], [64,32], [16,32,64], [64,32,16]

Data Training	Data Testing	Batch Size
70%	30%	[16],[32],[64], [16,32], [32,64], [64,32], [16,32,64], [64,32,16]

4.3. Evaluasi Data

Data akan dilatih dengan menggunakan 2 model algoritma sebagai perbandingan yaitu, model LSTM dan GRU, hasil dari evaluasi setiap model akan tertera dalam setiap table di bawah ini. Tabel 6 dan 7 akan memuat setiap eksperimen dengan nilai MAE, MAPE, MSE, RMSE, R2 terbaik pada setiap model dalam setiap harga jenis minyak. Evaluasi matriks pada model LSTM dilakukan dengan 97 eksperimen dengan kombinasi time step, dan unit layers layers yang berbeda. Jumlah pembagian data latih (70% atau 80%) dan data uji (30% atau 20%) pada LTSM tidak memiliki perbedaan yang jauh, keduanya memiliki performa yang baik dengan nilai MAE, MSE, RMSE yang rendah meskipun ada sedikit perbedaan dalam nilai MSE dan RSME

Tabel 4. Evaluasi matriks terbaik pada LSTM dengan data latih 80% data uji 20%


Jenis Minyak	Unit Layers	MAE	MSE	R2
Minyak	[32]	165,12	189644.36	0,96
Minyak Goreng Curah	[64]	191,18	150254,13	0,97
Minyak Kemasan Bermerk 1	[16]	195,21	218009,69	0,95
Minyak Kemasan Bermerk 2	[32]	186,19	295665,96	0,94

Tabel 5. Evaluasi matriks terbaik pada LSTM dengan data latih 70% data uji 30%

Jenis Minyak	Unit Layers	MAE	MSE	R2
Minyak	[32]	168,72	194469,7	0,959
Minyak Goreng Curah	[32]	185,35	151337,4	0,97
Minyak Kemasan Bermerk 1	[32]	198,4	233920,5	0,95
Minyak Kemasan Bermerk 2	[16,32,64]	169,53	255183,2	0,95

Perbandingan harga jenis – jenis minyak secara actual dan prediksi yang dilakukan oleh model LSTM dapat dilihat pada gambar 3. Garis biru merupakan harga actual, sedangkan garis orange menunjukkan harga yang diprediksi. Secara umum, pada gambar grafik minyak, minyak goreng curah, minyak goreng kemasan bermerk 1, dan bermerk 2, garis prediksi sudah cukup mengikuti pola dari harga actual, meskipun terjadi penyimpangan harga terutama pada

puncak – puncak harga, namun prediksi sudah cukup baik untuk mengatasi fluktuasi harga. Evaluasi matriks pada model GRU juga dilakukan seperti model LSTM. Model GRU bekerja dengan baik untuk semua jenis minyak ditunjukkan pada table 8 dan 9. Konsistensi nilai R2 yang tinggi menunjukkan bahwa model GRU mampu menangkap pola dalam data dan membuat prediksi yang akurat, secara keseluruhan, model GRU menunjukkan hasil yang baik



Gambar 2. Perbandingan data asli dengan hasil forecasting menggunakan metode LSTM


Tabel 6. Evaluasi matriks terbaik pada GRU dengan data latih 80% data uji 20%

Jenis Minyak	Unit Layers	MAE	MSE	R2
Minyak	[64,32]	168,84	204026,1	0,96
Minyak Goreng Curah	[16]	172,65	141905,8	0,977
Minyak Kemasan Bermerk 1	[32]	180,852	207829	0,96
Minyak Kemasan Bermerk 2	[16,32]	161,891	254763	0,956

Tabel 7. Evaluasi matriks terbaik pada GRU dengan data latih 70% data uji 30%

Jenis Minyak	Unit Layers	MAE	MSE	R2
Minyak	[64,32,16]	162	201421,7	0,96
Minyak Goreng Curah	[64]	168,55	136057,4	0,95
Minyak Kemasan Bermerk 1	[16]	180,07	206500	0,958
Minyak Kemasan Bermerk 2	[16]	158,09	254988,6	0,94

Kesesuaian Prediksi untuk semua komoditas, garis prediksi (oranye) cenderung mengikuti garis aktual (biru) seperti pada gambar 3 menunjukkan bahwa model GRU memiliki kemampuan yang baik dalam memprediksi.



Gambar 3. Perbandingan data asli dengan hasil forecasting menggunakan metode GRU

4.4. Hasil Prediksi Data

Secara keseluruhan, model GRU menunjukkan performa yang lebih baik dibandingkan model LSTM berdasarkan nilai MAE, MSE, dan R². GRU lebih baik dalam memprediksi harga dengan kesalahan yang lebih rendah dan memiliki kemampuan yang lebih baik dalam menjelaskan variabilitas data berdasarkan table 10 yang berisi rata – rata dari 97 eksperimen pada setiap masing – masing model dengan kombinasi time step dan unit layers yang berbeda – beda.

Tabel 8. Rata – Rata Perbandingan Evaluasi LSTM dan GRU

Model	Data (Latih -Uji)	MAE	MSE	R2
LSTM	80% - 20%	270,69	339310,6	0,939
	70% - 30%	268,77	333981	0,940
GRU	80% - 20%	226,89	229454,2	0,946
	70% - 30%	223,26	294995	0,947

Matriks korelasi menunjukkan bahwa secara umum, harga dari berbagai jenis minyak memiliki hubungan yang kuat dan positif satu sama lain. Jenis minyak yang dikemas, baik bermerk 1 maupun 2, memiliki korelasi yang sangat kuat dengan harga minyak mentah, menunjukkan bahwa pergerakan harga pada satu jenis minyak kemungkinan besar akan diikuti oleh pergerakan harga pada jenis minyak lainnya. Hubungan terlemah masih menunjukkan korelasi positif yang cukup signifikan, menunjukkan bahwa semua jenis minyak dalam analisis ini cenderung bergerak bersama-sama dalam hal harga.

Tren umum yang terlihat pada semua jenis minyak adalah adanya puncak harga pada pertengahan 2022, diikuti oleh penurunan yang signifikan dan stabilisasi harga di tingkat yang lebih rendah. Setelah terjadinya penurunan harga, harga minyak cenderung menunjukkan stabilisasi dengan fluktuasi kecil, menunjukkan bahwa pasar mungkin telah menemukan keseimbangan baru setelah periode volatilitas. Meskipun pola umum penurunan dan stabilisasi terlihat pada semua jenis minyak, beberapa jenis minyak menunjukkan fluktuasi yang lebih besar dalam harga, terutama minyak goreng kemasan bermerek. Grafik-grafik pada gambar 4 memberikan wawasan yang jelas tentang bagaimana harga minyak yang

berfluktuasi dan akhirnya stabil selama periode yang diamati.



Gambar 4. Min, max, dan average pada harga bulanan (monthly price)

5. KESIMPULAN DAN SARAN

Perbandingan performa antara LSTM dan GRU menunjukkan bahwa GRU lebih unggul dalam akurasi prediksi harga minyak goreng di Papua. Pada skenario 80 % latih–20 % uji, GRU menghasilkan MSE sebesar 229 454,2 dan MAE sebesar 226,89, sementara LSTM mencatat MSE 339 310,6 dan MAE 270,69. Selain itu, nilai R^2 model GRU—sebesar 0,947 pada skenario 70 % latih–30 % uji—menunjukkan kemampuan yang lebih baik dalam menjelaskan variabilitas data. Tren harga memperlihatkan puncak di pertengahan 2022, diikuti penurunan signifikan hingga Maret 2023, dan kemudian stabil pada level yang lebih rendah.

Untuk penelitian selanjutnya, perluasan variabel input dengan memasukkan faktor eksternal—seperti kurs valuta asing, inflasi, biaya logistik, dan data cuaca—diharapkan dapat meningkatkan akurasi prediksi. Eksplorasi arsitektur alternatif (misalnya Transformer atau Temporal Convolutional Networks) maupun pendekatan ensemble (contohnya stacking

GRU–LSTM), dipadukan dengan optimasi hyperparameter (grid search, random search, atau Bayesian optimization), akan membantu menemukan konfigurasi model yang paling optimal. Perluasan cakupan data ke frekuensi harian atau mingguan, dengan horizon prediksi tiga hingga enam bulan dan pengujian pada periode volatilitas ekstrem, penting untuk mengevaluasi stabilitas model. Selain itu, implementasi model dalam sistem pemantauan harga real-time dan validasi lapangan melalui umpan balik pengguna akan menambah relevansi praktis bagi pembuat kebijakan dan pelaku pasar.

Penanganan missing data serta outlier dengan teknik imputasi dan deteksi anomali perlu diutamakan, dan pelengkapan dataset hingga tahun berjalan memungkinkan analisis dampak kebijakan subsidi atau perubahan rantai pasok terkini. Dengan langkah-langkah ini, penelitian lanjutan diharapkan dapat menghasilkan model yang lebih akurat, robust, dan aplikatif.

DAFTAR PUSTAKA

- [1] G. Andira, "Pengaruh Kenaikan Harga Pangan Pokok terhadap Tingkat Inflasi di Kabupaten Temanggung," *Jurnal Paradigma Multidisipliner*, vol. 1, no. 2, pp. 111-122, 2020
- [2] O. Helbawanti, W. A. Saputro and A. Ulfa, "Pengaruh Harga Bahan Pangan terhadap Inflasi di Indonesia," *Jurnal Ilmu-Ilmu Pertanian*, vol. 5, no. 2, pp. 107-116, 2021
- [3] A. Setyono and B. Kiono, "Dari Energi Fosil Menuju Energi Terbarukan: Potret Kondisi Minyak dan Gas Bumi Indonesia Tahun 2020 – 2050," *JEBT: Jurnal Energi Baru & Terbarukan*, vol. 2, no. 3, pp. 154-162, 2021
- [4] H. L.S. and N. Y., "Prediksi Harga Minyak Goreng Curah dan Kemasan Menggunakan Algoritme Long Short-Term Memory (LSTM)," *Jurnal Ilmu Komputer dan Agri-Informatika*, vol. 9, no. 2, pp. 149-157, 2022
- [5] N. Andrianto, S. Fauzi, R. Perdana and T. Tauf, "Prahara Minyak Goreng," 2024
- [6] Y. Purbawa, H. Purba and Y. M. Bakti, "Acceptable price of packaged palm cooking oil amid scarcity in Indonesia," *Journal of Revenue and Pricing Management*, vol. 22, pp. 446-454, 2023
- [7] S. Wulandari and A. Zainuddin, "Preferensi Konsumen Minyak Goreng Curah dan Bermerk Pada Rumah Tangga Pedesaan di Kabupaten Jember," *Sebuah Analisis Multiatribut Fishben*, vol. 24, no. 2, pp. 477-487, 2023
- [8] P. I.B., "10 Largest Oil Palm Plantations in Indonesia"
- [9] S. Sitompul, N. Fahruqi, O. Ningsih, Y. Gustian, W. Azizah, C. Cancelia and H. Effendy, "Pengaruh Penurunan Harga Kelapa Sawit terhadap Harga Minyak Perkilogram di Sungai Bangek Tahun 2022," *Mathematic and*

- Applications Journal*, vol. 5, no. 1, pp. 88-94, 2023
- [10] S. Lutfi, A. Kurniawati, M. Ahmad, M. Fadhli and S. , "Analisis Perbandingan Metode Time Series Forecasting untuk Prediksi Penjualan Obat di Apotek," *Jurnal Jaringan dan Teknologi Informasi*, vol. 3, no. 1, pp. 96-106, 2023\
- [11] K. Sofi, A. Sunge, S. Rialdy and A. Kamalia, "Perbandingan Algoritma Linear Regression, LSTM, dan GRU dalam Memprediksi Harga Saham dengan Model Time Series," *Jurnal Seminastika*, vol. 3, no. 1, pp. 40-47, 2021
- [12] V. Kumar, N. Smith, S. Kiran and S. Abdulla, "Stock Closing Price and Trend Prediction with LSTM-RNN," *Journal of Artificial Intelligence and Big Data*, 2023
- [13] Y. Nugraha, I. Ariawan and W. Arifin, "Weather Forecast from Time Series Data Using LSTM Algorithm," *Jurnal Ilmiah Teknologi Informasi dan Komunikasi*, vol. 14, no. 1, pp. 144-152, 2023
- [14] M. Pratama and H. Utama, "Pendekatan Deep Learning Menggunakan Metode LSTM untuk Prediksi Harga Bitcoin,," *The Indonesian Journal of Computer Science Research*, vol. 2, no. 2, pp. 43-50, 2023
- [15] N. Agusmawati, F. Khoriyah and A. Tholib, "Prediksi Harga Emas Menggunakan Metode LSTM dan GRU," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 11, no. 3, pp. 620-627, 2023
- [16] D. Zhang, Y. Wang and W. Chen, "Prediction and Early Warning Methods for Agricultural Commodity Price," *Journal of Computers*, vol. 34, no. 3, pp. 357-370, 2023
- [17] C. Tanudy, T. Handhyani and J. Hendryli, "Prediksi Harga Emas di Indonesia Menggunakan Gated Recurrent Unit," *Jurnal Fasilkom*, vol. 13, no. 3, pp. 480-488, 2023
- [18] T. Shahi, A. Shrestha, A. Neupane and W. Guo, "Stock Price Forecasting with Deep Learning: A Comparative Study," *Mathematics*, vol. 8, no. 9, p. 1441, 2020