

PREDIKSI HARGA DAGING SAPI DI KOTA JAKARTA PUSAT MENGUNAKAN LSTM DAN GRU

Farhan Adithya Putra¹⁾, Teny Handhayani²⁾

1. Fakultas Teknologi Informasi, Universitas Tarumanagara, Jakarta
email: farhan.535210021@stu.untar.ac.id
2. Fakultas Teknologi Informasi, Universitas Tarumanagara, Jakarta
email: tenyh@fti.untar.ac.id

Abstract

This study analyzes the performance of two algorithms, Long Short-Term Memory (LSTM) and Gated Recurrent Unit (GRU), in predicting data from the PIHPS website, focusing on beef commodity prices. The dataset was divided into two proportions: 80:20 and 70:30, and evaluated using Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), and coefficient of determination (R^2). The experimental results showed that GRU with 128 units and a 70:30 proportion achieved the best performance, with metrics of MAE at 170, RMSE at 390.2889, and R^2 at 0.902. The goal of this research is to determine the most suitable algorithm and unit configuration for this dataset. Future research is expected to integrate additional data with more complex models to improve prediction accuracy.

Kata Kunci: Beef, Gated Recurrent Unit, Long Short-Term Memory, Prices

A. PENDAHULUAN

Masyarakat Indonesia sering mengonsumsi sumber protein hewani terbanyak urutan kedua yaitu bahan pokok daging sapi. Bertambahnya jumlah penduduk di Indonesia dengan kebutuhan masyarakat pada daging sapi terus meningkat [1]. Di pasaran daging sapi menjadi salah satu penghasil utama protein hewani, memiliki keunggulan nutrisi penting bagi tubuh. Protein dibagi menjadi dua jenis, berdasarkan asalnya yaitu protein hewani dan nabati [2].

Stabilisasi harga pangan tetap menjadi isu strategis yang penting di Indonesia, mengingat mayoritas pengeluaran masyarakat masih dialokasikan untuk kebutuhan pangan. Perubahan pola konsumsi dan preferensi masyarakat telah menjadikan daging sapi sebagai sumber

protein hewani kedua yang paling banyak dikonsumsi setelah daging unggas [3].

Komoditas paling penting di Indonesia seperti daging juga mengalami seperti perubahan harga, perubahan harga ini dapat berpengaruh dari beberapa pihak yaitu produsen, konsumen, yang menjual produk atau industri pengolahan daging [4]. Tingkat kenaikan daging juga sebagai indikator bahwa pasar tersebut memiliki ketertarikan yang tinggi.

Daging juga menjadi sumber nutrisi yang menjadikan salah satu komoditas yang paling penting dengan mengalami fluktuasi harga di Indonesia. Permintaan konsumen meningkat dan pasokan yang tidak stabil dikarenakan perubahan harga pada penjualan daging sapi. Wilayah terkenal dengan tingkat kebutuhan daging sapi di Indonesia salah satunya Provinsi

DKI Jakarta dengan dijadikan barometer konsumsi daging sapi nasional [5]. Hal ini menunjukkan pentingnya menjaga harga dan ketersediaan daging sapi di wilayah tersebut.

Menurut data Pusdatin Kemdikbudristek tahun 2021, Daging sapi di DKI Jakarta mencapai kebutuhan dengan angka tertinggi di Indonesia, yaitu sebesar 1.96 kg per kapita pada tahun 2020. Sekitar 0.48 kg per kapita adalah rata-rata nasional yang lebih rendah dibandingkan per kapita pada tahun 2020 [5]. Nilai konsumsi ini mewakili sebagai peran DKI Jakarta sebagai pusat konsumsi masyarakat pada daging sapi dan pentingnya pengecekan harga serta distribusi untuk mendukung kebutuhan masyarakat yang terus meningkat.

Selain itu, berdasarkan badan pusat statistic atau disebut BPS, konsumsi daging sapi per kapita di Indonesia pada tahun 2021 tercatat sebesar 2,66 kilogram per tahun, jauh lebih rendah dibandingkan rata-rata konsumsi dunia yang mencapai 6,4 kilogram per kapita per tahun. Namun, konsumsi daging sapi di DKI Jakarta menunjukkan angka yang lebih tinggi dari rata-rata nasional, yaitu sebesar 6,10 kilogram per kapita per tahun [6].

B. METODE PENELITIAN

Studi literatur merupakan bagian penting dalam penelitian ini, yang bertujuan untuk memahami dan menganalisis hasil-hasil penelitian sebelumnya terkait penggunaan algoritma *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) dalam memprediksi harga komoditas pangan. Beberapa penelitian telah dilakukan untuk membandingkan kinerja kedua

algoritma ini dalam konteks prediksi harga komoditas.

Studi yang relevan dengan penelitian penulis adalah "Perbandingan Model LSTM dan GRU untuk Memprediksi Harga Minyak Goreng di Indonesia" yang dilakukan oleh Mochammad Agus Sholeh dan Rahmat Hidayat pada tahun 2022 [7]. Studi ini menemukan bahwa model LSTM memiliki performa yang lebih unggul dibandingkan model GRU, dengan nilai *Mean Absolute Error* (MAE) validasi sekitar $\pm 0,04$ dan *Mean Squared Error* (MSE) validasi *loss* sekitar $\pm 0,002$.

Penelitian yang sesuai lainnya adalah karya Marwondo Marwondo pada tahun 2022 yang berjudul "Perbandingan Algoritma *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) untuk Prediksi Harga Emas Dunia" [8]. Dalam studi ini, ditemukan bahwa algoritma GRU memberikan kinerja yang lebih baik dibandingkan LSTM dalam memprediksi harga emas dunia, ditunjukkan oleh nilai *error* yang lebih rendah.

Penelitian lainnya berjudul "Perbandingan *Gated Recurrent Unit* (GRU) dan Algoritma *Long Short-Term Memory* (LSTM) *Linear Regression* dalam Prediksi Harga Emas Menggunakan Model *Time Series*" yang dilakukan oleh Anggi Putri Meriani dan Alam Rahmatulloh pada tahun 2024 [9]. Studi ini menunjukkan bahwa metode GRU memiliki tingkat akurasi yang lebih tinggi dibandingkan LSTM dalam memprediksi harga emas. Namun, pada perhitungan metrik evaluasi, LSTM menghasilkan nilai *error* yang lebih rendah.

LSTM dan GRU memiliki keunggulan masing-masing dan kekurangannya yang disesuaikan dengan dataset yang ada.

Namun dari kinerja algoritma ini sangat tergantung dari berapa parameter model yang digunakan. Oleh karena itu, pentingnya untuk melakukan eksperimen serta analisis dari hasil eksperimen yang telah dilakukan untuk menentukan algoritma mana yang sesuai dengan data dan tujuan prediksi yang kita inginkan.

Long Short-Term atau biasa disebut dengan (LSTM) adalah model prediksi yang biasa digunakan karena menghasilkan model yang bagus dalam sistem prediksi dan cocok untuk data yang berbasis *time series* yang berurutan. LSTM juga sebagai algoritma yang berasal dari pengembangan *Recurrent Neural Network* (RNN) yang dirancang untuk data *time series* secara efektif [10].

Penelitian ini dilakukan dengan model LSTM yang dimana lstm tersebut memiliki lapisan lstm, *dropout rate*, dan jumlah *neuron* pada *layer* yang tersembunyi atau *hidden layer* untuk meningkatkan setiap performa yang dilakukan oleh model [11]. Fungsi dari *input gate* dan *output gate* adalah untuk mengatur aliran data masuk dan keluar dari memori sel ke seluruh jaringan [12]. Selain itu, *forget gate* ditambahkan ke memori sel untuk meneruskan informasi output dengan bobot tinggi dari *neuron* sebelumnya ke *neuron* berikutnya [12]. Cara kerja LSTM yaitu dengan menghapus data lama yang tidak relevan serta menyimpan informasi penting sehingga sangat sesuai dengan data pada jangka Panjang dan jangka pendek . Design arsitektur pada lstm juga disebut *stacked lstm* yang memanfaatkan beberapa lapisan lstm untuk data dapat menggunakan model secara lebih efisien [13].

Proses pemodelan LSTM akan menghasilkan model yang baik ketika beberapa aspek ini diperhatikan, diperhatikan penentuan jumlah *hidden layer* yang optimal serta pemilihan hyperparameter yang sesuai untuk mencapai hasil prediksi yang akurat [14].

Gate Recurrent Unit atau GRU adalah salah satu model dari *Recurrent Neural Network* (RNN) yang dibuat dan disebarkan model ini oleh Kyunghyun Cho. GRU memiliki sebutan *update gate* pada arsitekturnya yang bertujuan untuk menentukan sejauh mana *input* pada GRU (x_t) dan *output* sebelumnya (h_{t-1}), *input* dan *output* ini akan dilanjutkan di dalam sel untuk proses lebih lanjutnya [15].

GRU memanfaatkan dua jenis *gate* yang disebutkan sebelumnya yaitu *update gate* dan *reset gate* untuk memilih informasi *input* atau *output* yang akan disalurkan. Data informasi yang disimpan penting dari data sebelumnya tanpa menghapus data yang tidak relevan terhadap prediksi dilakukan oleh dua komponen yaitu *update gate* dan *reset gate* [16].

Jika dibandingkan dengan LSTM, GRU memiliki arsitektur yang lebih simpel karena jumlah parameter yang dimiliki lebih sedikit. Data yang di proses oleh GRU juga lebih efisien secara komputasi sistem [17]. GRU memproses data secara berurut pada satu elemen waktu dengan memperbarui status tersembunyi berdasarkan input sekarang dan status tersembunyi pada data sebelumnya [17].

Selain komponen *update gate* melakukan penghapusan data yang tidak relevan, komponen ini juga menjaga sejauh mana data informasi dilakukan dari waktu sebelumnya yang disalurkan

ke waktu saat ini [18], sedangkan komponen *reset gate* melakukan dengan menentukan seberapa besar informasi dari waktu sebelumnya yang dapat diabaikan.

Evaluasi metrik untuk mengukur bagus atau tidaknya pada model yaitu menggunakan tiga metrik utama, seperti *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE), dan koefisien determinansi (R^2)

Mean Absolute Error atau MAE adalah metrik yang sering digunakan untuk perhitungan pada model GRU dan LSTM yang berfungsi sebagai penghitung pada nilai rata-rata absolut yang memiliki kesalahan pada nilai prediksi dengan nilai aktual. Informasi yang diberikan adalah seberapa besar rata-rata kesalahan prediksi tanpa melihat nilai arah kesalahan, baik itu prediksi yang bagus atau lebih rendah dibandingkan nilai sebenarnya [19]. Rumus MAE [20] sebagai berikut:

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - F(X_i)| \quad (1)$$

Dimana:

n adalah jumlah keseluruhan observasi dilakukan

Y_i adalah nilai sebenarnya

$F(X_i)$ adalah nilai prediksi model untuk observasi ke- i

Root Square Mean Error atau RMSE merupakan salah satu metrik yang lebih efisien dibandingkan MSE. RMSE menjadi metrik yang lebih bagus dibandingkan MSE dikarenakan memiliki skala yang sama dengan data yang dievaluasi [21]. Persamaan rumus RMSE [22] sebagai berikut:

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

Koefisien Determinasi adalah metrik statistik yang mengukur sejauh mana model dapat menjelaskan variasi dalam data hasil berdasarkan variabel independen atau prediktor yang digunakan dalam model [23]. Persamaan pada koefisien determinasi [24] sebagai berikut:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3)$$

C. HASIL DAN PEMBAHASAN

Data yang digunakan dalam penelitian ini adalah data harga daging sapi yang berasal dari website PIHPS Nasional atau pusat informasi harga pangan strategis nasional. *Dataset* ini berisi terkait informasi perkembangan harga pangan pada komoditas daging sapi di DKI Jakarta. Jumlah dari *dataset* ini yaitu 1540 baris atau selama lima tahun terakhir. *Dataset* ini terdiri dari kolom utama yaitu tanggal, daging sapi yang mencatat rata-rata daging sapi kualitas 1 dan mencatat daging sapi kualitas 2.

Pada *dataset* ini, dilakukan beberapa tahapan *preprocessing* untuk memastikan data siap digunakan dalam proses model. Pertama dilakukan adalah memasukkan data dari file CSV yang kemudian melakukan pengecekan setiap kolom dan struktur data. Selanjutnya kolom tanggal di konversi format *datetime* serta pembersihan data yang berupa tanggal terlewat atau “-“ pada kolom harga daging sapi, daging sapi kualitas 1, dan daging sapi kualitas 2 akan digantikan dengan “none” agar dapat diimputasi.

Tahapan selanjutnya melengkapi rentang tanggal dari awal hingga tanggal

terakhir pada *dataset*. Jika ada yang tidak memiliki data, data tersebut akan dimasukkan dengan metode *forward fill*. Setelah sudah di lengkapi datanya akan melakukan normalisasi menggunakan *MinMaxScaler* untuk merentangkan nilai data dalam skala 0 hingga 1. Proses *preprocessing* ini bermanfaat untuk data *cleaning*, konsisten, dan model akan siap dilatih.

Evaluasi metrik untuk mengukur bagus atau tidaknya pada model yaitu menggunakan tiga metrik utama, seperti *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE), dan koefisien determinansi (R^2) Pada penelitian ini menggunakan dua jenis pembagian data yaitu, 70:30 dan 80:20. Pada pembagian ini untuk 80% dan 70% adalah sebagian data latih untuk melatih model. Kemudian untuk 30% dan 20% sebagai data uji untuk mengevaluasi performa yang dihasilkan dari model LSTM dan GRU.

Eksperimen yang dilakukan menggunakan LSTM dan GRU dengan menggunakan jumlah unit pada *hidden layer* yang berjumlah 32, 48, 64, 128, dan 256. Hasil dari setiap kombinasi pembagian data ini menggunakan parameter untuk performa model seperti *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE), dan Koefisien Determinansi (R^2).

Pada eksperimen dengan model *Long Short Term Memory* (LSTM) menggunakan pembagian data dengan data latih dan data uji 80:20, yang disajikan dalam tabel 1 berikut:

Tabel 1. Evaluasi kinerja LSTM pada eksperimen menggunakan perbandingan data latih dan data uji 80%:20%

Eksperimen ke	MAE	RMSE	R^2	UNIT
1	568.34	774.46	0.62	32
2	687.58	896.87	0.47	48
3	326.59	546.38	0.80	64
4	227.66	509.70	0.83	128
5	912.61	1177.91	0.13	256

Dari hasil tabel 1 diatas menjelaskan bahwa unit 128 menghasilkan performa terbaik karena menunjukkan nilai MAE terendah dari unit lain sebesar 227.66, RMSE terendah sebesar 509.71, dan nilai R^2 tertinggi sebesar 0.834. Sebaliknya untuk hasil performa terburuk yaitu menggunakan 256 unit *neuron* yang bernilai MAE sebesar 912.62, RMSE sebesar 1177.91, dan R^2 sebesar 0.139.

Setelah menguji model LSTM dengan data latih dan data uji 80:20, dilanjutkan eksperimen dengan model GRU menggunakan data latih dan data uji 80:20. Hasil eksperimen GRU pada data ditampilkan dalam tabel 2 berikut:

Tabel 2. Evaluasi kinerja GRU pada eksperimen menggunakan perbandingan data latih dan data uji 80%:20%

Eksperimen ke	MAE	RMSE	R^2	UNIT
1	384.93	637.93	0.72	32
2	549.97	686.59	0.70	48
3	481.70	601.37	0.77	64
4	273.71	441.90	0.88	128

5	379.36	502.48	0.83	256
---	--------	--------	------	-----

Berdasarkan Tabel 2 pada model GRU 80:20, unit 128 menghasilkan performa terbaik dengan nilai MAE sebesar 273.71, RMSE sebesar 441.91, dan R^2 sebesar 0.882 dan performa yang terburuk pada unit 48 yang menghasilkan metrik MAE sebesar 549.97, RMSE sebesar 686.69, R^2 sebesar 0.705.

Selain pengujian data latih dan data uji 80:20 pada kedua model, akan dilanjutkan untuk mengavaluasi kinerja model yang sama tetapi berbeda proporsi yaitu 70:30, berikut hasil tabel pengujian LSTM pada data latih dan data uji 70:30:

Tabel 3 Evaluasi kinerja LSTM pada eksperimen menggunakan perbandingan data latih dan data uji 70%:30%

Eksperimen ke	MAE	RMSE	R^2	UNIT
1	616.09	874.38	0.68	32
2	702.90	927.52	0.61	48
3	572.88	801.33	0.74	64
4	530.62	806.31	0.73	128
5	563.45	868.75	0.68	256

Berdasarkan hasil eksperien pada tabel 3, LSTM unit 64 memberikan performa terbaik pada proporis data 70:30 bernilai MAE sebesar 572.88, RMSE sebesar 801.33, dan R^2 sebesar 0.747. Untuk hasil eksperimen terburuk berada pada unit 48 menghasilkan dengan nilai MAE dan RMSE jauh lebih tinggi.

Pengujian terakhir dilakukan pada model GRU dengan data latih dan data uji 70:30, memiliki variasi unit yang sama

dengan eksperimen sebelumnya. Hasil eksperimen untuk model GRU pada proporsi 70:30 sebagai berikut:

Tabel 4 Evaluasi kinerja GRU pada eksperimen menggunakan perbandingan data latih dan data uji 70%:40%

Eksperimen ke	MAE	RMSE	R^2	UNIT
1	320.51	583.96	0.86	32
2	233.24	501.49	0.89	48
3	287.47	531.61	0.88	64
4	563.45	892.26	0.64	128
5	269.25	496.88	0.89	256


Berdarkan hasil eksperimen pada Tabel 4 pada model GRU, unit 48 menunjukkan performa terbaik dengan nilai MAE sebesar 233.24, RMSE sebesar 501.49, dan R^2 sebesar 0.893. Selain itu hasil terburuk dari model GRU ini adalah dengan unit 128 yang memiliki nilai R^2 yang hanya sebesar 0.553 dan nilai kesalahan prediksi yang relative tinggi.

Evaluasi kinerja algoritma dengan membandingkan algoritma LSTM dan GRU, berdasarkan metrik evaluasi *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE), dan Koefisien Determinasi (R^2). Tabel 5 menampilkan performa terbaik dari hasil eksperimen yang telah dilakukan.


Tabel 5 Perbandingan Kinerja Algoritma LSTM dan GRU

Metode	MAE	RMSE	R^2	Unit
LSTM	227.66	509.70	0.83	128

GRU	233.24	501.49	0.89	48
-----	--------	--------	------	----



(a)



(b)

Gambar 1. Perbandingan prediksi menggunakan LSTM dan GRU

Dari hasil perbandingan kinerja algoritma *Long Short Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) berdasarkan MAE, RMSE, R^2 . Hasil menunjukkan bahwa unit sebesar 128 pada LSTM dan unit 48 pada GRU dengan proporsi yang berbeda, 80:20 memberikan nilai pada model LSTM, nilai MAE sebesar 227.661, RMSE sebesar 509.7085, dan R^2 sebesar 0.8342. Sementara itu, GRU menunjukkan kinerja yang hampir sama, dengan MAE sebesar 233.2475, RMSE sebesar 501.4944, dan R^2 sedikit lebih tinggi, yaitu 0.8934.

Kedua Algoritma ini dapat menangani data *sequence* dengan baik namun untuk algoritma GRU sedikit lebih unggul dibandingkan LSTM dalam hal akurasi

prediksi pada konfigurasi. Selain itu juga hanya terlihat sedikit berbeda dari gambar plot untuk membandingkan data aktual dan data prediksi dari hasil eksperimen terbaik pada masing-masing algoritma. Performa GRU yang lebih sederhana secara arsitektur menjadikannya lebih efisien tanpa mengubah kualitas prediksi dibandingkan dengan LSTM.

Kedua Algoritma ini dapat menangani data *sequence* dengan baik namun untuk algoritma GRU sedikit lebih unggul dibandingkan LSTM dalam hal akurasi prediksi pada konfigurasi. Selain itu juga hanya terlihat sedikit berbeda dari gambar plot untuk membandingkan data aktual dan data prediksi dari hasil eksperimen terbaik pada masing-masing algoritma. Performa GRU yang lebih sederhana secara arsitektur menjadikannya lebih efisien tanpa mengubah kualitas prediksi dibandingkan dengan LSTM.

D. KESIMPULAN DAN SARAN

Kesimpulannya, penelitian ini memperoleh hasil terbaik dengan menggunakan unit berjumlah 128 dengan memiliki data latih dan data uji yang berbeda pada kedua algoritma GRU dan LSTM sebesar 80:20 dan 70:30. Nilai pada GRU menunjukkan lebih unggul dibandingkan LSTM, yang dapat diidentifikasi bahwa GRU dapat menghasilkan prediksi yang lebih akurat pada *dataset* yang digunakan.

Algoritma GRU dengan arsitektur yang lebih sederhana, terbukti lebih unggul secara perhitungan model tanpa mengurangi kualitas prediksi, LSTM sendiri hanya sedikit nilai yang lebih rendah dibandingkan GRU. Oleh karena itu, kedua metode ini masih sangat bergantung dengan pemilihan parameter,

seperti pembagian jumlah unit dan pembagian data latih dan data uji.

Pemilihan hyperparameter untuk pengembangan lebih lanjut dapat meningkatkan kinerja model secara baik. Teknik *ensemble learning* juga dapat digunakan untuk melakukan prediksi dari beberapa model agar hasil yang dihasilkan lebih memuaskan. Hasil penelitian ini diharapkan dapat menjadi acuan dalam pengembangan model prediksi harga komoditas yang lebih efektif di masa yang akan datang

E. REFERENSI

- [1] Paiso and Wahyu Aji, *ANALISIS PERKEMBANGAN HARGA DAGING SAPI PADA PERIODE SEBELUM PUASA SAMPAI SEBELUM HARI RAYA IDUL FITRI TAHUN 2020 DI PASAR ANGSO DUO KOTA JAMBI*. 2021. Accessed: Nov. 26, 2024. [Online]. Available: <https://repository.unja.ac.id/id/eprint/27699>
- [2] N. D. L. Imani, T. Tarno, and B. A. Saputra, "PREDIKSI HARGA DAGING SAPI DI KABUPATEN BREBES MENGGUNAKAN PEMODELAN ARFIMA DENGAN EFEK GARCH," *Jurnal Gaussian*, vol. 12, no. 4, pp. 570–580, 2024.
- [3] D. Sapi, "VOLATILITAS DAN TRANSMISI HARGA DAGING SAPI DI INDONESIA: STUDI KASUS DI JAKARTA, BANDUNG, SEMARANG DAN SURABAYA".
- [4] A. I. Hasibuan and S. Mulatsih, "Covid-19 dan Disparitas Harga Daging Sapi Indonesia," *Policy Brief Pertanian, Kelautan, dan Biosains Tropika*, vol. 4, no. 1, pp. 175–178, 2022.
- [5] B. C. Saragih, "Analisis Faktor-Faktor Yang Mempengaruhi Permintaan Daging Sapi Di Provinsi Dki Jakarta," *Agrista*, vol. 11, no. 2, 2023.
- [6] A. F. Fajriaty, "Analisis Efisiensi Pemasaran Daging Sapi di Kabupaten Cirebon," *Agrista*, vol. 12, no. 1, 2024.
- [7] M. A. Sholeh, "Perbandingan Model LSTM Dan GRU Untuk Memprediksi Harga Minyak Goreng di Indonesia," *Edusaintek: Jurnal Pendidikan, Sains dan Teknologi*, vol. 9, no. 3, pp. 800–811, 2022.
- [8] M. Marwondo and T. Hidayah, "Perbandingan Algoritma Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU) Untuk Prediksi Harga Emas Dunia," *In Search (Informatic, Science, Entrepreneur, Applied Art, Research, Humanism)*, vol. 21, no. 2, pp. 230–239, 2022.
- [9] A. P. Meriani and A. Rahmatulloh, "Perbandingan Gated Recurrent Unit (Gru) Dan Algoritma Long Short Term Memory (Lstm) Linear Refression Dalam Prediksi Harga Emas Menggunakan Model Time Series," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 1, 2024.
- [10] M. F. Rizkillah and S. Widiyanesti, "Prediksi Harga Cryptocurrency Menggunakan Algoritma Long Short Term Memory (LSTM)," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 6, no. 1, pp. 25–31, 2022.
- [11] A. Hanafiah, Y. Arta, H. O. Nasution, and Y. D. Lestari, "Penerapan Metode Recurrent Neural Network dengan Pendekatan Long Short-Term Memory (LSTM) Untuk Prediksi Harga Saham," *Bulletin of Computer Science Research*, vol. 4, no. 1, pp. 27–33, 2023.

- [12] F. Shahid, A. Zameer, and M. Muneeb, "Predictions for COVID-19 with deep learning models of LSTM, GRU and Bi-LSTM," *Chaos Solitons Fractals*, vol. 140, p. 110212, 2020.
- [13] A. D. Milniadi and N. O. Adiwijaya, "Analisis Perbandingan Model Arima Dan Lstm Dalam Peramalan Harga Penutupan Saham (Studi Kasus: 6 Kriteria Kategori Saham Menurut Peter Lynch)," *SIBATIK JOURNAL: Jurnal Ilmiah Bidang Sosial, Ekonomi, Budaya, Teknologi, Dan Pendidikan*, vol. 2, no. 6, pp. 1683–1692, 2023.
- [14] S. Sautomo and H. F. Pardede, "Prediksi belanja pemerintah Indonesia menggunakan long short-term memory (LSTM)," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 1, pp. 99–106, 2021.
- [15] D. A. Aquinaldo, "Perbandingan Metode Multivariatif GRU dan VAR Berdasarkan Sentimen Investor dan Nilai Kurs Dollar Untuk Prediksi Harga Saham," *Innovative: Journal Of Social Science Research*, vol. 3, no. 6, pp. 10238–10257, 2023.
- [16] E. N. Waroi, A. Arief, and K. Khusnawi, "Prediksi Harga Laptop Menggunakan Algoritma GRU dan BiLSTM," *Jurnal Sosial Teknologi*, vol. 4, no. 7, pp. 408–424, 2024.
- [17] K. Danil, "Pengenalan Jenis Kelamin dalam Lingkungan Multiaksen Menggunakan Metode Multi Layer Perceptron (MLP) dan Gated Recurrent Unit (GRU): Gender Recognition in a Multiaccent Environment Using Multi Layer Perceptron (MLP) and Gated Recurrent Unit (GRU) Methods," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 3, pp. 803–811, 2024.
- [18] W. Li, H. Wu, N. Zhu, Y. Jiang, J. Tan, and Y. Guo, "Prediction of dissolved oxygen in a fishery pond based on gated recurrent unit (GRU)," *Information Processing in Agriculture*, vol. 8, no. 1, pp. 185–193, 2021.
- [19] E. Novarida, Y. P. Pasrun, and M. N. Sutoyo, "Implementasi Metode Time Series Simple Moving Average untuk Prediksi Penjualan Multi-Produk," *Journal of Information Systems and Technology*, vol. 1, no. 1, pp. 1–6, 2024.
- [20] I. Amansyah, J. Indra, E. Nurlaelasari, and A. R. Juwita, "Prediksi Penjualan Kendaraan Menggunakan Regresi Linear: Studi Kasus pada Industri Otomotif di Indonesia," *Innovative: Journal Of Social Science Research*, vol. 4, no. 4, pp. 1199–1216, 2024.
- [21] H. D. E. Sinaga and N. Irawati, "Perbandingan double moving average dengan double exponential smoothing pada peramalan bahan medis habis pakai," *JURTEKSI (Jurnal Teknologi dan Sistem Informasi)*, vol. 4, no. 2, pp. 197–204, 2018.
- [22] R. Al Kiramy, I. Permana, A. Marsal, M. R. Munzir, and M. Megawati, "Perbandingan Performa Algoritma RNN dan LSTM dalam Prediksi Jumlah Jamaah Umrah pada PT. Hajar Aswad: Comparison of RNN and LSTM Algorithm Performance in Predicting the Number of Umrah Pilgrims at PT. Hajar Aswad," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 4, pp. 1224–1234, 2024.
- [23] H. T. S. Harita and O. M. Siregar, "Pengaruh Direct Marketing Dan Product Quality Terhadap Minat Beli Ulang Pada Live Streaming Marketing Tiktok," *Jurnal Ekonomi Kreatif Dan Manajemen*

Bisnis Digital, vol. 1, no. 2, pp. 171–184, 2022.

[24] W. D. Febrian, Z. Zulhaida, and A. Ilosa, “Analisis Pengaruh Lingkungan Kerja Terhadap Kinerja Pegawai Bank Riau Kepri Syariah Pekanbaru,” *Syarikat: Jurnal Rumpun Ekonomi Syariah*, vol. 2, no. 2, pp. 77–87, 2019.