

Penerapan *Gated Recurrent Unit* dengan *Bayesian Optimization* dalam Prediksi Harga Saham Sektor FMCG

Mohammad Faizal Akmal¹, I Gede Susrama Mas Diyasa², Achmad Junaidi³

^{1,2,3} Program Studi Informatika, Fakultas Ilmu Komputer, Universitas Pembangunan Nasional "Veteran" Jawa Timur)
²igsusrama.if@upnjatim.ac.id

Abstrak— Peningkatan partisipasi investor muda terutama dari Generasi Z dan Milenial menciptakan kebutuhan mendesak untuk menggunakan metode prediksi yang lebih akurat guna meminimalkan risiko investasi. Penelitian ini bertujuan untuk mengembangkan model prediksi harga saham pada sektor *Fast-Moving Consumer Goods* (FMCG) di Indonesia dengan memanfaatkan algoritma *Gated Recurrent Unit* (GRU) yang dioptimalkan menggunakan teknik *Bayesian Optimization*. Data saham yang digunakan merupakan PT Hanjaya Mandala Sampoerna Tbk (HMSP) mencakup periode Januari 2019 hingga 21 Januari 2025. Prediksi dilakukan untuk tanggal 22 Januari 2025. Metode penelitian ini dimulai dengan pembagian dataset yang dibagi menjadi data *train* (60%), data *validation* (20%), dan data *test* (20%). Selanjutnya, dilakukan *preprocessing* data berupa normalisasi dan *sequencing* untuk mempersiapkan data. Model GRU yang diterapkan diuji dengan menggunakan metrik evaluasi seperti *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE), yang menghasilkan akurasi prediksi yang tinggi dengan RMSE 17.07, MAE 11.50, dan MAPE 1.48%. Penelitian ini menunjukkan bahwa penerapan *Bayesian Optimization* dapat memberikan efektivitas pemilihan *hyperparameter* menghasilkan model yang lebih presisi dalam memprediksi harga saham FMCG di Indonesia dan memberikan panduan yang lebih andal bagi investor dalam pengambilan keputusan investasi.

Kata Kunci— *Gated Recurrent Unit*, *Deep Learning*, *Prediksi Harga Saham*, *Bayesian Optimization*.

I. PENDAHULUAN

Tren investasi saham di Indonesia menunjukkan dinamika pertumbuhan yang signifikan, terutama di kalangan Generasi Z dan Milenial. Berdasarkan laporan dari PT Kustodian Sentral Efek Indonesia (KSEI), jumlah investor mengalami kenaikan sebesar 18,6% sepanjang periode akhir 2023 hingga akhir 2024, dengan proporsi dominan sebesar 79% berasal dari kelompok usia di bawah 40 tahun. Meskipun terjadi peningkatan partisipasi yang substansial, kinerja portofolio investasi secara umum masih belum mencapai hasil yang optimal. Salah satu penyebab utama adalah keterbatasan dalam penggunaan analisis data historis secara efektif serta belum optimalnya implementasi strategi prediktif dalam pengambilan keputusan, yang pada akhirnya meningkatkan risiko kerugian finansial [1].

Di antara berbagai sektor yang diminati oleh investor ritel, sektor *Fast-Moving Consumer Goods* (FMCG) menempati posisi strategis sebagai salah satu sektor unggulan. Hal ini disebabkan oleh karakteristik produknya yang berupa kebutuhan pokok dengan tingkat permintaan yang relatif stabil,

bahkan dalam kondisi ketidakpastian ekonomi sekalipun [2], [3]. Seiring meningkatnya eksposur dan minat terhadap sektor FMCG, terdapat kebutuhan mendesak akan penerapan metode prediksi yang lebih presisi untuk menunjang proses pengambilan keputusan investasi yang berbasis data dan analitik [4].

Sejalan dengan perkembangan teknologi kecerdasan buatan, metode *deep learning* seperti *Gated Recurrent Unit* (GRU) telah terbukti efektif dalam menangani pemodelan deret waktu, terutama dalam mengidentifikasi pola non-linear dan menangkap ketergantungan temporal jangka panjang [5]. Namun, performa prediksi model GRU sangat bergantung pada konfigurasi *hyperparameter* yang digunakan. Pemilihan *hyperparameter* secara manual seringkali tidak efisien dan suboptimal [6]. Oleh karena itu, pendekatan berbasis *Bayesian Optimization* menjadi solusi yang menjanjikan, karena menawarkan strategi pencarian yang lebih sistematis dan adaptif dengan memanfaatkan prinsip probabilitistik untuk menemukan kombinasi *hyperparameter* terbaik dalam ruang pencarian yang kompleks [7].

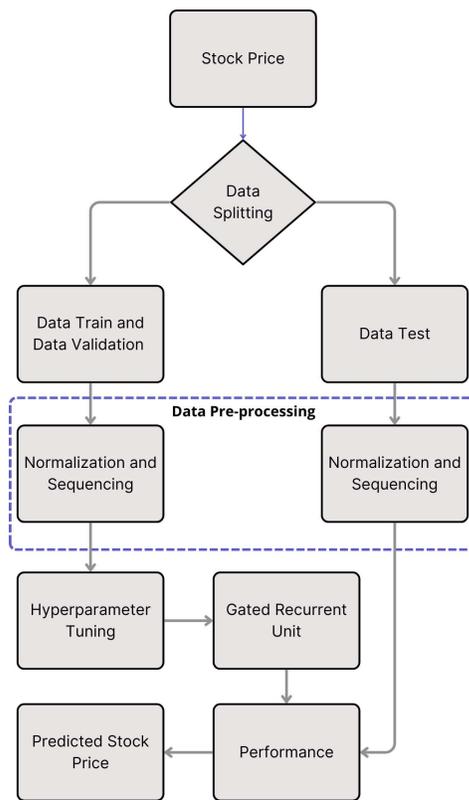
Sejumlah studi terdahulu telah mengkaji penggunaan model *Gated Recurrent Unit* (GRU) dalam prediksi harga saham. Meskipun penelitian [8] menunjukkan bahwa *Long Short-Term Memory* (LSTM) menghasilkan akurasi yang lebih tinggi dibandingkan GRU di pasar saham Tanzania. Hasil tersebut tidak dapat digeneralisasi karena keterbatasan ruang lingkup studi. GRU tetap relevan berkat efisiensi komputasinya yang lebih tinggi dan kompleksitas arsitektur yang lebih rendah dibandingkan LSTM serta kemampuannya dalam menangani ketergantungan jangka panjang data deret waktu [9]. Penerapan *Bayesian Optimization* terbukti efektif dalam meningkatkan akurasi model *deep learning* seperti GRU dengan menyempurnakan proses pemilihan *hyperparameter*. Teknik ini dapat menghasilkan prediksi yang lebih presisi terutama dengan menggabungkan strategi optimasi yang canggih untuk menghadapi data yang fluktuatif dan kompleks menjadikan GRU sebagai solusi prediktif yang efektif di pasar saham [10], [11].

Penelitian ini bertujuan untuk merancang model prediksi harga saham pada sektor *Fast-Moving Consumer Goods* (FMCG) di Indonesia dengan memanfaatkan algoritma *Gated Recurrent Unit* (GRU) yang ditingkatkan performanya melalui teknik *Bayesian Optimization* untuk pemilihan *hyperparameter* secara optimal. Penelitian ini menitikberatkan pada analisis

efektivitas optimasi tersebut terhadap akurasi model prediktif, yang dievaluasi menggunakan indikator Root Mean Square Error (RMSE), Mean Absolute Error (MAE), dan Mean Absolute Percentage Error (MAPE). Diharapkan hasil penelitian ini dapat menghasilkan model prediksi yang lebih andal dan efisien serta memberikan panduan strategis bagi investor dalam membuat keputusan investasi yang berbasis data pada sektor FMCG.

II. METODE PENELITIAN

Metode penelitian ini digunakan untuk mengembangkan prediksi harga saham PT Hanjaya Mandala Sampoerna Tbk (HMSP) yang didapat dari website <https://www.investing.com/>. Metode ini dimulai dari pemilihan data, *data splitting*, *preprocessing*, *hyperparameter tuning*, implementasi dengan model *Gated Recurrent Unit*, dan evaluasi untuk mengevaluasi kinerja model. Melalui tahapan-tahapan tersebut penelitian ini bertujuan untuk menghasilkan prediksi harga saham yang akurat untuk mendukung investor dalam strategi pembelian dan penjualan saham HMSP. Alur metode penelitian yang dilakukan dalam penelitian ini seperti terlihat pada Gambar 1.



Gbr. 1 Alur Penelitian

Berdasarkan Gambar 1. Gambaran umum penelitian, dapat diketahui langkah langkah yang akan diterapkan dalam penelitian ini, yaitu:

A. Data Splitting

Pada tahap pertama penelitian, data saham yang diperoleh dari periode awal Januari 2019 hingga 21 Januari 2025 dibagi menjadi tiga bagian dengan rasio 60% untuk data pelatihan, 20% untuk data validasi, dan 20% untuk data pengujian. Pembagian data ini dilakukan dengan tujuan untuk menghindari data *leakage* yang dapat menyebabkan hasil evaluasi tidak valid dan memastikan bahwa model tidak mengalami *overfitting* [12]. Pembagian yang dilakukan secara acak ini membantu untuk memisahkan data yang digunakan untuk melatih model memvalidasi model selama proses pelatihan dan menguji performa model pada data yang belum pernah dilihat sebelumnya, sehingga memberikan gambaran yang lebih akurat mengenai kemampuan generalisasi model terhadap data baru.

B. Data Preprocessing

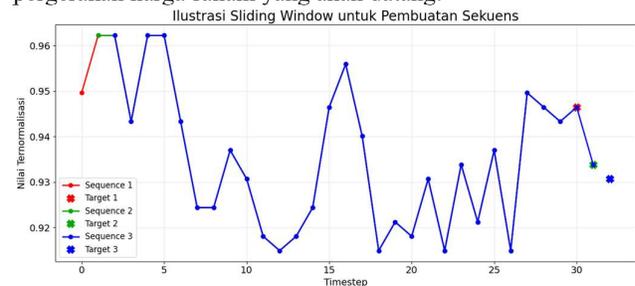
Setelah data terbagi, tahapan selanjutnya adalah preprocessing data yang mencakup beberapa langkah penting, yaitu normalisasi dan sequencing data. Normalisasi dilakukan dengan menggunakan *MinMaxScaler* untuk memastikan bahwa seluruh fitur dalam dataset berada pada rentang nilai yang seragam, yaitu antara 0 hingga 1 [13]. Hasil normalisasi data sesuai pada Gbr. 2.

Perbandingan data sebelum dan sesudah normalisasi (5 data pertama):

	Original	Normalized
0	3770	0.935065
1	3890	0.974026
2	3970	1.000000
3	3910	0.980519
4	3840	0.957792

Gbr. 2 Hasil Normalisasi Data

Langkah selanjutnya adalah pembuatan sekuens data menggunakan *window size* 30, di mana setiap input terdiri dari 30 hari harga saham yang digunakan untuk memprediksi harga pada hari ke-31 seperti pada Gbr. 3 [14]. Dengan pendekatan ini, model dapat mempelajari pola yang ada dalam data historis dan menggunakan informasi tersebut untuk memprediksi pergerakan harga saham yang akan datang.



Gbr. 3 Penerapan *Sliding Window*

C. Hyperparameter Tuning

Pada tahap ini, penelitian mengimplementasikan teknik optimasi *hyperparameter* dengan menggunakan *Bayesian Optimization*. Metode ini dipilih karena mampu secara efisien

mencari kombinasi hyperparameter yang optimal dengan memanfaatkan model probabilistik untuk mengeksplorasi dan mengeksploitasi ruang *hyperparameter*.

```
pbounds = {
    'hidden_size': (16, 128),
    'dropout_rate': (0.1, 0.5),
    'learning_rate': (0.0001, 0.01)
    'batch_size': (16, 64),
    'num_layers': (1, 3)
}
```

Gbr. 4 Ruang Pencarian *Bayesian Optimization*

Hyperparameter yang dioptimalkan sesuai Gbr. 4 meliputi jumlah unit GRU, *tingkat dropout*, *batch size*, *hidden size*, dan *learning rate* dimana semuanya berperan penting dalam meningkatkan akurasi prediksi model. Dengan melakukan *tuning* terhadap parameter-parameter ini, model diharapkan dapat mencapai performa terbaiknya dalam memprediksi harga saham.

D. Gated Recurrent Unit

Model yang digunakan dalam penelitian ini adalah Gated Recurrent Unit (GRU). GRU dipilih karena kemampuannya untuk menangani masalah *vanishing gradient* yang sering muncul pada model jaringan saraf berulang lainnya, seperti RNN. Dalam implementasinya, model GRU memiliki dua lapisan GRU yang saling berhubungan, di mana lapisan-lapisan tersebut diikuti oleh lapisan *dropout* untuk menghindari *overfitting*.

```
# Input layer dan first GRU layer
model.add(GRU(units=best_params['hidden_size'],
              return_sequences=(best_params['num_layers'] > 1),
              input_shape=(X_train.shape[1], X_train.shape[2])))
model.add(Dropout(best_params['dropout_rate']))

# Hidden GRU layers (if num_layers > 1)
for i in range(best_params['num_layers'] - 1):
    return_sequences = i < best_params['num_layers'] - 2 # True kecuali layer terakhir
    model.add(GRU(units=best_params['hidden_size'], return_sequences=return_sequences))
    model.add(Dropout(best_params['dropout_rate']))

# Output layer
model.add(Dense(1))
```

Gbr. 5 Inisiasi GRU

Pada Gbr. 5 *input layer* dan *first GRU layer* ditambahkan dengan jumlah unit GRU yang ditentukan oleh parameter terbaik yang ditemukan melalui *Bayesian Optimization*. Parameter *return sequences* diatur menjadi *True* jika jumlah lapisan GRU lebih dari satu, memastikan bahwa setiap lapisan GRU akan mengeluarkan output untuk setiap langkah waktu dalam urutan input, bukan hanya *output* untuk langkah terakhir.

Selain itu, *hidden GRU layers* ditambahkan dengan mengatur *return sequences* sesuai dengan lapisan terakhir untuk menghindari keluaran yang tidak relevan. Setiap lapisan GRU ini ditambahkan dengan *dropout* untuk mengurangi risiko *overfitting* dan model ini memiliki struktur yang efisien untuk menangkap pola jangka panjang dalam data *time series*. Dengan struktur yang efektif dan kemampuan untuk menangani ketergantungan jangka panjang, GRU mampu memberikan

hasil yang akurat dalam memprediksi harga saham berdasarkan data historis.

E. Evaluasi

Evaluasi model dilakukan untuk mengukur seberapa baik model dapat memprediksi harga saham dengan menggunakan beberapa metrik penting, yaitu Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), dan Mean Absolute Percentage Error (MAPE) [15][16]. RMSE digunakan untuk menilai kesalahan prediksi model dalam bentuk kuadrat, memberikan bobot lebih pada kesalahan yang lebih besar, sehingga memberikan gambaran tentang akurasi model secara keseluruhan. Sementara itu, MAE mengukur rata-rata selisih absolut antara nilai prediksi dan nilai aktual, yang memberikan gambaran yang lebih sederhana tentang kesalahan prediksi, dan MAPE memberikan kesalahan dalam bentuk persentase untuk memudahkan perbandingan kesalahan antar model yang berbeda. Dengan menggunakan ketiga metrik ini, evaluasi dapat dilakukan secara komprehensif untuk menilai kinerja model dalam memprediksi harga saham HMSP.

III. HASIL DAN PEMBAHASAN

Pada penelitian ini memanfaatkan *Bayesian Optimization* untuk mencari kombinasi terbaik yang akan digunakan pada arsitektur model. Model yang dihasilkan menunjukkan kemampuan untuk memprediksi harga saham PT Hanjaya Mandala Sampoerna Tbk.

```
Hyperparameter optimal yang ditemukan:
- batch_size: 23
- dropout_rate: 0.34629353339285807
- hidden_size: 113
- learning_rate: 0.004633227676233566
- num layers: 2
```

Gbr. 6 Hasil *Hyperparameter Tuning*

Pada Gbr. 6 merupakan hasil *hyperparameter* terbaik yang ditemukan oleh *Bayesian Optimization*. Proses pencarian tersebut dilakukan dengan menentukan iterasi sebanyak 10 kali serta penentuan 5 titik acak. Hasil kombinasi kemudian diterapkan pada inisialisasi GRU menghasilkan arsitektur berikut.

Layer (type)	Output Shape	Param #
gru_23 (GRU)	(None, 30, 113)	39,324
dropout_23 (Dropout)	(None, 30, 113)	0
gru_24 (GRU)	(None, 113)	77,292
dropout_24 (Dropout)	(None, 113)	0
dense_15 (Dense)	(None, 1)	114

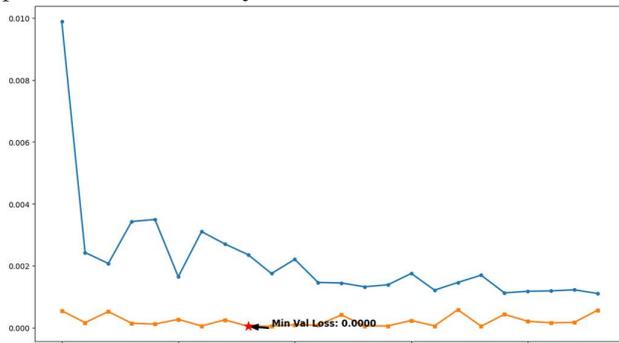
Gbr. 7 Arsitektur GRU

Model GRU dilatih pada *Google Collab* menggunakan *Python* dengan spesifikasi perangkat keras, yaitu prosesor Ryzen 7 5800H dan RAM 16 GB. Pelatihan model dievaluasi dengan metrik evaluasi. Metrik yang digunakan adalah *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE),

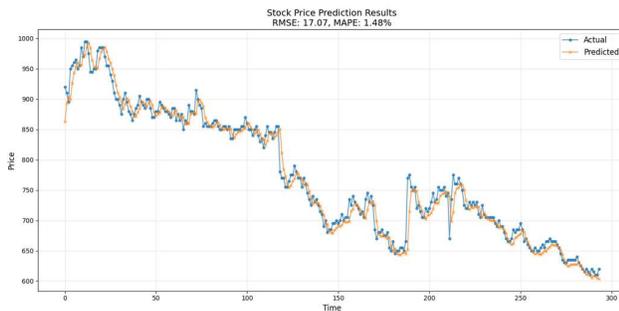
dan *Mean Absolute Percentage Error* (MAPE) untuk mengukur performa prediksi harga saham FMCG.

A. Akurasi

Akurasi model dapat diamati menggunakan grafik *train loss* dan *validation loss* yang menunjukkan bagaimana model mempelajari data selama pelatihan. Berdasar Gbr. 8 *train loss* yang berwarna biru menunjukkan penurunan yang stabil selama pelatihan, sementara *validation loss* yang berwarna oranye menunjukkan fluktuasi kecil namun cenderung stabil, menandakan bahwa model tidak mengalami *overfitting*. Grafik ini memberikan gambaran seberapa baik model dapat belajar dari data pelatihan dan generalisasi pada data yang belum pernah dilihat sebelumnya.



Gbr. 8 Grafik Train dan Validation Loss



Gbr. 9 Grafik Hasil Aktual dan Prediksi

Gbr. 9 menunjukkan hasil prediksi harga saham dibandingkan dengan harga aktual yang terjadi pada periode sama. Dapat dilihat bahwa prediksi yang dilakukan oleh model memiliki kecocokan yang sangat baik dengan pergerakan harga saham sesungguhnya. Pola yang ditunjukkan pada grafik ini mengindikasikan bahwa model GRU mampu menangkap tren harga saham dengan baik, bahkan model mampu mengikuti lonjakan yang terjadi. Hal ini mengindikasikan bahwa model dapat menangkap volatilitas saham yang fluktuatif.

B. Evaluasi

Evaluation metrics:	
- Root Mean Square Error (RMSE):	17.07
- Mean Absolute Error (MAE):	11.50
- Mean Absolute Percentage Error (MAPE):	1.48%

Gbr. 10 Hasil Evaluasi

Berdasarkan Gbr. 10 proses evaluasi dilakukan dengan menghitung nilai *Root Mean Squared Error* (RMSE) yang menunjukkan seberapa dekat prediksi harga saham dengan nilai aktual. Semakin kecil nilai RMSE maka semakin baik model dalam memprediksi harga saham. Dalam hal ini model menghasilkan nilai RMSE sebesar 17.07 yang menunjukkan bahwa rata-rata kesalahan kuadrat antara prediksi dan harga aktual adalah sebesar 17.07.

Selain itu, *Mean Absolute Error* (MAE) juga dihitung yang mengukur rata-rata kesalahan absolut antara prediksi dan nilai aktual dengan hasil 11.50. Metrik ini memberikan gambaran yang lebih jelas tentang konsistensi model dalam memprediksi harga saham tanpa terlalu dipengaruhi oleh fluktuasi besar.

Terakhir, *Mean Absolute Percentage Error* (MAPE) memberikan gambaran mengenai persentase kesalahan prediksi model. Dengan nilai MAPE sebesar 1.48%, ini menunjukkan bahwa model mampu memberikan prediksi harga saham dengan tingkat kesalahan yang sangat kecil dalam bentuk persentase.

C. Hasil Prediksi

Model yang telah dilatih dengan konfigurasi terbaik kemudian digunakan untuk memprediksi harga saham pada periode yang akan datang. Gbr. 11 menunjukkan prediksi harga saham untuk satu hari ke depan berdasarkan data historis yang tersedia. Hasil prediksi ini bertujuan untuk memberikan estimasi harga saham HMSP pada hari berikutnya dengan menggunakan informasi yang telah diproses dari data sebelumnya. Model memanfaatkan pola pergerakan harga saham yang tercatat selama periode yang ditentukan untuk memperkirakan pergerakan harga yang akan terjadi pada hari mendatang. Meskipun pergerakan harga saham cenderung fluktuatif model ini mampu memberikan prediksi yang relevan dan dapat digunakan sebagai salah satu pertimbangan dalam pengambilan keputusan investasi jangka pendek.



Gbr. 11 Hasil Prediksi

IV. KESIMPULAN

Penelitian ini berhasil mengembangkan model prediksi harga saham PT Hanjaya Mandala Sampoerna Tbk (HMSP) dengan menggunakan algoritma Gated Recurrent Unit (GRU) yang dioptimalkan melalui teknik Bayesian Optimization. Model ini menunjukkan kemampuan yang baik dalam memprediksi harga saham dengan tingkat akurasi yang cukup tinggi berdasarkan evaluasi yang menggunakan metrik *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE). Dengan nilai RMSE sebesar 17.07, MAE sebesar 11.50, dan MAPE sebesar 1.48%, model ini mampu memberikan prediksi yang lebih tepat dan konsisten terhadap pergerakan harga saham.

Selain itu, model yang dihasilkan juga terbukti efektif dalam menangkap pola pergerakan harga saham yang fluktuatif sebagaimana terlihat pada grafik *train loss* dan *validation loss* menunjukkan bahwa model tidak mengalami *overfitting* dan dapat belajar dengan baik dari data. Penerapan *Bayesian Optimization* dalam pemilihan *hyperparameter* terbukti meningkatkan performa model dengan meminimalkan kesalahan prediksi yang dihasilkan.

Hasil prediksi harga saham untuk satu hari ke depan menunjukkan bahwa model GRU dapat memberikan estimasi harga yang relevan dan berguna bagi investor dalam pengambilan keputusan investasi jangka pendek. Dengan demikian penelitian ini memberikan kontribusi dalam pengembangan model prediktif berbasis data yang lebih akurat untuk sektor saham FMCG.

REFERENSI

- [1] N. E. Sobita, M. I. Harori, R. Satya, A. Paluvi, and I. Aini, "Peluang Gen-Z Dalam Meraih Kesuksesan Melalui Investasi Saham," *Nanggroe: Jurnal Pengabdian Cendikia*, vol. 2, no. 3, pp. 430–434, 2023, doi: <https://doi.org/10.5281/zenodo.8099800>.
- [2] G. Putlia and C. A. Alphin, "Strategi Pemasaran untuk Industri FMCG pada Era Covid-19," *Widya Cipta: Jurnal Sekretari dan Manajemen*, Mar. 2021, doi: <https://doi.org/10.31294/widyacipta.v5i1.9711>.
- [3] A. M. Mayang and O. Ferli, "Pengaruh Likuiditas Saham terhadap Stock Price Crash Risk pada Perusahaan Industri Consumer Goods di Bursa Efek Indonesia," Apr. 2022, doi: <https://doi.org/10.26740/jim.v10n2.p382-393>.
- [4] A. A. Kurniasi, M. A. Saptari, and V. Ilhadi, "APLIKASI PERAMALAN HARGA SAHAM PERUSAHAAN LQ45 DENGAN MENGGUNAKAN METODE ARIMA," *SISFO: Jurnal Ilmiah Sistem Informasi*, vol. 5, pp. 13–26, 2021, doi: <https://doi.org/10.29103/sisfo.v5i1.4849>.
- [5] R. Satria Andromeda and N. Anisa Sri Winarsih, "Sistemasi: Jurnal Sistem Informasi Perbandingan Kinerja Metode LSTM dan GRU dalam Prediksi Harga Close Cryptocurrency Performance Comparison of LSTM and GRU Methods in Predicting Cryptocurrency Closing Prices." [Online]. Available: <http://sistemasi.ftik.unisi.ac.id>
- [6] L. Hakim, Z. Sari, A. Rizaldy Aristyo, and S. Pangestu, "Optimizing Android Program Malware Classification Using GridSearchCV Optimized Random Forest," *Computer Network, Computing, Electronics, and Control Journal*, vol. 9, no. 2, pp. 173–180, 2024.
- [7] N. Fajriyani, E. Esyudha, P. #2, and R. Septiriana, "JEPIN (Jurnal Edukasi dan Penelitian Informatika) Optimasi Hyperparameter pada Neural Network (Studi Kasus: Identifikasi Komentar Cyberbullying Instagram)," 2023, doi: <https://doi.org/10.26418/jp.v9i2.68319>.
- [8] S. Joseph, N. Mduma, and D. Nyambo, "A Deep Learning Model for Predicting Stock Prices in Tanzania," 2023. [Online]. Available: www.etasr.com
- [9] C. Alkahfi, A. Kurnia, and A. Saefuddin, "Perbandingan Kinerja Model Berbasis RNN pada Peramalan Data Ekonomi dan Keuangan Indonesia," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 4, pp. 1235–1243, Jul. 2024, doi: [10.57152/malcom.v4i4.1415](https://doi.org/10.57152/malcom.v4i4.1415).
- [10] E. T. Habtemariam, K. Kekeba, M. Martínez-Ballesteros, and F. Martínez-Álvarez, "A Bayesian Optimization-Based LSTM Model for Wind Power Forecasting in the Adama District, Ethiopia," *Energies (Basel)*, vol. 16, no. 5, Mar. 2023, doi: <https://doi.org/10.3390/en16052317>.
- [11] J. Violos, S. Tsanakas, T. Theodoropoulos, A. Leivadreas, K. Tserpes, and T. Varvarigou, "Hypertuning GRU Neural Networks for Edge Resource Usage Prediction," in *Proceedings - IEEE Symposium on Computers and Communications*, Institute of Electrical and Electronics Engineers Inc., 2021, doi: <https://doi.org/10.1109/ISCC53001.2021.9631548>.
- [12] S. Kapoor and A. Narayanan, "Leakage and the reproducibility crisis in machine-learning-based science," *Patterns*, vol. 4, no. 9, Sep. 2023, doi: <https://doi.org/10.1016/j.patter.2023.100804>.
- [13] S. J. Pipin, R. Purba, and H. Kurniawan, "Prediksi Saham Menggunakan Recurrent Neural Network (RNN-LSTM) dengan Optimasi Adaptive Moment Estimation," *Journal of Computer System and Informatics (JoSYC)*, vol. 4, no. 4, pp. 806–815, Aug. 2023, doi: [10.47065/josyc.v4i4.4014](https://doi.org/10.47065/josyc.v4i4.4014).
- [14] E. B. Alvior, "Journal of Business and Management Studies (JBMS) Moving Average Indicator and Trade Set-up as Correlates to Investment Trading in Stock Market: Basis for e Predictability Primer," 2021, doi: [10.32996/jbms](https://doi.org/10.32996/jbms).
- [15] T. O. Hodson, "Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not," Jul. 19, 2022, *Copernicus GmbH*. doi: [10.5194/gmd-15-5481-2022](https://doi.org/10.5194/gmd-15-5481-2022).

- [16] Ilham Amansyah, I. Jamaludin, N. Euis, and J. Ayu Ratna, "Prediksi Penjualan Kendaraan Menggunakan Regresi Linear: Studi Kasus pada Industri Otomotif di Indonesia," *Innovative:*

Journal Of Social Science Research, vol. 4, pp. 1199–1216, 2024, doi: <https://doi.org/10.31004/innovative.v4i4.12735>.