



Prediksi Harga Saham Berdasarkan Data Histori Menggunakan Algoritma LSTM, GRU & RNN

M. Anwar Abbas*, Heru Dwi Saputra, Adi Octavianantara, Ade Irfan
Efendi, Yasrizal

*Ilmu Komputer, Universitas Nusa Mandiri,
Jalan Kramat Raya No. 18, Senen, Jakarta Pusat
* 14220008@nusamandiri.ac.id*

Abstrak:

Prediksi harga saham adalah tantangan sulit dalam deep learning dan machine learning, dipengaruhi oleh banyak faktor yang rumit dalam penawaran dan permintaan. Meskipun model berbasis long short-term memory (LSTM) menarik, ada kondisi di mana model seperti Recurrent Neural Network (RNN) dan Gated Repetitive Unit (GRU) memiliki keunggulan. Penelitian ini memperkenalkan desain prediksi biaya penutupan "close" saham menggunakan tiga model deep learning: GRU, LSTM, dan RNN, pada indeks saham gabungan. LSTM terbukti efisien dalam prediksi urutan dengan kemampuan menyimpan informasi historis dan merespons dengan baik terhadap setiap sampel data individu dan pembelajaran dalam beberapa epochs terbatas. Sebaliknya, GRU dan RNN memberikan respons yang baik pada pengolahan batch data besar selama periode pelatihan yang panjang, serta menunjukkan konsistensi kinerja yang baik pada periode pelatihan yang lebih lama. Dalam konteks ini, signifikansi pengaruh harga saham masa lalu terhadap masa depannya menjadi penting. Meskipun prediksi harga saham akurat sulit, penelitian ini menunjukkan bahwa pengembangan model dapat memberikan indikasi arah pergerakan harga saham.

This is an open access article under the [CC BY-NC](https://creativecommons.org/licenses/by-nc/4.0/) license



Kata Kunci:

Deep Learning;
Gru;
Lstm;
RNN;
Prediction;

Riwayat Artikel:

Diserahkan 09 Januari, 2024
Direvisi 28 Juli 2024
Diterima 31 Juli, 2024

DOI:

10.22441/incomtech.v14i3.25132

1. PENDAHULUAN

Dalam dunia digital saat ini pencarian informasi tentang data digunakan di setiap perusahaan dalam mendukung setiap pengambilan keputusan berdasarkan data. Dengan harga saham dipengaruhi dengan beragam faktor di area pasar, dan perubahan harga mengikuti pola yang tidak teratur [1]. Peramalan berdasarkan

kurun waktu ekonomi dan keuangan telah menjadi salah satu topik paling menarik bagi banyak pihak di masyarakat kita dan perlu pemahaman lebih mendalam tentang prediktabilitas perlu penyelidikan lebih lanjut [2]. Pengambilan keputusan yang tegas tentang harga di masa depan membutuhkan kemampuan yang cukup sulit dan perlu melakukan studi mendalam tentang prediksi harga.

Perilaku Pasar diperoleh dari pola data mengenai atribut temporal. Pola temporal ini memiliki tantangan yang berbeda dalam perhitungan data pasar saham karena fluktuasi acak dari waktu ke waktu. Metode statistik telah dirancang untuk menghitung data secara sistematis. Ukuran data yang selalu meningkat signifikan dari hari ke hari dengan banyak kerentanan yang memiliki kompleksitas berbeda untuk dianalisis dan dihitung dengan model pembelajaran mendalam yang digunakan untuk mengatasi kelemahan model tradisional dengan menangani manipulasi data yang berantakan dan besar dengan biaya komputasi yang lebih sedikit [3].

Dalam era digital informasi semakin banyaknya studi peramalan keuangan yang telah menggunakan model pembelajaran mendalam untuk bertujuan meramalkan harga saham dalam beberapa tahun terakhir [1]. Penggunaan jaringan LSTM, CNN, RNN, *Recurrent Neural Networks* (RNNs) dan *Gated Recurrent Units* (GRUs) adalah model pembelajaran mendalam lainnya yang umum digunakan untuk prediksi pengembalian saham [2]. Banyak peneliti telah memperkenalkan berbagai macam model untuk mengetahui informasi tentang perilaku pasar dimasa depan berdasarkan data historis dan sekarang.

Beberapa Penelitian terkait dengan menggunakan model RNN, LSTM dan Gru untuk memperkirakan harga penutupan delapan indeks harga pasar saham dengan model RNN, LSTM dan GRU [4]. prediksi harga saham [5]. Prediksi Konsumsi Listrik Rumah [6]. Prediksi lalu lintas [7].

Penelitian ini mengembangkan dari penelitian sebelumnya tentang “prediksi harga saham menggunakan teknik *deep learning*” [8]. Dengan menggunakan 3 algoritma LSTM, GRU dan ARIMA-GRU *Stack*. Penelitian sebelumnya hanya menggunakan satu indeks saham, yaitu TCS, sedangkan penelitian kami menggunakan 10 indeks saham gabungan untuk memberikan analisis yang lebih komprehensif dan valid. Penelitian selanjutnya akan melakukan hal yang serupa dengan mengubah algoritma ARIMA-GRU *Stack* dengan RNN dan melakukan optimasi sebanyak 3 algoritma yang telah kami lakukan untuk mencari perbandingan yang terbaik dari keempat algoritma yang digunakan dalam penelitian ini.

2. METODE

a. *Optimization*

Optimasi digunakan dalam machine learning sebagai proses penyesuaian dan pengembangan strategi untuk meningkatkan efisiensi, mengurangi biaya, dan meningkatkan efektivitas dalam berbagai bidang. Optimasi dalam machine

learning sangat penting karena memungkinkan kita untuk meningkatkan akurasi model, mengurangi margin kesalahan, dan meningkatkan kinerja secara keseluruhan. Selain itu, optimasi juga membantu dalam mengatasi masalah lokal atau offline dataset yang statis, yang umum digunakan dalam pelatihan machine learning [9].

b. LSTM

LSTM adalah arsitektur jaringan saraf yang dirancang untuk memproses data urutan. Dalam LSTM Status memori dikendalikan oleh tiga gerbang: gerbang memori, gerbang *input*, dan *output gate*. Fungsi gerbang memori adalah untuk memutuskan apakah akan menyimpan data dalam keadaan memori sebelumnya, port akses memutuskan untuk menambahkan data baru ke status memori, dan output gerbang menentukan apakah akan menghapus data dari status memori saat ini. Unit LSTM dapat dikombinasikan untuk membentuk jaringan saraf yang dalam di mana output dari satu unit dimasukkan sebagai input ke unit berikutnya. Output akhir dari jaringan LSTM terdiri dari lapisan padat yang menggunakan memori terakhir dari input. *Back propagation in time* (BPTT) sering digunakan untuk melatih jaringan LSTM. BPTT termasuk memperbaiki kesalahan jaringan dari output ke input dan mengurangi kesalahan dengan menyesuaikan bobot jaringan [8].

c. GRU (*Gated Recurrent Unit*)

GRU adalah arsitektur jaringan saraf yang dirancang untuk memecahkan masalah redaman di RNN tradisional. GRU adalah versi yang lebih sederhana mirip dengan LSTM tetapi dengan kompleksitas yang lebih sedikit dan pembelajaran yang lebih cepat. Port reset menentukan berapa banyak status tersembunyi sebelumnya yang harus dilupakan, sedangkan port pembaruan menentukan seberapa sering entri baru sekarang harus ditambahkan ke status tersembunyi. Gerbang ini memungkinkan GRU untuk selektif memilih atau melupakan informasi sebelumnya berdasarkan input saat ini. *Back propagation over time* (BPTT) digunakan untuk melatih jaringan GRU, yang akan menyebarkan kesalahan kembali ke masa lalu dari output ke input jaringan dan menyesuaikan bobot jaringan untuk mengurangi kesalahan. Singkatnya, GRU adalah arsitektur jaringan saraf yang kuat yang terutama digunakan untuk memproses data deret waktu dan telah menunjukkan kesuksesan besar dalam pemrosesan bahasa alami dan pengenalan suara [10].

d. RNN (*Recurrent Neural Networks*)

RNN adalah jenis jaringan saraf tiruan yang digunakan untuk memproses data sekuensial atau data berurutan. RNN memiliki kemampuan untuk mengolah input dan memprosesnya dengan berbagai informasi yang sudah pernah diperoleh sebelumnya, sehingga RNN memiliki kemampuan memori. RNN

banyak digunakan dalam berbagai aplikasi seperti Siri, *Google Translate*, *voice search*, *image captioning*, dan sebagainya. RNN bekerja dengan cara mempertimbangkan input yang masuk sekaligus hal-hal lain yang telah diproses sebelumnya, dan kemudian menghasilkan *output*. RNN memiliki beberapa kelemahan, seperti masalah *vanishing* dan *exploding gradient*, serta waktu pelatihan yang lambat [11].

e. *R-SQUARED SCORE*

R-square score juga dikenal sebagai koefisien determinasi, adalah ukuran yang digunakan untuk mengevaluasi kinerja model pembelajaran mesin berbasis regresi. Ini menunjukkan proporsi varians dalam variabel dependen yang dapat diprediksi dari variabel independen. Skor R^2 bervariasi antara 0 dan 1, di mana 1 menunjukkan kecocokan sempurna, 0 menunjukkan bahwa model akan berkinerja buruk pada dataset yang tidak terlihat, dan nilai negatif menunjukkan bahwa model sesuai dengan data lebih buruk daripada model yang paling buruk [12].

Skor R^2 dihitung menggunakan rumus berikut:

$$R^2 = 1 - \frac{SS_{res}}{SS_{tot}}$$

dimana:

- (SS_{res}) adalah jumlah residu kuadrat
- (SS_{tot}) adalah jumlah total kuadrat

f. *Mean Absolute Error (MAE)*

MAE adalah ukuran besarnya rata-rata kesalahan antara sekumpulan prediksi dan nilai sebenarnya yang sesuai. Ini biasanya digunakan dalam konteks mengevaluasi kinerja model regresi dalam pembelajaran mesin. MAE dihitung sebagai rata-rata perbedaan absolut antara nilai prediksi dan aktual. Rumus untuk MAE diberikan oleh:

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

dimana:

- (n) adalah jumlah pengamatan dalam dataset.
- (y_i) adalah nilai sebenarnya.
- (\hat{y}_i) adalah nilai prediksi.

MAE adalah metrik yang berguna karena memberikan ukuran kesalahan rata-rata yang mudah dan dapat ditafsirkan tanpa mempertimbangkan arah kesalahan.

Ini kurang sensitif terhadap pencilon dibandingkan dengan metrik lain seperti Mean Squared Error (MSE), menjadikannya pilihan yang baik untuk mengevaluasi model di hadapan pencilon. Selain itu, MAE tahan terhadap efek kesalahan besar karena penggunaan perbedaan absolut [12].

g. *Root Mean Squared Error (RMSE)*

RMSE adalah ukuran yang banyak digunakan dari perbedaan rata-rata antara nilai prediksi model statistik dan nilai aktual. Ini dianggap sebagai salah satu dari dua indikator kinerja utama untuk model regresi dan memberikan estimasi seberapa baik model mampu memprediksi nilai target (akurasi). RMSE dihitung menggunakan rumus berikut:

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

dimana:

- (n) adalah jumlah pengamatan dalam dataset.
- (y_i) adalah nilai sebenarnya.
- (\hat{y}_i) adalah nilai prediksi.

RMSE adalah ukuran umum yang digunakan dari perbedaan rata-rata antara nilai prediksi model dan nilai aktual. Namun, ia memiliki beberapa keterbatasan, seperti sensitif terhadap pencilon dan tidak menjadi skala-invarian, yang dapat membuatnya sulit untuk menafsirkan dan membandingkan model [13].

h. *Mean Squared Error (MSE)*

MSE adalah ukuran yang digunakan untuk menilai kualitas model statistik atau pembelajaran mesin, khususnya dalam konteks analisis regresi. Ini dihitung sebagai rata-rata kuadrat kesalahan antara nilai prediksi dan aktual. Formula untuk MSE diberikan oleh:

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

dimana:

- (n) adalah jumlah pengamatan dalam dataset.
- (y_i) adalah nilai sebenarnya.
- (\hat{y}_i) adalah nilai prediksi.

MSE adalah metrik fundamental untuk mengevaluasi kinerja model regresi. Ini memberikan ukuran perbedaan kuadrat rata-rata antara nilai perkiraan dan nilai aktual. Namun, MSE tidak berada dalam unit asli data, sehingga lebih sulit untuk ditafsirkan dalam konteks dunia nyata. Akibatnya, sering digunakan bersama dengan metrik lain seperti RMSE dan MAE untuk evaluasi kinerja model yang lebih komprehensif.

3. HASIL DAN PEMBAHASAN

Dataset yang digunakan dalam penelitian ini berasal dari *Yahoo Finance* <https://finance.yahoo.com/> dengan kurun waktu pengambilan data (2013-2023) dan situs Github <https://github.com/hklchung/StockPricePredictor> interval waktu data (1992-2017) dengan rincian pada Tabel 1

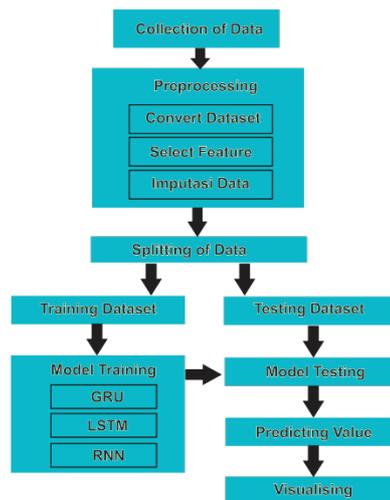
Tabel 1. Dataset

Index Saham	Banyak data
JKSE	2766
FTSE	2663
ASX	6397
CAC40	6932
DAX	6913
DJI	6755
HIS	6819
N225	6821
NASDAQ	6755
SP500	6755

Atribut dalam dataset ini ditampilkan pada Tabel 2.

Tabel 2. Rincian dataset

No	Atribut	Keterangan
1	<i>Date</i>	Tanggal pengamatan atau catatan harga saham
2	<i>Open</i>	Harga saham pada awal periode waktu tertentu
3	<i>High</i>	Harga tertinggi yang dicapai oleh saham selama periode waktu tersebut
4	<i>Low</i>	Harga terendah yang dicapai oleh saham selama periode waktu tersebut
5	<i>Close</i>	Harga saham pada akhir periode waktu tersebut
6	<i>Adj Close</i>	Harga penutup saham yang disesuaikan
7	<i>Volume</i>	Jumlah saham yang diperdagangkan selama periode waktu tersebut



Gambar 1. Tahapan Penelitian

Berikut adalah tahapan penelitian yang dilakukan dalam memprediksi harga saham:

- a. *Collection of data* / pengumpulan data pada tahap ini menggunakan data yang bersumber dari *Yahoo Finance* untuk indeks saham JKSE dan FTSE penarikan data dilakukan untuk histori data saham sejak tahun 2013 sampai dengan 2023, selanjutnya sebanyak 8 (delapan) data saham berasal dari *Github* : <https://github.com/hklchung/StockPricePredictor> data historis dari tahun 1992 sampai dengan 2017.
- b. *Preprocessing data* dalam metode *preprocessing* data dilakukan transformasi variabel dalam data sesuai kebutuhan, normalisasi menggunakan teknik *min-max scaling* 0 – 1, serta Imputasi (*Imputation*) data yaitu mengisi nilai yang hilang pada dataset dengan teknik *backward filling* yaitu mengganti nilai yang hilang pada data menggunakan nilai terdekat sebelumnya.
- c. *Splitting data* digunakan pada tahap ini yaitu menmbagi dataset menjadi 2 (dua) bagian yaitu untuk training data dan testing data, dimana untuk data yang berasal dari *Yahoo Finance* data yang berada pada interval waktu (2013-2022) sebagai training data dan untuk data pada tahun 2023 sebagai testing data, sedangkan untuk data yang berasal dari *Github* data yang berada pada interval waktu (1992-2015) adalah training data dan data yang berada pada interval waktu (2016-2017) adalah testing data.
- d. *Model Training* pada tahap ini, kami membangun model pada data pelatihan (training data) menggunakan tiga algoritma *deep learning*, yaitu LSTM, RNN, dan GRU, dengan konfigurasi parameter ditampilkan pada Tabel 3, kemudian menguji model dengan data pengujian (*testing data*). Kami melakukan 2 (dua) kali percobaan untuk mengetahui

bagaimana variasi kombinasi “*batch_size*” dan “*epochs*” dapat memengaruhi performa model. Pada percobaan pertama dengan *batch_size* 1 dan *epochs* 3, kami ingin melihat bagaimana model merespon terhadap setiap sampel data individual dalam satu iterasi dan sejauh mana model dapat belajar dari dataset dalam beberapa *epochs* yang terbatas. Sementara pada percobaan kedua dengan *batch_size* 32 dan *epochs* 60, kami ingin mengamati bagaimana model bereaksi terhadap pengolahan *batch data* yang lebih besar dalam periode pelatihan yang lebih panjang, dengan harapan dapat mencapai konvergensi yang lebih baik dan kinerja yang lebih baik secara keseluruhan.

- e. *Predicting value* pada tahap ini kami menggunakan model yang telah dibangun untuk melakukan prediksi nilai pada data pengujian (*testing*) berdasarkan pola dan tren yang ditemukan dari data historis. Selanjutnya, kami melakukan visualisasi hasil prediksi dalam bentuk grafik.

Tabel 3. Parameter model

Model	Layer I & II	Layer Dense I	Layer Dense II	Optimizer	Loss
LSTM	50 units	25 units	1 units	adam	mean_squared_error
RNN	50 units	25 units	1 units	adam	mean_squared_error
GRU	50 units	25 units	1 units	adam	mean_squared_error

Hasil dari percobaan pertama di tunjukan pada Tabel 4 dan hasil percobaan kedua di tunjukan pada Tabel 5 dibawah ini.

Tabel 4. Hasil percobaan 1

Saham	Model	Parameter	r2_score	MAE	MSE	RMSE
ASX	LSTM		0,978544	0,006093	0,000063	0,007909
	RNN		0,960830	0,008289	0,000114	0,010686
	GRU		0,962014	0,008814	0,000111	0,010524
CAC40	LSTM		0,976598	0,008736	0,000119	0,010919
	RNN		0,973914	0,009126	0,000133	0,011528
	GRU		0,982958	0,006845	0,000087	0,009318
DAX	LSTM		0,988781	0,007974	0,000107	0,010358
	RNN	<i>batch_size = 1,</i>	0,818260	0,039246	0,001738	0,041689
	GRU	<i>epochs = 3</i>	0,959819	0,017537	0,000384	0,019602
DJI	LSTM		0,982792	0,010342	0,000139	0,011798
	RNN		0,857314	0,032510	0,001154	0,033974
	GRU		0,858835	0,032952	0,001142	0,033792
FTSE	LSTM		0,909231	0,013254	0,000340	0,018452
	RNN		0,873164	0,017787	0,000476	0,021812
	GRU		0,495809	0,040346	0,001891	0,043489
HIS	LSTM		0,992401	0,005908	0,000063	0,007908

	RNN	0,992174	0,006066	0,000064	0,008025
	GRU	0,991896	0,006335	0,000067	0,008167
JKSE	LSTM	-0,016107	0,033451	0,001248	0,035324
	RNN	0,770178	0,013751	0,000282	0,016799
	GRU	0,771047	0,013868	0,000281	0,016768
N225	LSTM	0,892045	0,023886	0,000664	0,025767
	RNN	0,962521	0,011973	0,000231	0,015182
	GRU	0,978357	0,007796	0,000133	0,011537
NASDAQ	LSTM	0,989725	0,008143	0,000103	0,010132
	RNN	0,989725	0,008143	0,000103	0,010132
	GRU	0,989925	0,007972	0,000101	0,010033
SP500	LSTM	0,936232	0,019118	0,000409	0,020220
	RNN	0,987558	0,007214	0,000080	0,008931
	GRU	0,887451	0,025539	0,000722	0,026862

Pada Tabel 4 terlihat bahwa ketiga model mencapai performa terbaik pada percobaan menggunakan dataset HIS dimana hasil terbaik untuk model menggunakan algoritma LSTM dengan $r2_score = 0,992401$; MAE = 0,005908; MSE = 0,000062; dan RMSE = . 0,007908 diikuti RNN dengan $r2_score = 0,992174$; MAE = 0,006066; MSE = 0,000064; dan RMSE = 0,008025 dan terakhir adalah GRU dengan $r2_score = 0,991896$; MAE = 0,006335; MSE = 0,000067; dan RMSE = . 0,008167.

Tabel 5. Hasil percobaan 2

Saham	Model	Parameter	r2_score	MAE	MSE	RMSE
ASX	LSTM		0,978901	0,006057	0,000062	0,007843
	RNN		0,978002	0,006133	0,000064	0,008008
	GRU		0,978724	0,005991	0,000062	0,007876
CAC40	LSTM		0,975008	0,009043	0,000127	0,011284
	RNN		0,977005	0,008469	0,000117	0,010824
	GRU		0,981472	0,007258	0,000094	0,009716
DAX	LSTM		0,977733	0,012548	0,000213	0,014592
	RNN		0,989918	0,006990	0,000096	0,009819
	GRU		0,990458	0,007014	0,000091	0,009552
DJI	LSTM	<i>batch_size = 32, epochs = 60</i>	0,911587	0,026020	0,000715	0,026743
	RNN		0,975236	0,012544	0,000200	0,014154
	GRU		0,957708	0,017588	0,000342	0,018496
FTSE	LSTM		0,860508	0,018498	0,000523	0,022875
	RNN		0,882509	0,016719	0,000441	0,020993
	GRU		0,909729	0,013177	0,000339	0,018401
HIS	LSTM		0,991982	0,006082	0,000066	0,008123
	RNN		0,980831	0,010852	0,000158	0,012560
	GRU		0,987339	0,008114	0,000104	0,010207
JKSE	LSTM		0,872045	0,009520	0,000157	0,012535
	RNN		0,751449	0,014659	0,000305	0,017471

	GRU	0,862071	0,010171	0,000169	0,013014
	LSTM	0,978917	0,007690	0,000130	0,011387
N225	RNN	0,968755	0,010606	0,000192	0,013862
	GRU	0,946288	0,015484	0,000330	0,018175
	LSTM	0,992492	0,006844	0,000075	0,008661
NASDAQ	RNN	0,993000	0,006283	0,000070	0,008363
	GRU	0,993480	0,005978	0,000065	0,008071
	LSTM	0,991243	0,005887	0,000056	0,007493
SP500	RNN	0,982694	0,009223	0,000111	0,010534
	GRU	0,993125	0,004823	0,000044	0,006639

Pada Tabel 5 terlihat bahwa ketiga model mencapai performa terbaik pada percobaan menggunakan dataset NASDAQ dimana hasil terbaik untuk model menggunakan algoritma GRU dengan $r2_score = 0,993480$; $MAE = 0,005978$; $MSE = 0,000065$; dan $RMSE = 0,008071$ diikuti RNN dengan $r2_score = 0,993000$; $MAE = 0,006283$; $MSE = 0,000070$; dan $RMSE = 0,008363$ dan terakhir adalah LSTM dengan $r2_score = 0,992492$; $MAE = 0,006844$; $MSE = 0,000075$; dan $RMSE = 0,008661$.

4. KESIMPULAN

Forecasting membantu dalam membuat perkiraan yang cukup akurat dan berguna tidak hanya bagi peneliti tetapi juga bagi pialang saham dan siapa pun yang tertarik pada bursa saham. Menggunakan LSTM, RNN, dan GRU, kami melakukan percobaan menggunakan tiga metode tersebut untuk menemukan perkiraan paling akurat dalam penelitian ini.

Dari dua kali percobaan yang kami lakukan dengan pengaturan parameter yang berbeda, analisis kami menunjukkan bahwa LSTM mengungguli RNN dan GRU pada percobaan pertama. Ini dapat diartikan bahwa LSTM merespon lebih baik terhadap setiap sampel data individual dalam satu iterasi dan dapat belajar dari dataset dalam beberapa epochs yang terbatas. Pada percobaan pertama, kami menggunakan $batch_size$ 1 dan epoch 3.

Sedangkan pada percobaan kedua menunjukkan bahwa GRU mengungguli LSTM dan RNN. Percobaan ini menggunakan $batch_size$ 32 dan epoch 60. Hasil ini menunjukkan bahwa GRU bereaksi lebih baik terhadap pengolahan batch data yang lebih besar dalam periode pelatihan yang lebih panjang. Model ini juga memiliki konsistensi yang lebih baik dalam hal kinerja model untuk periode pelatihan yang lebih panjang dan menghasilkan prediksi yang lebih baik untuk dataset yang sedang. Jika menyangkut dataset yang lebih besar, LSTM dapat berkinerja lebih baik dan memberikan prediksi yang akurat dibandingkan algoritma lainnya.

REFERENSI

- [1] J. Venkatarao, D. V. Deeban Chakravarthy, S. Meadi, K. L. Durga, K. Pranay, and N. Purushotham, "Stock Price Prediction by Normalizing LSTM and GRU Models," 2023.
- [2] M. Li, Y. Zhu, Y. Shen, and M. Angelova, "Clustering-enhanced stock price prediction using deep learning," *World Wide Web*, vol. 26, no. 1, pp. 207–232, Jan. 2023, doi: 10.1007/s11280-021-01003-0.
- [3] R. Jaiswal and B. Singh, "A Hybrid Convolutional Recurrent (CNN-GRU) Model for Stock Price Prediction," in *Proceedings - 2022 IEEE 11th International Conference on Communication Systems and Network Technologies, CSNT 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 299–304. doi: 10.1109/CSNT54456.2022.9787651.
- [4] Y. Zhong Jing and D. Pathmanathan, "FINANCIAL MARKET PREDICTIONS WITH DEEP LEARNING," 2023. [Online]. Available: <http://www.ukm.my/jqma>
- [5] T. Kim and H. Y. Kim, "Forecasting stock prices with a feature fusion LSTM-CNN model using different representations of the same data," *PLoS One*, vol. 14, no. 2, Feb. 2019, doi: 10.1371/journal.pone.0212320.
- [6] S. Emshagin, W. K. Halim, and R. Kashef, "Short-term Prediction of Household Electricity Consumption Using Customized LSTM and GRU Models," 2022.
- [7] Y. Shao, Y. Zhao, F. Yu, H. Zhu, and J. Fang, "The Traffic Flow Prediction Method Using the Incremental Learning-Based CNN-LTSM Model: The Solution of Mobile Application," *Mobile Information Systems*, vol. 2021, 2021, doi: 10.1155/2021/5579451.
- [8] A. Raghate, N. Tare, S. Magare, S. Holkar, V. Sidgiddi, and U. G. Student, "STOCK PRICE PREDICTIONS USING DEEP LEARNING TECHNIQUES," *www.irjmets.com @International Research Journal of Modernization in Engineering*, vol. 5, no. 4, pp. 1–8, 2023, [Online]. Available: www.irjmets.com
- [9] S. Sun, Z. Cao, H. Zhu, and J. Zhao, "A Survey of Optimization Methods from a Machine Learning Perspective," Jun. 2019, [Online]. Available: <http://arxiv.org/abs/1906.06821>
- [10] Y. Zhong Jing and D. Pathmanathan, "FINANCIAL MARKET PREDICTIONS WITH DEEP LEARNING," 2023. [Online]. Available: <http://www.ukm.my/jqma>
- [11] [G. Il Kim and B. Jang, "Petroleum Price Prediction with CNN-LSTM and CNN-GRU Using Skip-Connection," *Mathematics*, vol. 11, no. 3, Feb. 2023, doi: 10.3390/math11030547.
- [12] F. Rustam et al., "COVID-19 Future Forecasting Using Supervised Machine Learning Models," *IEEE Access*, vol. 8, pp. 101489–101499, 2020, doi: 10.1109/ACCESS.2020.2997311.
- [13] M. Calasan, S. H. E. Abdel Aleem, and A. F. Zobaa, "On the root mean square error (RMSE) calculation for parameter estimation of photovoltaic models: A novel exact analytical solution based on Lambert W function," *Energy Convers Manag*, vol. 210, Apr. 2020, doi: 10.1016/j.enconman.2020.112716.