

Received: 29 April 2022

Revised: 12 June 2022

Accepted: 28 June 2022

Published: 30 June 2022

Perbandingan Model RNN, Model LSTM, dan Model GRU dalam Memprediksi Harga Saham-Saham LQ45

Andrew Nilsen

Institut Teknologi Bandung, Jalan Ganesha 10, Bandung 40132, Indonesia

Email: 20821010@mahasiswa.itb.ac.id

Abstract

Stock prices always fluctuate, can go up and can go down. This uncertainty cannot be ignored, because it can cause losses if it is wrong in predicting the direction of movement of the stock price. A more accurate prediction of the direction of stock price movements can reduce the risk of loss. For this research, the prediction of the direction of stock price movements used the factor that influences the direction of stock movement itself, namely the stock price as a predictor variable. For this research, a comparison was made between the Recurrent Neural Network (RNN), Long Short-Term Memory (LSTM) model, and the Gated Recurrent Unit (GRU) model in predicting stock prices. The stock price data used in this study is the stock price data listed on the LQ45 index. The performance of the models were evaluated with Root Mean Square Error, Mean Square Error, and Mean Absolute Error. In this study, the same hyperparameters were used for all models, which are {epoch=200, batch size=32, and units=24}. From the average of Root Mean Square Error (RMSE), average of Mean Square Error (MSE), and average of Mean Absolute Error (MAE) generated from the 3 models, it is concluded that the GRU model has better accuracy than the Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) models.

Keywords: stock, gated recurrent unit, long short-term memory, recurrent neural network

Abstrak

Harga saham selalu mengalami fluktuasi, dapat naik dan dapat turun. Ketidakpastian tersebut dapat menyebabkan kerugian, jika salah dalam memprediksi arah pergerakan harga saham. Prediksi arah pergerakan harga saham yang lebih akurat dapat mengurangi risiko kerugian. Pada penelitian ini, prediksi arah pergerakan harga saham menggunakan faktor yang mempengaruhi arah pergerakan saham itu sendiri, yaitu harga saham sebagai variabel prediktor. Pada penelitian ini dilakukan perbandingan antara model *Recurrent Neural Network* (RNN), model *Long Short-Term Memory* (LSTM), dan model *Gated Recurrent Unit* (GRU) dalam memprediksi harga saham. Data harga saham yang digunakan pada penelitian ini adalah data harga saham-saham yang terdaftar di indeks LQ45. Performa model-model yang digunakan dievaluasi dengan *Root*

Mean Square Error, *Mean Square Error*, dan *Mean Absolute Error*. Pada penelitian digunakan *hyperparameter* yang sama untuk semua model yaitu {*epoch* = 200, *batch size* = 32, dan *units* = 24}. Dari rata-rata *Root Mean Square Error* (RMSE), rata-rata *Mean Square Error* (MSE), dan *Mean Absolute Error* (MAE) yang dihasilkan dari 3 model yang digunakan, disimpulkan bahwa model GRU memiliki akurasi yang lebih baik dari model *Recurrent Neural Network* (RNN) dan model *Long Short-Term Memory* (LSTM).

Kata-kata kunci: saham, *gated recurrent unit*, *long short-term memory*, *recurrent neural network*

PENDAHULUAN

Terdapat banyak jenis investasi, salah satu jenis investasi adalah investasi di pasar modal. Pasar modal merupakan pasar untuk berbagai aset keuangan jangka panjang yang dapat diperjualbelikan, baik surat utang, saham, maupun instrumen lainnya (BEI, 2022). Saham merupakan salah satu aset keuangan yang paling populer di pasar modal. Saham menurut BEI merupakan surat bukti kepemilikan suatu perusahaan (BEI, 2022). Saat membeli saham, investor terpapar risiko terjadinya penurunan harga saham. Hal ini disebabkan pergerakan harga saham yang berfluktuasi, terkadang harga saham dapat naik maupun turun. Adanya fluktuasi harga saham menyebabkan investasi pada saham bukanlah hal yang mudah dan memiliki risiko kerugian karena memerlukan prediksi dari para investor mengenai harga saham di masa depan (BEI, 2022).

Seiring perkembangan ilmu pengetahuan, para peneliti terutama peneliti di bidang pembelajaran mesin (*machine learning*) berusaha untuk mencari solusi atas permasalahan tersebut dengan mengembangkan metode-metode untuk memprediksi pergerakan harga saham berdasarkan data-data historis secara otomatis. Salah satu bagian dari pembelajaran mesin adalah Artificial Neural Network. Artificial Neural Network merupakan sebuah metode yang bekerja dengan menirukan cara kerja otak manusia dalam mengolah data untuk digunakan dalam mendeteksi objek, mengenali ucapan, dan membuat keputusan (Maind dan Wankar, 2014).

Penelitian yang telah dilakukan dengan menggunakan Artificial Neural Network yaitu oleh Cho et al. (2014). Pada penelitian tersebut, dilakukan perbandingan model *Gated Recurrent Unit* (GRU), model LSTM, dan model RNN dalam melakukan pemodelan *sequence*. Dari perbandingan tersebut ditemukan bahwa model GRU lebih baik dari model LSTM dan model RNN (Cho et al., 2014). Kemudian pada penelitian selanjutnya, Sethia dan Raut (2018), dilakukan perbandingan model LSTM, GRU, *Support Vector Machines* (SVM), dan *Multiple Layer Perceptron* (MLP) dalam memprediksi harga saham. Dari perbandingan tersebut ditemukan bahwa metode LSTM memiliki akurasi prediksi terbaik dibandingkan model-model lainnya (Sethia dan Raut, 2018). Pada penelitian selanjutnya yang dilakukan Shahi et al. (2020), dilakukan perbandingan model *Long Short-Term Memory* (LSTM) dengan model *Gated Recurrent Unit* (GRU) dalam meramalkan harga saham. Dari kedua metode tersebut GRU memberikan hasil akurasi yang lebih baik dibandingkan dengan model LSTM (Shahi et al., 2020).

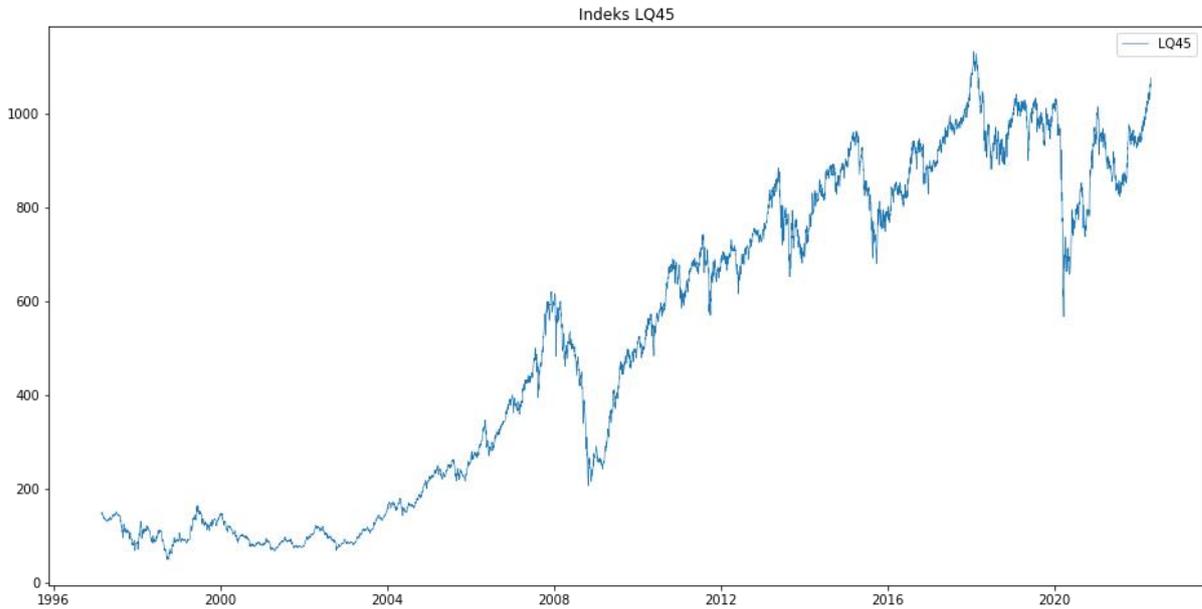
Pada penelitian ini, dibandingkan model *Recurrent Neural Network* (RNN), model *Long Short-Term Memory* (LSTM), dan model *Gated Recurrent Unit* (GRU) dalam memprediksi harga saham-saham yang terdaftar di indeks LQ45. Hasil prediksi dievaluasi dengan *Root Mean Square Error* (RMSE), *Mean Square Error* (MSE), dan *Mean Average Error* (MAE).

METODOLOGI

Bahan dan Data

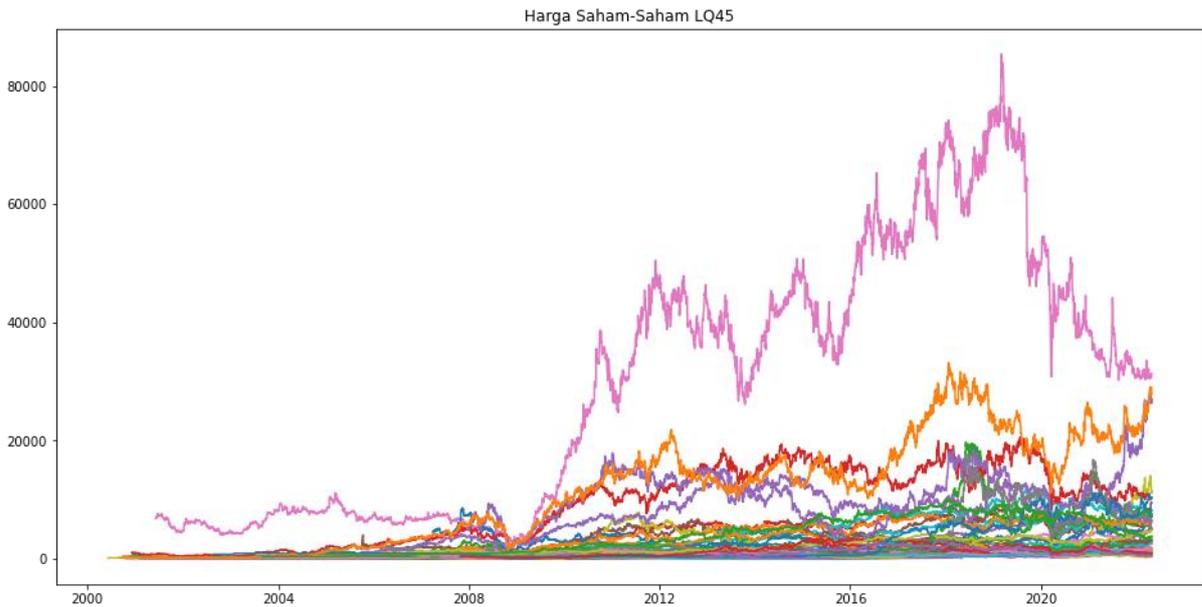
Data yang digunakan pada penelitian ini adalah data sekunder yang diperoleh dari *website Yahoo Finance*. Data ini merupakan data harga saham-saham yang terdaftar di indeks LQ45 dengan rentang waktu dari awal saham tersebut terdaftar di Bursa Saham Indonesia hingga waktu dibuatnya penelitian ini yaitu 20 April 2022. Penelitian ini menggunakan saham-saham yang terdaftar di indeks LQ45

karena saham-saham tersebut memiliki nilai kapitalisasi pasar, frekuensi transaksi, dan rata-rata nilai transaksi terbesar di Indonesia. Saham-saham yang terdaftar di indeks LQ45 juga merupakan saham-saham dari perusahaan-perusahaan yang memiliki kondisi finansial baik dan masa depan perusahaan baik (BEI, 2022). Dengan memilih saham-saham yang terdaftar di indeks LQ45, diharapkan bahwa penelitian ini dapat mencerminkan keadaan pasar saham di Indonesia. Tampilan dari grafik nilai indeks LQ45 ditunjukkan oleh GAMBAR 1,



GAMBAR 1. Indeks Harga Saham Gabungan (IHSG)

Tampilan dari grafik harga saham-saham yang terdaftar pada indeks LQ45 ditunjukkan oleh GAMBAR 2,



GAMBAR 2. Grafik harga saham-saham LQ45

Berdasarkan GAMBAR 2, harga saham-saham di LQ45 tidak semuanya memiliki *trend* yang naik. Terdapat saham yang memiliki *trend* naik, *trend* turun, dan *trend* mendatar. Sehingga, model-model yang digunakan pada penelitian ini tidak hanya dicoba ketika harga saham memiliki *trend* naik saja, melainkan dicoba untuk semua keadaan yang dapat terjadi pasar saham yaitu mengalami *trend* naik, *trend* mendatar, dan *trend* turun.

Metode Penelitian

Tahapan analisis yang dilakukan pada penelitian ini adalah,

1. *Input dataset* harga saham-saham yang terdaftar pada indeks LQ45 yang telah diunduh dari *website Yahoo Finance*.
2. Melakukan *pre-processing* data.
3. Melakukan pemodelan data dengan model *Recurrent Neural Network* (RNN), *Long Short Term Memory* (LSTM), dan *Gated Recurrent Unit* (GRU).
4. Mencari nilai galat masing-masing model dengan menggunakan *Root Mean Square Error* (RMSE), *Mean Square Error* (MSE), dan *Mean Absolute Error* (MAE).
5. Membandingkan nilai galat yang telah didapatkan dan mendapatkan model terbaik.

Pre-processing data

Pada penelitian ini, dilakukan dua buah proses *pre-processing* data, yaitu *splitting dataset* dan *feature scaling*. *Splitting dataset* adalah sebuah proses dimana *dataset* dibagi menjadi dua buah bagian, yaitu *dataset* pelatihan dan *testing dataset*. *Dataset* pelatihan digunakan untuk melatih model-model yang digunakan pada penelitian ini untuk mendapatkan bobot-bobot yang paling optimal. Sedangkan, *testing dataset* digunakan untuk menguji performa model. Proporsi antara *dataset* pelatihan dan *testing dataset* adalah 80% *dataset* pelatihan dan 20% *testing dataset* (Rahman et al., 2019). Pada penelitian ini, proses *splitting dataset* dilakukan kepada semua *dataset* harga saham yang di-*fitting* ke model RNN, model LSTM, dan model GRU. Selanjutnya, dipaparkan proses *feature scaling*. *Feature Scaling* adalah sebuah proses dimana data dinormalisasi sehingga memiliki rentang nilai yang sama. Pada penelitian ini, proses *feature scaling* dilakukan kepada semua *dataset* harga saham yang di-*fitting* ke model RNN, model LSTM, dan model GRU. Metode *feature scaling* yang digunakan pada penelitian ini adalah *min-max normalization*. *Min-max normalization* menormalisasikan nilai-nilai pada data sehingga rentang nilai data menjadi [0,1] (Rahman et al., 2019). Persamaan dari *min-max normalization* adalah (Rahman et al., 2019),

$$x' = \frac{x - \text{minimum}(x)}{\text{maksimum}(x) - \text{minimum}(x)} \quad (1)$$

dimana x adalah nilai di dataset, x' adalah nilai setelah dinormalisasi menjadi rentang 0 hingga 1. Setelah *dataset-dataset* yang digunakan telah dilakukan *pre-processing*, dilaksanakan pemodelan dengan model *Recurrent Neural Network* (RNN), model *Long Short-Term Memory* (LSTM), dan model *Gated Recurrent Unit* (GRU).

Pemodelan dengan model Recurrent Neural Network (RNN)

Model *Recurrent Neural Network* (RNN) merupakan pengembangan dari model *Artificial Neural Network* (ANN). Model *Recurrent Neural Network* (RNN) dikembangkan untuk mengolah data *sequence* seperti kata atau kalimat. Model RNN memiliki kemampuan untuk mengingat informasi yang dapat digunakan dalam mengenali informasi dari masa lalu dalam pembelajaran modelnya (Choi, Changkyu, 2018). Ketika sebuah *input* masuk ke model RNN, *input* tersebut akan diproses langsung oleh *hidden state* h_t . Fungsi *hidden state* pada RNN adalah sebagai tempat perhitungan,

memperbaharui, dan menyimpan bobot RNN. Dalam perhitungan fungsi *hidden state* digunakan fungsi aktivasi yang umumnya berupa fungsi *Relu* atau fungsi *hyperbolic tangent*. Persamaan dari *hidden state* waktu t RNN adalah (Choi, Changkyu, 2018),

$$h_t = f(W_{hh} \cdot h_{t-1} + W_{xh} \cdot x_t + b_h) \quad (2)$$

Pemodelan model *Recurrent Neural Network* (RNN) pada penelitian ini menggunakan parameter-parameter yang sama untuk semua *dataset*. Parameter-parameter RNN tersebut adalah: {*unit* = 24, *optimizer* = *stochastic gradient descent* (SGD), *batch size* = 32, dan *epoch* = 200}.

Pemodelan dengan model *Long Short-Term Memory* (LSTM)

Model *Long Short-Term Memory* merupakan pengembangan dari model *Recurrent Neural Network* (RNN). Model *Long Short-Term Memory* (LSTM) dikembangkan untuk mengolah data *sequence* seperti kata atau kalimat tanpa mengalami permasalahan *vanishing gradient* pada RNN. Permasalahan *vanishing gradient* menyebabkan RNN tidak dapat menangkap *long term dependencies*, sehingga akurasi yang dihasilkan oleh RNN berkurang. LSTM terdiri dari 3 buah *gate*, yaitu *input gate* (memiliki fungsi untuk memutuskan nilai yang diperbaharui), *forget gate* (memiliki fungsi untuk memutuskan informasi yang perlu dibuang), dan *output gate* (memiliki fungsi untuk memutuskan bagian yang akan dihasilkan) (Choi, Changkyu, 2018).

Bagian pertama dari LSTM adalah *forget gate* f_t . Fungsi dari *forget gate* adalah menentukan seberapa banyak informasi dari *cell state* sebelumnya (C_{t-1}) yang akan diteruskan ke *cell state* pada waktu t (C_t). Hasil dari *forget gate* dibatasi antara 0 hingga 1, karena fungsi *forget gate* memiliki fungsi sigmoid ($\sigma(\cdot)$). Persamaan dari *forget gate* adalah (Choi, Changkyu, 2018),

$$f_t = \sigma(W_{hf} \cdot h_{t-1} + W_{xf} \cdot x_t + b_f) \quad (3)$$

Bagian kedua dari LSTM adalah *input gate* i_t dan *candidate state* \tilde{C}_t . Fungsi dari *input gate* adalah menentukan nilai mana yang akan dilakukan pembaharuan. Sedangkan, *candidate state* memiliki peranan mengumpulkan dan memperbaharui informasi baru dari data. *Candidate state* memiliki fungsi yang sama dengan *cell state* h_t yang ada di RNN. Perbedaannya adalah kalau *cell state* di RNN meneruskan informasi ke *cell* berikutnya secara langsung, sedangkan *Candidate state* di LSTM digunakan untuk memperbaharui *cell state* C_t . Persamaan dari *input gate* dan *candidate state* adalah (Choi, Changkyu, 2018),

$$\tilde{C}_t = \tanh(W_{hc} \cdot h_{t-1} + W_{xc} \cdot x_t + b_c) \quad (4)$$

$$i_t = \sigma(W_{hi} \cdot h_{t-1} + W_{xi} \cdot x_t + b_i) \quad (5)$$

Bagian keempat dari LSTM adalah *cell state* C_t . Fungsi dari *cell state* adalah menggabungkan hasil perhitungan *input gate*, *candidate state*, dan *forget gate*. Persamaan dari *cell state* adalah (Choi, Changkyu, 2018),

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (6)$$

Bagian kelima dari LSTM adalah *state* h_t dan *output gate* o_t . State h_t memiliki fungsi untuk mengantarkan informasi ke *cell* berikutnya. Pada *state* h_t digunakan fungsi aktivasi *hyperbolic tangent*.

Sedangkan fungsi *output gate* adalah mengatur seberapa banyak informasi yang perlu diteruskan ke *cell* berikutnya. Persamaan dari *state* h_t dan *output gate* adalah (Choi, Changkyu, 2018),

$$h_t = o_t \odot \tanh(C_t) \quad (7)$$

$$o_t = \sigma(W_{ho} \cdot h_{t-1} + W_{xo} \cdot x_t + b_o) \quad (8)$$

Pemodelan model *Long Short-Term Memory* (LSTM) pada penelitian ini menggunakan parameter-parameter yang sama untuk semua *dataset*. Parameter-parameter RNN tersebut adalah: {*unit* = 24, *optimizer* = *stochastic gradient descent* (SGD), *batch size* = 32, dan *epoch* = 200}.

Pemodelan dengan Gated Recurrent Unit (GRU)

Model *Gated Recurrent Unit* (GRU) adalah sebuah model hasil modifikasi model *Recurrent Neural Network* (RNN). Model GRU memiliki arsitektur yang lebih sederhana dibandingkan arsitektur *Long Short-Term Memory* (LSTM). Pada model LSTM terdapat 3 buah *gate* (*input gate*, *forget gate*, dan *output gate*), sedangkan pada model GRU hanya terdapat 2 buah *gate* (*update gate* dan *reset gate*). Walaupun model GRU memiliki *gate* yang lebih sedikit dan arsitektur model yang lebih sederhana, model ini memberikan akurasi prediksi yang sebanding dengan model LSTM. Walaupun demikian, tidak diketahui antara model LSTM dan model GRU, yang mana yang lebih baik (Cho et al., 2014). Ketika sebuah *input* masuk ke model GRU, *input* tersebut pertama-tama akan diproses oleh *update gate*. *Update gate* adalah sebuah *gate* yang menentukan seberapa banyak informasi dari masa lalu yang perlu diteruskan ke masa depan dengan menggunakan fungsi aktivasi sigmoid $\sigma(\cdot)$. Persamaan dari *update gate* (u_t) adalah (Choi, Changkyu, 2018):

$$u_t = \sigma(W_{hu} \cdot h_{t-1} + W_{xu} \cdot x_t + b_u) \quad (9)$$

Kemudian, *input* yang masuk juga akan diproses oleh *reset gate* r_t . *Reset gate* adalah sebuah *gate* yang berfungsi untuk menentukan seberapa banyak informasi masa lalu yang perlu dilupakan dengan menggunakan fungsi aktivasi sigmoid $\sigma(\cdot)$. Persamaan dari *reset gate* adalah (Choi, Changkyu, 2018):

$$r_t = \sigma(W_{hr} \cdot h_{t-1} + W_{xr} \cdot x_t + b_r) \quad (10)$$

Kemudian, hasil perhitungan *reset gate* digunakan untuk menghitung *candidate state* (\tilde{h}_t). *Candidate state* digunakan untuk menghitung *hidden state* pada waktu t (h_t). Pada perhitungan *candidate state* digunakan fungsi aktivasi *hyperbolic tangent* ($\tanh(\cdot)$). Persamaan dari *candidate state* adalah (Choi, Changkyu, 2018):

$$\tilde{h}_t = \tanh(W_{hh} \cdot (r_t \odot h_{t-1}) + W_{xh} \cdot x_t + b_h) \quad (11)$$

Simbol \odot pada persamaan 3 dikenal sebagai *hadamard product*. Fungsi *hadamard product* adalah melakukan perkalian antara elemen-elemen di baris dan kolom yang sama yang berasal dari dua matriks dengan ukuran sama. Setelah *update gate*, *Reset gate*, dan *candidate state* dihitung, GRU melaksanakan perhitungan *hidden state* (h_t). Fungsi dari *hidden state* adalah menyimpan *output* pada waktu t yang akan diteruskan ke *unit* GRU berikutnya. Persamaan dari *hidden state* adalah (Choi, Changkyu, 2018):

$$h_t = (1 - u_t) \odot h_{t-1} + u_t \odot \tilde{h}_t \tag{12}$$

Pemodelan model *Gated Recurrent Unit* (GRU) pada penelitian ini menggunakan parameter-parameter yang sama untuk semua *dataset*. Parameter-parameter RNN tersebut adalah: {*unit* = 24, *optimizer* = *stochastic gradient descent* (SGD), *batch size* = 32, dan *epoch* = 200}.

Setelah pemodelan dengan *dataset training* dan prediksi dengan *dataset testing* telah dilakukan untuk setiap model dan setiap *dataset* harga saham-saham yang terdaftar di indeks LQ45, langkah berikutnya adalah melakukan perbandingan nilai galat dari masing-masing model. Perbandingan ini dilakukan dengan melihat nilai *Root Mean Square Error* (RMSE), *Mean Square Error* (MSE), dan *Mean Absolute Error* (MAE) dari hasil *testing* dengan *dataset testing* lalu dicari nilai RMSE, MSE, dan MAE terkecil.

HASIL DAN PEMBAHASAN

Pada bagian ini, dipaparkan hasil dari penelitian ini. Hasil dari penelitian ini adalah nilai galat dari masing-masing metode. Nilai galat RMSE, MSE, MAE memiliki satuan Rupiah (Rp). Hasil dari penelitian ini ditunjukkan oleh TABEL 1,

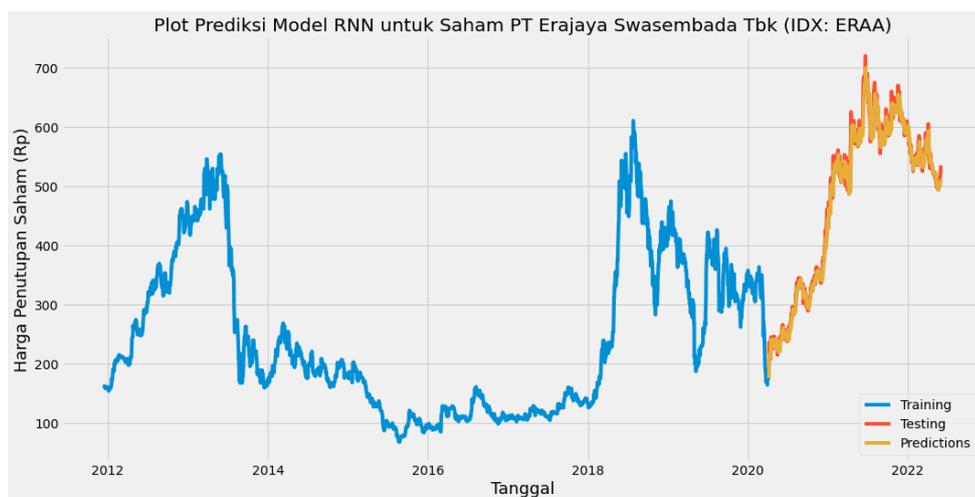
TABEL 1. Nilai galat masing-masing metode untuk masing-masing saham

Nomor	Saham	RNN RMSE	RNN MSE	RNN MAE	LSTM RMSE	LSTM MSE	LSTM MAE	GRU RMSE	GRU MSE	GRU MAE
1	ADR O	132.37	17521.30	73.40	109.28	11943.15	65.29	62.84	3949.14	39.09
2	AMR T	63.10	3981.18	40.12	84.74	7181.11	52.10	43.58	1898.84	26.79
3	ANT M	75.97	5770.82	46.94	113.34	12846.55	67.62	80.05	6407.43	47.96
4	ASII	136.10	18524.05	103.65	195.09	38061.40	145.33	135.05	18239.81	100.52
5	BBCA	400.66	160529.64	280.19	496.81	246822.72	418.52	229.93	52866.34	188.44
6	BBNI	223.03	49740.77	167.83	264.46	69941.48	184.08	183.67	33736.31	134.80
7	BBRI	280.05	78429.19	233.18	254.32	64680.32	209.74	135.33	18314.38	109.14
8	BBTN	51.99	2702.61	38.37	80.03	6404.96	58.32	54.65	2986.73	40.20
9	BFIN	50.68	2568.21	28.47	98.78	9758.09	57.31	26.21	686.89	16.26
10	BMRI	219.47	48167.47	158.40	240.82	57994.45	175.30	171.33	29354.52	129.52
11	BRPT	181.69	33011.80	138.79	66.70	4448.24	43.62	40.14	1611.56	26.22
12	BUK A	38.71	1498.29	32.54	70.17	4924.03	63.86	59.13	3495.95	54.12
13	CPIN	390.57	152543.81	318.13	312.46	97631.17	234.93	198.46	39384.73	144.63
14	EMT K	396.73	157391.61	285.59	254.83	64937.43	179.85	85.61	7329.10	58.24
15	ERAA	17.07	291.32	12.46	24.92	620.93	18.02	17.47	305.15	12.31
16	EXCL	81.55	6650.13	60.21	108.67	11810.10	79.75	91.82	8431.02	67.84
17	GGR M	1738.46	3022237.03	1150.73	2269.42	5150266.92	1541.65	1415.28	2003023.18	963.09
18	HMSP	99.16	9833.41	71.51	85.44	7299.14	58.94	57.82	3343.40	40.34
19	HRU M	546.42	298576.69	301.65	863.37	745406.27	506.64	319.29	101948.34	176.93
20	ICBP	309.15	95575.31	227.18	516.57	266846.22	394.26	201.83	40735.33	141.79
21	INCO	157.03	24659.65	108.06	239.77	57487.68	167.01	159.38	25403.31	108.87
22	INDF	155.39	24146.09	109.59	173.12	29969.22	126.62	139.75	19529.97	100.05
23	INKP	753.99	568505.35	518.04	1698.61	2885287.58	1070.50	715.69	512214.78	505.06
24	INTP	508.77	258845.11	381.73	614.72	377881.11	461.02	486.94	237115.37	364.44
25	ITMG	878.96	772572.84	524.77	1059.19	1121873.24	641.18	553.62	306489.80	356.30

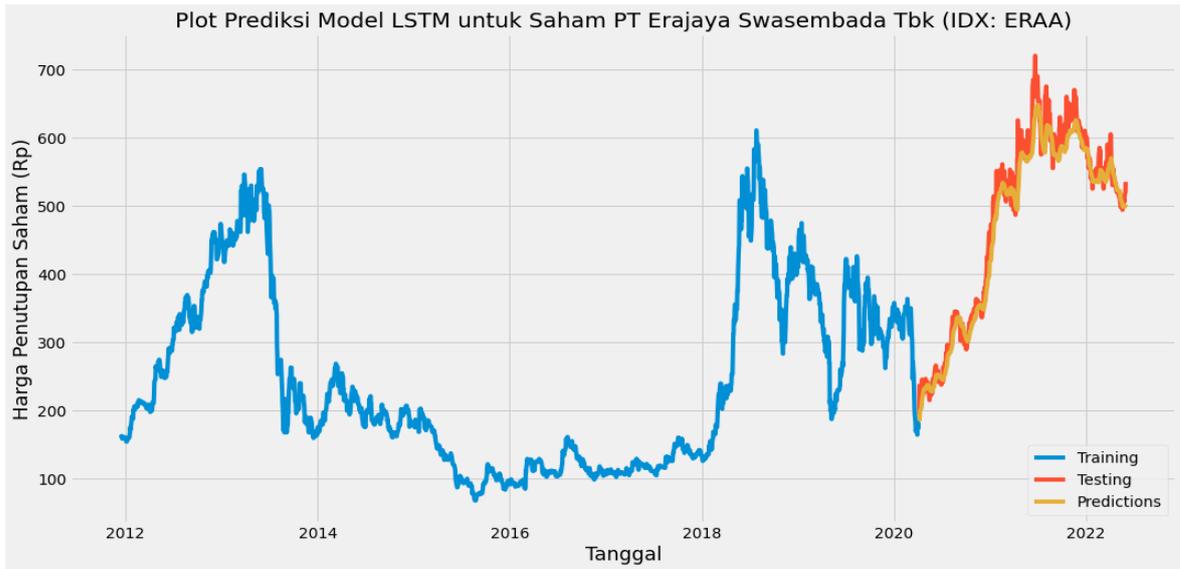
TABEL 1. Nilai galat masing-masing metode untuk masing-masing saham

Nomor	Saham	RNN RMSE	RNN MSE	RNN MAE	LSTM RMSE	LSTM MSE	LSTM MAE	GRU RMSE	GRU MSE	GRU MAE
26	JPFA	89.30	7974.73	61.77	84.79	7189.73	57.07	55.94	3128.84	38.27
27	KLBF	35.12	1233.68	25.18	45.72	2090.25	32.88	35.21	1239.95	24.89
28	MDKA	726.18	527334.51	534.99	371.87	138285.97	258.53	162.92	26541.98	111.74
29	MEDC	30.68	941.14	21.82	36.49	1331.63	25.90	26.60	707.79	18.79
30	MIKA	73.77	5441.90	52.65	91.03	8285.73	66.75	65.52	4292.89	47.37
31	MNCN	42.97	1846.52	30.09	55.79	3112.45	39.00	38.35	1470.91	26.52
32	PGAS	48.62	2363.82	35.31	69.45	4823.41	49.88	54.88	3011.52	39.06
33	PTBA	108.33	11735.49	79.33	123.83	15333.97	90.69	93.54	8749.98	68.45
34	PTPP	59.14	3497.07	44.18	72.74	5291.23	53.09	60.48	3658.10	43.75
35	SMGR	276.63	76523.21	198.44	446.98	199790.73	317.53	317.85	101026.61	230.39
36	TBIG	386.35	149268.90	285.52	249.80	62398.15	186.21	77.74	6043.00	51.92
37	TINS	50.59	2559.48	31.71	80.41	6465.71	52.77	55.52	3082.95	35.19
38	TKIM	3348.50	11212419.94	2767.98	1229.49	1511638.47	886.42	1094.82	1198620.57	929.42
39	TLKM	89.40	7992.58	66.64	108.53	11778.65	81.93	75.90	5761.36	56.65
40	TOWR	115.75	13397.38	92.79	87.56	7667.05	71.15	26.94	725.56	18.07
41	TPIA	1260.05	1587727.29	918.53	539.86	291444.82	398.76	244.78	59917.79	174.93
42	UNTR	696.52	485139.75	534.41	988.26	976665.57	765.19	694.40	482197.93	519.37
43	UNVR	154.42	23844.57	111.65	234.68	55075.89	175.16	147.91	21876.60	107.17
44	WIKA	82.62	6825.45	60.67	88.01	7745.32	61.84	60.07	3608.07	42.71
45	WSKT	49.30	2430.75	34.90	64.63	4176.65	44.19	51.39	2640.82	34.30

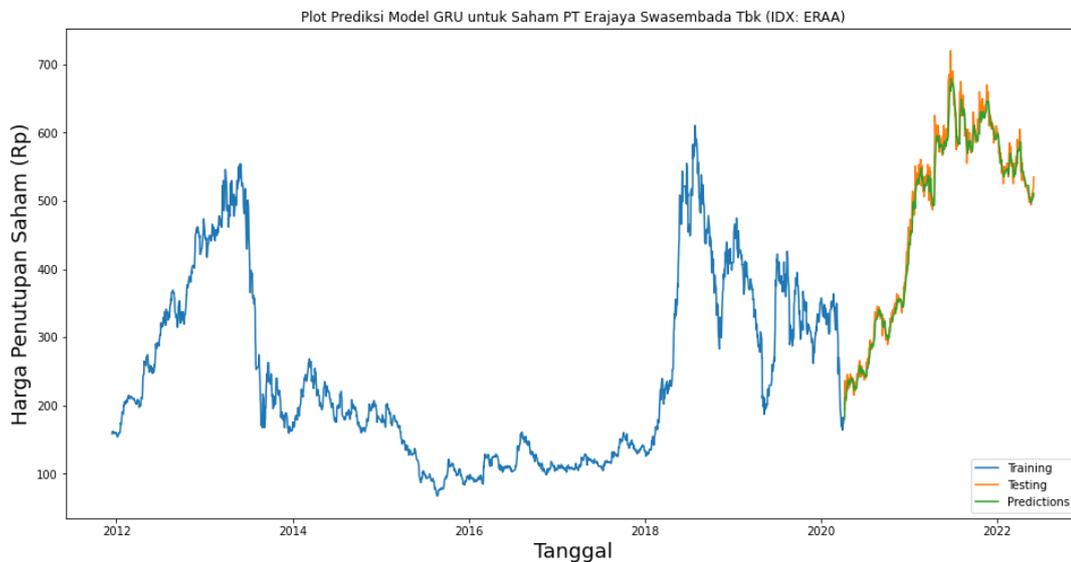
Berdasarkan TABEL 1, didapatkan nilai galat *Root Mean Square Error* (RMSE), *Mean Square Error* (MSE), dan *Mean Absolute Error* (MAE) masing-masing metode untuk setiap saham yang terdaftar di indeks LQ45 dan didapatkan bahwa nilai galat saham ERAA adalah yang terendah untuk ketiga model. Untuk melihat performa model RNN, LSTM, dan GRU dalam memprediksi saham ERAA, ditunjukkan grafik prediksi model RNN, LSTM, dan GRU pada GAMBAR 3, GAMBAR 4, dan GAMBAR 5.



GAMBAR 3. Grafik prediksi model RNN untuk saham PT Erajaya Swasembada Tbk (IDX: ERAA)

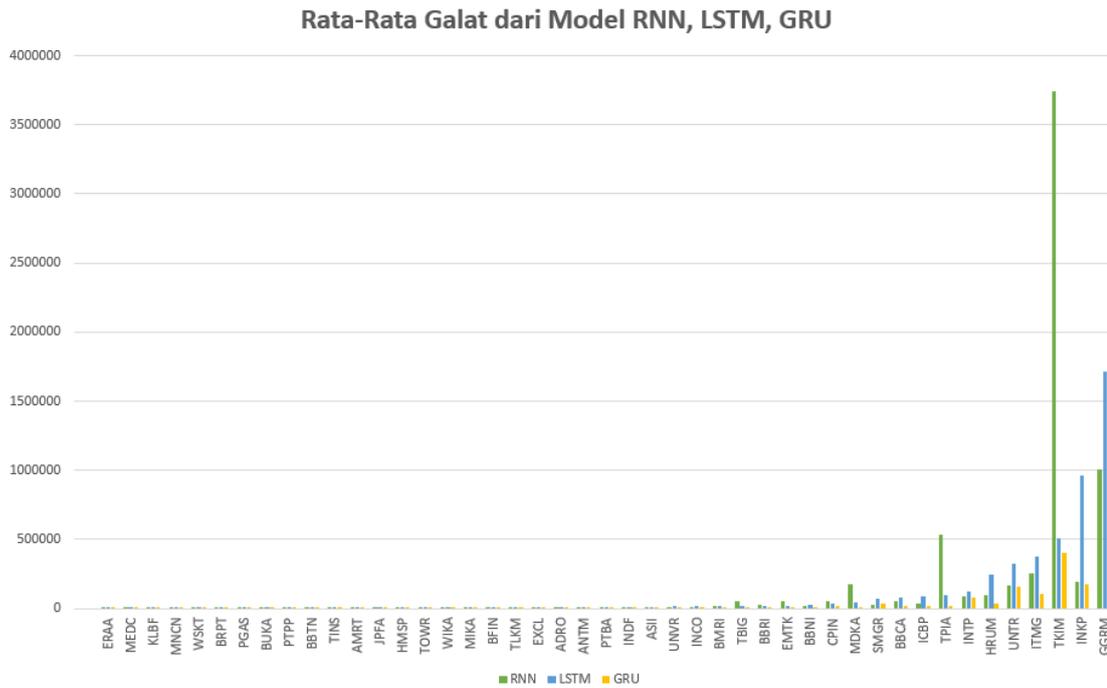


GAMBAR 4. Grafik prediksi model LSTM untuk saham PT Erajaya Swasembada Tbk (IDX: ERAA)



GAMBAR 5. Grafik prediksi model GRU untuk saham PT Erajaya Swasembada Tbk (IDX: ERAA)

Berdasarkan GAMBAR 3, GAMBAR 4, dan GAMBAR 5, dapat dianalisis bahwa ketiga model memodelkan data harga saham ERAA dengan baik karena grafik Predictions (hasil prediksi model) dekat dan searah dengan grafik Testing (data harga saham aktual). Dari ketiga gambar tersebut, dapat dianalisis juga bahwa hasil prediksi dengan model RNN dan model GRU memiliki tingkat akurasi yang mirip, karena grafik Predictions dan grafik Testing pada GAMBAR 3 dan GAMBAR 5 mirip. Kemudian, dapat dianalisis juga bahwa tingkat akurasi LSTM lebih rendah dibandingkan model RNN dan model GRU karena grafik Predictions pada GAMBAR 4 tidak seakurat grafik Predictions pada GAMBAR 3 dan GAMBAR 5 dalam memprediksi grafik Testing saham ERAA. Analisis ini dikonfirmasi kebenarannya oleh nilai galat RMSE, MSE, MAE pada Tabel 1. Berikutnya, ditunjukkan rata-rata galat dari RMSE, MSE, dan MAE dari setiap model untuk masing-masing saham yang terdaftar pada indeks LQ45 dalam bentuk sebuah bagan berkolom yang diberikan pada GAMBAR 6,



GAMBAR 6. Bagan berkolom rata-rata galat RMSE, MSE, dan MAE dari masing-masing model

Berdasarkan GAMBAR 6, dapat dianalisis bahwa saham dengan nilai maksimum rata-rata galat dari model RNN, LSTM, dan GRU berbeda. Saham dengan nilai maksimum rata-rata galat untuk model RNN adalah saham TKIM (PT Pabrik Kertas Tjiwi Kimia Tbk.). Sedangkan, saham dengan nilai maksimum rata-rata galat untuk model LSTM dan model GRU adalah GGRM (PT Gudang Garam Tbk). Kemudian, dapat dianalisis bahwa saham TKIM merupakan saham yang sulit untuk dimodelkan oleh model tanpa gate (model RNN tidak memiliki gate sedangkan model LSTM dan model GRU memiliki gate) ditunjukkan oleh nilai rata-rata galat yang sangat besar pada model RNN. Kemudian, dapat dianalisis bahwa model GRU memiliki performa yang lebih baik dibandingkan model RNN dan model LSTM, ditunjukkan oleh bagan berkolom GRU yang lebih pendek dibandingkan model RNN dan LSTM. Untuk mengkonfirmasi analisis tersebut, dianalisis secara menyeluruh akurasi dari ketiga model untuk memprediksi harga saham-saham yang terdaftar pada indeks LQ45 dengan rata-rata galat semua saham yang terdaftar di indeks LQ45. Rata-rata galat dari ketiga model ditunjukkan oleh TABEL 2,

TABEL 2. Nilai rata-rata galat masing-masing metode

Nilai Rata-rata Galat Masing-masing Metode			
Metode	RMSE	MSE	MAE
RNN	346.91758	443217.15	253.3347008
LSTM	341.45668	326064.78	238.5863937
GRU	202.3475	120380.1	146.0420626

Berdasarkan TABEL 2, didapatkan bahwa rata-rata nilai galat *Root Mean Square Error* (RMSE), *Mean Square Error* (MSE), dan *Mean Absolute Error* (MAE) dari GRU merupakan yang paling kecil. Jika dibandingkan dengan rata-rata nilai galat RMSE, MSE, dan MAE model RNN, didapatkan bahwa GRU memiliki akurasi yang lebih tinggi sebanyak 52% dibandingkan model RNN. Sedangkan itu, model LSTM memiliki nilai rata-rata galat terkecil kedua setelah model GRU. Jika dibandingkan dengan model RNN, model LSTM memiliki akurasi yang lebih tinggi sebanyak 11% dibandingkan model RNN. Kemudian, ketika model LSTM dan GRU dibandingkan, didapatkan bahwa model GRU

memiliki akurasi yang lebih tinggi sebanyak 47.53%. Dari analisis tersebut, dapat disimpulkan bahwa model GRU adalah model yang memiliki akurasi tertinggi dalam memprediksi harga saham-saham yang terdaftar di indeks LQ45 ketika dibandingkan dengan model LSTM dan model RNN.

KESIMPULAN DAN SARAN

Berdasarkan hasil dan pembahasan dapat disimpulkan bahwa dari ketiga model (*Recurrent Neural Network* (RNN), *Gated Recurrent Unit* (GRU), dan *Long Short-Term Memory* (LSTM)) yang telah diimplementasikan dan diterapkan pada nilai historis harga penutupan saham-saham yang terdaftar di indeks LQ45, model *Gated Recurrent Unit* (GRU) memiliki tingkat akurasi terbaik.

REFERENSI

- PT Bursa Efek Indonesia, 2022, Pasar modal, diakses 20 April 2022, <https://www.idx.co.id/investhub/belajar-pasar-modal/#welcome>.
- PT Bursa Efek Indonesia, 2022, Saham, diakses 20 April 2022, <https://www.idx.co.id/produk/saham/>.
- Maind, S.B., Wankar, P., R. (2014) Research Paper on Basic of Artificial Neural Network: International Journal on Recent and Innovation Trends in Computing and Communication, Volume. 2, Issue. 1
- Chung, J., Gulcehre, C., Cho, K., Bengio, Y. (2014) Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modelling: arXiv:14123555v1 [csNE].
- Sethia, A., Raut, P. (2019). Application of LSTM, GRU and ICA for Stock Price Prediction. In: Satapathy, S., Joshi, A. (eds) Information and Communication Technology for Intelligent Systems . Smart Innovation, Systems and Technologies, vol 107. Springer, Singapore. https://doi.org/10.1007/978-981-13-1747-7_46.
- Shahi, Tej B., Ashish Shrestha, Arjun Neupane, and William Guo. 2020. "Stock Price Forecasting with Deep Learning: A Comparative Study" Mathematics 8, no. 9: 1441. <https://doi.org/10.3390/math8091441>.
- PT Bursa Efek Indonesia, 2022, LQ45 Index Methodology, diakses 20 April 2022, <https://www.idx.co.id/Portals/0/StaticData/Information/ForInvestor/StockMarketIndicies/FileDownload/LQ45%20Index%20Methodology%20By%20IDX.pdf>.
- Choi, Changkyu (2014) Time Series Forecasting with Recurrent Neural Networks in Presence of Missing Data: Master thesis-UiT The Arctic University of Norway.
- Rahman, M.O., Hossain, Md.S., Junaid, T., Forhad, Md.S.A., Hossen, M.K. (2019) Predicting Prices of Stock Market using Gated Recurrent Units (GRUs) Neural Networks: IJCSNS International Journal of Computer Science and Network Security, Vol. 19, No. 1, January 2019