



JEPIN

(Jurnal Edukasi dan Penelitian Informatika)

ISSN(e): 2548-9364 / ISSN(p) : 2460-0741

Vol. 7
No. 2
Agustus
2021

Optimasi *Deep Learning* untuk Prediksi Saham di Masa Pandemi *Covid-19*

Widi Hastomo^{#1}, Adhitho Satyo Bayangkari Karno^{*2}, Nawang Kalbuana⁺³, Ervina Nisfiani⁻⁴, Lussiana ETP⁻⁵

[#]Program Studi Teknologi Informasi, Fakultas Teknik, ITB Ahmad Dahlan
Jl. Ir. H. Juanda No. 77, Cirendeu, Ciputat, Tangerang Selatan 15419

¹widie.has@gmail.com

^{*}Fakultas Teknologi Informasi, Universitas Gunadarma
Jl. Margonda Raya No. 100, Depok, Jawa Barat 16424

²adh1t10.2@gmail.com

⁺Politeknik Penerbangan Indonesia Curug, Banten
Jl. Raya PLP Curug, Serdang Wetan, Kec. Legok, Tangerang, Banten 15820

³nawang.kalbuana@gmail.com

⁻Magister Teknologi Informasi, STMIK Jakarta STI&K
Jl. BRI No.17 Radio Dalam, Kebayoran Baru, Jakarta Selatan 12140 D.K.I. Jakarta

⁴ervinanispiani@gmail.com

⁵lussiana.ETP@gmail.com

Abstrak— Penelitian ini bertujuan untuk meningkatkan akurasi dengan menurunkan tingkat kesalahan prediksi dari 5 data saham blue chip di Indonesia. Dengan cara mengkombinasikan desain 4 hidden layer neural network menggunakan Long Short Term Memory (LSTM) dan Gated Recurrent Unit (GRU). Dari tiap data saham akan dihasilkan grafik rmse-epoch yang dapat menunjukkan kombinasi layer dengan akurasi terbaik, sebagai berikut; (a) BBCA dengan layer LSTM-GRU-LSTM-GRU (RMSE=1120,651, e=15), (b) BBRI dengan layer LSTM-GRU-LSTM-GRU (RMSE =110,331, e=25), (c) INDF dengan layer GRU-GRU-GRU-GRU (RMSE =156,297, e=35), (d) ASII dengan layer GRU-GRU-GRU-GRU (RMSE =134,551, e=20), (e) TLKM dengan layer GRU-LSTM-GRU-LSTM (RMSE =71,658, e=35). Tantangan dalam mengolah data Deep Learning (DL) adalah menentukan nilai parameter epoch untuk menghasilkan prediksi akurasi yang tinggi.

Kata kunci— Covid-19, Deep Learning, LSTM, GRU

I. PENDAHULUAN

Dalam membentuk ekonomi pada suatu negara, pasar modal merupakan salah satu komponen yang cukup penting, banyak instrumen dapat ditransaksikan seperti obligasi, reksadana dan saham. Selain untuk mendapatkan dana segar yang cepat dari masyarakat luas, pasar modal memberikan manfaat pada perusahaan, diversifikasi portfolio dan likuiditas, perubahan modal pemilik dan pengakuan investor, yang menjadi alasan kenapa perusahaan melakukan pemilihan pada *initial public offering* (IPO) [1].

Strategi dalam melakukan investasi, seorang investor harus mampu menciptakan portofolio risiko yang kecil dan mendapatkan tingkat pengembalian yang tinggi. Di tengah masa pandemi covid-19 seperti sekarang ini yang tidak menentu, berdampak sangat luas pada saham [2], perekonomian global [3] dan tanah air. Indeks Harga Saham Gabungan (IHSG) sempat mengalami valuasi terendah dalam dekade ini, pada level 3.937 dikarenakan investor memberikan respon negatif [4]. Saham blue chip menjadi unggulan dalam masa pandemi, karena terbukti membukukan *net buy* yang cukup besar [5].

Dalam menentukan sebuah kebijakan yang sangat krusial maka dibutuhkan sebuah metode untuk memprediksi harga saham. *Closing price* yang berfluktuatif dan sensitifitas yang tinggi, cukup sulit untuk diprediksi secara konvensional, agar investasi dapat diminimalisir risikonya. Investor biasanya melakukan analisis secara fundamental pada bisnis perusahaan serta menganalisa faktor eksternal yang dapat mempengaruhi kinerja perusahaan. Proses analisis seperti ini biasanya membutuhkan waktu cukup lama serta membutuhkan analisa teknikal dan *mandatory*.

Selama dekade terakhir ini, algoritma deep learning telah banyak diimplementasikan dalam bidang *financial* [6], [7]. Penelitian yang dilakukan oleh Islam dan Hossain [8] memprediksi pasar valuta asing menggunakan algoritma LSTM dan GRU, untuk validasi hasil menggunakan *Mean Square Error* (MSE), *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE) dan skor *R-squared* (R^2). Penelitian yang dilakukan oleh Patel et.all [9] prediksi *cryptocurrencies* menggunakan GRU dan LSTM, validasi

menggunakan RMSE. Penelitian yang dilakukan oleh Appati et,all [10] memprediksi harga saham dengan dua pendekatan yaitu LSTM dan GRU, validasi menggunakan MSE & MAE.

LSTM mampu menangani kendala *vanishing gradient* pada saat pelatihan di *Recurrent Neural Network* (RNN), namun LSTM memiliki kompleksitas yang cukup tinggi dibandingkan dengan GRU. GRU memiliki 2 sigmoid dan 1 tanh, sedangkan LSTM memiliki 3 sigmoid dan 2 tanh. Karena kompleksitas tersebut, maka secara teori kemampuan latih GRU lebih cepat. Namun hal ini perlu dicoba pada data yang berfluktuatif tinggi seperti data saham blue chip Indonesia agar mendapatkan hasil yang optimal.

Penelitian ini akan menggabungkan dua algoritma deep learning yaitu LSTM dan GRU untuk mencari optimasi karakteristik epoch dan RMSE. Tantangan dalam mengolah data Deep Learning (DL) yaitu dengan menentukan nilai parameter epoch yang diperlukan untuk menghasilkan prediksi akurasi tinggi [11]. Tindakan yang sering dilakukan selama ini adalah dengan melakukan coba-salah (*try-error*), mencoba dan mengulangi dengan beberapa nilai epoch untuk mendapatkan hasil prediksi yang diharapkan [12]. Tindakan ini sangat sulit dilakukan dengan 6 model layer, memerlukan waktu yang lama serta hasil prediksi yang kurang baik [12].

Untuk mengatasi hal ini, maka dalam penelitian ini dibuat suatu program iterasi yang menghasilkan grafik yang dapat memperlihatkan dan menunjukkan secara numerik epoch, layer, dan RMSE minimum, sehingga memudahkan investor untuk melakukan proses prediksi agar memperoleh hasil yang diinginkan. Dengan demikian perkiraan nilai epoch yang dipergunakan dengan RMSE yang minim, dapat lebih mudah dilaksanakan.

Dalam penelitian ini akan dipilih 5 dari 9 data saham blue chip yang ada, dilakukan melalui proses korelasi untuk memperoleh hubungan yang kuat (korelasi ≥ 5) dipilih dan dijadikan sebagai dataset. Data saham tersebut yaitu saham BBKA, BBRI, INDF, ASII, dan TLKM. Saham blue chip dijadikan obyek karena termasuk kategori *market leader* dibidangnya, kapitalisasi pasar yang besar, mampu bertahan dalam kondisi pandemi covid-19 seperti sekarang ini, hal ini dibuktikan dengan *net buy* yang cukup besar oleh pihak asing [5].

Beberapa manfaat dari penelitian ini dengan model arsitektur dan jumlah data tertentu, adalah:

- Menguji kemampuan model LSTM dan GRU dalam mengolah data saham blue chip Indonesia.
- Hasil prediksi yang lebih baik dengan nilai RMSE yang minim.
- Mengkombinasikan hidden layer dengan menggunakan variasi kedua model LSTM dan GRU
- Mengetahui karakteristik epoch-rmse untuk setiap dataset, sehingga dapat diperoleh nilai epoch yang tepat untuk menghasilkan prediksi yang lebih akurat.
- Menggunakan metode korelasi untuk melihat tingkat hubungan antar dua data saham.

- Menggunakan metode korelasi sebagai filter dari data mentah menjadi dataset.

II. TINJAUAN PUSTAKA

A. Korelasi

Hasil dari pembuatan program korelasi (menggunakan library seaborn) ditunjukkan secara visual dan numerik dalam bentuk matrik heatmap, dengan tampilan warna menunjukkan level dari nilai korelasi antara 2 data saham. Perhitungan korelasi menggunakan rumus korelasi Pearson [13], sebagai berikut :

$$r_{x_i,y} = \frac{n(\sum X_i Y) - (\sum X_i)(\sum Y)}{\sqrt{\{n(\sum X_i^2) - (\sum X_i)^2\}\{n(\sum Y^2) - (\sum Y)^2\}}}$$

Dimana:

$\sum X_i$ = Jumlah data X_i

$\sum Y$ = Jumlah dari Y

$\sum X_i Y$ = Jumlah dari $X_i \cdot Y$

$\sum X_i^2$ = Jumlah dari X_i^2

Selain warna heatmap juga memberikan nilai numerik korelasi berupa bilangan dengan rentang antara -1 dan 1, dimana nilai ± 1 menunjukkan hubungan yang kuat, dan nilai 0 menunjukkan hubungan yang rendah antara dua data.

B. Python

Python dipilih sebagai bahasa pemrograman dalam penelitian ini, karena bahasa ini mempunyai banyak library yang memudahkan dalam hal pembuatan program yang melibatkan banyak manipulasi vektor dan matrik (library keras [14], tensorflow [15], numpy pandas [7]), serta tampilan visual berbagai grafik yang menarik dan mudah dibaca (*library scikit learn matplotlib*, dan juga *heatmap (library seaborn)* untuk menunjukkan korelasi dalam bentuk peta warna dan numerik.

C. RMSE dan MSE


Arsitektur DL dalam penelitian ini menggunakan 1 input, 4 hidden, dan 1 output layer, 50 node untuk tiap hidden layer, drop down = 0.2, batch size = 32, dan jumlah nilai epoch (e) yang diperlukan untuk melakukan proses perulangan pembelajaran. Besaran RMSE dipergunakan untuk mengukur kesalahan dalam proses prediksi. Tantangan yang dihadapi setelah merancang layer dan parameter yang diperlukan dalam DL, adalah menentukan nilai *epoch* (e) agar prediksi menghasilkan nilai RMSE yang kecil. Untuk menunjukkan tingkat akurasi, dipergunakan besaran nilai kesalahan RMSE (*Root Mean Square Error*) dan MSE (*Mean Square Error*). Semakin tinggi akurasi yang dihasilkan ditunjukkan dengan nilai RMSE dan MSE yang kecil. RMSE adalah nilai akar kuadrat dari MSE, dipergunakan untuk mengukur kesalahan suatu model [16].

Rumus RMSE dan MSE:

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(y_1 - \hat{y}_1)^2}{n}} \text{ dan } MSE = \frac{1}{n} \sum_{i=1}^n (y_1 - \hat{y}_1)^2$$

Dimana:

$\hat{y}_1, \hat{y}_2, \dots, \hat{y}_n = \text{nilai yang diprediksi}$
 $y_1, y_2, \dots, y_n = \text{nilai yang diamati}$



Gambar 1. (a) RMSE dan (b) MSE [17]

D. Stochastic Gradient Descent (SGD)

SGD merupakan sebuah algoritma optimasi untuk pembelajaran mesin khususnya *artificial neural network* yang di implementasikan dalam deep learning. Algoritma ini berfungsi untuk mendapatkan satu set model parameter pada model internal yang berkemampuan baik terhadap sebagian skala kinerja semisal *mean squared error* serta *loss logaritmik*. Sifat dari algoritma ini adalah iteratif, hal ini bermakna bahwa dalam menentukan langkah diskrit dibutuhkan proses pencarian. Dari langkah tersebut untuk meningkatkan model parameter [18].


Desain kombinasi layer antara Long Short Term Memory (LSTM) dan Gated Recurrent Unit (GRU), dilakukan untuk menghasilkan akurasi yang lebih baik [19]–[22]. Dari hasil kombinasi ini menunjukkan bahwa prediksi dapat lebih ditingkatkan untuk setiap data time series saham yang dipergunakan dalam penelitian ini. Hasil dari program iteratif ini berbentuk visual grafik dan numerik yang memudahkan dalam memilih nilai epoch dan desain kombinasi lapisan LSTM-GRU yang diperlukan untuk memperoleh hasil prediksi terbaik.

III. METODE

A. LSTM – GRU

Model awal mesin learning yang berbasis neural network adalah RNN (Recurrent Neural Network). Ketidakmampuan RNN dalam mengkaitkan informasi yang panjang [23], menimbulkan masalah hilangnya nilai gradien (*vanishing gradient*) dalam proses perulangan di neural network (*back propagation neural network*). Untuk mengatasi masalah ini maka dibuat suatu model baru yaitu LSTM (Long Short Term Memory). LSTM berupa cel yang

ber isi rangkaian 4 gate dan 5 fungsi aktivasi yang cukup rumit. Walaupun LSTM sukses dalam menyimpan informasi yang panjang dan saling berkaitan dengan data sebelum dan sesudahnya (*data time series*), namun rumitnya rangkaian menjadikan LSTM memerlukan waktu proses yang lebih besar. Untuk menyempurnakan LSTM dirancang suatu model yang lebih sederhana yaitu model GRU (Gated Recurrent Unit). GRU merupakan cel dengan kandungan 2 gate dan 3 fungsi aktivasi. Dengan gate dan fungsi aktivasi yang minim ini tentunya akan mempercepat proses pengolahan data yang umumnya berjumlah sangat besar. Kemampuan GRU dirancang untuk menjadi lebih baik dari LSTM terutama untuk dataset yang jumlahnya sedikit [24]



Gambar 2. RNN , LSTM , GRU

Formula LSTM

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

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

$$C_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c)$$

$$C_t = f_t * C_{t-1} + i_t * C_t$$

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

$$h_t = O_t + \tanh(C_t)$$

Formula GRU

$$z = \sigma(X_t U^z + S_{t-1} W^z)$$

$$r = \sigma(X_t U^r + S_{t-1} W^r)$$

$$h = \tanh(X_t U^h + (S_{t-1} o r) W^h)$$

$$S_t = (1 - z) o h + z o S_{t-1}$$

B. Data Mentah

Sumber data 9 saham blue chip Indonesia diperoleh dari *finance.yahoo.com* mulai dari 2 Februari 2015 sampai dengan 19 Juni 2020 (tiap saham berisi 1.357 baris).

Symbols	ASII.JK	BBCA.JK	BBRI.JK	INDF.JK	JSMR.JK	PTBA.JK	TLKM.JK	UNTR.JK	UNVR.JK
2015-02-02	7750.0	13350.0	2345.0	7600.0	7108.350098	2275.0	2805.0	17900.0	7235.0
2015-02-03	7825.0	13500.0	2350.0	7450.0	7108.350098	2285.0	2825.0	17900.0	7275.0
2015-02-04	7725.0	13900.0	2355.0	7500.0	7108.350098	2300.0	2845.0	18025.0	7280.0

Symbols	ASII.JK	BBCA.JK	BBRI.JK	INDF.JK	JSMR.JK	PTBA.JK	TLKM.JK	UNTR.JK	UNVR.JK
2020-06-17	4970.0	28800.0	3100.0	6550.0	4150.0	2470.0	3210.0	17700.0	8275.0
2020-06-18	4800.0	27925.0	3050.0	6475.0	4170.0	2450.0	3280.0	17650.0	8050.0
2020-06-19	4890.0	27875.0	3100.0	6575.0	4130.0	2280.0	3280.0	17850.0	8050.0

(1357, 9)

Gambar 3. Data mentah 9 saham

Data mentah ini terdiri dari 6 fitur kolom, yaitu *High, Low, Open, Close, Volume, Adj Close*. Dari 6 fitur dipilih fitur *Close* yang akan digunakan sebagai dataset untuk proses berikutnya (Gambar 3).

C. Training dan Testing Dataset

Mesin mampu belajar dari data time series, maka dataset yang ada harus dibagi menjadi training dataset berkisar 70%-80% dari keseluruhan dataset. Selanjutnya dari hasil pembelajaran, selanjutnya mesin akan diuji untuk memprediksi testing dataset (20%-30%). Hasil dari prediksi testing dataset akan diukur nilai kesalahannya dengan nilai real testing dataset (data target). Nilai kesalahan yang diperoleh akan dipergunakan untuk memperbaiki (update) nilai bobot. Nilai bobot yang baru akan dipergunakan dalam prediksi iterasi selanjutnya.

Bayaknya data input yang dipergunakan adalah sesuai dengan nilai *time step*, biasanya adalah angka 7 (1 minggu = 7 hari). Sebagai contoh untuk n dataset, dengan 7 *time step*, pergeseran data input (shift) = 1, dapat dilihat dalam gambar 4.

Dataset	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	...	Xn	Target
Input 1	X1	X2	X3	X4	X5	X6	X7						X8
Input 2		X2	X3	X4	X5	X6	X7	X8					X9
Input 3			X3	X4	X5	X6	X7	X8	X9				X10
...		
Input n-7					Xn-6	Xn-5	Xn-4	Xn-3	Xn-2	Xn-1			Xn


Gambar 4. Pergeseran data input dari dataset

D. Kombinasi Layer

Terdapat 3 layer dalam mesin learning, yaitu input layer, hidden layer, dan output layer. Dalam penelitian ini dipergunakan 4 hidden layer, dengan menggunakan kombinasi LSTM dan GRU untuk setiap layer. Desain layer ini membentuk 6 model untuk setiap dataset dari 5 dataset saham (BBCA, BBRI, INDF, ASII, dan TLKM), sebagai berikut :

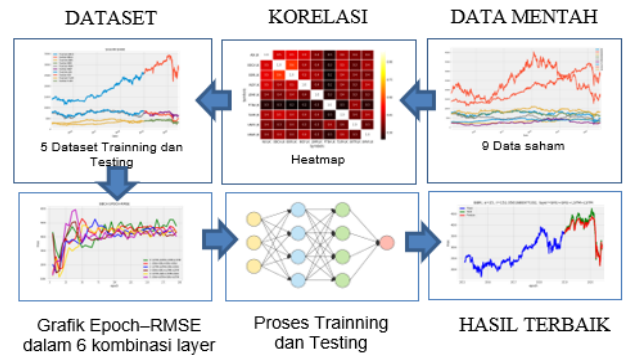
TABEL I
DESAIN LAYER UNTUK MODEL 5

Hidden layer	1	2	3	4
Model 0	LSTM	LSTM	LSTM	LSTM
Model 1	GRU	GRU	GRU	GRU
Model 2	LSTM	LSTM	GRU	GRU
Model 3	GRU	GRU	LSTM	LSTM
Model 4	LSTM	GRU	LSTM	GRU
Model 5	GRU	LSTM	GRU	LSTM




Gambar 5. Desain hidden layer (model 5)

Alur penelitian secara garis besar dapat digambarkan sebagai berikut:



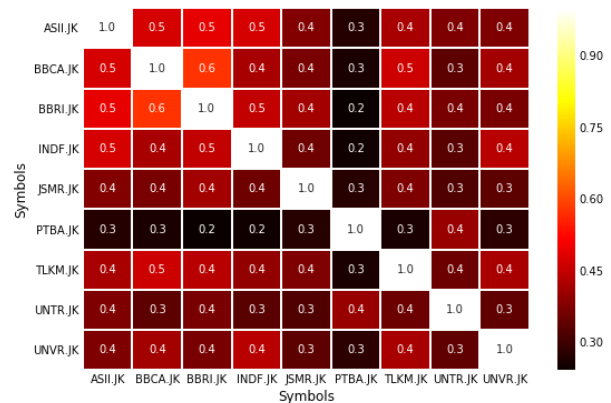
Gambar 6. Skenario penelitian

Pada gambar 7 terlihat fluktuatif dataset saham blue chip Indonesia dari 2 Februari 2015 sampai dengan 19 Juni 2020.



Gambar 7. Data 9 saham blue chip Indonesia

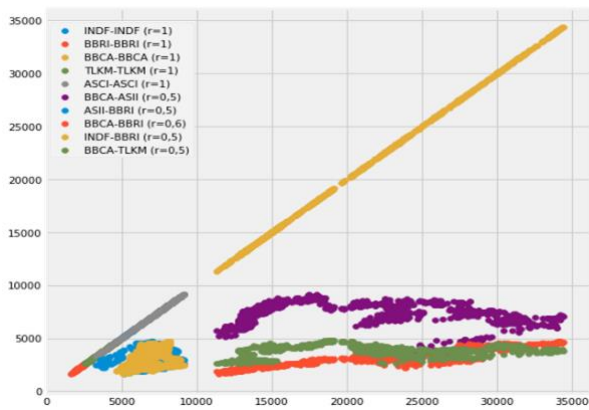
Dari 9 data mentah saham blue chip akan dilakukan filterisasi dengan menggunakan metode korelasi untuk mencari hubungan yang kuat antara data tersebut. Hasil korelasi ditampilkan dalam bentuk visual matrik heatmap yang mudah dilihat berdasarkan tingkatan warna dan numerik yang tercantum di matrik heatmap tersebut (gambar 8).



Gambar 8. Matrik heatmap – korelasi

Dari matrik heatmap dipilih 5 data saham dengan korelasi lebih besar sama dengan 0,5 ($r \geq 0,5$) yaitu Bank Central Asia (BBKA), Bank Rakyat Indonesia (BBRI),


Astra Indonesia (ASII), Indofood (INDF), dan Telkom (TLKM). Sebaran 5 data saham ini juga dapat dilihat dengan jelas secara visual di gambar 9.



Gambar 9. Sebaran 5 data saham

E. Pemisahan Data Training dan Testing

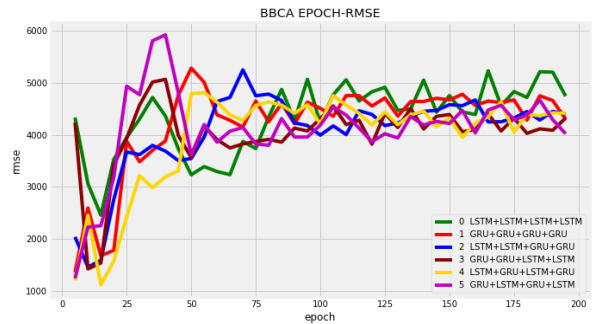
Dari 5 data saham tersebut, dilakukan pemisahan data untuk *training* sekitar 70% - 80% (986 data) dan sisanya untuk proses *testing* (371 data). Grafik training dan testing dari 5 data saham terlihat di gambar 10.



Gambar 10. Training dan testing dari 5 saham

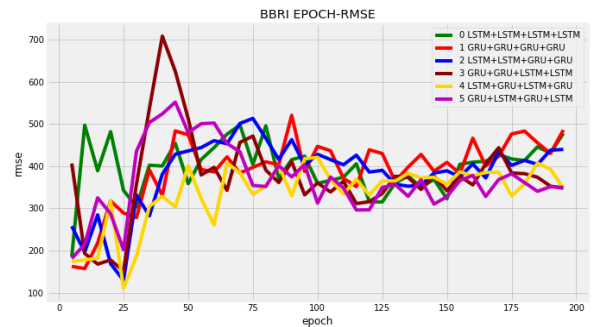
F. Karakteristik EPOCH-RMSE dengan 6 Model Layer

Nilai RMSE minimum dari 5 data saham, dengan model layer tertentu dan nilai epoch yang tepat sangat diperlukan untuk memperoleh prediksi dengan akurasi terbaik [25]. Dalam penelitian ini juga dibuat program iteratif yang menghasilkan grafik yang dapat memperlihatkan dan menunjukkan secara numerik epoch, layer, dan RMSE minimum.



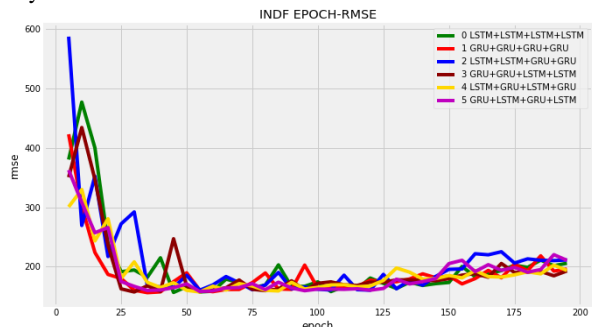
Gambar 11. EPOCH-RMSE saham BBKA

Untuk saham BBKA (Bank BCA), nilai RMSE minimum adalah 1120.6517, epoch = 15, dan model layer 4 yaitu LSTM-GRU-LSTM-GRU.



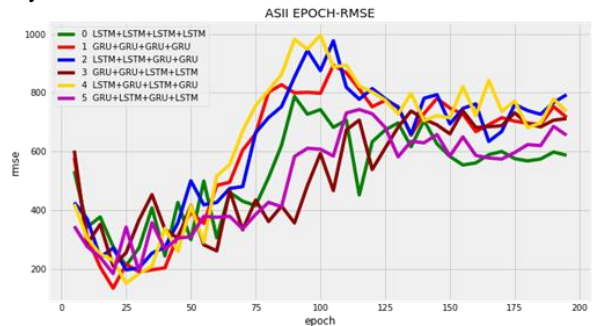
Gambar 12. EPOCH-RMSE saham BBRI

Untuk saham BBRI (Bank BRI), nilai RMSE minimum adalah 110.3306, epoch = 25, dan model layer 4 yaitu LSTM-GRU-LSTM-GRU.



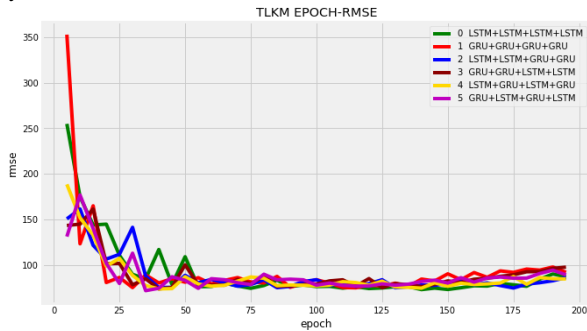
Gambar 13. EPOCH-RMSE saham INDF

Untuk saham INDF (Indofood), nilai RMSE minimum adalah 156.2976, epoch = 35, dan model layer 1 yaitu GRU-GRU-GRU-GRU.



Gambar 14. EPOCH-RMSE saham ASII

Untuk saham ASII (Astra Indonesia), nilai RMSE minimum adalah 134.5511, epoch = 20, dan model layer 1 yaitu GRU-GRU-GRU-GRU.



Gambar 15. EPOCH-RMSE saham TLKM

Untuk saham TLKM (TELKOM), nilai RMSE minimum adalah 71.6578, epoch = 35, dan model layer 5 yaitu GRU-LSTM-GRU-LSTM.

IV. HASIL PENELITIAN

Dari gambar karakteristik Epoch vs RMSE 5 data saham, dapat dengan mudah dilakukan proses prediksi dengan menggunakan nilai parameter epoch yang tepat dan memilih model layer tertentu sehingga diperoleh grafik prediksi terbaik, sebagai berikut :



Gambar 16. (a) Hasil tes dan prediksi BBKA

Hasil tes dan prediksi BBKA pada epoch 15 menghasilkan model dengan nilai RMSE terkecil yaitu 1120,651.



Gambar 17. (b) Hasil training, tes dan prediksi BBKA

Hasil tes training, tes dan prediksi BBKA jika ingin mendapatkan nilai RMSE yang kecil harus disetting pada epoch 15.




Gambar 18. (a) Hasil tes dan prediksi BBRI

Hasil tes dan prediksi BBRI pada epoch 25 menghasilkan model dengan nilai RMSE terkecil yaitu 110,330.



Gambar 19. (b) Hasil training, tes dan prediksi BBRI

Hasil training, tes dan prediksi BBRI dapat disetting pada epoch 25 untuk mendapatkan hasil RMSE terkecil.




Gambar 20. (a) Hasil tes dan prediksi INDF

Hasil tes dan prediksi INDF mendapatkan nilai RMSE terkecil 156,297 pada epoch ke 35.



Gambar 21. (b) Hasil training, tes dan prediksi INDF

Hasil training, tes dan prediksi INDF dapat mendapatkan hasil terbaik di epoch 35 dengan nilai RMSE 156,297.



Gambar 22. (a) Hasil tes dan prediksi ASII

Hasil tes dan prediksi ASII mendapatkan hasil RMSE 134,551 pada epoch 20.



Gambar 23. (b) Hasil training, tes dan prediksi ASII

Hasil training, tes dan prediksi ASII pada epoch 20 mendapatkan RMSE terkecil yaitu 134,551.



Gambar 24. (a) Hasil tes dan prediksi TLKM

Hasil tes dan prediksi TLKM pada epoch 35 menghasilkan nilai RMSE 71,657.



Gambar 25. (b) Hasil training, tes dan prediksi TLKM

Hasil training, tes dan prediksi TLKM mendapatkan nilai RMSE terkecil 71,657 pada epoch 35.

V. KESIMPULAN

1. Saham BCA dengan nilai RMSE terkecil yaitu 1120,651, epoch = 15, ada dalam empat susunan hidden layer sebagai berikut LSTM, GRU, LSTM, GRU.
2. Saham BBRI, nilai RMSE terkecil yaitu 110,331, epoch = 25, ada dalam empat susunan hidden layer sebagai berikut LSTM, GRU, LSTM, GRU
3. Saham INDF nilai RMSE terkecil yaitu 156,297, epoch = 35, ada dalam empat susunan hidden layer sebagai berikut GRU, GRU, GRU, GRU.
4. Saham ASII dengan nilai RMSE terkecil yaitu 134,551, epoch = 20, ada dalam empat susunan hidden layer sebagai berikut GRU, GRU, GRU, GRU.
5. Saham TLKM, dengan nilai RMSE terkecil yaitu 71,658, epoch = 35 ada dalam empat susunan hidden layer sebagai berikut GRU, LSTM, GRU, LSTM.

REFERENSI

- [1] A. C. Waluyo and M. T. Parasetya, "Pengaruh Manajemen Laba Terhadap Tingkat Oversubscription Pada Umkm Yang Melakukan Initial Public Offering Di Bursa Efek ...," *Diponegoro J.*, vol. 10, pp. 1–10, 2021.
- [2] A. Fernandez-perez, A. Gilbert, I. Indriawan, and N. H. Nguyen, "COVID-19 pandemic and stock market response: A culture effect," no. January, 2021.
- [3] F. J. Contractor, "The world economy will need even more globalization in the post-pandemic 2021 decade," *J. Int. Bus. Stud.*, 2021.
- [4] B. S. dan A. Fauzi, "IHSG Sempat Anjlok ke Level Paling Rendah," *Suara.com*, 2020. [Online]. Available: <https://www.suara.com/bisnis/2020/04/24/134110/gegara-corona-bos-bei-ihsg-sempt-anjlok-ke-level-paling-rendah>. [Accessed: 18-Jan-2021].
- [5] Tri Putra, "5 Saham Blue Chip Ini Tahan Kejatuhan IHSG," 2020. [Online]. Available: <https://www.cnbcindonesia.com/market/20200626153809-17-168348/terima-kasih-5-saham-blue-chip-ini-tahan-kejatuhan-ihsg>. [Accessed: 18-Jan-2021].
- [6] W. Hastomo and A. Satyo, "Kemampuan Long Short Term Memory Machine," vol. 4, no. September, pp. 229–236, 2020.
- [7] W. Hastomo and A. Satyo, "Long Short Term Memory Machine Learning Untuk Memprediksi Akurasi Nilai Tukar IDR Terhadap USD," vol. 3, 2019.
- [8] E. Islam, M. S., & Hossain, "Foreign exchange currency rate prediction using a GRU-LSTM Hybrid Network," *Soft Comput. Lett.*, vol. 100009, 2020.
- [9] N. Patel, M. M., Tanwar, S., Gupta, R., & Kumar, "A deep learning-based cryptocurrency price prediction scheme for financial institutions," *J. Inf. Secur. Appl.*, vol. 55, p. 102583, 2020.
- [10] M. A. T. Appati, J. K., Denwar, I. W., Owusu, E., & Soli, "Construction of an ensemble scheme for stock price prediction using deep learning techniques," *Int. J. Intell. Inf. Technol.*, vol. 17, no. 2, pp. 72–95, 2021.
- [11] L. M. Rasdi Rere, M. I. Fanany, and A. M. Arymurthy, "Metaheuristic Algorithms for Convolution Neural Network," *Comput. Intell. Neurosci.*, vol. 2016, 2016.
- [12] V. Ayumi, L. M. R. Rere, M. I. Fanany, and A. M. Arymurthy, "Optimization of convolutional neural network using microcanonical annealing algorithm," *2016 Int. Conf. Adv. Comput. Sci. Inf. Syst. ICACSIS 2016*, pp. 506–511, 2017.
- [13] K. Pearson, "Notes on Regression and Inheritance in the Case of Two Parents Proceedings of the Royal Society of London," vol. 58,

- pp. 240–242, 2015.
- [14] R. Conlin, K. Erickson, J. Abbate, and E. Kolemen, “Keras2c: A library for converting Keras neural networks to real-time compatible C,” *Eng. Appl. Artif. Intell.*, vol. 100, 2021.
 - [15] E. Sutanto, H. Abror, Y. Gita, Y. Yhuwana, and M. Aziz, “THRESHOLD VOLTAGE FOR DIGITAL RESIDUAL CURRENT CIRCUIT,” 2021.
 - [16] L. J. Tashman, “Out-of-sample tests of forecasting accuracy: An analysis and review,” *Int. J. Forecast.*, vol. 16, no. 4, pp. 437–450, 2000.
 - [17] P. Waldmann, G. Mészáros, B. Gredler, C. Fuerst, and J. Sölkner, “Evaluation of the lasso and the elastic net in genome-wide association studies,” *Front. Genet.*, vol. 4, no. DEC, 2013.
 - [18] W. Hastomo, A. S. Bayangkari Karno, N. Kalbuana, A. Meiriki, and Sutarno, “Characteristic Parameters of Epoch Deep Learning to Predict Covid-19 Data in Indonesia,” *J. Phys. Conf. Ser.*, vol. 1933, no. 1, p. 012050, 2021.
 - [19] P. W. Khan, Y. C. Byun, and N. Park, “IoT-blockchain enabled optimized provenance system for food industry 4.0 using advanced deep learning,” *Sensors (Switzerland)*, vol. 20, no. 10, pp. 1–24, 2020.
 - [20] L. Liu, R. C. Chen, and S. Zhu, “Impacts of weather on short-term metro passenger flow forecasting using a deep LSTM neural network,” *Appl. Sci.*, vol. 10, no. 8, 2020.
 - [21] X. Li, C. Wang, X. Huang, and Y. Nie, “A GRU-based Mixture Density Network for Data-Driven Dynamic Stochastic Programming,” pp. 1–11, 2020.
 - [22] C. Bai, “AGA-LSTM: An Optimized LSTM Neural Network Model Based on Adaptive Genetic Algorithm,” *J. Phys. Conf. Ser.*, vol. 1570, p. 012011, 2020.
 - [23] S. Hochreiter and J. Schmidhuber, “Long Short-Term Memory,” *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780, 1997.
 - [24] J. Chung, C. Gulcehre, K. Cho, and Y. Bengio, “Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling,” pp. 1–9, 2014.
 - [25] A. S. B. Karno, W. Hastomo, & Arif, D., and E. S. Moreta, “Optimasi Portofolio Dan Prediksi Cryptocurrency Menggunakandep Learning Dalam Bahasa Python,” vol. 4, no. September, 2020.