

Model Prediksi Harga Saham *Apple Inc* Pada Beberapa Bursa Efek Menggunakan Metode *Multivariate Gated Recurrent Unit*

Cecilia Tania Emanuella¹⁾, Armin Lawi²⁾, Hendra³⁾

^{1,2,3} Program Studi Sistem Informasi, Departemen Matematika, Fakultas MIPA, Universitas Hasanuddin

² Institut Teknologi B.J. Habibie

¹emanuella18h@student.unhas.ac.id, ²armin@unhas.ac.id, ²armin@ith.ac.id, ³hendra@unhas.ac.id

Abstrak

Saham menjadi salah satu instrumen pasar keuangan dan investasi yang banyak diminati oleh investor. Pergerakan harga saham yang nonlinear dan nonstasioner yang dipengaruhi oleh banyak faktor, sehingga sangat sulit untuk meramalkan harga saham. Salah satu metode yang cocok untuk digunakan dalam memprediksi harga saham yang bersifat nonlinear adalah *Recurrent Neural Network* (RNN). Penelitian ini menggunakan salah satu arsitektur RNN yaitu *Gated Recurrent Unit* (GRU) untuk memprediksi harga saham dengan menggunakan model *multivariate* GRU sebagai masukannya menggunakan harga *low*, *open*, *close*, *high* dan *volume* dalam memprediksi harga *low*, *open*, *close* dan *high*. Evaluasi kinerja yang digunakan untuk mengukur tingkat kesalahan prediksi adalah MAE, RMSE, MAPE dan RMSPE. Berdasarkan hasil MAE dan RMSE dari AAPL(*Nasdaq*), APC.F(*Frankfurt*) dan AAPL.MX(*Mexico*) memberikan hasil tingkat kesalahan yang bernilai kecil. Adapun berdasarkan hasil evaluasi MAPE dan RMSPE memberikan hasil yang sangat baik dengan masing – masing persentase kesalahan yang dihasilkan < 10%. Kemudian didapatkan hasil yang baik pada hasil evaluasi RMSPE prediksi data *train* pada AAPL.MX(*Mexico*) dengan masing – masing persentase kesalahan yang dihasilkan berada pada $10\% \leq \text{RMSPE} < 20\%$.

Keywords: Harga Saham, Prediksi, Multivariate GRU.

I. PENDAHULUAN

Dalam membentuk suatu perekonomian pada suatu negara, pasar modal merupakan salah satu komponen yang cukup penting. Di masa hingga saat ini kesadaran akan pentingnya perencanaan keuangan selalu meningkat dari tahun ke tahun. Salah satu bentuk perencanaan keuangan yang cukup populer adalah investasi. Investasi merupakan aktivitas menanam modal dengan harapan akan memberikan keuntungan pada masa depan. Saham menjadi salah satu instrumen pasar keuangan dan investasi yang banyak diminati oleh investor. Saham dikenal mampu memberikan tingkat keuntungan yang besar atau capital gain yang didapatkan dari selisih harga jual dan harga beli saham, tetapi risiko fluktuasi harga saham yang sangat cepat dapat mengakibatkan kerugian yang besar dalam waktu yang singkat.

Sampai saat ini berbagai penelitian yang bertujuan untuk memprediksi suatu kejadian di masa mendatang dengan tingkat akurasi tinggi masih terus dilakukan. Bagaimana meningkatkan akurasi prediksi harga indeks saham dianggap sebagai salah satu topik paling menarik di pasar saham [5]. Tidak ada yang pernah mengetahui dengan tepat apa yang akan terjadi di masa yang akan datang, namun manusia dengan kemampuan berpikirnya berusaha untuk dapat memperkirakan kejadian di masa depan dengan berbagai metode dan analisa untuk memperoleh tingkat kesalahan yang sekecil mungkin [9]. Prediksi deret waktu bertujuan untuk membangun model untuk mensimulasikan nilai masa depan yang diberikan dari nilai masa lalu.

Peramalan harga aset keuangan merupakan tantangan yang kompleks yang secara umum, harga saham ditentukan oleh jumlah variabel yang tidak terbatas. Salah satu metode yang cocok untuk digunakan dalam memprediksi harga saham yang bersifat nonlinear adalah *Recurrent Neural Network* (RNN) yang melakukan perulangan pada prosesnya. GRU memiliki 2 *sigmoid* dan 1 *tanh*, sedangkan LSTM memiliki 3 *sigmoid* dan 2 *tanh*. Karena kompleksitas tersebut, maka secara teori kemampuan latihan GRU lebih cepat [7]. Model *multivariate* mempertimbangkan beberapa faktor, model *multivariate* tidak dapat sepenuhnya menutupi kompleksitas pasar. Namun, hal ini menawarkan realitas yang lebih rinci daripada model *univariate*. Dengan demikian model *multivariate* cenderung memberikan prediksi yang lebih akurat dan berkinerja lebih baik daripada model *univariate* [12].

II. KAJIAN LITERATUR

A. Prediksi Stock / Saham

Prediksi adalah suatu proses memperkirakan tentang sesuatu yang mungkin terjadi di masa depan berdasarkan informasi masa lalu dan sekarang yang dimiliki. Prediksi dilakukan untuk mencari jawaban yang sedekat mungkin dengan apa yang akan terjadi [8].

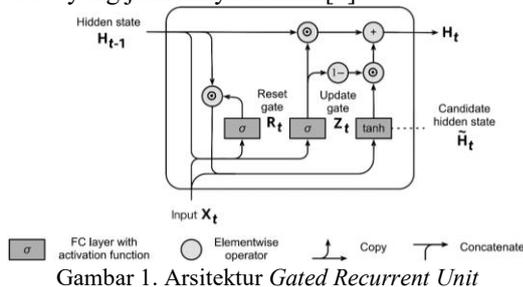
Saham merupakan surat berharga atau instrumen pasar keuangan yang menjadi bukti kepemilikan seseorang atas suatu perusahaan maupun badan usaha yang menanamkan modal pada suatu perusahaan penerbit [4]. Saham dikenal mampu memberikan tingkat keuntungan yang besar tetapi risiko fluktuasi harga saham yang sangat cepat dapat mengakibatkan kerugian yang besar dalam waktu yang singkat [1]. Pergerakan

harga saham cenderung nonlinear dan nonstasioner yang dipengaruhi oleh banyak faktor, sehingga sangat sulit untuk meramalkan harga saham [11]. Peramalan harga saham merupakan tantangan yang kompleks dan sulit untuk ditebak akan pergerakannya. Dalam memprediksi dapat dilakukan dengan tiga faktor yang mempengaruhi, yaitu faktor teknikal, faktor fundamental dan faktor sentiment [3].

Harga *low* dan *high*, masing-masing adalah pencapaian harga terendah dan tertinggi pada hari tersebut. Harga *open* dan *close* masing-masing adalah harga pembukaan dan penutupan pada hari tersebut. *Adjusted close* adalah harga penutupan setelah penyesuaian untuk semua pembagian dan pembagian dividen yang berlaku. *Volume* adalah banyaknya pertukaran yang diperdagangkan selama beberapa periode waktu, seringkali selama satu hari.

B. Gated Recurrent Unit (GRU)

Gated Recurrent Unit (GRU) merupakan turunan dari arsitektur *Recurrent Neural Network* (RNN). GRU adalah arsitektur yang diciptakan oleh Kyunghun Cho pada 2014 [2]. Tujuan utama dari pembuatan GRU adalah untuk membuat setiap recurrent unit untuk dapat menangkap *dependencies* dalam skala waktu yang berbeda-beda secara adaptif [13]. Serupa dengan LSTM, GRU juga menggunakan sistem gerbang, arsitektur GRU lebih sederhana daripada LSTM. GRU tidak menggunakan *cell state*, tetapi memanfaatkan *hidden state* untuk menyimpan informasi [6]. Di dalam GRU, komponen pengatur alur informasi tersebut disebut sebagai *gate* dan GRU mempunyai 2 *gate*, yaitu *reset gate* dan *update gate*. Banyaknya informasi dari *time step* terdahulu yang dapat dilupakan ditentukan pada *reset gate*. Sementara *update gate* akan menentukan seberapa banyak informasi dari *time step* terdahulu yang dapat disimpan untuk digunakan sebagai *input* untuk *time step* berikutnya. Kemampuan GRU dirancang untuk menjadi lebih baik dari LSTM terutama untuk dataset yang jumlahnya sedikit [7].



Gambar 1. Arsitektur Gated Recurrent Unit

Perhitungan pada *reset gate* diuraikan pada persamaan (1).

$$R_t = \sigma(X_t W_r + b_{xr} + H_{t-1} U_r + b_{hr}) \quad (1)$$

Perhitungan pada *update gate* diuraikan pada persamaan (2).

$$Z_t = \sigma(X_t W_z + b_{xz} + H_{t-1} U_z + b_{hz}) \quad (2)$$

Proses penentuan *candidate hidden state* diuraikan pada persamaan (3).

$$\tilde{H}_t = \tanh(X_t W_h + b_{xh} + R_t \odot (H_{t-1} U_h + b_{hh})) \quad (3)$$

Proses penghitungan *output* terakhir diuraikan pada persamaan (4).

$$H_t = Z_t \odot H_{t-1} + (1 - Z_t) \odot \tilde{H}_t \quad (4)$$

C. Metode Evaluasi Kinerja Model

Dalam metode pembelajaran machine learning dan *deep learning* evaluasi kinerja penting untuk dilakukan. Hal ini dilakukan karena ini bertujuan untuk mengukur tingkat akurasi kinerja suatu metode yang digunakan.

1) Mean Absolute Error (MAE)

Mean Absolute Error (MAE) adalah nilai mutlak (absolut) kesalahan rata-rata dari nilai sebenarnya dengan nilai prediksi. Rumus MAE diuraikan pada persamaan (5).

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (5)$$

2) Root Mean Square Error (RMSE)

Root Mean Square Error (RMSE) adalah jumlah dari kesalahan kuadrat kemudian membagi jumlah tersebut dengan banyaknya data dan kemudian menarik akarnya. Semakin kecil nilai RMSE mengindikasikan semakin baik performa dari model dalam memprediksi. Rumus RMSE diuraikan pada persamaan (6).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad (6)$$

3) Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) adalah ukuran akurasi dari suatu prediksi dengan menunjukkan nilai mutlak (absolut) dari persentase *error* data terhadap rata-rata. Rumus MAPE diuraikan pada persamaan (7).

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \times 100\% \quad (7)$$

Nilai evaluasi MAPE memiliki kriteria sebagai berikut [12]:

- MAPE < 10% :Kemampuan prediksi sangat baik.
- 10% ≤ MAPE < 20% :Kemampuan prediksi baik.
- 20% ≤ MAPE < 50% :Kemampuan prediksi cukup.
- MAPE ≥ 50% :Kemampuan prediksi buruk.

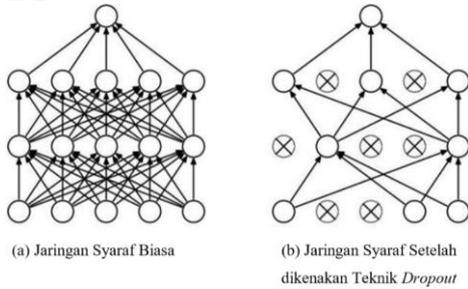
4) Root Mean Square Percentage Error (RMSPE)

Root Mean Square Percentage Error (RMSPE) adalah ukuran akurasi dari suatu prediksi dengan menunjukkan nilai kesalahan kuadrat dari persentase *error* terhadap rata-rata dan kemudian menarik akarnya. Rumus RMSPE diuraikan pada persamaan (8).

$$RMSPE = \sqrt{\frac{1}{n} \sum_{i=1}^n \left(\frac{Y_i - \hat{Y}_i}{Y_i} \right)^2} \times 100\% \quad (8)$$

D. Dropout

Dropout merupakan teknik regularisasi model jaringan syaraf tiruan untuk mengurangi *overfitting* dan juga mempercepat proses learning pada dataset. Metode ini secara acak melakukan *drop* neuron atau tidak digunakan pada jaringan selama proses *training*. Dengan melakukan *drop* pada neuron berarti, neuron yang dibuang tidak akan mengambil bagian dalam propagasi maju dan akan diberhentikan sementara dan bobot baru juga tidak diterapkan pada neuron pada saat melakukan propagasi mundur selama proses *training*. Contoh implementasi *dropout* dapat dilihat pada Gambar 2.



Gambar 2. Dropout

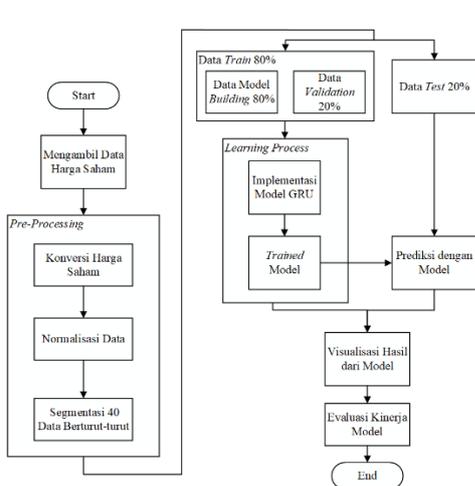
E. Normalisasi

Normalisasi data adalah proses membuat skala nilai pada variabel sehingga data berada pada rentang nilai yang sama. Tujuan dari normalisasi data adalah menghindari fitur yang memiliki nilai yang lebih besar mendominasi fitur yang memiliki nilai lebih kecil [13]. Metode normalisasi data yang digunakan dalam penelitian ini adalah Min-Max Scaling Normalization. Persamaan umum untuk scaling dalam rentang [0, 1] diuraikan pada persamaan (9).

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (9)$$

III. METODE PENELITIAN

Penelitian dimulai dari pengumpulan data, mengkonversi nilai harga saham ke dalam USD, *preprocessing* data, implementasi model pada dataset, *training* data, evaluasi kinerja model yang terlihat pada Gambar 3.



Gambar 3. Alur Penelitian

A. Preprocessing

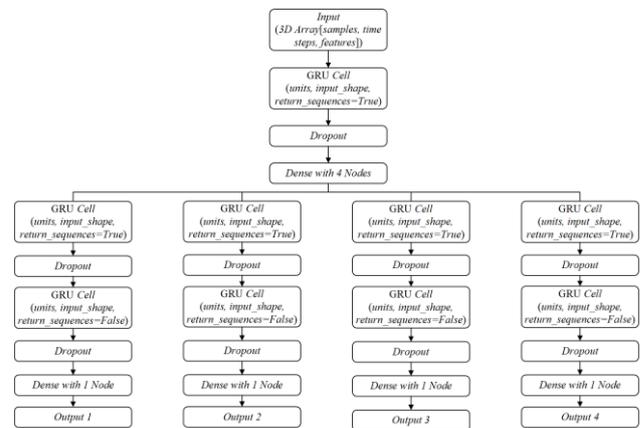
Pertama mengambil data saham dari Yahoo Finance di mana AAPL(Nasdaq) sebanyak 3046 data, APC.F(Frankfurt) sebanyak 3069 data dan AAPL.MX(Mexico) sebanyak 3035 data. Selanjutnya dilakukan konversi harga saham ke dalam USD untuk APC.F(Frankfurt) dan AAPL.MX(Mexico) dengan mengambil data EURUSD=X dan MXNUSD=X. Selanjutnya menormalisasi data dengan *rescaling* menjadi rentang 0-1. Kemudian melakukan segmentasi sebanyak 40 data berturut-turut untuk memprediksi data ke-41 dan seterusnya.

B. Split Data

Data dibagi menjadi tiga bagian yaitu data *train*, data *validation* dan data *test*. Masing-masing data *train*, data *validation* dan data *test* dibagi menjadi 80% data *train* dari total keseluruhan masing-masing data, data *validation* sebesar 20% dari total hasil data *train* dan 20% data *test* dari total keseluruhan masing-masing data.

C. Training Multivariate GRU

Sebelum melakukan proses pelatihan dan validasi pada model dilakukan inialisasi *hyperparameter* yang akan digunakan kemudian model akan terlebih dahulu dilatih menggunakan data *training* dan divalidasi menggunakan data *validation* untuk melihat kinerja model. Kemudian melakukan *testing* model terhadap data *test*. Pada penelitian ini *Multivariate GRU* model yang dibangun ini masing-masing *hidden layer* terdapat jumlah neuron dan fungsi aktivasi yang sama, awalnya dibangun dengan 1 *layer* dalam menggunakan 5 fitur dan *dense layer* pertama yang menghasilkan 4 *output* dari proses *training* dengan jumlah *cell units* sebanyak 4 kemudian dibangun dengan 2 *hidden layer* GRU. Kemudian *layer* terakhir yang digunakan adalah *dense layer* yang menghasilkan *output* masing-masing 1 dari 4 *output* dengan jumlah masing-masing *cell units* 1 yaitu *output* nilai harga saham pada hari selanjutnya. Arsitektur model dapat dilihat pada Gambar 4.



Gambar 4. Arsitektur Model

D. Evaluasi

Model yang telah dihasilkan akan dilakukan evaluasi terhadap data yang telah digunakan. Beberapa metode evaluasi yang digunakan pada model berupa hasil kinerja untuk masing-masing data saham seperti melihat *loss*, MAE, RMSE, MAPE dan RMSPE. Dari hasil evaluasi kinerja model ini akan ditentukan kelayakan model dalam melakukan prediksi data saham yang digunakan.

IV. HASIL DAN PEMBAHASAN

A. Deskripsi Data

Data yang digunakan dalam penelitian ini diambil langsung dari *website Yahoo Finance* menggunakan library *yfinance* dari Python. Semua data diambil dari 4 Januari 2010 – 7 Februari 2022. Data yang digunakan merupakan data numerik dan nilai semua harga saham dalam USD dengan menggunakan 5 variabel yaitu harga *low*, *open*, *close*, *high*, dan *volume*. Saham perusahaan Apple Inc dengan kode AAPL(*Nasdaq*) yang berjumlah 3046 data. Untuk kode saham APC.F(*Frankfurt*) sebanyak 3069 data dan AAPL.MX(*Mexico*) sebanyak 3035 data.

B. Preprocessing

1) Konversi Harga Saham

Konversi harga saham pada APC.F(*Frankfurt*) dengan mengambil data EURUSD=X dan AAPL.MX(*Mexico*) dengan mengambil data MXNUSD=X sehingga kedua data saham berada dalam satuan USD yang sama dengan AAPL(*Nasdaq*).

Tabel 1. Sebelum dan Sesudah Konversi Harga

| Date | Ticker | Low | Open | Close | High | Volume |
|------------|--------|------------|------------|------------|------------|--------|
| 2010-01-04 | APC.F | 5.251784 | 5.278571 | 5.301784 | 5.317856 | 209916 |
| 2010-01-05 | APC.F | 5.292857 | 5.307141 | 5.364284 | 5.364284 | 288148 |
| 2010-01-06 | APC.F | 5.232141 | 5.353570 | 5.264285 | 5.355357 | 151340 |
| 2010-01-07 | APC.F | 5.210713 | 5.253571 | 5.25 | 5.294641 | 171584 |
| 2010-01-08 | APC.F | 5.214284 | 5.258927 | 5.237500 | 5.307141 | 230132 |
| 2010-01-11 | APC.F | 5.150000 | 5.264285 | 5.167857 | 5.285714 | 236376 |
| 2010-01-12 | APC.F | 5.099999 | 5.164285 | 5.107141 | 5.166070 | 185108 |
| ... | ... | ... | ... | ... | ... | ... |
| 2022-02-04 | APC.F | 148.919998 | 153.0 | 151.479995 | 153.0 | 13210 |
| 2022-02-07 | APC.F | 149.5 | 150.720001 | 149.660003 | 152.0 | 6170 |
| ... | ... | ... | ... | ... | ... | ... |
| 2010-01-04 | APC.F | 7.490137 | 7.553657 | 7.647283 | 7.685318 | 209916 |
| 2010-01-05 | APC.F | 7.596275 | 7.656666 | 7.706309 | 7.769146 | 288148 |
| 2010-01-06 | APC.F | 7.477372 | 7.690918 | 7.582693 | 7.730241 | 151340 |
| 2010-01-07 | APC.F | 7.452394 | 7.566716 | 7.516966 | 7.648011 | 171584 |
| 2010-01-08 | APC.F | 7.441324 | 7.531259 | 7.547808 | 7.661419 | 230132 |
| 2010-01-11 | APC.F | 7.449409 | 7.614720 | 7.499212 | 7.693011 | 236376 |
| 2010-01-12 | APC.F | 7.374417 | 7.492832 | 7.393404 | 7.513410 | 185108 |
| ... | ... | ... | ... | ... | ... | ... |
| 2022-02-04 | APC.F | 169.968956 | 174.957118 | 173.228873 | 175.700504 | 13210 |
| 2022-02-07 | APC.F | 170.679645 | 172.644075 | 171.437738 | 174.192058 | 6170 |

2) Normalisasi Data

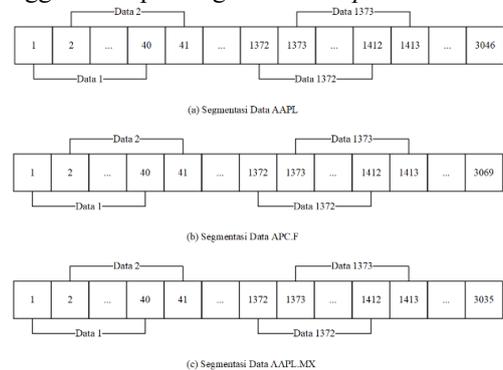
Pada Tabel 2 merupakan proses normalisasi data yang mentransformasi data sehingga berada pada rentang 0 sampai 1.

Tabel 2. Sebelum dan Sesudah Normalisasi

| Date | Ticker | Low | Open | Close | High | Volume |
|------------|--------|------------|------------|------------|------------|-----------|
| 2010-01-04 | AAPL | 7.585000 | 7.622500 | 7.643214 | 7.660714 | 493729600 |
| 2010-01-05 | AAPL | 7.616071 | 7.664286 | 7.656429 | 7.699643 | 601904800 |
| 2010-01-06 | AAPL | 7.526786 | 7.656429 | 7.534643 | 7.686786 | 552160000 |
| ... | ... | ... | ... | ... | ... | ... |
| 2022-02-03 | AAPL | 172.119995 | 174.479995 | 172.899993 | 176.240005 | 89418100 |
| 2022-02-04 | AAPL | 170.679993 | 171.679993 | 172.389999 | 174.100006 | 82391400 |
| 2022-02-07 | AAPL | 170.949997 | 172.860001 | 171.660004 | 173.949997 | 77251200 |
| ... | ... | ... | ... | ... | ... | ... |
| 2010-01-04 | AAPL | 0.004586 | 0.004279 | 0.004477 | 0.003755 | 0.246048 |
| 2010-01-05 | AAPL | 0.004766 | 0.004517 | 0.004553 | 0.003976 | 0.304839 |
| 2010-01-06 | AAPL | 0.004248 | 0.004472 | 0.003857 | 0.003903 | 0.277804 |
| ... | ... | ... | ... | ... | ... | ... |
| 2022-02-03 | AAPL | 0.959379 | 0.953629 | 0.947987 | 0.961918 | 0.026314 |
| 2022-02-04 | AAPL | 0.951022 | 0.937698 | 0.945076 | 0.949755 | 0.022535 |
| 2022-02-07 | AAPL | 0.952589 | 0.944412 | 0.940908 | 0.948903 | 0.019701 |

3) Segmentasi Data

Data dikelompokkan menjadi *time step* dengan panjang 40 data. Semakin panjang *time step* maka akan semakin bagus hasilnya karena model nantinya akan lebih banyak mempelajari pola data, tetapi membutuhkan waktu *training* yang lebih lama. *Time step* data input x sepanjang 40 data, yaitu x_1 sampai x_{40} kemudian x_{41} menjadi data prediksi. Langkah ini akan terus berulang hingga mencapai langkah *time step* terakhir.



Gambar 5. Segmentasi Data

C. Split Data

Adapun untuk pembagian data masing-masing data *train*, data *validation* dan data *test* dibagi menjadi 80% data *train* dari total keseluruhan masing-masing data, data *validation* sebesar 20% dari total hasil data *train* dan 20% data *test* dari total keseluruhan masing-masing data yang nantinya akan dilakukan prediksi dan akan dibandingkan dengan data aslinya.

Tabel 3. Komposisi Data Saham

| Ticker | Data Training (80%) | | Data Testing (20%) |
|---------|--|--|--|
| | Data Model Building (80%) | Data Validation (20%) | |
| AAPL | 3 Maret 2010 – 19 Oktober 2017 (1924 data) | 20 Oktober 2017 – 18 September 2019 (480 data) | 19 September 2019 – 7 Februari 2022 (602 data) |
| APC.F | 1 Maret 2010 – 16 Oktober 2017 (1939 data) | 17 Oktober 2017 – 16 September 2019 (484 data) | 17 September 2019 – 7 Februari 2022 (606 data) |
| AAPL.MX | 2 Maret 2010 – 20 Oktober 2017 (1917 data) | 23 Oktober 2017 – 20 September 2019 (479 data) | 23 September 2019 – 4 Februari 2022 (599 data) |

D. Modelling Multivariate GRU

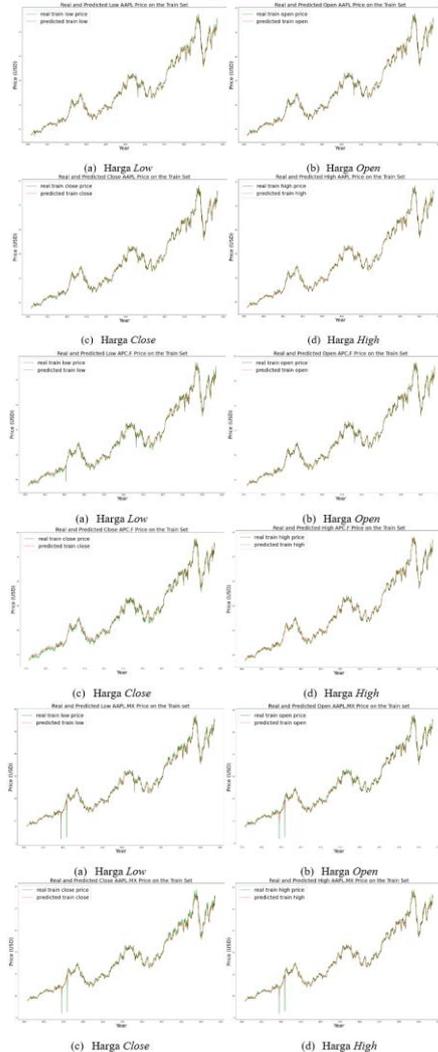
Model *multivariate GRU* yang dibangun masing-masing *hidden layer* terdapat jumlah neuron dan fungsi aktivasi yang sama. Awalnya dibangun dengan 1 *layer* dalam menggunakan 5 fitur yang terdiri dari 200 *units hidden* neuron dengan vektor *input* sepanjang 40 dan *dense layer* pertama yang menghasilkan 4 *output*. Kemudian masing-masing dibangun dengan 2 *hidden layer GRU* yang terdiri dari 200 *units* dan *dense layer* terakhir masing-masing 1 unit dari 4 *output*. Nilai *dropout* sebesar 0.5 dan untuk *hyperparameter* telah ditentukan yaitu *epoch* sebanyak 20, *batch size* sebesar 32, dan *optimizer* adam dengan *learning rate* sebesar 0.001.



Gambar 6. Arsitektur *Multivariate GRU*

E. Training Data

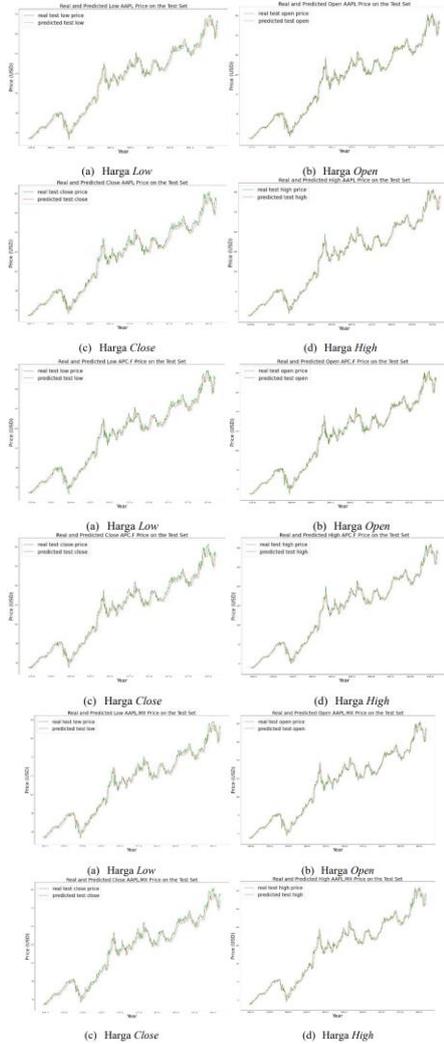
Pada Gambar 7 merupakan grafik visualisasi dari hasil prediksi data *training* model *Multivariate GRU* pada *AAPL(Nasdaq)*, *APC.F(Frankfurt)* dan *AAPL.MX(Mexico)* dengan harga *low*, *open*, *close* dan *high*. Masing-masing data asli diberi tanda dengan warna hijau dan data prediksi diberi tanda dengan warna merah. Dari hasil visualisasi dapat dilihat bahwa secara umum didapatkan hasil prediksi yang baik pada data *train* ditandai dengan hasil visualisasi hasil prediksi dan data asli yang tidak jauh berbeda.



Gambar 7. Visualisasi Hasil Prediksi Data *Training* pada *AAPL*, *APC.F* dan *AAPL.MX*.

F. Evaluasi

Model yang telah dihasilkan dari proses *training* dan *testing* akan dilakukan evaluasi terhadap data yang telah digunakan. Evaluasi model menggunakan ukuran kesalahan *MAE*, *RMSE*, *MAPE* dan *RMSPE*. Prediksi yang baik didasarkan pada tingkat kesalahan prediksi, semakin kecil tingkat kesalahan yang dihasilkan, semakin bagus juga sebuah metode dalam memprediksi.



Gambar 8. Visualisasi Hasil Prediksi Data *Testing* pada *AAPL*, *APC.F* dan *AAPL.MX*

Pada Gambar 8 menunjukkan visualisasi *testing* model *Multivariate GRU* yang menampilkan prediksi *AAPL(Nasdaq)*, *APC.F(Frankfurt)* dan *AAPL.MX(Mexico)*. Hasil prediksi model *Multivariate GRU* pada data *testing* masing – masing diberi tanda garis putus – putus. Berdasar grafik terlihat bahwa evaluasi cukup baik yang menunjukkan perbedaan yang tidak jauh berbeda dengan data aslinya.

Tabel 4. Evaluasi MAE dan RMSE

| | Data | Ticker | | |
|------|-------------|-------------|-------------|-------------|
| | | AAPL | APC.F | AAPL.MX |
| MAE | train_low | 0.535117583 | 0.525279143 | 1.37976721 |
| | test_low | 2.950743045 | 2.44789176 | 2.872564285 |
| | train_open | 0.468042059 | 0.457889047 | 0.508773596 |
| | test_open | 2.156732832 | 2.40699552 | 2.850556142 |
| | train_close | 0.554529818 | 1.178235997 | 1.115547695 |
| | test_close | 3.247700935 | 2.477131878 | 2.586399649 |
| | train_high | 0.461236854 | 1.108037301 | 0.676326153 |
| | test_high | 2.234525649 | 2.72095234 | 2.277557315 |
| RMSE | train_low | 0.751914802 | 0.759910652 | 1.549814078 |
| | test_low | 3.752270507 | 3.327937782 | 3.634294325 |
| | train_open | 0.662672606 | 0.650142028 | 0.82562949 |
| | test_open | 2.995079446 | 3.23613716 | 3.656359131 |
| | train_close | 0.75923608 | 1.343353762 | 1.323334971 |
| | test_close | 4.197950125 | 3.41140473 | 3.472154054 |
| | train_high | 0.657180989 | 1.25139677 | 0.954757669 |
| | test_high | 3.11063545 | 3.502633041 | 3.198769214 |

Nilai yang ditampilkan merupakan nilai yang telah dinormalisasi sehingga nilai MAE dan RMSE yang dihasilkan dapat diukur dengan data aslinya. Melalui tabel di atas, dapat disimpulkan bahwa kinerja *Multivariate* GRU dalam memprediksi harga saham sangat baik dengan hasil tingkat kesalahan yang bernilai kecil.

Tabel 5. Evaluasi MAPE dan RMSPE

| | Data | Ticker (%) | | |
|-------|-------------|-------------|-------------|-------------|
| | | AAPL | APC.F | AAPL.MX |
| MAPE | train_low | 2.051004512 | 2.214416013 | 7.077865312 |
| | test_low | 2.702350761 | 2.266907016 | 2.705764664 |
| | train_open | 1.990576544 | 1.873870718 | 2.403801432 |
| | test_open | 1.944610972 | 2.162497054 | 2.49574312 |
| | train_close | 2.300776411 | 5.663711628 | 5.750123546 |
| | test_close | 2.865677264 | 2.202838433 | 2.330661986 |
| | train_high | 1.833392226 | 4.856449484 | 3.495427063 |
| | test_high | 1.966771549 | 2.373113051 | 1.989815279 |
| RMSPE | train_low | 2.718375186 | 3.307788509 | 17.42632788 |
| | test_low | 3.371969553 | 3.158582703 | 3.447296775 |
| | train_open | 2.766247786 | 2.507899816 | 17.4681952 |
| | test_open | 2.719685585 | 2.894324054 | 3.097255841 |
| | train_close | 2.997158207 | 6.922272916 | 17.30781438 |
| | test_close | 3.556615984 | 3.016510539 | 3.073205274 |
| | train_high | 2.472925491 | 5.618875895 | 17.27868138 |
| | test_high | 2.670104418 | 2.971302483 | 2.744763251 |

Evaluasi MAPE dan RMSPE memberikan hasil yang sangat baik, dengan masing-masing persentase kesalahan yang dihasilkan < 10% dan persentase dari tiap data *train* dan *test* yang tidak jauh berbeda. Kemudian didapatkan hasil yang baik pada hasil evaluasi RMSPE prediksi data *train* AAPL.MX(*Frankfurt*) dengan masing-masing persentase kesalahan yang dihasilkan berada pada 10% ≤ RMSPE < 20%.

V. KESIMPULAN

Dari hasil penelitian berdasarkan hasil *training* dan *testing* dengan menggunakan 3046 data untuk AAPL(*Nasdaq*), 3069 data untuk APC.F(*Frankfurt*) dan 3035 untuk AAPL.MX(*Mexico*) menggunakan model *multivariate* GRU menunjukkan bahwa prediksi harga saham mendapatkan hasil yang sangat baik, hal ini berdasarkan hasil evaluasi MAE dan RMSE dengan hasil tingkat kesalahan yang bernilai kecil. Adapun berdasarkan hasil evaluasi MAPE dan RMSPE memberikan hasil yang sangat baik, hal ini ditunjukkan dengan masing – masing persentase kesalahan yang dihasilkan < 10% dan persentase

dari tiap data *train* dan *test* yang tidak jauh berbeda. Kemudian didapatkan hasil yang baik pada hasil evaluasi RMSPE prediksi data *train* pada AAPL.MX(*Mexico*) dengan masing – masing persentase kesalahan yang dihasilkan berada pada 10% ≤ RMSPE < 20% dalam memprediksi harga *low*, *open*, *close* dan *high*..

UCAPAN TERIMA KASIH

Semua pihak yang telah memberikan bantuan kepada penulis baik berupa materi dan non materi yang tidak dapat penulis sebutkan satu per satu, terima kasih untuk bantuan dan dukungannya.

REFERENSI

- [1] Arfan, A., & ETP, L. (2019). Prediksi harga saham di Indonesia menggunakan algoritma long short-term memory. *SeNTIK*, 3(1), 225–230.
- [2] Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder-decoder for statistical machine translation. *EMNLP 2014 - 2014 Conference on Empirical Methods in Natural Language Processing, Proceedings of the Conference*, 1724–1734. <https://doi.org/10.3115/v1/d14-1179>
- [3] Dwiyanto, M. A., Djamal, C. E., & Maspupah, A. (2019). Prediksi Harga Saham menggunakan Metode *Recurrent Neural Network*. *Seminar Nasional Aplikasi Teknologi Informasi (SNATI)*, 33–38.
- [4] Fauzi, A. (2019). Forecasting Saham Syariah Dengan Menggunakan Lstm. *Al-Masraf: Jurnal Lembaga Keuangan Dan Perbankan*, 4(1), 65. <https://doi.org/10.15548/al-masraf.v4i1.235>
- [5] Gao, P., Zhang, R., & Yang, X. (2020). The Application of Stock Index Price Prediction with Neural Network. *Mathematical and Computational Applications*, 25(3), 53. <https://doi.org/10.3390/mca25030053>
- [6] Ghudafa, M., Akbar, T., Panggabean, S., & Noor, M. (2022). *Perbandingan Prediksi Harga Saham Dengan Menggunakan LSTM GRU Dengan Transformer*. 11(1), 2020–2023.
- [7] Hastomo, W., Karno, A. S. B., Kalbuana, N., Nisfiani, E., ETP, L. (2021). Optimasi *Deep learning* untuk Prediksi Saham di ... (*Jurnal Edukasi Dan ...*, 7(2), 133–140. <https://jurnal.untan.ac.id/index.php/jepin/article/view/47411>
- [8] Herdianto. (2013). *Prediksi Kerusakan Motor Induksi Menggunakan Tesis Oleh Herdianto Fakultas Teknik. Fakultas Teknik, Universitas Sumatera Utara, Medan.*
- [9] Karno, A. S. B. (2020). Prediksi Data *Time series* Saham Bank BRI Dengan Mesin Belajar LSTM (Long ShortTerm Memory). *Journal of Informatic and Information Security*, 1(1), 1–8. <https://doi.org/10.31599/jiforty.v1i1.133>
- [10] Müller, F. (2020). *Stock Market Prediction using Multivariate Time series and Recurrent Neural Networks in Python*. <https://www.relatally.com/stock-market-prediction-using-Multivariate-time-series-in-python/>
- [11] Rochman, E. M. S., & Djunaidy, A. (2014). Prediksi Harga Saham Yang Mempertimbangkan Faktor Eksternal Menggunakan Jaringan Saraf Tiruan. *Jurnal Ilmiah NERO*, 1(2), 5–11.
- [12] Siringoringo, Z. (2021). *Prediksi Tingkat Inflasi Nasional Menggunakan Metode Gated Recurrent Unit*.
- [13] Wardana, R. P. (2020). Penerapan Model *Gated Recurrent Unit* Untuk Peramalan Jumlah Penumpang Kereta Api Di PT.KAI (Persero).