

Recurrent Neural Network With Gate Recurrent Unit For Stock Price Prediction

Recurrent Neural Network Dengan Gate Recurrent Unit Untuk Prediksi Harga Saham

Afif Ilham Caniago¹, Wilis Kaswidjanti², Juwairiah³

^{1, 2, 3} Informatika, Universitas Pembangunan Nasional Veteran Yogyakarta, Indonesia

¹afifilhamcaniago@gmail.com, ²wilis.kas@gmail.com, ³juwairiah@upnyk.ac.id

*corresponding author

Informasi Artikel

Received: August 2021

Revised: September 2021

Accepted: September 2021

Published: October 2021

Abstract

Stock price prediction is a solution to reduce the risk of loss from investing in stocks go public. Although stock prices can be analyzed by stock experts, this analysis is analytical bias. Recurrent Neural Network (RNN) is a machine learning algorithm that can predict a time series data, non-linear data and non-stationary. However, RNNs have a vanishing gradient problem when dealing with long memory dependencies. The Gate Recurrent Unit (GRU) has the ability to handle long memory dependency data. In this study, researchers will evaluate the parameters of the RNN-GRU architecture that affect predictions with MAE, RMSE, DA, and MAPE as benchmarks. The architectural parameters tested are the number of units/neurons, hidden layers (Shallow and Stacked) and input data (Chartist and TA). The best number of units/neurons is not the same in all predicted cases. The best architecture of RNN-GRU is Stacked. The best input data is TA. Stock price predictions with RNN-GRU have different performance depending on how far the model predicts and the company's liquidity. The error value in this study (MAE, RMSE, MAPE) constantly increases as the label range increases. In this study, there are six data on stock prices with different companies. Liquid companies have a lower error value than non-liquid companies.

Keywords: stock exchange; RNN ; GRU; Shallow, Stacked, Tecnical analysis, Chartist

Kata kunci: Saham; RNN; GRU; Shallow; Stacked; Tecnical analysis, Chartist

Abstrak

Prediksi harga saham merupakan solusi untuk mengurangi resiko kerugian dari investasi pada saham yang go public. Walaupun harga saham dapat dianalisis oleh para pakar saham, namun analisis ini bersifat bias analisis. Recurrent Neural Network (RNN) merupakan algoritma pembelajaran mesin yang dapat melakukan prediksi terhadap data saham yang bersifat time series , data non linear dan non stationary. Namun RNN mempunyai masalah vanishing gradient ketika berhadapan dengan data yang bersifat long memory dependency. Gate Recurrent Unit (GRU) mempunyai kemampuan dalam menangani data yang bersifat long memory depedency. Pada penelitian ini peneliti akan melakukan evaluasi pada parameter-parameter arsitektur RNN-GRU yang mempengaruhi prediksi dengan tolak ukur MAE, RMSE, DA, dan MAPE. Parameter arsitektur yang diuji adalah jumlah unit/neuron, hidden layer (Shallow dan Stacked) dan data input (Chartist dan TA). Jumlah unit terbaik tidak sama pada semua kasus prediksi. Arsitektur terbaik RNN-GRU adalah Stacked. Data input terbaik adalah TA. Prediksi harga saham dengan RNN-GRU memiliki performa yang berbeda beda tergantung berapa jauh model memprediksi dan liquiditas perusahaan. Nilai error pada penelitian ini (MAE, RMSE, MAPE) secara konstan naik seiring dengan bertambahnya rentang label. Pada penelitian ini terdapat enam data harga saham dengan perusahaan berbeda. Perusahaan liquid memiliki nilai error yang lebih rendah daripada perusahaan non liquid.

1. Pendahuluan

Saham merupakan surat berharga yang memberikan peluang keuntungan yang tinggi namun juga berpotensi risiko tinggi. Dengan fluktuasi harga saham yang tinggi, saham juga dapat membuat investor mengalami kerugian besar dalam waktu singkat [20]. Fluktuasi ini terjadi karena faktor-faktor ekonomi yang terjadi secara tiba-tiba dan susah diprediksi. Untuk itu investor membutuhkan sistem prediksi yang dapat membantu dalam mengambil keputusan investasi pembelian saham.

Data pada pergerakan harga saham memiliki tiga isu yaitu bersifat nonlinear, nonstationary, dan memiliki long memory dependency [4]. Pergerakan harga saham dipengaruhi berbagai hal namun faktor ekonomi, performa perusahaan dan psikologi pasar adalah faktor yang sangat berpengaruh. Hal ini membuat pergerakan saham bersifat nonlinear dan nonstationary [4]. Secara statistik para pakar saham menggunakan analisis teknikal dalam memprediksi harga saham. Namun teknik ini bersifat subjektif dan bias analisis karena analisis pakar satu dengan

yang lainnya dapat berbeda tergantung dari pengalaman dan pemilihan Technical Indicator yang digunakan [4].

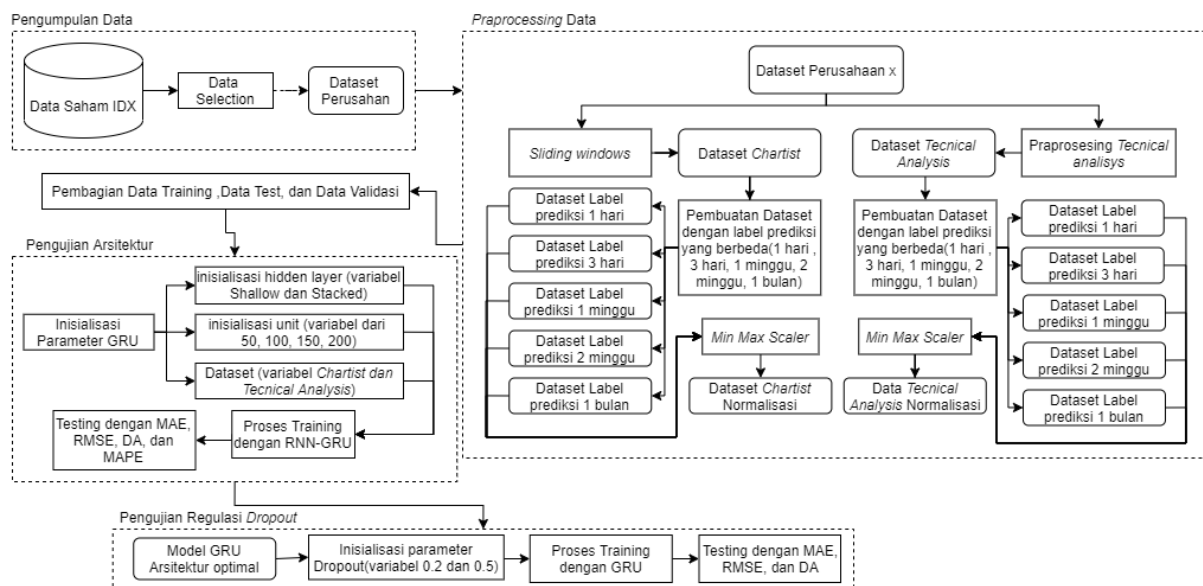
Data pergerakan harga saham merupakan data time series Sehingga membuat adanya keterikatan pengaruh data masa lampau secara beruntun. Pendekatan komputasional telah banyak dilakukan dalam memprediksi pergerakan harga saham. [14] membandingkan metode Autoregressive Integrated Moving Average (ARIMA), Artificial Neural Network (ANN) dan hybrid ANN-ARIMA dengan dua dataset berbeda yaitu ASPI dan SL20 dengan hasil pada dataset ASPI adalah MAE ARIMA sebesar 62,7512 ,MAE ANN sebesar 36,9834 ,MAE ANN-ARIMA sebesar 21,2208 dan dataset SL20 adalah MAE ARIMA sebesar 28,8660 ,MAE ANN sebesar 19,8767 ,MAE ANN-ARIMA sebesar 14,1000. Rata-rata performa akurasi yang menggunakan metode T-test adalah ANN (75,74%) lebih baik ketimbang SVM (71,52%) [9]. ANN merupakan metode yang sering dipakai ketika menghadapi data yang bersifat nonlinear dan nonstationary. [13] mengatakan ANN dapat digunakan untuk memprediksi data time series yang tidak beraturan (non linear). ANN dapat memprediksi data yang mempunyai dimensi data yang tinggi dan dapat mempelajari fluktuasi dari data yang nonlinear dan nonstationary [6].

Salah satu model dari ANN yang cukup populer dalam prediksi dan klasifikasi data time series adalah Recurrent Neural Networks (RNN). RNN cocok dipakai pada dataset yang bersifat time series karena model ini memiliki kemampuan dalam mempelajari data sequence di mana output jaringan bergantung pada jumlah yang berubah ubah dari input sebelumnya. RNN dapat menjadi model yang berguna untuk membuat prediksi deret waktu yang tidak beraturan, terutama dalam membuat prediksi multi-step [7]. Namun RNN memiliki kelemahan dalam menghadapi prediksi dengan frame waktu yang cukup panjang yang mana permasalahan ini lebih dikenal dengan long memory dependency. Karena RNN akan mengalami permasalahan yang dinamakan Vanishing Gradient dan Gradient Exploding apabila RNN menangani masalah prediksi dengan panjang range waktu yang panjang [19]. Gated Recurrent Unit (GRU) datang sebagai pengembangan lebih lanjut dari unit RNN konvensional yang memiliki kemampuan dalam menangani kasus prediksi dan klasifikasi tanpa adanya permasalahan Vanishing Gradient dan Gradient Exploding [19]. GRU merupakan unit RNN yang merupakan sebuah model machine learning merupakan pengembangan dari unit Long Short Term Memory (LSTM). GRU merupakan penyederhanaan dari LSTM yang berupa pengurangan gate dan parameter untuk mempercepat waktu pelatihan dan mempermudah implementasi [1].

Dari permasalahan tersebut maka dapat dirancang sebuah model machine learning dengan menggunakan metode Recurrent Neural Networks dengan unit Gated Recurrent Unit (RNN-GRU) dengan melakukan evaluasi terhadap beberapa parameter baik dari sisi data maupun dari sisi model dengan harapan model GRU dapat melakukan prediksi terhadap pergerakan harga saham dengan error yang rendah.

2. Metode

Pada penelitian ini terdapat empat tahapan utama yaitu pengumpulan data, Pra processing data, Pengujian Arsitektur, dan pengujian regulasi dropout. Ilustrasi dari metode penelitian ini terdapat pada Gambar 1. Berikut adalah tahapan dari penelitian ini.



Gambar 1. Metodologi Penelitian

2.1. Pengumpulan Data

Data yang dipakai pada penelitian ini didapatkan dari website Stock Exchange Indonesia (IDX) (<https://www.idx.co.id/data-pasar/ringkasan-perdagangan/ringkasan-saham/>). Data yang diambil merupakan data dengan rentang dari tahun 2015 sampai tahun 2019. Data yang diambil berupa data harga saham harian. Fitur yang diperlukan pada penelitian ini adalah harga pembuka (open), harga tertinggi (high), harga terendah (low), harga penutupan (close), dan Volume yang disingkat OHLCV.

Tabel 1. Daftar Dataset yang digunakan

Sektor	Saham	Quote
Mining	PT. Adaro Energy Tbk	ADRO
	PT. Vale Indonesia Tbk	INCO
Miscellaneous	PT. Astra International Tbk	ASII
	PT. Indomobil Sukses Internasional Tbk	IMAS
Infrastructure	PT. Telekomunikasi Indonesia (Persero) Tbk	TLKM
	PT. Garuda Indonesia (Persero) Tbk	GIAA

Dataset yang dipakai dipilih berdasarkan dua jenis saham berdasarkan tingkat liquiditas yang berbeda yaitu tinggi dan rendah. Dataset yang dipakai dipilih berdasarkan dua jenis saham berdasarkan tingkat liquiditas yang berbeda yaitu tinggi dan rendah. Liquiditas adalah kemampuan suatu perusahaan dalam melunasi hutang atau bisa diartikan kualitas kinerja suatu perusahaan. Dataset berasal dari tiga sektor yang berbeda yang terdaftar pada Jakarta Stock Industrial Classification (JASICA). Tabel 1 adalah daftar perusahaan yang akan diujikan dengan highlight biru adalah saham dengan Liquid dan yang tidak di-highlight adalah saham Non-Liquid.

2.2. Data Preprocessing

Ada dua bentuk dataset yang akan diujikan pada penelitian ini yaitu data dengan bentuk Technical Analysis (TA) dan Chartist. Dataset TA akan menggunakan 10 Teknikal Indicator


(TI). Indikator teknis (Tecnikal Indicator) berguna dalam memprediksi kecenderungan arah pergerakan saham. Data input TA juga diterapkan pada penelitian [9] dan [4]. Tecnikal Indicator ini merupakan nilai-nilai yang dipakai oleh para broker saham ketika melakukan analisis saham. Terdapat 10 Tecnikal Indicator yang akan digunakan seperti yang tertampil di Tabel 2 yang merujuk pada penelitian [9]. Pada Tabel 2 terdapat parameter validasi yang harus ditetapkan untuk menghitung nilai Tecnikal Indicator yang akan digunakan. Dasar pemilihan nilai parameter pada TA dirujuk dari penelitian [4]. Chartist adalah metode proses analisis saham yang hanya melihat dari fitur dasar yaitu harga pembuka (opening) , harga terendah (low) , harga tertinggi (high) dan harga penutupan (close) (OHLC) [4]. Chartist merupakan data mentah pergerakan harga saham.

Tabel 2. Parameter *Technical Analysis*

No	Technical Analysis	Validasi
1	Simple 10-day Moving Average(SMA10)	Time period = 10
2	Weighted 10-day Moving Average(WMA10)	Time period = 10
3	Momentum (M)	Time period = 10
4	Stochastic K% (K%)	K period = 5
5	Stochastic D% (D%)	D period=3
6	Relative Strength Index (RSI)	Time Period =14
7	Moving Average Convergence Divergence(MACD)	Fast period = 12 Slow Period =26
8	Larry William's R% (R%)	Time Period = 14
9	Accumulation / Distribution Oscillator (A/D)	Time Period = 10
10	Commodity Channel Index (CCI)	Time Period = 14

Dalam tahapan ini kegiatan yang dilakukan adalah menganalisis kebutuhan untuk membuat sistem informasi manajemen notulensi. Yang pertama adalah proses analisis dengan dasar hasil wawancara yang sudah dilakukan dengan bagian monitoring dan evaluasi (monev) CV. Sinergi Telematika Yogyakarta.

Praprocessing data pada setiap bentuk dataset (TA atau Chartist) akan dilakukan dengan 3 tahapan yang sama yaitu pembentukan dataset, pelabelan dan min max scaler. Pembentukan dataset pada dataset TA dan chartist berbeda. Dataset TA akan didapatkan dengan mengubah data OHLCV menjadi Tecnikal Indicator melalui rumus yang tertera diaatas. Dataset TA akan diimplementasikan menggunakan library python ta-lib (<https://github.com/mrjbq7/ta-lib>). Dataset Chartist akan menerapkan proses sliding window yaitu proses agar dataset mentah harga saham memiliki suatu time step tertentu. Ilustrasi data yang di terapkan sliding window terdapat pada Gambar 2.



Gambar 2. Ilustrasi Sliding Window

Pada penelitian ini terdapat lima label berbeda yang akan diuji satu persatu. Lima label tersebut adalah time period atau rentang jauh prediksi yaitu 1 hari, 3 hari, 1 minggu, 2 minggu, dan 1 bulan. Apabila dataset dilabeli 1 minggu maka nilai aktual pada suatu dataset adalah 1 minggu kedepan dari satu set data. setelah diberi label kemudian data akan dinormalisasi dengan min max scaler agar setiap fitur tidak terlalu sensitif terhadap satu fitur tertentu.

2.3. Proses Partisi Data

Proses sebelum melakukan proses uji arsitektur RNN-GRU yaitu pembagian dataset. Dataset akan dibagi kedalam tiga bagian yaitu training, validation, dan testing. Panduan baku dalam menentukan jumlah partisi data ini belum mempunyai aturan baku. Menurut [10] partisi yang paling sering dipakai adalah 70% data training dan 30% data testing. Pada penelitian ini akan menggunakan 70% data training, 10% data validasi, dan 20% data testing. Data training merupakan data yang akan dilatih didalam jaringan. Data validation adalah data uji dalam training, data ini akan dilatih ketika data training sudah dilatih terlebih dahulu. Data testing adalah data yang digunakan untuk menguji model. Berikut rumus *min max scaler*:

$$x_{scaled} = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (1)$$

Keterangan: x = data

2.4. Gated Recurrent Unit (GRU)

Gated Recurrent Unit (GRU) adalah model RNN yang telah dikembangkan dalam mengatasi masalah long memory dependency ketika menghadapi data dengan frame waktu yang panjang karena RNN akan mengalami Vanishing Gradient ketika melakukan BTT [21]. Pada Gambar 3 terlihat bagaimana implementasi GRU pada RNN. GRU merupakan pengembangan dari metode Long Short Term Memory (LSTM). Kelebihan dari GRU adalah bobot dan parameter yang di latih lebih sedikit dari LSTM sehingga kecepatan pelatihan model lebih cepat dari pada LSTM dan implementasi GRU yang lebih sederhana dari LSTM [17]. Bobot latih dan parameter GRU lebih sedikit daripada LSTM karena Gate GRU lebih sedikit daripada LSTM. LSTM memiliki tiga gerbang yaitu forget gate(f_t), input gate(i_t), dan output gate(O_t). GRU menggabungkan gerbang forget dan input menjadi update gate (z). Gerbang kedua dari GRU adalah reset gate (r). Apabila output yang dihasilkan LSTM ada dua nilai yaitu hidden state dan cell state maka Output dari GRU hanya satu yaitu hidden state [2]. Ilustrasi gerbang GRU terdapat pada Gambar 2. Berikut persamaan pada gerbang-gerbang GRU:

$$z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z) \quad (2)$$

$$r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \quad (3)$$


$$\tilde{h}_t = \tanh(W_h x_t + U_h (r_t \odot h_{t-1}) + b_h) \quad (4)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (5)$$


Keterangan :

z_t	= update gate	W_z	= bobot update yang terkoneksi dengan input
r_t	= reset gate	W_r	= bobot reset yang terkoneksi dengan input
\tilde{h}_t	= candidates value	W_h	= bobot candidates yang terkoneksi dengan input
h_t	= output atau hidden state		
h_{t-1}	= output dari state	U_z	= bobot update yang terkoneksi dengan output

	Sebelumnya	sebelumnya
σ	= <i>sigmoid</i>	U_r = bobot <i>reset</i> yang terkoneksi dengan output sebelumnya
\tanh	= fungsi aktivasi <i>tanh</i>	U_h = bobot <i>candidates</i> yang terkoneksi dengan output sebelumnya
x_t	= input	b_r = bias <i>reset</i>
h_{t-1}	= output sebelumnya	b_h = bias <i>candidates</i>
b_z	= bias <i>update</i>	



Gambar 2. Arsitektur Modul GRU



Gambar 3. Arsitektur RNN-GRU

2.5. Pengujian Arsitektur

Pengujian arsitektur mempunyai tujuan untuk menemukan arsitektur atau hyperparameter terbaik yang dapat memprediksi harga saham dengan tepat. Pengujian arsitektur menggunakan tiga parameter yaitu banyaknya unit GRU di hidden layers (50, 100, 150, dan 200), Hidden layer (Shallow dan Stacked) dan Data Input (Chartist dan TA). Shallow adalah arsitektur RNN-GRU satu layer. Stacked adalah arsitektur RNN-GRU lebih dari satu layer dengan arah time step yang sama dengan layer sebelumnya. Pada penelitian ini arsitektur stacked mempunyai 2 layer. Sebelum membandingkan tiga hyperparameter (banyak Unit, Hidden Layer, dan Data input) tersebut, jaringan ANN mempunyai parameter lainnya yang harus diinisialisasi terlebih dahulu diantaranya seperti pada Tabel 3. Tolak ukur kemampuan model akan diukur dengan empat nilai yaitu Mean Absolute Error (MAE), Root Mean Squared Error

(RMSE), Directional Accuracy (DA), dan Mean Absolute Percentage Error (MAPE). Pengujian dilakukan dengan tahapan inialisasi hyperparameter tetap seperti Tabel 3, kemudian hyperparameter yang diujikan akan dinisiasi, lalu dilakukan proses training. Training akan dilakukan dengan kombinasi hyperparameter yang diujikan. Setiap kombinasi hyperparameter akan diujikan dengan lima label yang berbeda dan unit GRU yang berbeda. Perbandingan pada penelitian akan dibagi lima bagian sesuai dengan jumlah label sehingga label yang berbeda tidak dapat dibandingkan. Setelah melakukan training, data testing dan hasil prediksi harus melewati proses Denormalisasi. Denormalisasi adalah proses mengembalikan nilai-nilai yang sudah di praprocessing kembali menjadi nilai-nilai sebelum di praprocessing. Pada penelitian ini praprocessing yang merubah nilai dataset adalah Min Max Scaler. Proses Denormalisasi untuk praprocessing Min Max Scaler adalah membalik rumus Min Max Scaler.

Tabel 3. Parameter RNN-GRU tetap

No	Parameter	Validasi
1	Unit layer output	1
2	Fungsi aktivasi output	Sigmoid
3	<i>Epoch</i>	300
4	Optimasi <i>gradient descent</i>	ADAM
5	<i>Batch</i>	252
6	<i>Loss function</i>	MAE

2.6. Pengujian Dropout

Dropout merupakan regulasi untuk menghindari overfitting. Metode ini diimplementasikan dengan menambahkan layer diantara 2 hidden layer yang mana layer ini akan mematikan neuronnya agar jaringan tersebut terputus. Layer Dropout berada diantara Hidden layer. Berapa banyak neuron yang mati akan ditentukan dengan parameter yang diberikan. Parameter yang akan diujikan adalah (0,2) dan (0,5). Untuk penentuan parameter dropout belum ada ketentuan khusus sampai sekarang. Pengujian Dropout hanya akan menguji model terbaik dari setiap pengujian arsitektur. Dropout akan diujikan pada model dengan unit terbaik pada setiap model dengan arsitektur hidden layer dan data input yang berbeda.

3. Hasil dan Pembahasan

Hasil pada penelitian ini akan dijabar secara terpisah sesuai label dan penerapan regulasi dropout akan dijelaskan secara terpisah. Pengujian model RNN-GRU telah dilakukan dengan jumlah unit (50, 100, 150, 200) pada setiap model dengan kombinasi arsitektur hidden layer dan data input yang berbeda. Nilai MAE terbaik akan menjadi tolak ukur utama dalam memilih model dengan jumlah unit terbaik. Setelah diuji, model dengan jumlah unit terbaik akan dipilih dan dibandingkan dengan model lainnya pada perusahaan yang sama untuk diukur Arsitektur hidden layer dan data input apa yang terbaik. Pada perbandingan perusahaan, nilai MAPE yang dibandingkan adalah nilai MAPE terendah pada hasil perbandingan arsitektur hidden layer dan data input.

3.1. Label 1 Hari

Tabel 4 adalah daftar model dengan nilai pengujian (MAE, RMSE, DA, MAPE) terbaik pada jumlah unit di setiap perusahaan, arsitektur, dan data input dengan label 1 hari.

Tabel 4. Nilai metode pengujian jumlah unit GRU terbaik

Perusahaan	Arsitektur	Input Data	MAE	RMSE	DA	MAPE
PT. Adaro Energy (ADRO)	Shallow	Chartist	31,27234043	42,3238276	52,99145299	2,36199423
		TA	42,14529915	47,04108043	92,70386266	3,326586746
	Staked	Chartist	29,26382979	39,45193682	51,28205128	2,222242485
		TA	11,04700855	14,84406123	93,13304721	0,836404594
PT. Vale Indonesia (INCO)	Shallow	Chartist	79,76595745	100,0542619	53,84615385	2,379707896
		TA	33,65811966	46,53038709	92,70386266	1,005798504
	Staked	Chartist	79,54468085	99,3062103	55,12820513	2,373679919
		TA	29,63675214	41,81833933	93,56223176	0,890396625
PT. Astra International Tbk (ASII)	Shallow	Chartist	106,5276596	137,6830773	50,85470085	1,493366786
		TA	56,33760684	67,50508053	96,99570815	0,809927247
	Staked	Chartist	103,8212766	136,1219103	51,70940171	1,45395854
		TA	47,37179487	60,50482074	97,85407725	0,677825422
PT. Indomobil Sukses Internasional Tbk (IMAS)	Shallow	Chartist	62,05957447	85,332541	55,98290598	3,28997247
		TA	82,72649573	109,2502812	93,13304721	4,1608269
	Staked	Chartist	58,78297872	79,42307934	55,55555556	3,276845625
		TA	61,71794872	98,23902475	92,27467811	2,967832934
PT. Telekomunikasi Indonesia (Persero) Tbk (TLKM)	Shallow	Chartist	48,9234043	63,6199821	50,0000000	1,2229222
		TA	20,1068376	28,1459110	97,8540773	0,5114257
	Staked	Chartist	48,0382979	61,9451714	50,4273504	1,1971767
		TA	14,6880342	19,1852196	98,2832618	0,3681199
PT. Garuda Indonesia (Persero) Tbk (GIAA)	Shallow	Chartist	16,65106383	23,25611336	55,12820513	3,437270465
		TA	10,84615385	14,27208141	90,55793991	2,20413261
	Staked	Chartist	15,74893617	22,21471623	57,69230769	3,28413903
		TA	10,54273504	13,57111689	90,55793991	2,161819392

Pada Tabel 4 dapat diamati nilai error (MAE, RMSE, MAPE) memiliki nilai terendah pada model arsitektur Stacked dengan data input TA. Nilai DA tertinggi terdapat pada arsitektur Stacked dengan data input TA. Namun pada satu kasus pada perusahaan IMAS nilai error terbaik terdapat model dengan Staked dengan data input chartist.

3.2. Label 3 Hari

Berikut adalah daftar model dengan nilai pengujian terbaik pada jumlah unit setiap perusahaan, arsitektur, dan data input dengan label 3 hari.

Tabel 5. Nilai metode pengujian jumlah unit GRU terbaik

Perusahaan	Arsitektur	Input Data	MAE	RMSE	DA	MAPE
PT. Adaro Energy (ADRO)	Shallow	Chartist	52,02978723	67,30163919	55,98290598	3,922477447
		TA	49,61802575	63,31042805	50	3,778974184
	Staked	Chartist	51,47234043	66,0863394	58,11965812	3,917572553
		TA	41,39484979	52,28795313	50,86206897	3,153169922
PT. Vale Indonesia (INCO)	Shallow	Chartist	134,3744681	167,3780534	54,27350427	4,023522226
		TA	110,4206009	133,6914005	46,55172414	3,328201546
	Staked	Chartist	130,2723404	162,3774431	53,84615385	3,897615474
		TA	110,7896996	134,2477691	48,70689655	3,328168893

Tabel 5. Nilai metode pengujian jumlah unit GRU terbaik

Perusahaan	Arsitektur	Input Data	MAE	RMSE	DA	MAPE
PT. Astra International Tbk (ASII)	Shallow	Chartist	170,0170213	213,4413468	57,26495726	2,391842721
		TA	143,5407725	185,8539161	53,01724138	2,01624146
	Staked	Chartist	161,5489362	200,3794486	56,41025641	2,269776827
		TA	144,6609442	187,3124584	50,86206897	2,033067936
PT. Indomobil Sukses Internasional Tbk (IMAS)	Shallow	Chartist	94,65531915	126,505504	57,26495726	4,715869682
		TA	124,2746781	155,9491499	55,17241379	5,688410128
	Staked	Chartist	96,74468085	126,0395244	56,41025641	4,89187878
		TA	84,49785408	113,286109	53,87931034	4,145833272
PT. Telekomunikasi Indonesia (Persero) Tbk (TLKM)	Shallow	Chartist	74,81702128	93,53260895	55,12820513	1,862017228
		TA	65,12446352	85,2182253	47,84482759	1,621279977
	Staked	Chartist	74	91,881098	53,84615385	1,844086939
		TA	62,7639485	81,07586655	49,56896552	1,565438868
PT. Garuda Indonesia (Persero) Tbk (GIAA)	Shallow	Chartist	24,83404255	33,13582621	55,98290598	5,199395772
		TA	22,02575107	28,79154025	55,17241379	4,61629905
	Staked	Chartist	24,43829787	33,0101854	56,41025641	5,120791546
		TA	21,89699571	28,35686139	56,46551724	4,618997971

Pada Tabel 5 dapat diamati nilai error (MAE, RMSE, MAPE) memiliki nilai terendah pada model arsitektur Staked dengan data input TA. Namun pada perusahaan INCO dan ASII perbedaan arsitektur tidak berpengaruh. Nilai DA tertinggi tidak memiliki arsitektur spesifik maupun data input spesifik yang mempengaruhinya.

3.3. Label 1 Minggu

Berikut adalah daftar model dengan nilai pengujian terbaik pada jumlah unit setiap perusahaan, arsitektur, dan data input dengan label 1 minggu.

Tabel 6. Nilai metode pengujian jumlah unit GRU terbaik

Perusahaan	Arsitektur	Input Data	MAE	RMSE	DA	MAPE
PT. Adaro Energy (ADRO)	Shallow	Chartist	89,63247863	110,7637819	52,78969957	6,879468495
		TA	79,83261803	102,7559925	53,87931034	6,028573436
	Staked	Chartist	84,1025641	106,958495	52,78969957	6,392296868
		TA	75,59656652	96,73054473	51,72413793	5,742310919
PT. Vale Indonesia (INCO)	Shallow	Chartist	183,7863248	227,3926158	49,35622318	5,574260114
		TA	178,9484979	220,4957641	51,29310345	5,401855334
	Staked	Chartist	179,6282051	225,2256134	52,36051502	5,151144294
		TA	181,1416309	220,8217	53,87931034	5,468198351
PT. Astra International Tbk (ASII)	Shallow	Chartist	248,034188	309,7636954	57,08154506	3,494792462
		TA	231,3218884	287,984844	52,15517241	3,256202421
	Staked	Chartist	243,9273504	302,9480577	57,51072961	3,444700366
		TA	231,695279	292,5371258	51,29310345	3,260423553
PT. Indomobil Sukses Internasional Tbk (IMAS)	Shallow	Chartist	160,1495726	204,1555779	58,79828326	7,963986993
		TA	152,3562232	186,7822284	56,46551724	7,201708974
	Staked	Chartist	158,4487179	202,699759	58,36909871	7,749394369
		TA	141,9399142	172,6151789	56,46551724	6,83669892
PT. Telekomunikasi	Shallow	Chartist	100,6196581	127,4812036	54,93562232	2,512731174

Tabel 6. Nilai metode pengujian jumlah unit GRU terbaik

Perusahaan	Arsitektur	Input Data	MAE	RMSE	DA	MAPE
Kasi Indonesia (Persero) Tbk (TLKM)	Staked	TA	93,45922747	121,8278177	53,44827586	2,326569391
		Chartist	97,78205128	122,6954572	55,36480687	2,435960731
		TA	89,87124464	117,0158274	52,15517241	2,242305893
PT. Garuda Indonesia (Persero) Tbk (GIAA)	Shallow	Chartist	35,41452991	48,60537939	57,51072961	7,381074637
		TA	34,85407725	47,90185782	59,05172414	7,233046732
	Staked	Chartist	35,79487179	48,70002369	62,23175966	7,498768507
		TA	34,74678112	46,03199111	59,05172414	7,34561767

Pada Tabel 6 dapat diamati nilai error (MAE, RMSE, MAPE) memiliki nilai terendah pada model arsitektur Stacked dengan data input TA pada empat perusahaan yaitu ADRO, IMAS, TLKM, dan GIAA. Nilai DA tertinggi pada empat perusahaan yaitu INCO, ASII, TLKM, dan GIAA dengan arsitektur Stacked. DA tertinggi pada empat perusahaan yaitu ASII, IMAS, TLKM, dan GIAA dengan data input.

3.4. Label 2 Minggu

Berikut adalah daftar model dengan nilai pengujian terbaik pada jumlah unit setiap perusahaan, arsitektur, dan data input dengan label 2 minggu.

Tabel 7. Nilai metode pengujian jumlah unit GRU terbaik

Perusahaan	Arsitektur	Input Data	MAE	RMSE	DA	MAPE
PT. Adaro Energy Tbk (ADRO)	Shallow	Chartist	129,167382	164,0141049	52,5862069	9,963823336
		TA	112,4112554	145,7687637	54,7826087	8,505994893
	Staked	Chartist	129,6266094	163,4686908	55,60344828	10,0181909
		TA	120,6103896	152,8833554	52,17391304	9,322231685
PT. Vale Indonesia Tbk (INCO)	Shallow	Chartist	222,27897	269,4529269	59,05172414	6,799423238
		TA	219,1774892	279,9283458	52,60869565	6,65135616
	Staked	Chartist	221,3690987	265,7657412	60,34482759	6,782144935
		TA	210,991342	266,4264963	53,04347826	6,423489069
PT. Astra International Tbk (ASII)	Shallow	Chartist	368,0901288	435,7749202	52,15517241	5,209412404
		TA	361,5367965	424,5990061	56,0869565	5,0999653
	Staked	Chartist	356,6266094	421,6966243	55,60344828	5,032086462
		TA	347,5064935	411,9063799	54,7826087	4,888168101
PT. Indomobil Sukses Internasional Tbk (IMAS)	Shallow	Chartist	232,0772532	320,9667933	51,72413793	11,69849203
		TA	222,8571429	298,99077	56,52173913	10,61832479
	Staked	Chartist	220,7467811	311,6628805	56,03448276	11,09777692
		TA	180,8398268	249,2418982	55,2173913	8,695445068
PT. Telekomunikasi Indonesia (Persero) Tbk (TLKM)	Shallow	Chartist	119,9227468	150,5643461	51,72413793	2,989828725
		TA	131,7012987	162,8417685	51,30434783	3,2776882
	Staked	Chartist	118,5150215	144,4207313	53,01724138	2,938488751
		TA	125,1038961	156,8034726	52,60869565	3,106360907
PT. Garuda Indonesia (Persero) Tbk (GIAA)	Shallow	Chartist	49,93133047	66,86839294	56,89655172	10,12939291
		TA	49,36363636	65,67442326	57,39130435	10,07470806
	Staked	Chartist	50,78540773	67,9954871	58,62068966	10,45801536
		TA	50,58008658	66,26236714	58,26086957	10,31055246

Pada Tabel 7 dapat diamati nilai error (MAE, RMSE, MAPE) memiliki nilai terendah pada model arsitektur Stacked dengan data input TA kecuali pada dua perusahaan yaitu ADRO dan GIAA yang nilai errornya terendah jatuh pada arsitektur shallow. Nilai DA tertinggi ada pada arsitektur Stacked kecuali pada perusahaan ADRO.

3.5. Label 1 Bulan

Berikut adalah daftar model dengan nilai pengujian terbaik pada jumlah unit setiap perusahaan, arsitektur, dan data input dengan label 1 bulan.

Tabel 8. Nilai metode pengujian jumlah unit GRU terbaik

Perusahaan	Arsitektur	Input Data	MAE	RMSE	DA	MAPE
PT. Adaro Energy (ADRO)	Shallow	Chartist	162,426087	200,7759296	53,71179039	12,97943719
		TA	143,3114035	181,0277555	58,14977974	11,27204926
	Staked	Chartist	175,6086957	211,5731963	55,45851528	14,03625637
		TA	148,5964912	186,2940046	56,82819383	11,84032253
PT. Vale Indonesia (INCO)	Shallow	Chartist	361,1869565	426,5684766	58,95196507	10,69485294
		TA	368,6359649	454,2191825	49,77973568	10,97895215
	Staked	Chartist	362,573913	415,1703579	52,83842795	10,892784
		TA	356,5745614	437,0049931	46,69603524	10,59037428
PT. Astra International Tbk (ASII)	Shallow	Chartist	364,6565217	474,1031671	65,06550218	5,12832552
		TA	393,3947368	488,8140589	56,82819383	5,5717442
	Staked	Chartist	394,7217391	474,2871997	60,69868996	5,548660675
		TA	337,5745614	447,8424937	54,18502203	4,715919276
PT. Indomobil Sukses Internasional Tbk (IMAS)	Shallow	Chartist	372,6652174	495,4283039	54,58515284	18,30454083
		TA	344,0438596	493,0455212	53,74449339	15,52341727
	Staked	Chartist	341,7782609	496,2778543	53,27510917	15,66090983
		TA	318,9605263	460,7345918	51,10132159	14,61971667
PT. Telekomuni kasi Indonesia (Persero) Tbk (TLKM)	Shallow	Chartist	135,9130435	186,903137	56,33187773	3,362249404
		TA	155,1754386	215,7131176	51,54185022	3,85699917
	Staked	Chartist	118,5150215	144,4207313	53,01724138	2,938488751
		TA	144,6403509	200,8643603	51,10132159	3,599550672
PT. Garuda Indonesia (Persero) Tbk (GIAA)	Shallow	Chartist	75,09130435	98,30562371	58,95196507	15,03716884
		TA	77,25	99,61278101	61,67400881	15,34439264
	Staked	Chartist	78,13043478	106,2126251	60,26200873	15,7165925
		TA	75,62719298	99,33288443	62,55506608	15,03748716

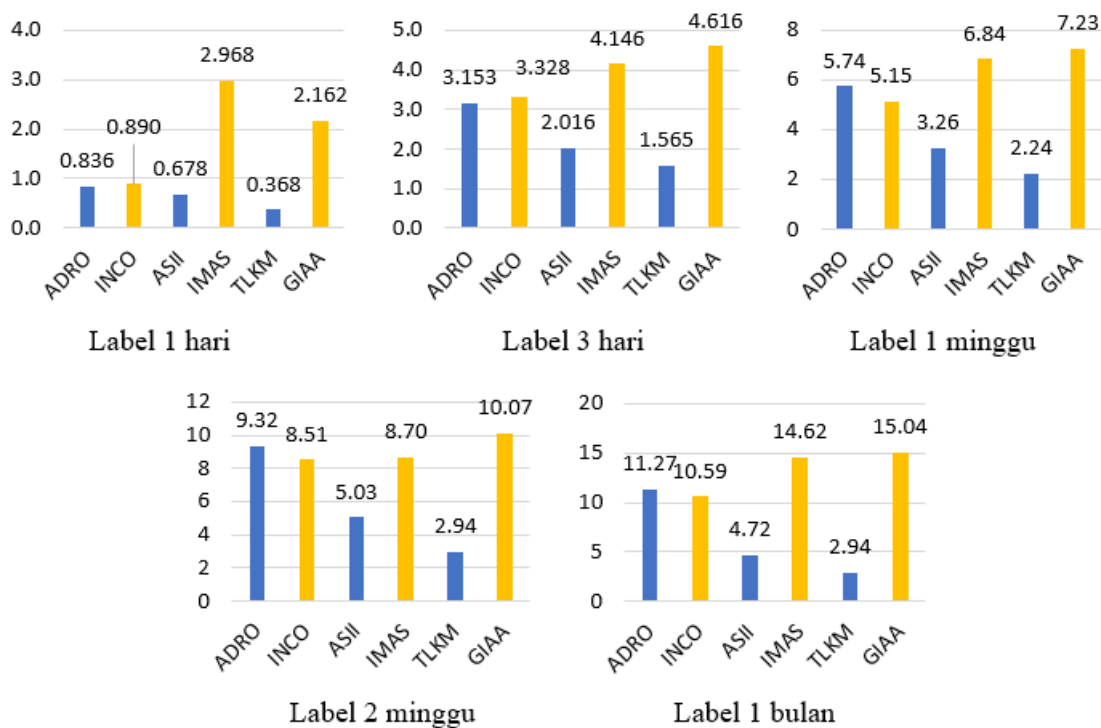
Pada Tabel 8 dapat diamati nilai error (MAE, RMSE, MAPE) memiliki nilai terendah pada model arsitektur Stacked kecuali pada dua perusahaan yaitu ADRO dan GIAA. Nilai error terendah terdapat pada data input TA kecuali pada dua perusahaan yaitu TLKM dan GIAA. Nilai DA tertinggi ada pada arsitektur Stacked dan data input chartist kecuali pada perusahaan ADRO dan GIAA.

3.6. Perbandingan Perusahaan Berdasarkan Liquiditas

Pada Gambar 6 dapat diamati perusahaan Liquid memiliki MAPE yang lebih rendah dari pada perusahaan non-liquid. Hanya 3 kasus dari perbandingan perusahaan liquid dan non liquid dimana perusahaan non liquid memiliki nilai MAPE yang lebih rendah dari pada perusahaan non liquid yaitu pada sektor mining pada tiga label (1 minggu, 2 minggu, 1 bulan). Perusahaan INCO (non liquid) mempunyai nilai MAPE yang lebih rendah daripada ADRO (liquid). Perbedaan nilai MAPE pada tiga kasus tersebut tidak signifikan. Gambar 6 merupakan visualisasi dari Tabel 9.

Tabel 9. Perbandingan perusahaan label 1 hari dan 3 hari

Sektor	Perusahaan	MAPE				
		Label 1 hari	Label 3 hari	Label 1 minggu	Label 2 minggu	Label 1 bulan
Mining	ADRO	0,836405	3,153169922	5,742310919	9,322231685	11,27204926
	INCO	0,890397	3,328168893	5,151144294	8,505994893	10,59037428
Miscellaneous	ASII	0,677825	2,01624146	3,256202421	5,032086462	4,715919276
	IMAS	2,967833	4,145833272	6,83669892	8,695445068	14,61971667
Infrastructure	TLKM	0,36812	1,565438868	2,242305893	2,938488751	2,938488751
	GIAA	2,161819	4,61629905	7,233046732	10,07470806	15,03716884



Gambar 6. Perbandingan Perusahaan

3.7. Model dengan Implementasi Regulasi Dropout

Sebagian besar model dengan regulasi Dropout tidak dapat menurunkan nilai error (MAE, RMSE, MAPE) dan meningkatkan nilai DA. Dari 120 model (5 label x 6 perusahaan x 4 model terbaik setiap perusahaan) yang diterapkan regulasi Dropout hanya 43 model yang nilai errornya turun. Dari 43 model yang nilai error turun dan DA naik 6 model terdapat pada label 1 hari, 7 model terdapat pada model label 3 hari, 11 model terdapat pada model label 1 minggu, 8 model terdapat pada label 2 minggu, dan 11 model terdapat pada model label 1 bulan.

4. Kesimpulan dan Saran

Dari penelitian yang telah dilakukan, maka diperoleh kesimpulan sebagai berikut. Jumlah unit/neuron yang diujikan pada model metode RNN-GRU tidak memiliki jumlah unit/neuron

yang sama pada semua kasus prediksi pada penelitian ini. Setiap perusahaan, arsitektur model dan data input memiliki banyak unit/neuron terbaik yang berbeda-beda. Metode pengujian (MAE, RMSE, DA, dan MAPE) pada beberapa kasus pengujian memiliki jumlah unit terbaik pada model yang berbeda-beda. Semakin jauh model RNN-GRU memprediksi nilai saham maka nilai error (MAE, RMSE, MAPE) akan semakin besar. Pada penelitian ini yang menggunakan lima label (1 hari, 3 hari, 1 minggu, 2 minggu, 1 bulan), nilai error dari label 1 hari menuju 1 bulan memiliki kenaikan secara konstan. Hal ini terjadi pada setiap pengujian Perusahaan, arsitektur, dan data input.

Arsitektur Stacked merupakan arsitektur yang lebih stabil daripada Shallow dalam menghasilkan nilai error yang rendah (MAE, RMSE, MAPE) dan menghasilkan nilai DA yang tinggi. Walaupun dalam beberapa kasus pada penelitian ini arsitektur Shallow dapat menghasilkan nilai error yang rendah dan DA yang tinggi dibandingkan Stacked tetapi pada 30 kali perbandingan arsitektur (5 label x 6 perusahaan) arsitektur Stacked dapat mengungguli Shallow sebanyak 21 kali dalam rendahnya nilai error dan 19 kali dalam tingginya nilai DA. Data input TA merupakan data input yang mampu menghasilkan nilai error (MAE, RMSE, MAPE) yang rendah daripada data input chartist. Walaupun dalam beberapa kasus pada penelitian ini data input Chartist dapat unggul dalam rendahnya nilai error namun pada 30 kali perbandingan data input (5 label x 6 perusahaan) data input TA dapat mengungguli chartist sebanyak 25 kali dalam rendahnya nilai error. Tetapi pada penelitian ini data input chartist mengungguli data input TA dalam tingginya nilai DA sebanyak 15 kali dari 30 kali perbandingan. Perusahaan Liquid lebih mudah diprediksi oleh model RNN-GRU dari pada non liquid. Nilai MAPE pada perusahaan Liquid lebih rendah daripada perusahaan non liquid. Dropout tidak berpengaruh terhadap turunnya nilai error pada model RNN-GRU.

Penelitian ini masih terdapat kekurangan dan keterbatasan. Kekurangan dan keterbatasan ini diharapkan menjadi pertimbangan dan acuan pada penelitian selanjutnya. Penelitian ini belum dapat menyelesaikan masalah tingginya nilai error pada model yang melakukan prediksi lebih dari tiga hari kedepan. Model yang melakukan prediksi lebih dari tiga hari kedepan membutuhkan perlakuan data dan analisis pembangunan model yang lebih dalam.

Daftar Pustaka

- [1] Althelaya, K.A., El-Alfy, E.S.M. and Mohammed, S., 2018. Stock Market Forecast Using Multivariate Analysis with Bidirectional and Stacked (LSTM, GRU). *21st Saudi Computer Society National Computer Conference, NCC 2018*, pp.1–7.
- [2] Chen, J.X., Jiang, D.M. and Zhang, Y.N., 2019. A Hierarchical Bidirectional GRU Model With Attention for EEG-Based Emotion Classification. *IEEE Access*, 7, pp.118530–118540.
- [3] Chung, J., Gulcehre, C., Cho, K. and Bengio, Y., 2014. Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling. [online] pp.1–9. Available at: <<http://arxiv.org/abs/1412.3555>>.
- [4] Faurina, R., 2019. Klasifikasi Pergerakan Harga Saham Jangka Pendek Menggunakan Principal Component Analysis dan Jaringan Long Short Term Memory : Studi Kasus Pada Saham Bursa Efek Indonesia. S2. Universitas Gajah Mada

- [5] Fu, R., Zhang, Z. and Li, L., 2016. Using LSTM and GRU Neural Network Methods for Traffic Flow Prediction. *31st Youth Academic Annual Conference of Chinese Association of Automation Wuhan*, pp.324–328.
- [6] Guresen, E., Kayakutlu, G. and Daim, T.U., 2011. Using artificial neural network models in stock market index prediction. *Expert Systems with Applications*, [online] 38(8), pp.10389–10397. Available at: <<http://dx.doi.org/10.1016/j.eswa.2011.02.068>>.
- [7] Id, T.A.R., Abbas, D.K. and Turel, Y.K., 2019. A multi hidden recurrent neural network with a modified grey wolf optimizer. *PLOS ONE*, [online] pp.1–23. Available at: <<https://doi.org/10.1371/journal.pone.0213237>>.
- [8] Imandoust, S.B. and Bolandraftar, M., 2014. Forecasting the direction of stock market index movement using three data mining techniques: the case of Tehran Stock Exchange. *Journal of Engineering Research and Applications www.ijera.com*, [online] 4(6), pp.106–117. Available at: <www.ijera.com>.
- [9] Kara, Y., Acar Boyacioglu, M. and Baykan, Ö.K., 2011. Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange. *Expert Systems with Applications*, [online] 38(5), pp.5311–5319. Available at: <<http://dx.doi.org/10.1016/j.eswa.2010.10.027>>.
- [10] Khoolish, N, T.(2019). Gated Recurrent Unit – Recurrent Neural Network Untuk Peramalan Nilai Tukar Mata Uang Rupiah Terhadap Dolar Amerika. S1. Universitas Gajah Mada
- [11] Kui, lin L., Chun, jiw Z. and Jian, min X., 2017. Short term traffic flow prediction Using methodology based on arima and RBF-ANN. *IEEE*, p.634.
- [12] Kumar, S., Hussain, L., Banarjee, S. and Reza, M., 2018. Energy Load Forecasting using Deep Learning Approach-LSTM and GRU in Spark Cluster. *Proceedings of 5th International Conference on Emerging Applications of Information Technology, EAIT 2018*, pp.1–4.
- [13] Ma, T., Antoniou, C. and Toledo, T., 2020. Hybrid machine learning algorithm and statistical time series model for network-wide traffic forecast. *Transportation Research Part C: Emerging Technologies*, [online] 111(December 2019), pp.352–372. Available at: <<https://doi.org/10.1016/j.trc.2019.12.022>>.
- [14] Ratnayaka, R.M.K.T., Seneviratne, D.M.K.N., Jianguo, W. and Arumawadu, H.I., 2015. A hybrid statistical approach for stock market forecasting based on Artificial Neural Network and ARIMA time series models. *2015 International Conference on Behavioral, Economic and Socio-Cultural Computing, BESC 2015*, (Besc), pp.54–60.
- [15] Sugiartawan, P., Pulungan, R. and Sari, A.K., 2017. Prediction by a Hybrid of Wavelet Transform and Long-Short-Term-Memory Neural Network. *International Journal of Advanced Computer Science and Applications*, Vol. 8, No.2 (June), pp.326–332.
- [16] Struye, J. and Latré, S., 2020. Hierarchical temporal memory and recurrent neural networks for time series prediction: An empirical validation and reduction to

- multilayer perceptrons. *Neurocomputing*, [online] 396(xxxx), pp.291–301. Available at: <<https://doi.org/10.1016/j.neucom.2018.09.098>>.
- [17] Tambunan, A. P., 2007. Menilai Harga Wajar Saham. Jakarta: Penerbit PT Elek Media Komputindo
- [18] Wang, J., Yan, J., Li, C., Gao, R.X. and Zhao, R., 2019. Deep heterogeneous GRU model for predictive analytics in smart manufacturing: Application to tool wear prediction. *Computers in Industry*, [online] 111, pp.1–14. Available at: <<https://doi.org/10.1016/j.compind.2019.06.001>>.
- [19] Wira, D., 2014. Analisis Fundamental Saham Edisi Kedua. Jakarta: Penerbit Exceed Books
- [20] Zhang, D. and Kabuka, M.R., 2018. Combining weather condition data to predict traffic flow: A GRU-based deep learning approach. *IET Intelligent Transport Systems*, 12(7), pp.578–585.