

Implementasi Deep Learning Pemodelan Pergerakan Harga Saham dalam Time Series

Nonik Mega Sapitri¹, Riza Sawitri^{*2}, Edwin Russel³

^{1,2}Jurusan Matematika, FMIPA Universitas Lampung, Bandar Lampung, Indonesia

e-mail: ¹nonikmega@fmipa.unila.ac.id, ² * rizasawitri@fmipa.unila.ac.id,

³winrush08@gmail.com

Abstrak

The movement of stock prices is difficult to predict the direction of progress. Therefore, a method is needed that can model stock price movements in order to make it easier for investors to make investment decisions. One method that can be used is modeling time series stock price movements with deep learning. First, we will look at the Autocorrelation Function (ACF) to determine the stock data in the form of stationary or non-stationary. Furthermore, several parameters will be determined that can affect the accuracy of predicting stock price movements. A good prediction result of stock price movements is that there is no overfitting of the model and also provides predictive data results that are close to actual data. This can be seen by the small difference between MSE training and MSE testing.

Kata kunci— *time series, autocorrelation function, Deep Learning, overfitting*

Abstract

Pergerakan harga saham sulit untuk ditebak akan arah kelajuannya. Oleh karena itu, diperlukan metode yang dapat memodelkan pergerakan harga saham tersebut supaya mempermudah investor untuk pengambilan keputusan dalam berinvestasi. Salah satu metode yang dapat digunakan adalah pemodelan time series pergerakan harga saham dengan Deep Learning. Terlebih dahulu akan dilihat Autocorrelation Function (ACF) untuk menentukan data saham berupa stasioner atau nonstasioner. Selanjutnya, akan ditentukan beberapa parameter yang dapat mempengaruhi akurasi prediksi pergerakan harga saham. Hasil prediksi pergerakan harga saham yang baik adalah tidak terjadinya overfitting pada model dan juga memberikan hasil data prediksi yang mendekati data aktual. Hal ini dapat dilihat berdasarkan selisih yang kecil antara MSE training dan MSE testing.

Keywords— *time series, autocorrelation function, Deep Learning, overfitting*

1. PENDAHULUAN

Di bidang perekonomian, kata investasi sudah lazim dipergunakan dan sering diartikan sebagai penanaman uang dengan harapan mendapatkan keuntungan dimasa yang akan datang (Mudjiyono, 2012). Dalam kamus Bahasa Indonesia Kontemporer, kata investasi diartikan lebih jelas, yaitu penanaman uang atau modal di suatu proyek atau perusahaan dengan tujuan untuk mencari untung di masa yang akan datang (Salim, 1991). Ada beberapa jenis investasi yang terdapat di pasar modal, salah satunya adalah investasi saham.

Investasi dalam bentuk saham, atau biasa disebut dengan investasi saham merupakan pembelian atau penyertaan atau kepemilikan saham perusahaan lain dengan tujuan untuk mendapatkan keuntungan dan lainnya (Mudjiyono, 2012). Dalam pasar modal, hal terpenting

yang harus diketahui investor sebelum melakukan investasi saham adalah harga saham. Harga saham yang terjadi di pasar modal selalu berubah setiap harinya selama trading day. Pergerakan harga saham terjadi secara kontinu.

Pergerakan harga saham sulit untuk ditebak akan arah kelajuannya. Dalam memprediksi dapat dilakukan dengan tiga faktor yang mempengaruhi, yaitu faktor teknikal, faktor fundamental, dan faktor sentiment (Troiano, 2018). Faktor teknikal merupakan pergerakan dengan cara mengamati harga pada masa lalu, faktor fundamental merupakan teknik analisis pendekatan secara bisnis yang terjadi, sedangkan faktor sentiment merupakan pergerakan harga saham yang dipengaruhi oleh faktor-faktor bisnis, berita dan pelaku operasional bisnis.

Sebelum memilih saham yang akan diinvestasikan, maka alangkah baiknya terlebih dahulu mengetahui pergerakan harga saham mana yang bagus atau sesuai dengan keinginan. Oleh karena itu, diperlukan metode yang dapat memodelkan pergerakan harga saham tersebut supaya mempermudah investor untuk pengambilan keputusan dalam berinvestasi.

Banyak metode dan cara yang dilakukan untuk memprediksi pergerakan harga saham, terlebih lagi jika menggunakan bantuan komputasi. Dewasa ini, perkembangan komputasi untuk pembelajaran mesin sangat pesat, salah satu yang berkembang adalah Deep Learning (Heaton, 2016). Deep Learning sangat memungkinkan melakukan pembelajaran dengan lapisan yang lebih kompleks agar mendapatkan akurasi yang tinggi. Deep Learning mempunyai kemampuan belajar lebih efisien karena dapat belajar pada Jaringan Syaraf Tiruan yang lebih dalam atau lapisan tersembunyi yang lebih banyak. Dalam Deep Learning terdapat sebuah jaringan yang disebut Artificial Neural Network (ANN) yang dapat digunakan untuk mengolah data Time Series yang selanjutnya dapat digunakan untuk memprediksi pergerakan harga saham.

Pada penelitian ini, dilakukan eksperimen untuk memprediksi pergerakan harga beberapa saham. Hal ini dilakukan dengan memodelkan time series pergerakan harga saham menggunakan Pembelajaran Mendalam (Deep Learning). Dalam pemodelan ini nantinya akan ditentukan beberapa parameter yang mempengaruhi akurasi prediksi pergerakan harga saham. Saham yang dipilih untuk digunakan pada penelitian ini adalah PT Indofarma (Persero) Tbk (INAF), Surya Citra Media Tbk (SCMA), dan Perusahaan Gas Negara Tbk (PGAS).

2. METODE PENELITIAN

Pada penelitian ini, digunakan pemodelan time series pergerakan harga saham dengan menggunakan Pembelajaran Mendalam (Deep Learning). Selanjutnya, akan ditentukan beberapa parameter yang dapat mempengaruhi akurasi prediksi pergerakan harga saham. Kemudian dipilih parameter mana yang dapat memberikan hasil terbaik pada model tersebut. Hasil terbaik yang diinginkan adalah data hasil prediksi yang mendekati data aktual. Dalam hal ini, akan dilihat Mean Square Error (MSE) dari hasil training dan testing pada model tersebut. Model yang baik adalah model yang menghasilkan MSE training mendekati MSE testing dengan MSE testing lebih kecil daripada MSE training.

Sebelum dilakukan pemodelan, maka terlebih dahulu dilakukan input data berdasarkan data saham yang telah dipilih dan didownload dari yahoo finance. Data yang digunakan terdiri dari tiga saham yang berbeda. Data dari ketiga saham tersebut dipilih berdasarkan historical data selama tiga tahun terakhir, yaitu dari tanggal 7 Oktober 2017 hingga 4 Desember 2020. Dengan mengambil sebanyak 800 data observasi, maka selanjutnya data tersebut dibagi menjadi dua bagian yaitu sebanyak 680 data digunakan untuk training dan sebanyak 120 data digunakan untuk testing

2.1 2.3 Autocorrelation Function (ACF)

Dalam metode *time series*, alat utama untuk mengidentifikasi model dari data yang akan diramalkan salah satunya adalah dengan menggunakan fungsi Autokorelasi/ *Autocorrelation Function* (ACF). Menurut Makridakis (1999) pada dasarnya koefisien autokorelasi

menunjukkan korelasi antara deret berkala dengan deret berkala itu sendiri dengan selisih waktu (lag) 0, 1, 2 periode atau lebih. Kovarian antara Z_t dan Z_{t+k} adalah sebagai berikut:

$$\gamma_k = \text{Cov}(Z_t, Z_{t+k}) = E(Z_t - \mu)(Z_{t+k} - \mu) \quad (2.1)$$

Dan korelasi antara Z_t dan Z_{t+k} adalah

$$\rho_k = \frac{\text{Cov}(Z_t, Z_{t+k})}{\sqrt{\text{Var}(Z_t)}\sqrt{\text{Var}(Z_{t+k})}} = \frac{\gamma_k}{\gamma_0} \quad (2.2)$$

2.2 Pembelajaran Mendalam (Deep Learning)

Rangkaian dari berbagai Perceptron akan membentuk layer (hidden layer dan output layer) dan rangkaian dari beberapa hidden layers di ANN akan membentuk model *Deep Learning*.

Di dalam model Perceptron umumnya digunakan model nonlinier hanya saja kali ini notasi parameter β akan diganti dengan notasi parameter w .

$$y = f(X, w) + e \quad (2.3)$$

dengan $f()$ merupakan fungsi aktivasi yang bisa berupa fungsi *Sigmoid*

$$f(z) = \frac{1}{1 + \exp(-z)} \quad (2.4)$$

dengan

$$z = Xw \quad (2.5)$$

Sifat dari fungsi *Sigmoid* antara lain adalah:

$$0 < f(z) < 1, \text{ untuk } -\infty < z < \infty \quad (2.6)$$

$$f'(z) = f(z)(1 - f(z)) \rightarrow f'(0) = 0.25 \quad (2.7)$$

Model nonlinier (2.3) dengan $f()$ berupa fungsi *Sigmoid* (2.4) akan disebut dengan nama model regresi logistik. Algoritma untuk penaksiran parameter w masih tetap bisa digunakan, yaitu:

$$W^{(n+1)} = W^{(n)} - t_n P_n \gamma_n \quad (2.8)$$

dengan

$$\gamma_n = \frac{\partial S(W)}{\partial W} \Big|_{W^{(n)}} \quad (2.9)$$

dan

$$P_n = I_K \quad (2.10)$$

sehingga algoritma (2.8) akan menjadi

$$W^{(n+1)} = W^{(n)} - t_n \gamma_n \quad (2.11)$$

Bila bentuk algoritma (2.11) dibandingkan dengan algoritma (2.8), maka akan terlihat bahwa peranan t_n pada algoritma (2.11) seperti menggantikan $t_n P_n$ pada algoritma (2.8). Dari hasil ini kelak di dalam prakteknya perlu kehati-hatian seseorang di dalam pemilihan t_n . Pedoman umumnya, mulai dengan t_n yang kecil dulu sehingga dimulai langkah dengan step yang pendek-pendek.

Algoritma (2.11) yang semula disebut dengan nama algoritma *Steepest Descent* di Ekonometrika ini akan diberi nama algoritma *Gradient Descent* di dalam *Deep Learning*. Ini mempermudah penafsiran algoritma. Bila pada iterasi ke- n diperoleh nilai gradient yang positif

$$\frac{\partial S(W)}{\partial w_i} \Big|_{w_i^{(n)}} > 0 \quad (2.12)$$

maka pada iterasi berikutnya akan dipilih nilai w_i yang lebih kecil (melangkah ke kiri) sesuai dengan panjang step agar lama-lama akan tercapai FOC. Demikian pula sebaliknya, bila diperoleh nilai gradient yang negatif maka pada iterasi berikutnya akan dipilih w_i yang lebih besar (melangkah ke kanan).

Jadi pada algoritma *gradient descent* ini akan dihitung dulu gradient dari fungsi objektif kemudian di-*descent*-kan, di-negatif-kan. Langkah dari algoritma selalu berlawanan arah dengan gradientnya. Bila diperoleh nilai gradient yang negatif itu pertanda fungsi objektif sedang turun sehingga langkah ke kanan (nilai parameter w_i diperbesar) merupakan langkah yang paling sesuai agar diperoleh nilai fungsi objektif yang semakin kecil untuk menuju titik minimum. Sebaliknya, bila nilai gradient positif, maka fungsi objektif sedang naik sehingga langkah ke kiri (nilai parameter w_i diperkecil) merupakan langkah yang paling tepat agar diperoleh nilai fungsi objektif yang semakin kecil untuk menuju titik minimum. Algoritma yang demikian hanya cocok untuk masalah *minimization* dari fungsi objektif.

3. HASIL DAN PEMBAHASAN

Pengolahan data pada penelitian ini menggunakan bantuan aplikasi Python versi 3.8. Penelitian ini akan memodelkan time series pergerakan harga beberapa saham dengan menggunakan Pembelajaran Mendalam (Deep Learning). Selanjutnya ditentukan parameter-parameter yang cocok untuk model tersebut yang dapat mempengaruhi akurasi prediksi pergerakan harga saham.

Berikut ini statistik deskriptif dari saham INAF berdasarkan observasi data yang dilakukan selama kurang lebih tiga tahun.

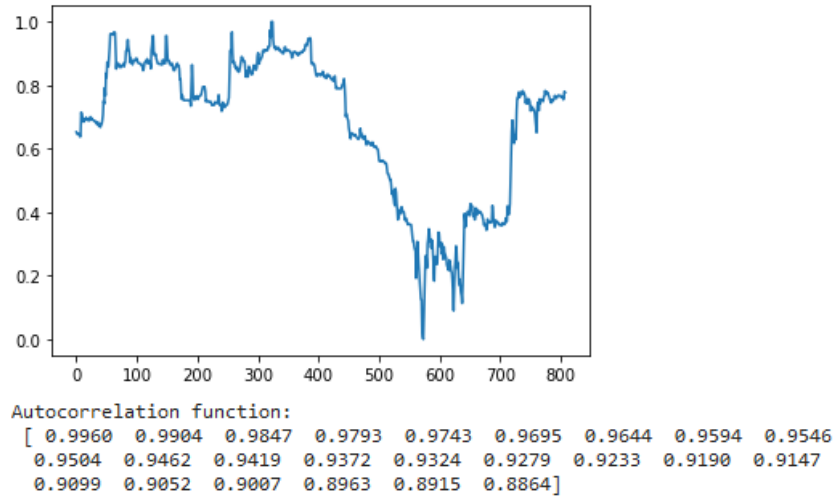
	Open	High	Low	Close	Adj Close	Volume
count	800.000000	800.000000	800.000000	800.000000	800.000000	8.000000e+02
mean	3031.343750	3110.358750	2959.515000	3024.735000	3024.735000	3.333246e+06
std	1514.452929	1541.867342	1486.28362	1515.67411	1515.67411	9.089547e+06
min	346.000000	372.000000	334.000000	344.000000	344.000000	0.000000e+00
25%	1546.250000	1593.750000	1503.750000	1525.000000	1525.000000	4.115000e+04
50%	3150.000000	3245.000000	3100.000000	3140.000000	3140.000000	2.031000e+05
75%	4370.000000	4450.000000	4310.000000	4370.000000	4370.000000	2.223825e+06
max	6500.000000	6500.000000	6500.000000	6500.000000	6500.000000	9.743410e+07

Gambar 1. saham INAF

Berdasarkan data saham INAF selama kurang lebih tiga tahun seperti di atas, terlihat bahwa rata-rata harga saham penutupan mendekati harga saham pembukaan, yaitu sebesar Rp3024,735 per lembar dan Rp3031,344 per lembar saham. Akan tetapi, standar deviasi harga penutupan lebih besar dari harga pembukaan, yaitu sebesar 1515,674. Diikuti dengan rata-rata volume transaksi selama tiga tahun sekitar 3.333.246 lembar saham. Untuk nilai maksimum pada harga pembukaan hingga harga penutupan diperoleh hasil yang sama, yaitu sebesar Rp6500 per lembar dengan nilai minimum harga penutupan sebesar Rp344.

Berdasarkan *historical data* dari saham INAF, dibuat pemodelan *time series* pergerakan harga saham INAF selama tiga tahun dengan menggunakan Pembelajaran Mendalam (*Deep Learning*). Berikut ini hasil dan analisa dari pemodelannya.

Gambar 2. *Autocorrelation Function (ACF)*



Berdasarkan hasil di atas, jika dilihat dari *autocorrelation function* maka data membentuk suatu pola yang semakin lama nilai *autocorrelation* semakin menurun. Pola tersebut mengartikan bahwa data berkorelasi dengan dirinya sendiri. Dengan kata lain, data mengingat masa lalu dengan kuat. Dari identifikasi tersebut, mengindikasikan bahwa data berupa nonstasioner. Dalam hal ini, data berkorelasi banyak dengan data masa lalu. Oleh karena itu, jika ingin menaksir data esok hari, tidak dibutuhkan banyak data ke belakang. Cukup data hari ini saja karena data hari ini sudah dapat mewakili data-data sebelumnya.

Hasil Plot Saham INAF dengan *Deep Learning*

Pemodelan ini dilakukan dengan menggunakan beberapa parameter yang berbeda. Selanjutnya dari parameter yang berbeda tersebut, akan dibandingkan dan dipilih parameter mana yang menghasilkan model yang bagus. Dalam hal ini, dikatakan model yang bagus jika dihasilkan MSE (*Mean Square Error*) untuk *testing* yang lebih kecil daripada MSE *training* serta nilai MSE keduanya saling mendekati (selisihnya kecil).

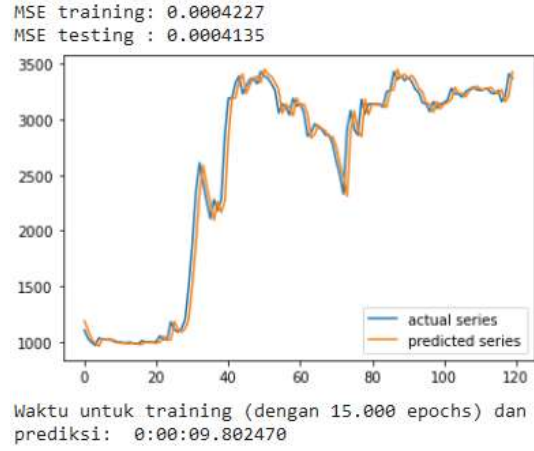
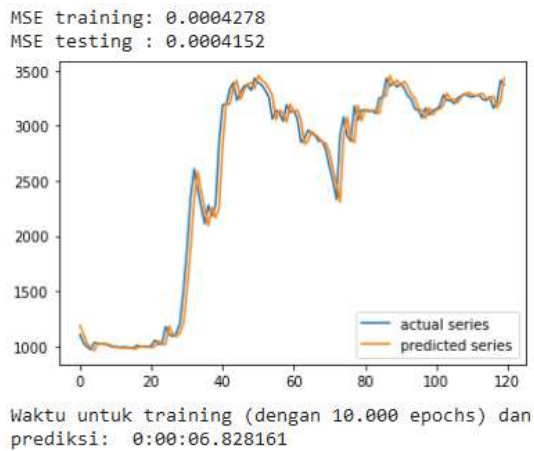
Tabel 1. Plot Saham INAF dengan *Deep Learning*

α	ts	$H1$	$H2$	epochs	MSE training	MSE testing
10	1	4	4	10.000	0.0004278	0.0004152
				15.000	0.0004227	0.0004135
				50.000	0.0004096	0.0004260
				100.000	0.0004026	0.0004178

Pada penelitian ini, dilakukan percobaan sebanyak empat kali dengan nilai epochs yang berbeda, yaitu 10.000, 15.000, 50.000, dan 100.000. Pemilihan parameter α (*learning rate*) pada keempat percobaan tersebut adalah sama, yaitu 10. Diikuti dengan jumlah neurons di *hidden layer* ke-1 dan ke-2 masing-masing sebanyak 4 neurons. Karena saham INAF merupakan data yang nonstasioner, maka dipilih ts (*time step*) sebanyak 1. Hal ini disebabkan karena data banyak berkorelasi dengan data masa lalu sehingga cukup data hari ini yang digunakan jika diinginkan memprediksi pergerakan harga saham untuk esok hari.

Berdasarkan tabel di atas, terlihat bahwa pada epochs yang berbeda-beda menghasilkan MSE *training* dan MSE *testing* yang berbeda pula. Semakin besar nilai epochs, maka semakin kecil MSE *training* tetapi tidak berlaku demikian untuk MSE *testing*. Bisa dilihat pada epochs 15.000 nilai MSE *testing* menurun, tetapi pada epochs 50.000 nilai MSE *testing* naik lagi.

Selain itu pada epochs 50.000 dan 100.000 nilai MSE *testing* lebih besar dari MSE *training* sehingga model mengalami *overfitting*.



Jika dilihat dari grafik di atas, terlihat bahwa tidak ada perubahan yang signifikan antara epochs 10.000 dan 15.000. Akan tetapi, akurasi data pada epochs 15.000 lebih baik daripada epochs 10.000. Hal ini terlihat dari selisih yang kecil antara nilai MSE *training* dan MSE *testing* pada epochs 15.000. Dengan demikian, model yang bagus untuk prediksi pergerakan harga saham INAF adalah dengan memilih $\alpha = 10$, $ts = 1$, $H1 = 4$, $H2 = 4$, dan epochs sebesar 15.000. Sedangkan model dengan epochs 50.000 dan 100.000 tidak dipilih karena model mengalami *overfitting*.

a) PT Surya Citra Media Tbk (SCMA)

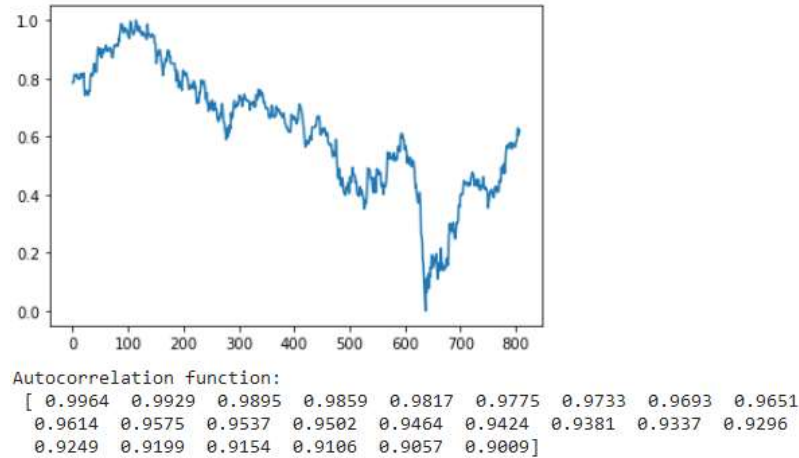
Berikut ini statistik deskriptif dari saham SCMA berdasarkan observasi data yang dilakukan selama kurang lebih tiga tahun.

	Open	High	Low	Close	Adj Close	Volume
count	800.00000	800.000000	800.000000	800.000000	800.000000	8.000000e+02
mean	1703.36875	1731.693750	1670.868750	1701.293750	1633.361025	1.746670e+07
std	529.78134	532.990395	524.709254	530.029914	470.301498	2.370061e+07
min	600.00000	645.000000	600.000000	635.000000	635.000000	0.000000e+00
25%	1255.00000	1280.000000	1230.000000	1250.000000	1240.000000	7.078675e+06
50%	1662.50000	1687.500000	1650.000000	1657.500000	1617.000000	1.196675e+07
75%	2060.00000	2092.500000	2010.000000	2040.000000	1938.464722	2.133850e+07
max	2880.00000	2980.000000	2820.000000	2880.000000	2691.045166	5.144306e+08

Berdasarkan data saham SCMA selama kurang lebih tiga tahun seperti di atas, terlihat bahwa rata-rata harga saham penutupan mendekati harga saham pembukaan, yaitu sebesar Rp1701,29 per lembar dan Rp1703,37 per lembar saham. Akan tetapi, standar deviasi harga penutupan lebih besar dari harga pembukaan, yaitu sebesar 530,03. Diikuti dengan rata-rata volume transaksi selama tiga tahun sekitar 1.746.670 lembar saham. Untuk nilai maksimum pada harga pembukaan dan harga penutupan diperoleh hasil yang sama, yaitu sebesar Rp2880 per lembar dengan nilai minimum harga penutupan sebesar Rp635.

Berdasarkan *historical data* dari saham SCMA, dibuat pemodelan *time series* pergerakan harga saham SCMA selama tiga tahun dengan menggunakan Pembelajaran Mendalam (*Deep Learning*). Berikut ini hasil dan analisa dari pemodelannya.

Autocorrelation Function (ACF)



Seperti halnya saham INAF, berdasarkan hasil di atas, diperoleh data *autocorrelation function* saham SCMA membentuk suatu pola yang semakin lama nilai *autocorrelation* semakin menurun. Pola tersebut mengartikan bahwa data berkorelasi dengan dirinya sendiri. Dengan kata lain, data mengingat masa lalu dengan kuat.

Dari identifikasi tersebut, mengindikasikan bahwa data berupa nonstasioner. Dalam hal ini, data berkorelasi banyak dengan data masa lalu. Oleh karena itu, jika ingin menaksir data esok hari, tidak dibutuhkan banyak data ke belakang. Cukup data hari ini saja karena data hari ini sudah dapat mewakili data-data sebelumnya.

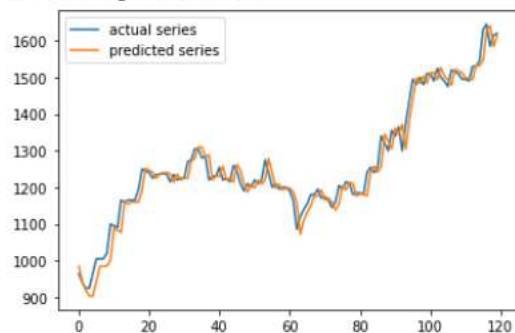
Hasil Plot Saham SCMA dengan Deep Learning

Berikut ini hasil yang diperoleh dari plot saham SCMA menggunakan *Deep Learning* dengan pemilihan parameter-parameter yang berbeda. Selanjutnya parameter tersebut dibandingkan dan dipilih parameter mana yang memberikan hasil prediksi lebih akurat atau mendekati data aktual.


α	ts	$H1$	$H2$	epochs	MSE training	MSE testing
10	1	4	4	10.000	0.0003722	0.0003092
				15.000	0.0003927	0.0003920
				50.000	0.0003461	0.0002843
				100.000	0.0003421	0.0002723

Berdasarkan tabel di atas, terlihat bahwa semakin besar epochs, maka semakin kecil nilai MSE *training* dan MSE *testing*. Namun, hal ini tidak berlaku untuk epochs 15.000 karena menghasilkan nilai MSE *training* dan MSE *testing* yang semakin besar. Dapat dilihat juga bahwa selisih terkecil antara MSE *training* dan MSE *testing* terdapat pada epochs 10.000. Sedangkan untuk epochs 50.000 dan 100.000 masih memberikan selisih MSE *training* dan MSE *testing* yang cukup besar.

MSE training: 0.0003722
MSE testing : 0.0003096



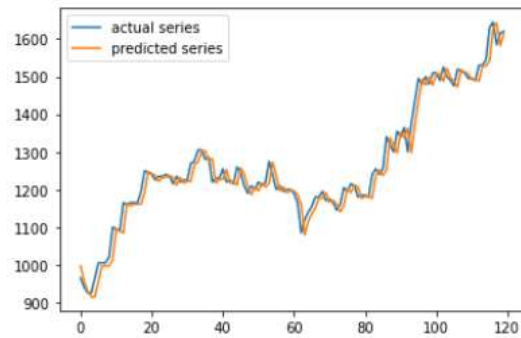
MSE training: 0.0003927
MSE testing : 0.0003920



Waktu untuk training (dengan 10.000 epochs) dan prediksi: 0:00:05.745340 4

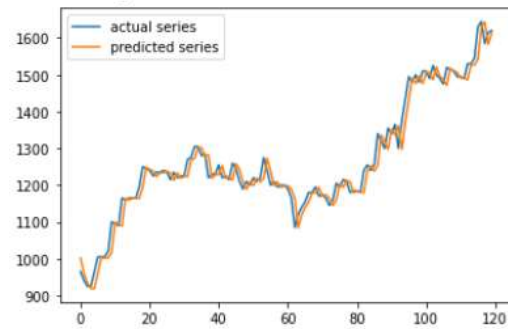
Waktu untuk training (dengan 15.000 epochs) dan prediksi: 0:00:12.182238

MSE training: 0.0003461
MSE testing : 0.0002843



Waktu untuk training (dengan 50.000 epochs) dan prediksi: 0:00:41.061040

MSE training: 0.0003421
MSE testing : 0.0002723



Waktu untuk training (dengan 100.000 epochs) dan prediksi: 0:01:31.401657

Berdasarkan keempat grafik di atas, model yang bagus ada pada epochs 10.000. Hal ini terlihat dari data prediksi yang paling mendekati data aktual ada pada epochs 10.000 jika dibandingkan dengan nilai epochs yang lain. Meskipun selisih antara MSE *training* dan MSE *testing* pada epochs 15.000 paling kecil diantara yang lainnya, tetapi akurasi data nya masih lebih bagus epochs 10.000. Dengan demikian, model yang bagus untuk prediksi pergerakan harga saham SCMA adalah dengan memilih $\alpha = 10$, $ts = 1$, $H1 = 4$, $H2 = 4$, dan epochs sebesar 10.000.

b) PT Perusahaan Gas Negara Tbk (PGAS)

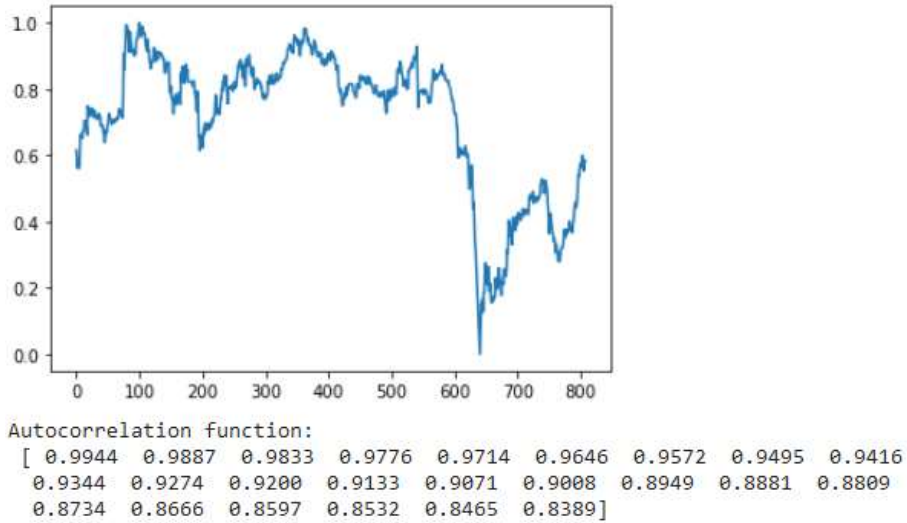
Berikut ini statistik deskriptif dari saham PGAS berdasarkan observasi data yang dilakukan selama kurang lebih tiga tahun.

	Open	High	Low	Close	Adj Close	Volume
count	800.000000	800.000000	800.000000	800.000000	800.000000	8.000000e+02
mean	1848.275000	1883.343750	1815.150000	1844.987500	1658.370370	8.613622e+07
std	495.801105	501.503098	487.924626	494.149311	406.600391	8.298534e+07
min	610.000000	680.000000	605.000000	605.000000	548.061462	0.000000e+00
25%	1537.500000	1575.000000	1516.250000	1528.750000	1403.575043	3.439632e+07
50%	1985.000000	2020.000000	1960.000000	1985.000000	1786.861633	6.024615e+07
75%	2200.000000	2232.500000	2152.500000	2190.000000	1956.715332	1.099948e+08
max	2720.000000	2860.000000	2660.000000	2720.000000	2361.993408	7.461132e+08

Berdasarkan data saham PGAS di atas, terlihat bahwa rata-rata harga saham penutupan mendekati harga saham pembukaan, yaitu sebesar Rp1844,99 per lembar dan Rp1848,28 per lembar saham. Akan tetapi, standar deviasi harga penutupan lebih kecil dari harga pembukaan, yaitu sebesar 494,15. Diikuti dengan rata-rata volume transaksi selama tiga tahun sekitar 8.613.622 lembar saham. Untuk nilai maksimum pada harga pembukaan dan harga penutupan diperoleh hasil yang sama, yaitu sebesar Rp2720 per lembar dengan nilai minimum harga penutupan sebesar Rp605.

Berdasarkan *historical data* dari saham PGAS, dibuat pemodelan *time series* pergerakan harga saham PGAS selama tiga tahun dengan menggunakan Pembelajaran Mendalam (*Deep Learning*). Berikut ini hasil dan analisa dari pemodelannya.

Autocorrelation Function (ACF)



Seperti halnya saham INAF dan SCMA, berdasarkan hasil di atas, diperoleh data *autocorrelation function* saham PGAS membentuk suatu pola yang semakin lama nilai *autocorrelation* semakin menurun. Pola tersebut mengartikan bahwa data berkorelasi dengan dirinya sendiri. Dengan kata lain, data mengingat masa lalu dengan kuat.

Dari identifikasi tersebut, mengindikasikan bahwa data berupa nonstasioner. Dalam hal ini, data berkorelasi banyak dengan data masa lalu. Oleh karena itu, jika ingin menaksir data esok hari, tidak dibutuhkan banyak data ke belakang. Cukup data hari ini saja karena data hari ini sudah dapat mewakili data-data sebelumnya.


Hasil Plot Saham PGAS dengan Deep Learning

Berikut ini hasil yang diperoleh dari plot saham PGAS menggunakan *Deep Learning* dengan pemilihan parameter-parameter yang berbeda. Selanjutnya parameter tersebut dibandingkan dan dipilih parameter mana yang memberikan hasil prediksi lebih akurat atau mendekati data aktual.

α	ts	$H1$	$H2$	epochs	MSE training	MSE testing
10	1	4	4	10.000	0.0005451	0.0004595
				15.000	0.0005384	0.0004611
				50.000	0.0005219	0.0004488
				100.000	0.0005102	0.0005163

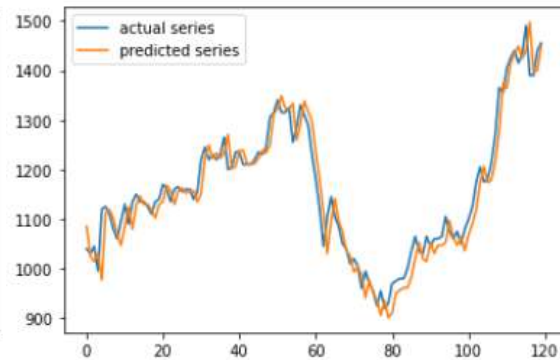
Berdasarkan tabel di atas, terlihat bahwa semakin besar nilai epochs, maka semakin kecil MSE *training*, tetapi berlaku sebaliknya untuk MSE *testing*. Dapat dilihat pada epochs 100.000, nilai MSE *testing* lebih besar daripada MSE *training*. Hal ini menyebabkan terjadinya *overfitting*.

MSE training: 0.0005451
 MSE testing : 0.0004595

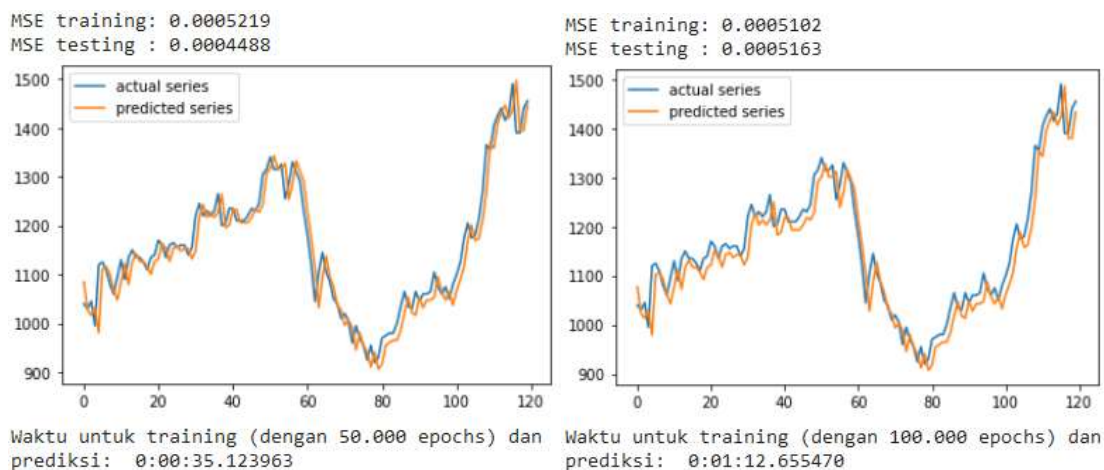


Waktu untuk training (dengan 10.000 epochs) dan prediksi: 0:00:22.282018

MSE training: 0.0005384
 MSE testing : 0.0004611



Waktu untuk training (dengan 15.000 epochs) dan prediksi: 0:00:13.533809



Dari keempat grafik di atas, terlihat bahwa pada epochs 100.000 menghasilkan model yang tidak akurat jika dibandingkan dengan nilai epochs lainnya. Hal ini disebabkan karena adanya *overfitting* pada model. Untuk ketiga percobaan lainnya, diperoleh perbedaan hasil yang tidak signifikan. Akan tetapi jika dilihat dari grafik, model yang bagus ada pada epochs 15.000 karena memberikan selisih terkecil antara *MSE training* dan *MSE testing* jika dibandingkan dengan epochs 10.000. Selain itu, epochs 15.000 memberikan hasil yang lebih akurat jika dibandingkan dengan epochs 50.000 karena diperoleh data prediksi yang lebih mendekati data aktual. Dengan demikian, model yang bagus untuk prediksi pergerakan harga saham PGAS adalah dengan memilih $\alpha = 10$, $ts = 1$, $H1 = 4$, $H2 = 4$, dan epochs sebesar 15.000.

4. KESIMPULAN

Kesimpulan harus mengindikasikan secara jelas hasil-hasil yang diperoleh dan kelebihan dan kekurangannya.

Kesimpulan berupa paragraf, **tidak boleh** berbentuk point-point atau bullet atau numbering.

5. SARAN

Bagian ini adalah opsional. Apabila ada maka saran-saran berisi saran penelitian lebih lanjut untuk menutup kekurangan penelitian saat ini atau pengembangan dari penelitian yang sudah dilakukan.

DAFTAR PUSTAKA

- [1] D. H. Zulfikar and A. Harjoko, "Perbandingan Kapasitas Pesan pada Steganografi DCT Sekuensial dan Steganografi DCT F5 dengan Penerapan Point Operation Image Enhancement," *IJCCS (Indonesian J. Comput. Cybern. Syst.*, vol. 10, no. 1, p. 35, Jan. 2016 [Online]. Available: <https://jurnal.ugm.ac.id/ijccs/article/view/11187>. [Accessed: 16-Feb-2017]
- [2] M. Thierry and T. K. Priyambodo, "SMS and Web-Based e-Government Model Case Study: Citizens Complaints Management System at District of Gihosha –Burundi," *IJCCS (Indonesian J. Comput. Cybern. Syst.*, vol. 11, no. 1, p. 67, Jan. 2017 [Online]. Available: <https://journal.ugm.ac.id/ijccs/article/view/17167>. [Accessed: 16-Feb-2017]
- [3] T. Wachowicz and P. Błaszczuk, "TOPSIS Based Approach to Scoring Negotiating Offers in Negotiation Support Systems," *Gr. Decis. Negot.*, vol. 22, no. 6, pp. 1021–1050, Nov. 2013 [Online]. Available: <http://link.springer.com/10.1007/s10726-012-9299-1>

- [4] H. Núñez, M. Sánchez-Marrè, U. Cortés, J. Comas, M. Martínez, I. Rodríguez-Roda, and M. Poch, "A comparative study on the use of similarity measures in case-based reasoning to improve the classification of environmental system situations," *Environ. Model. Softw.*, vol. 19, no. 9, pp. 809–819, 2004.
- [5] S. Baskara, D. Lelono, and T. W. Widodo, "Pengembangan Hidung Elektronik untuk Klasifikasi Mutu Minyak Goreng dengan Metode Principal Component Analysis," *IJEIS (Indonesian J. Electron. Instrum. Syst.)*, vol. 6, no. 2, p. 221, Oct. 2016 [Online]. Available: <https://jurnal.ugm.ac.id/ijeis/article/view/15347>. [Accessed: 30-May-2017]
- [6] D. B. Widyantara, R. Sumiharto, and S. B. Wibowo, "Purwarupa Sistem Kendali Kestabilan Pesawat Tanpa Awak Sayap Tetap Menggunakan Robust PID," *IJEIS (Indonesian J. Electron. Instrum. Syst.)*, vol. 6, no. 2, p. 139, Oct. 2016 [Online]. Available: <https://jurnal.ugm.ac.id/ijeis/article/view/15260>. [Accessed: 30-May-2017]
- [7] U. W. T. P. Putro, T. K. Priyambodo, and R. Sumiharto, "Pengembangan Antarmuka Stasiun Pemantauan Pesawat Tanpa Awak Menggunakan Aplikasi Android," *IJEIS (Indonesian J. Electron. Instrum. Syst.)*, vol. 4, no. 2, pp. 113–122, 2014 [Online]. Available: <https://jurnal.ugm.ac.id/ijeis/article/view/7110>. [Accessed: 08-May-2017]
- [8] P. S. Ardiantara, R. Sumiharto, and S. B. Wibowo, "Purwarupa Kontrol Kestabilan Posisi dan Sikap pada Pesawat Tanpa Awak Menggunakan IMU dan Algoritma Fusion Sensor Kalman Filter," *IJEIS (Indonesian J. Electron. Instrum. Syst.)*, vol. 4, no. 1, pp. 25–34, 2014 [Online]. Available: <https://jurnal.ugm.ac.id/ijeis/article/view/4219>. [Accessed: 08-May-2017]
- [9] I. Dwicahyo Pratomo, A. Rouf, and T. Wahyu Supardi, "Pengukuran Jarak Lubang Pada Benda Padat Menggunakan Sensor Ultrasonik," *IJEIS (Indonesian J. Electron. Instrum. Syst.)*, vol. 6, no. 1, p. 81, Apr. 2016 [Online]. Available: <https://jurnal.ugm.ac.id/ijeis/article/view/10774>. [Accessed: 25-Apr-2017]
- [10] T. Nur Syahril Sidiq, A. Rouf, and T. Wahyu Supardi, "Sistem Deteksi Bentuk Kecacatan Benda Padat Menggunakan Teknik Variasi Sudut Ultrasonik," *IJEIS (Indonesian J. Electron. Instrum. Syst.)*, vol. 6, no. 1, p. 69, Apr. 2016 [Online]. Available: <https://jurnal.ugm.ac.id/ijeis/article/view/10773>. [Accessed: 25-Apr-2017]
- [11] N. D. Putranti and E. Winarko, "Analisis Sentimen Twitter untuk Teks Berbahasa Indonesia dengan Maximum Entropy dan Support Vector Machine," *IJCCS (Indonesian J. Comput. Cybern. Syst.)*, vol. 8, no. 1, pp. 91–100, 2014 [Online]. Available: <https://jurnal.ugm.ac.id/ijccs/article/view/3499>. [Accessed: 21-Apr-2017]
- [12] M. P. Allwine, and I. J. Tarigan, "Sistem Penunjang Keputusan Seleksi Calon Karyawan Menggunakan Metode SAW (Simple Additive Weighting) Pada PT. Delta Kristalis", *JurnalMI*, vol. 7, no. 2, pp. 159–165, Jan. 2023.