

Pemodelan *Time Series* Pergerakan Harga Saham dengan *Deep Learning*

 **Nonik Mega Sapitri^{1*}**,  **Grita Tumpi Nagari²**,  **Apriana³**

^{1,2,3} Institut Teknologi dan Sains Nahdlatul Ulama Lampung, Indonesia

 nonikmega@gmail.com, gritatumpinagari@gmail.com, aprianaa021@gmail.com

Article Information:

Received April 18, 2024

Revised May 15, 2024

Accepted June 28, 2024

Keywords: time series,
autocorrelation function,
Deep Learning, overfitting

Abstract

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.

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).

Tinjauan Pustaka

Pergerakan Harga Saham

Dalam pasar modal, hal terpenting yang harus diketahui investor adalah harga saham. Harga saham adalah harga suatu saham yang terjadi di pasar bursa pada saat tertentu yang ditentukan oleh pelaku pasar dan ditentukan oleh permintaan dan penawaran saham yang bersangkutan di pasar modal (Hartono, 2008:167). Harga saham yang ada di pasar selalu berfluktuasi, atau selalu berubah.

Pergerakan harga saham terjadi secara kontinu dan sulit untuk ditebak akan arah kelajuannya. Sebelum melakukan investasi, maka investor perlu melakukan analisa atau prediksi terhadap pergerakan harga saham tersebut dengan melihat *time series* data saham di masa lalu untuk memprediksi harga saham di masa yang akan datang. Hal ini dilakukan supaya investor tidak keliru untuk memilih saham dan juga untuk mempermudah investor dalam milih dan mengambil keputusan dalam berinvestasi.

Ada banyak sekali jenis saham yang terdapat di dalam pasar modal. Saham-saham tersebut dikelompokkan dalam berbagai sektor seperti *Banking*, *Consumer*, *Construction*, *Property*, *Resources* dan masih ada sektor lainnya. Pada penelitian ini, akan dilakukan pemodelan *time series* pergerakan harga saham dengan menggunakan *Pembelajaran Mendalam* (*Deep Learning*). Saham-saham yang dipilih adalah PT Indofarma (Persero) Tbk (INAF), Surya Citra Media Tbk (SCMA), dan Perusahaan Gas Negara Tbk (PGAS).

1. PT Indofarma (Persero) Tbk (INAF)



PT Indofarma (Persero) Tbk. (IDX: INAF) merupakan perusahaan multinasional yang memproduksi farmasi dan bermarkas di Jakarta, Indonesia. Perusahaan ini didirikan pada tahun 1918 dengan nama pabrik Obat Manggarai.

Pada tahun 1950, Pabrik Obat Manggarai ini diambil alih oleh Pemerintah Republik Indonesia dan dikelola oleh Departemen Kesehatan. Pada tahun 1979, nama pabrik obat ini diubah menjadi Pusat Produksi Farmasi Departemen Kesehatan. Kemudian, berdasarkan Peraturan Pemerintah Republik Indonesia (PP) No.20 tahun 1981, Pemerintah menetapkan Pusat Produksi Farmasi Departemen Kesehatan menjadi Perseroan Umum Indonesia Farma (Perum Indofarma). Selanjutnya pada tahun 1996, status badan hukum Perum Indofarma diubah menjadi Perusahaan (Persero). Seperti yang kita ketahui dari namanya, perusahaan ini menghasilkan berbagai macam produk farmasi.

2. PT Surya Citra Media Tbk (SCMA)



PT Surya Citra Media Tbk (IDX: SCMA) (sebelumnya bernama **PT Sindo Citra Media** dan **PT Cipta Aneka Selaras**) adalah perusahaan yang bergerak dalam industri media berbasis konten. PT Surya Citra Media Tbk, atau selanjutnya disebut 'Perseroan', didirikan pada 22 Juli 1990 sebagai PT Sindo Citra Media dengan fokus bidang usaha meliputi jasa multimedia, hiburan dan komunikasi, terutama di bidang pertelevisian.

Perusahaan ini memiliki stasiun televisi terrestrial swasta nasional SCTV dan Indosiar telah tercatat publik di Bursa Efek Jakarta (sekarang Bursa Efek Indonesia) dengan IDX: SCMA sejak tanggal 16 Juli 2002 sebagai papan utama.

3. PT Perusahaan Gas Negara Tbk (PGAS)



PT Perusahaan Gas Negara Tbk. (disingkat **PGN**, IDX: PGAS) adalah sebuah perusahaan yang bergerak di bidang transmisi dan distribusi gas bumi. Semula perusahaan gas di Indonesia adalah perusahaan gas swasta Belanda yang bernama I.J.N. Eindhoven & Co berdiri pada tahun 1859 dengan memperkenalkan penggunaan gas kota di Indonesia yang terbuat dari batu bara.

PGN kemudian memasuki babak baru menjadi perusahaan terbuka ditandai dengan tercatatnya saham PGN pada tanggal 15 Desember 2003 di Bursa Efek Indonesia (BEI) dan namanya resmi menjadi PT Perusahaan Gas Negara (Persero) Tbk. Pada tahun 2018, dalam rangka membentuk holding BUMN Migas, PGN menjadi anak perusahaan Pertamina dan nama resminya berganti menjadi PT Perusahaan Gas Negara Tbk.

Time Series

Time series atau runtun waktu adalah himpunan observasi data terurut dalam waktu (Hanke dan Winchern, 2005: 58). Metode *time series* adalah metode peramalan dengan menggunakan analisa pola hubungan antara variabel yang akan diperkirakan dengan variabel waktu. Suatu data *time series* dapat dilihat sebagai suatu representasi dari realisasi suatu variabel random yang biasanya mempunyai interval waktu yang sama dan diamati pada suatu periode tertentu (Ashari, 2011).

Data *time series* tersebut merupakan suatu deskripsi masa lampau dan digunakan untuk meramalkan masa depan. Artinya, kita berharap masa depan dapat dijelaskan dengan informasi yang ada pada masa lampau. Jika memang hal ini yang terjadi, maka kita dapat menawarkan suatu model matematik yang mampu merepresentasikan proses terjadinya data *time series* tersebut. Selanjutnya, kita gunakan model matematik ini untuk membuat suatu ramalan tentang masa depan.

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:

$$\gamma_k = Cov(Z_t, Z_{t+k}) = E(Z_t - \mu)(Z_{t+k} - \mu) \quad (1)$$

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

$$\rho_k = \frac{Cov(Z_t, Z_{t+k})}{\sqrt{Var(Z_t)} \sqrt{Var(Z_{t+k})}} = \frac{\gamma_k}{\gamma_0} \quad (2)$$

Pembelajaran Mendalam (Deep Learning)

Deep learning merupakan model *Artificial Neural Network* (ANN) dengan jumlah hidden layers minimal dua buah. Setiap layer (hidden layer dan output layer) akan tersusun dari beberapa neuron yang kemudian akan dimodelkan sebagai sebuah Perceptron. Karena itu upaya seseorang untuk memahami *deep learning* harus dimulai dari pemahaman terhadap model Perceptron. Bila ini tidak dilakukan maka model *deep learning* akan dipandang sebagai *black box* yang penuh misteri.

Model Perceptron ini tidak lain merupakan bentuk khusus dari model nonlinier di Ekonometrika. Di dalam sebuah model *deep learning* kadang akan ditemui beribu-ribu Perceptron. Jadi kalau di Ekonometrika biasanya hanya akan dipelajari satu buah model nonlinier (atau satu buah model Perceptron) maka pada praktek penggunaan *deep learning* bisa melibatkan beribu-ribu model nonlinier, beribu-ribu model Perceptron. Dari cara pandang ini model *deep learning* akan mempunyai kemampuan sebagai *curve fitting* yang jauh lebih umum dibandingkan sebuah model nonlinier di Ekonometrika.

Model Perceptron

Model Perceptron boleh disebut sebagai model yang paling sederhana di *Artificial Neural Network* (ANN). 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 .

$$y = f(X, w) + e \quad (3)$$

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

$$f(z) = \frac{1}{1 + \exp(-z)} \quad (4)$$

dengan

$$z = Xw \quad (5)$$

Sifat dari fungsi *Sigmoid* antara lain adalah:

$$0 < f(z) < 1, \text{ untuk } -\infty < z < \infty \quad (6)$$

$$f'(z) = f(z)(1 - f(z)) \rightarrow f'(0) = 0.25 \quad (7)$$

Model nonlinier (3) dengan $f()$ berupa fungsi *Sigmoid* (4) akan disebut dengan nama model regresi logistik. Algoritma untuk penaksiran parameter w masih tetap bisa digunakan, yaitu:

$$W^{(n+1)} = W^{(n)} - t_n P_n \gamma_n \quad (8)$$

dengan

$$\gamma_n = \frac{\partial S(w)}{\partial w} \bigg|_{W^{(n)}} \quad (9)$$

dan

$$P_n = I_K \quad (10)$$

sehingga algoritma (8) akan menjadi

$$W^{(n+1)} = W^{(n)} - t_n \gamma_n \quad (11)$$

Bila bentuk algoritma (11) dibandingkan dengan algoritma (8), maka akan terlihat bahwa peranan t_n pada algoritma (11) seperti menggantikan $t_n P_n$ pada algoritma (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 (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

$$\frac{\partial S(W)}{\partial w_i} \bigg|_{w_i^{(n)}} > 0 \quad (12)$$

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.

Tujuan Eksperimen

Tujuan eksperimen ini adalah untuk memperoleh hasil prediksi pergerakan harga saham yang baik. Secara terperinci, berdasarkan rumusan masalah di atas, maka pada penelitian ini dilakukan beberapa hal berikut:

1. Melakukan pemodelan *time series* pergerakan harga saham dengan menggunakan *Pembelajaran Mendalam (Deep Learning)*. Saham yang digunakan pada penelitian ini adalah PT Indofarma (Persero) Tbk (INAF), Surya Citra Media Tbk (SCMA), dan Perusahaan Gas Negara Tbk (PGAS).
2. Menentukan beberapa parameter yang mempengaruhi akurasi prediksi pergerakan harga saham. Pada penelitian ini, diinginkan data hasil prediksi yang mendekati dengan data aktual.

METODE

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. 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*.

HASIL DAN PEMBAHASAN

Penelitian ini memodelkan *time series* pergerakan harga beberapa saham dengan menggunakan *Deep Learning*. Selanjutnya ditentukan parameter-parameter yang cocok untuk model tersebut yang dapat mempengaruhi akurasi prediksi pergerakan harga saham. Adapun hasil serta analisa dari pemodelan penelitian ini diuraikan pada bahasan berikut.

1. PT Indofarma (Persero) Tbk (INAF)

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

Tabel 1. Statistik deskriptif dari 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.

Autocorrelation Function (ACF)



Gambar 1. *Autocorrelation Function* Saham INAF

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.


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).

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


Tabel 2. Hasil Plot Saham INAF dengan *Deep Learning*

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 2**, 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*.



Gambar 2. INAF dengan epochs 10.000



Gambar 3. INAF dengan epochs 15.000

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*.

2. 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

Tabel 3. Statistik Deskriptif dari Saham SCMA

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)



Gambar 4. *Autocorrelation Function* Saham SCMA

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.

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

Tabel 4. Hasil Plot Saham SCMA dengan *Deep Learning*


Berdasarkan **Tabel 4**, 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.




Gambar 5. SCMA dengan epochs 10.000



Gambar 6. SCMA dengan epochs 15.000



Gambar 7. SCMA dengan epochs 50.000



Gambar 8. SCMA dengan epochs 100.000

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.

3. 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

Tabel 5. Statistik Deskriptif dari Saham PGAS

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)



Gambar 9. *Autocorrelation Function* Saham PGAS

Seperti halnya saham INAF dan SCMA, berdasarkan **Gambar 9**, 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.


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

Tabel 6. Hasil Plot Saham PGAS dengan *Deep Learning*

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

Gambar 10. PGAS dengan epochs 10.000


MSE training: 0.0005384
MSE testing : 0.0004611



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

Gambar 11. PGAS dengan epochs 15.000


MSE training: 0.0005219
MSE testing : 0.0004488



Waktu untuk training (dengan 50.000 epochs) dan prediksi: 0:00:35.123963

Gambar 12. PGAS dengan epochs 50.000

MSE training: 0.0005102
MSE testing : 0.0005163



Waktu untuk training (dengan 100.000 epochs) dan prediksi: 0:01:12.655470

Gambar 13. PGAS dengan epochs 100.000

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.

KESIMPULAN

Dari hasil dan analisis penelitian yang telah dijabarkan, maka dapat disimpulkan bahwa hasil prediksi pergerakan harga saham yang baik adalah tidak terjadinya *overfitting* pada model. Hal ini dapat dilihat berdasarkan selisih yang kecil antara *MSE training* dan *MSE testing*. Namun, perlu dilihat juga grafik hasil plot dari model karena model yang bagus adalah memberikan hasil data prediksi yang mendekati data aktual.

DAFTAR PUSTAKA

- Ashari. 2011. Penerapan Metode Time Series dalam Simulasi Forecasting Perkembangan Akademik Mahasiswa. *Jurnal Science*, Hal. 10.
- Hanke, J. E. & Wichers, D. W. 2005. *Business Forecasting Eight Edition*. New Jersey: Pearson Prentice hall.
- Hartono, Jogiyanto. 2008. *Teori Portofolio Dan Analisis Investasi*. BPFE, Yogyakarta.
- J. B. Heaton. 2016. *Deep Learning in Finance*. no. February, pp. 1–20.
- L. Troiano, E. M. Villa, and V. Loia. 2018. Replicating a Trading Strategy by Means of LSTM for Financial Industry Applications. *IEEE Transactions on Industrial Informatics*, vol. 14, no. 7, pp. 3226– 3234.
- Makridakis, S., Wheelwright, S.C., McGee, V.E. 1999. *Metode dan Aplikasi Peramalan, Jilid 1 Edisi Kedua*. Ir. Untung Sus Andriyanto, penerjemah. Jakarta. Erlangga. *Terjemahan dari: Forecasting, 2nd Edition*.
- Mudjiyono. 2012. Investasi dalam Saham & Obligasi dan Meminimalisasi Risiko Sekuritas pada Pasar Modal Indonesia. *Jurnal STIE Semarang*, Vol 4, No 2, Hal 2-5