

# ANALISIS PREDIKSI HARGA SAHAM SEKTOR PERBANKAN MENGUNAKAN ALGORITMA *LONG-SHORT TERMS MEMORY* (LSTM)

Prismahardi Aji Riyantoko <sup>(1)</sup>, Tresna Maulana Fahrudin <sup>(1)</sup>, Kartika Maulida Hindrayani <sup>(1)</sup>, Eristya Maya Safitri <sup>(1,2)</sup>

(1) Prodi Sains Data, Fakultas Ilmu Komputer, UPN "Veteran" Jawa Timur

(2) Sistem Informasi, Fakultas Ilmu Komputer, UPN "Veteran" Jawa Timur

Alamat Instansi

e-mail : [prismahardi.aji.ds@upnjatim.ac.id](mailto:prismahardi.aji.ds@upnjatim.ac.id)<sup>(1)\*</sup>

## Abstract

*Investing, buying or selling activity on the stock exchange requires knowledge and skill in the field of data analysis. The movement of the curve in the stock market place is very dynamic, hence it requires data modelling to predict stock prices in order to get a price with a high degree of accuracy. Currently, machine learning has a good level of accuracy in processing and predicting data. In this work, we proposed the data modelling using the Long-Short Term Memory (LSTM) algorithm to predict stock prices. The main purpose for this research is to analyze the accuracy of the machine learning algorithm in predicting stock price data and analyzing the number of epochs in the optimal model formation. The results of our study indicate that the LSTM algorithm has an accurate level of prediction as indicated by the RMSE value and the data model obtained the variation of the epochs value.*

**Keywords : LSTM Algorithm, Stock Price, Analysis Prediction, Machine Learning**

Untuk melakukan investasi atau jual beli di bursa saham memerlukan pemahaman dibidang analisis data. Pergerakan kurva pada pasar saham sangat dinamis, sehingga memerlukan pemodelan data untuk melakukan prediksi harga saham agar mendapatkan harga dengan tingkat akurasi yang tinggi. *Machine Learning* pada saat ini memiliki tingkat keakuratan yang baik dalam mengolah dan memprediksi data. Pada penelitian ini kami melakukan pemodelan data menggunakan algoritma *Long-Short Term Memory* (LSTM) untuk memprediksi harga saham. Tujuan utama pada jurnal ini adalah untuk menganalisis tingkat keakuratan algoritma *Machine Learning* dalam melakukan prediksi data harga saham serta melakukan analisis pada banyaknya *epochs* dalam pembentukan model yang optimal. Hasil penelitian kami menunjukkan bahwa algoritma LSTM memiliki tingkat prediksi yang akurat dengan ditunjukkan pada nilai RMSE serta model data yang di dapatkan pada variasi nilai *epochs*.

**Kata Kunci : Algoritma LSTM, Harga Saham, Analisis Prediksi, Machine Learning**

## 1. PENDAHULUAN

Perekonomian suatu negara sangat dipengaruhi oleh peranan pasar modal. Pasa modal merupakan suatu instrumen keuangan jangka panjang yang didalamnya terdapat transaksi jual beli saham, sarana pendanaan bagi perusahaan, serta sebagai sarana untuk kegiatan investasi. Beberapa negara yang mengikuti system ekonomi pasar, sumber kemajuan ekonomi negara tersebut sangat dipengaruhi oleh pasar modal, karena pasar modal menjadi sumber dana alternatif bagi perusahaan-perusahaan yang bergabung didalamnya. Sedangkan perusahaan tersebut secara nasional telah membentuk suatu *Gross Domestic Product* (GDP). Jadi, dengan perkembangan suatu pasar modal, peningkatan GDP dapat mendorong kemajuan ekonomi suatu negara (Widoatmodjo, 2008).

Didalam pasar modal, salah satu bentuk investasi yang bisa dilakukan adalah investasi dalam bentuk saham. Saham merupakan bentuk penyertaan dari suatu perusahaan atau badan usaha yang melakukan tanam modal didalam pasar modal (Bursa Efek Indonesia, 2020). Bursa Efek Indonesia merupakan salah satu bursa saham yang terdapat di Indonesia. Salah satu sektor industri saham dari tahun ke tahun yang memiliki prospek yang baik dan stabil terdapat pada sektor perbankan. Berdasarkan *Forbes 2000 The World Biggest Companies* yang memuat lebih dari 2000 perusahaan publik terbesar didunia, terdapat tiga bank dibawah BUMN yang masuk didalam *Forbes 2000* yaitu, Bank Rakyat Indonesia, Bank Negara Indonesia dan Bank Mandiri. Melihat kondisi saham yang terus mengalami fluktuasi di setiap harinya, membuat para investor

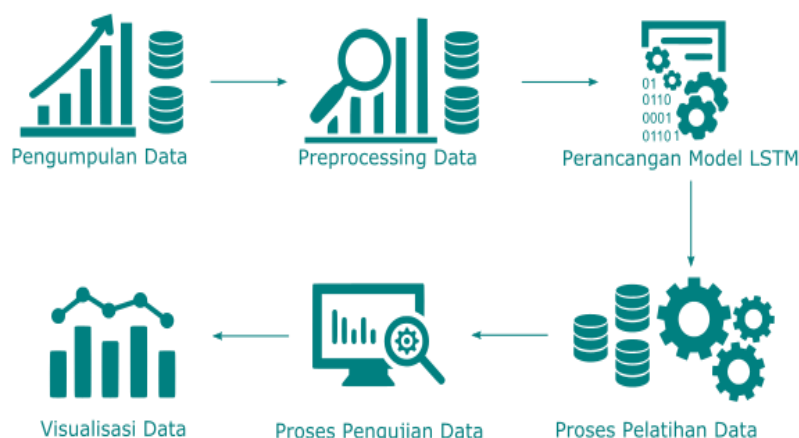
perlu memperhatikan dan mempelajari data perbankan tersebut di masa lalu, sebagai strategi untuk berinvestasi. Hal tersebut sangat penting dilakukan karena investor dapat mengetahui prospek keadaan harga saham yang ada di dalam perusahaan tersebut. Investor dapat melakukan analisis secara fundamental terhadap perusahaan perbankan yang akan menjadi muara investasi. Oleh karena itu, metode yang tepat untuk melakukan analisis adalah dengan menggunakan metode peralaman atau prediksi.

Banyak metode yang bisa dilakukan dalam memprediksi harga saham. *Machine Learning* menjadi salah satu metode untuk melakukan pendekatan dalam memprediksi harga saham. *Machine Learning* merupakan sub dari *Artificial Intelligence* yang memiliki tujuan untuk meningkatkan pengetahuan atau performa (Provost & Fawcett, 2013). *Recurrent Neural Network* (RNN) merupakan salah satu algoritma dari *Machine Learning*. RNN memiliki tingkat keakuratan yang tinggi untuk melakukan prediksi data dalam bentuk *time series* (Cao et al., 2019). Salah satu algoritma yang dikembangkan berdasarkan algoritma RNN adalah algoritma *Long-Short Term Memory* (LSTM), dimana algoritma tersebut dapat mengekstraksi informasi dari data.

Penelitian terdahulu yang dilakukan oleh Fauzi (2019), dimana beliau melakukan prediksi model dengan algoritma LSTM untuk beberapa variasi epoch. Dari penelitian tersebut dengan menggunakan 20 Epoch, menghasilkan MSE sebesar 0,00019 dan RMSE sebesar 0,014. Sehingga, berdasarkan variasi epoch menghasilkan tidak terlalu signifikannya perubahan nilai MSE dan RMSE. Dilain hal, penelitian yang dilakukan oleh Suyudi et al (2019) dengan melakukan 3 tahap dalam memprediksi yaitu *pra-proses*, proses pelatihan data dan proses pengujian. Hasil penelitian tersebut menunjukkan bahwa metode RNN kurang baik dalam memprediksi harga saham. Didalam penelitian Arfan & Lussiana (2020), dijelaskan bahwa semakin besar rentang data yang digunakan dalam SVM, maka semakin besar nilai MSE yang dihasilkan. Sedangkan untuk nilai MSE yang dihasilkan LSTM memiliki nilai yang sama walaupun menggunakan rentang data yang berbeda. Melihat hasil prediksi saham menunjukkan nilai kesalahan yang kecil maka disimpulkan bahwa LSTM mampu menanggulangi ketergantungan jangka Panjang dan mampu memprediksi harga saham dengan hasil yang akurat.

Dengan demikian, dalam penelitian ini akan dilakukan beberapa tahap uji coba, diantaranya *pre-proses*, pemodelan data LSTM, proses pelatihan data, proses pengujian data, dan visualisasi data. Pada tahap awal penelitian ini, diambil data dari yahoo finance untuk data saham bank yang berada dibawah BUMN diantaranya BRI, BNI, BTN, dan Mandiri. Data saham diambil dari tahun 2015-2019. Tahap kedua, dilakukan proses pembagian data pelatihan dan data pengujian, dimana 80% (1006 data) untuk data pelatihan dan 20% (251 data) untuk data pengujian. Dalam proses uji coba, kami menggunakan tiga *optimizer* yang berbeda diantaranya Adam, RMSProp, dan SGD. Selain itu, uji coba juga menggunakan variasi epochs, diantaranya 25, 50, 75, dan 100. Tahap terakhir, melakukan visualisasi data uji coba dengan menampilkan data pelatihan, data actual, dan prediksi.

## 2. METODE PENELITIAN



Gambar 1. Rancangan Sistem Pengolahan Data

Data saham diperoleh dari *yahoo finance* dengan melakukan pengambilan data saham perbankan yang berada dibawah BUMN diantaranya BRI, BNI, BTN, dan Mandiri dari Januari 2015 hingga Desember 2019. Data yang diperoleh meliputi kolom tanggal, pembukaan harga saham, harga tertinggi, harga terendah, volume, penutupan harga, serta *adj close* atau penutupan harga meliputi *dividen* dan *stock split*. Berdasarkan data tersebut akan masuk kedalam pre-proses pengelompokan data atau biasa yang disebut dengan segmentasi. Setelah langkah tersebut selesai, maka dilakukan perancangan model LSTM yang merupakan bagian dari *Recurrent Neural Network (RNN)*. Setelah pemodelan data, dilakukan proses pelatihan dan proses pengujian data dengan rasio pembagian data 80% dan 20%.

### 2.1. Pengumpulan Data


Tabel 1. Data Saham BRI

Date	Open	High	Low	Close*	Adj Close**	Volume
27/12/2019	4.380	4.440	4.380	4.430	4.263,68	56.465.900
26/12/2019	4.420	4.450	4.400	4.410	4.244,43	50.234.000
23/12/2019	4.450	4.470	4.360	4.450	4.282,93	123.276.700
⋮	⋮	⋮	⋮	⋮	⋮	⋮
06/01/2015	2.310	2.325	2.300	2.305	1.334,90	65.091.500
05/01/2015	2.320	2.340	2.315	2.320	1.343,59	49.569.000
02/01/2015	2.305	2.345	2.305	2.330	1.349,38	45.155.000

Data saham perbankan berasal dari *yahoo finance*, meliputi data saham BRI, BNI, BTN, serta Mandiri. Data saham yang diambil meliputi kolom *date*, *open*, *close*, *high*, *low*, *adj close*, *volume*. *Date* merupakan data tanggal, bulan, dan tahun untuk data saham yang diterbitkan dalam waktu sesuai pembukaan pasar saham. *Open* merupakan data harga saham pertama kali melakukan transaksi pada hari itu. *High* dan *Low* merupakan pergerakan harga harian untuk melakukan posisi jual atau beli saham secara rasionalitas. *Close* merupakan harga saham pada saat semua perdagangan di bursa saham berakhir. *Adj Close* merupakan harga pada saat penutupan harga saham yang mempengaruhi pembagian dividen dan stock split. *Volume* merupakan seluruh jumlah lembar atau *lot* saham pada periode tertentu. Pada penelitian ini, difokuskan pada harga saham *close* atau penutupan harga saham harian sebagai acuan atau data *input* yang akan diolah untuk data pelatihan dan data pengujian.

### 2.2. Preprocessing Data


Pada proses preprocessing data akan dilakukan segmentasi atau pengelompokan data dari proses pengambilan data pada *yahoo finance*. Data yang diambil sebanyak 1257 baris dan 7 kolom berdasarkan data perbankan.



Gambar 2. Segmentasi Data Latih dan Data Uji

### 2.3. Perancangan Model LSTM

*Long Short Term Memory* (LSTM) merupakan salah satu variasi dari *Recurrent Neural Network* (RNN) yang digunakan untuk mengatasi permasalahan *hidden layer*. Inti dari algoritma LSTM adalah menggabungkan control *non-linier* dan *dependent* kedalam sel RNN (Gao et al, 2017), dilain hal untuk memastikan gradien fungsi tujuan dengan memperhatikan sinyal tidak menghilang. LSTM digunakan untuk mengatasi *vanishing gradient* atau situasi ketika *gradient* bernilai 0 atau mendekati 0 dengan melewati mekanisme *gate* (Pulver & Lyu, 2017). Algoritma LSTM menggabungkan *state* sebelumnya, dengan memori saat ini serta nilai *input*. Untuk tingkat efisiensi, LSTM mampu merekam *long-term dependencies*.



Gambar 3. Desain Algoritma Long Short Term Memory

Berdasarkan gambar 3, LSTM mempunyai tiga gate diantaranya *Forget gate* ( $f_t$ ) yang digunakan untuk menentukan informasi yang akan dieliminasi dari *cell* menggunakan *sigmoid layer* dengan mengaktifkan fungsi Relu. *Input gate* ( $i_t$ ) digunakan sebagai meneruskan informasi dari *sigmoid layer* yang akan dilakukan pembaharuan dan *tanh layer* akan dilakukan perubahan sebuah vector yang akan diperbaharui. *Output gate* digunakan untuk memaparkan isi sel memori pada proses output LSTM.

Pada proses LSTM, langkah pertama akan dilakukan pemutusan informasi dari  $C_{t-1}$  dengan menggunakan *forget gate*. Gerbang ini mempunyai tugas untuk membaca nilai  $s_{t-1}$  dan  $x_t$ , sehingga menghasilkan nilai antara 0 hingga 1, untuk setiap elemen dalam  $C_{t-1}$ . Apabila diformulakan akan membentuk persamaan sebagai berikut

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

Untuk elemen dalam  $C_{t-1}$  memungkinkan tersimpan informasi gender subyek *temporary*, sehingga kata ganti yang benar dapat digunakan. Ketika melihat subyek baru, maka elemen lama dalam  $C_{t-1}$  bisa ditiadakan.

Proses selanjutnya *input gate* melakukan pemutusan nilai mana yang akan dilakukan pembaharuan. Kemudian, untuk *tanh layer* menghasilkan kandidat vektor konteks baru  $\tilde{C}_t$ . Oleh karena itu akan dilakukan penggabungan diantara keduanya untuk membuat pembaruan ke konteks nanti. Sehingga, dalam hal ini proses tersebut dapat diformulakan sebagai berikut

$$i_t = \sigma(W_i \cdot [s_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_c \cdot [s_{t-1}, x_t] + b_c) \quad (3)$$

Saat ini akan dilakukan untuk memperbaharui konteks lama  $C_{t-1}$  ke dalam konteks baru  $C_t$ . Untuk menghilangkan hal-hal yang sudah diputuskan maka proses *forget gate* ( $f_t$ ) pada persamaan (1) dikalikan dengan konteks lama pada persamaan (2) dan persamaan (3). Maka, akan diperoleh persamaan baru sebagai berikut

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (4)$$

Pada proses *output gate* akan dilakukan pembaharuan pada *cell* dan *sigmoid layer* untuk memutuskan bagian-bagian apa dari konteks yang akan dihasilkan. Sehingga akan diperoleh persamaan sebagai berikut ini

$$o_t = \sigma(W_o \cdot [s_{t-1}, x_t] + b_o) \quad (5)$$

$$s_t = o_t * \tanh(C_t) \quad (6)$$

Dimana untuk *sigma* ( $\sigma$ ) merupakan fungsi aktivasi *sigmoid* dengan rentang nilai antara -1 dan 1 lalu *tanh* merupakan fungsi aktivasi target dengan nilai (-1,1) sedangkan  $W_t, W_i, W_c, W_o$  merupakan bobot matriks dan untuk  $s_{t-1}$  merupakan *hidden state* sebelumnya serta  $b_t, b_i, b_c, b_o$  merupakan vektor bias.

### 3. HASIL DAN PEMBAHASAN

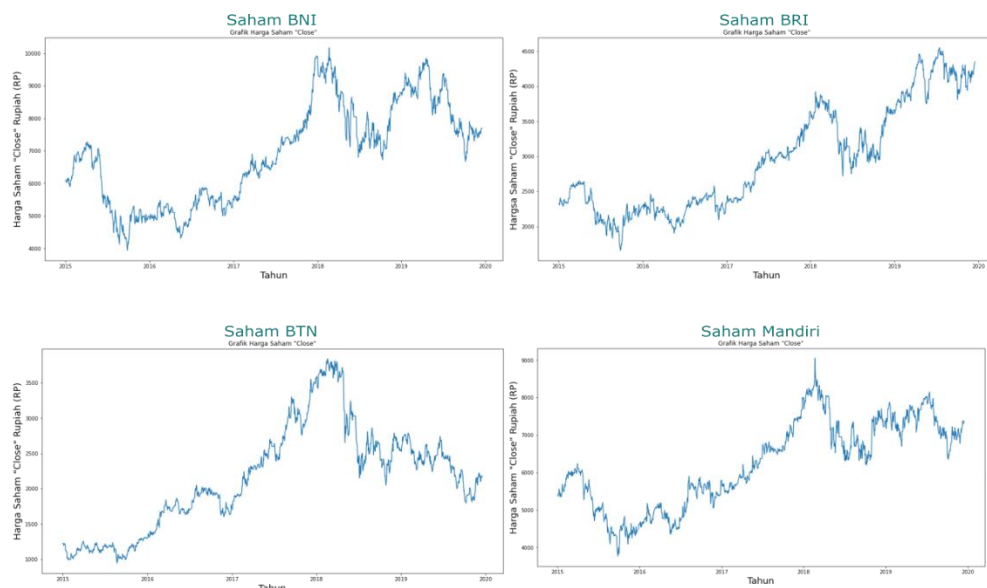
Pada subbab ini akan dilakukan pembahasan mengenai hasil penelitian yang dilakukan dengan menggunakan dataset perbankan yang berada dibawah BUMN diantaranya BRI, BNI, BTN, serta Mandiri dari tahun 2015-2019 dengan melakukan pembagian data latih 80% dan data pengujian 20% dengan menekankan pada data saham kolom harga *close*. Pada proses menjalankan algoritma LSTM dibagi menjadi beberapa proses diantara penggunaan *optimizer* Adam, SGD serta Rmsprop dengan variasi epoch 25, 50, 75 serta 100.

#### 3.1. Dataset Saham Perbankan

Dataset yang digunakan dalam penelitian ini didapatkan dari *yahoo finance* dengan melakukan *sorting data* dari 1 Januari 2015 hingga 30 Desember 2019. Proses analisis data dengan menggunakan *machine learning* ini di fokuskan pada kolom harga *close*, dimana hal ini merupakan penutupan harga harian pada setiap data saham.

Tabel 2. Data Saham Close Perbankan

Date	BRI – (Close)	BNI – (Close)	BTN – (Close)	Mandiri – (Close)
27/12/2019	4.430	7.925	2.150	7.750
26/12/2019	4.410	7.950	2.130	7.800
23/12/2019	4.450	7.925	2.120	7.725
⋮	⋮	⋮	⋮	⋮
06/01/2015	2.305	6.025	1.195	5.362
05/01/2015	2.320	6.025	1.220	5.400
02/01/2015	2.330	6.100	1.225	5.412



Gambar 4. Data Aktual untuk Saham BNI, BRI, BTN dan Mandiri

Data aktual berdasarkan dataset pada penelitian ini divisualisasikan dalam bentuk grafik dengan garis horizontal menampilkan harga saham *close* dan garis vertikal menampilkan tahun. Saham *close* untuk empat bank tersebut terendah terjadi pada tahun 2015, sedangkan harga tertinggi terjadi pada tahun 2018. Tetapi dapat dikatakan bahwa harga dari ke empat bank tersebut, saham BRI lebih stabil mengalami kenaikan dari tahun 2015-2019, dari nilai menyentuh sekitar 1.300 hingga harga 4.500 per lembar. Sedangkan untuk tiga bank lainnya juga mengalami naik turun yang mendapatkan harga rata-rata atau tengah diantara harga terendah dan tertinggi.

### 3.2. Membandingkan Antara Tiga Model Optimasi

Percobaan pada Tabel 3 menggunakan data saham empat bank dengan melakukan analisis pada model optimasi, variasi *epochs*, *loss*, serta Akurasi. Dari ke empat data saham *close* semakin tinggi nilai *epochs*, maka semakin rendah nilai *loss* yang dihasilkan, hal ini sedikit banyak mempengaruhi tingkat akurasi model optimasi. Tetapi apabila dilihat dari data percobaan di kolom akurasi dari ke empat bank tersebut, setiap model optimasi menghasilkan data akurasi yang berbeda, sehingga hal ini perlu dilakukan analisis tersendiri.

Pertama, dapat dilihat pada data model optimasi SGD. Pada hasil percobaan, semakin tinggi nilai epoch, semakin rendah tingkat *loss*-nya, sehingga mengakibatkan nilai akurasi semakin meningkat. Meskipun ada beberapa nilai yang menunjukkan nilai naik turun. Dapat disimpulkan dari data tersebut, *loss* terdapat pada data bank BRI saat nilai epoch 100 dengan *loss* 0,0013. Sedangkan untuk nilai akurasi tertinggi pada model optimasi ini adalah 61%. Hal ini ditunjukkan pada tiga bank dengan nilai epoch 100 yaitu BRI, BNI, Mandiri, tetapi pada bank BTN terjadi pada saat epoch 50.

Kedua, dapat dilihat pada model optimasi Adam. Pada hasil percobaan, semakin tinggi nilai epoch maka, semakin rendah tingkat *loss*-nya. Pada data kedua ini, nilai *loss* jauh lebih kecil dibandingkan dengan nilai *loss* pada model optimasi SGD. Tetapi dapat dilihat dari ke empat bank tersebut, nilai akurasinya selalu naik, dan hampir semua nilai akurasinya diatas 90%. Nilai akurasi terendah terjadi pada bank BRI saat epoch bernilai 25 dengan tingkat akurasi 89%, sedangkan nilai akurasi tertinggi pada dua bank, yaitu BRI dan Mandiri pada saat nilai epoch 100 dengan tingkat akurasi 95%.

Ketiga, dapat dilihat pada model RMSprop. Pada hasil percobaan, semua nilai *loss* dari keempat bank tersebut sangat rendah dibandingkan kedua model optimasi. Tetapi, untuk data akurasinya mengalami naik turun berdasarkan nilai epoch. Sehingga, jikalau dilihat model optimasi ini dengan variasi epoch semakin tinggi bisa terjadi tingkat akurasinya rendah.

**Tabel 3. Pengujian Data Saham Loss dan Akurasi**

Model Optimasi	Epochs	BRI		BNI		BTN		Mandiri	
		Loss	Akurasi	Loss	Akurasi	Loss	Akurasi	Loss	Akurasi
SGD	25	0,0014	57%	0,0023	57%	0,0021	49%	0,0021	55%
	50	0,0015	52%	0,0022	52%	0,0017	61%	0,002	56%
	75	0,0014	57%	0,0022	57%	0,0017	60%	0,0016	59%
	100	0,0013	61%	0,0019	61%	0,0017	58%	0,0017	61%
ADAM	25	4,28E-04	89%	6,27E-04	90%	5,40E-04	90%	6,43E-04	92%
	50	4,75E-04	92%	5,48E-04	91%	4,18E-04	91%	6,00E-04	92%
	75	3,76E-04	93%	5,89E-04	92%	3,95E-04	92%	5,09E-04	94%
	100	3,44E-04	95%	4,97E-04	92%	4,31E-04	92%	4,92E-04	95%
RMSprop	25	5,51E-04	95%	8,11E-04	92%	7,14E-04	84%	7,54E-04	86%
	50	4,67E+00	85%	6,54E-04	91%	5,90E-04	86%	6,85E-04	91%
	75	4,48E+00	53%	5,99E-04	79%	5,31E-04	90%	5,95E-04	88%
	100	4,44E+00	46%	5,52E-04	78%	4,91E-04	92%	5,63E-04	86%

Pada data percobaan Tabel 4 dapat dilihat bahwa dalam proses pelatihan dan pengujian data dipengaruhi oleh banyaknya epoch, model optimasi, waktu komputasi, serta RMSE. Dari ketiga model optimasi semakin tinggi nilai epoch maka semakin tinggi waktu komputasi yang dihasilkan. Untuk waktu komputasi tercepat dengan nilai 103 detik pada model optimasi RMSprop di saham bank Mandiri saat nilai epoch 25. Sedangkan untuk waktu komputasi terlama pada saat epoch 100 di saham bank BRI dengan waktu komputasi 619 detik.


Tetapi apabila dilihat dari data RMSE memiliki nilai yang bervariasi, ada yang mengalami nilai naik turun bahkan ada yang mengalami data RMSE monoton turun. Dalam hal monoton turun dapat menunjukkan bahwa data prediksi yang dihasilkan semakin akurat. Pertama pada model optimasi SGD, data RMSE mengalami penurunan data, tetapi tidak selalu mengalami penurunan, karena ada juga data saham yang mengalami kenaikan. Begitu juga terjadi pada model optimasi RMSprop. Di lain hal, data RMSE model optimasi Adam lebih stabil atau monoton turun untuk nilai RMSEnya, hal ini dapat dikatakan model prediksi yang dihasilkan semakin akurat.

Untuk nilai terendah RMSEnya pada data bank BTN dengan nilai 48,82 pada saat nilai epoch 100, sedangkan nilai RMSE tertinggi terjadi pada bank BNI dengan nilai 325,82 pada saat nilai epoch 25. Tetapi dapat disimpulkan bahwa model optimasi mempengaruhi waktu komputasi, dari waktu komputasi yang dihasilkan sangat mempengaruhi nilai RMSE. Semakin tinggi waktu komputasi yang dihasilkan, maka semakin tinggi pula nilai RMSE yang dihasilkan.

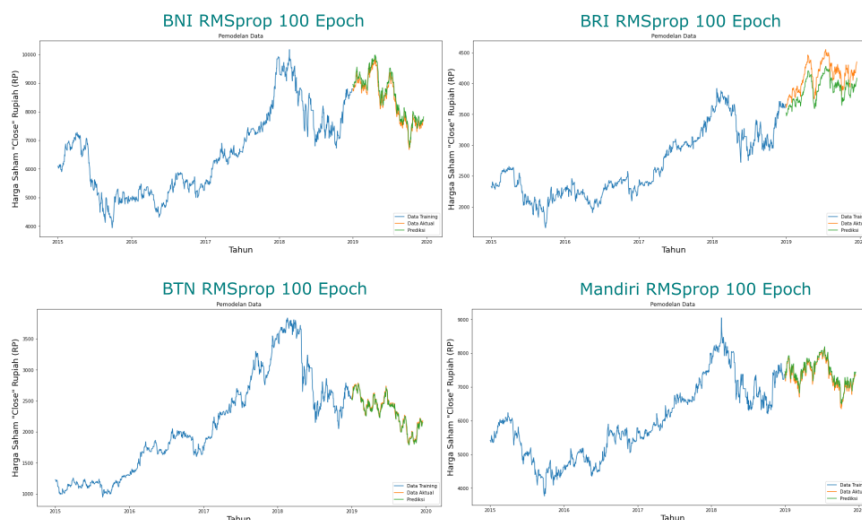
Pada data gambar 5, dapat dilihat pada saat percobaan menggunakan model optimasi Adam dengan nilai epoch 100. Dari ke empat grafik tersebut, antara data pengujian dan data prediksi dengan menggunakan algoritma LSTM sangat tidak jauh berbeda. Dimana untuk data pengujian atau 20% dari data aktual berwarna *orange* berjalan dari tahun 2019 awal hingga akhir, garis grafik hampir berhimpitan dengan data prediksi yang berwarna hijau. Sehingga dapat dikatakan bahwa model optimasi Adam semakin tinggi nilai epoch, semakin tinggi juga tingkat akurasi.

**Tabel 4. Pengujian Data Saham Waktu Komputasi dan RMSE**

Optimizer	Epochs	BRI		BNI		BTN		Mandiri	
		Waktu Komputasi	RMSE	Waktu Komputasi	RMSE	Waktu Komputasi	RMSE	Waktu Komputasi	RMSE
SGD	25	138	149,06	125	325,82	113	141,51	128	240,71
	50	274	162,73	249	316,28	241	108,26	253	236,15
	75	423	145,18	360	317,16	313	111,46	387	214,76
	100	619	134,99	501	291,62	493	116,94	490	219,97
ADAM	25	131	79,17	122	140,22	109	62,74	126	155,72
	50	253	75,71	220	167,81	225	64,16	262	126,21
	75	382	65,12	383	139,12	293	57,86	352	121,97
	100	524	57,31	505	140,24	433	48,32	447	116,64
RMSprop	25	125	57,39	114	136,04	113	105,49	103	146,41
	50	232	83,11	211	137,85	204	56,91	243	114,83
	75	394	179,51	376	194,68	311	51,44	329	127,91
	100	494	219,57	486	194,77	430	48,82	475	140,15



**Gambar 5. Data Prediksi untuk Saham BNI, BRI, BTN dan Mandiri menggunakan model optimasi Adam dengan 100 epoch**




**Gambar 6. Data Prediksi untuk Saham BNI, BRI, BTN dan Mandiri menggunakan model optimasi RMSprop dengan 100 epoch**

Pada data Gambar 6, dapat dilihat pada saat percobaan dengan menggunakan model optimasi RMSprop dengan nilai epoch 100. Dari ke empat grafik tersebut, data pengujian atau actual dengan data prediksi pada saham BRI mengalami jarak yang renggang, artinya bahwa data prediksi menjauhi data actual. Karena apabila dilihat pada tabel 4, nilai RMSE bank BRI 219,57, sehingga sangat besar. Oleh karena itu prediksi yang dihasilkan kurang baik, sehingga garis data prediksi dan actual sedikit renggang. Dalam ilmu peralaman, dapat dikatakan prediksi tersebut kurang akurat.

Pada data Gambar 7, dapat dilihat pada saat percobaan dengan menggunakan model optimasi SGD dengan nilai epoch 100. Berdasarkan pada Tabel 4, untuk nilai RMSE diantara 100 hingga 300, maka menghasilkan model prediksi yang kurang akurat. Sehingga grafik yang dihasilkan tetap mengikuti data pengujian atau actual, tetapi garis yang dihasilkan tidak berhimpit, sehingga dapat dikatakan model optimasi SGD dengan belum akurat untuk menganalisis data saham *close*.





Gambar 7. Data Prediksi untuk Saham BNI, BRI, BTN dan Mandiri menggunakan model optimasi SGD dengan 100 epoch

## KESIMPULAN

Pada penelitian ini didapatkan beberapa percobaan diantaranya melakukan analisis pada model optimasi, variasi epoch, waktu komputasi, nilai *loss* dan akurasi, serta nilai RMSE. Variasi nilai epoch mempengaruhi waktu komputasi, semakin besar nilai epoch, maka semakin tinggi juga waktu komputasi yang dibutuhkan untuk menyelesaikan algoritma LSTM. Model optimasi juga mempengaruhi hasil setiap variasi epoch pada nilai *loss* dan akurasi. Tetapi model optimasi Adam, menunjukkan bahwa semakin tinggi nilai epoch, maka semakin rendah nilai *loss*. Oleh karena itu, semakin rendah nilai *loss*, semakin tinggi tingkat akurasi prediksi data saham yang dihasilkan. Untuk nilai RMSE juga sangat dipengaruhi oleh variasi nilai epoch dan model optimasi, tetapi dari ketiga model optimasi, model Adam dengan variasi epoch sangat menunjukkan stabil turun nilai RMSE-nya dari epoch rendah ke tinggi. Sehingga, dapat disimpulkan bahwa, variasi epoch dengan menggunakan model optimasi Adam pada algoritma LSTM menghasilkan nilai RMSE yang monoton turun, sehingga menghasilkan nilai prediksi saham *close* yang tinggi.

## DAFTAR PUSTAKA

- A. Palver and S. Lyu. 2017. *LSTM with working memory*. Proceedings of the International Joint Conference on Neural Networks vol-May 2017, pp. 845-851.
- Bursa Efek Indonesia. 2010. Retrieved from Saham: <https://www.idx.co.id/produk/saham/>
- Cao, J., Li, Z., & Li, J. 2019. *Financial Time Series Forecasting Model Based in CEEMDAN and LSTM*. *Physic A: Statistical Mechanics and its Applications*, 519: 127-139.
- Fauzi, A. 2019. *Forecasting Saham Syariah Dengan Menggunakan LSTM*. Research Article: Al-Masraf Jurnal Lembaga Keuangan dan Perbankan.
- L. Gao, Z.Guo, H. Zhang, X. Xu, and H. T. Shen. 2018. *Video Captioning with Attention-Based LSTM and Semantic Consistency*. *IEEE Transaction on Multimedia*, vol. 19, no 19, pp. 20145-2055.
- Suyudi, MAD., Djamil, EC., dan Asri Maspupah. 2019. *Prediksi Harga Saham Menggunakan Metode Recurrent Neural Network*. Makalah disajikan dalam Seminar Nasional Aplikasi Teknologi Informasi, Yogyakarta.
- Provost, F. & Fawcett, T. 2013. *Data Science and it Relationship to Big Data and Data Driven Decision Making*. *Big Data*, 1(1): 51-59.
- Widoatmodjo, S. 2008. *Cara Sehat Investasi di Pasar Modal*. Jakarta: PT Elex Media Komputindo