

STUDI PREDIKSI HARGA BITCOIN MENGGUNAKAN RECURRENT NEURAL NETWORK

L. M. Rasdi Rere, Hariyanto dan Rozi

STMIK Jakarta STI&K

Jl. BRI No.17, Radio Dalam, Kebayoran Baru, Jakarta Selatan 12140
{rasdirere267@, haryanto, roziborang75}@gmail.com

ABSTRAK

Bitcoin adalah salah satu jenis cryptocurrency yang semakin dikenal dan terus meningkat pemakaiannya dalam beberapa tahun terakhir. Mata uang digital ini memungkinkan orang untuk bertukar nilai tanpa memerlukan perantara pihak ketiga. Terlepas dari banyak kelebihan yang dimiliki dibandingkan mata uang kripto lainnya, harga Bitcoin adalah kelas aset yang sangat fluktuatif karena murni hanya bergantung pada penawaran dan permintaan. Hal ini menghadirkan peluang yang menarik untuk membuat model prediksi peramalan. Dengan model sistem prediksi harga Bitcoin, investor baik institusi maupun perorangan dapat mengambil keputusan yang tepat, sehingga dapat terhindar dari kerugian yang tidak diinginkan. Penelitian ini menghadirkan salah satu metode machine learning yang populer dalam kasus data time series, yaitu Recurrent Neural Network untuk prediksi harga Bitcoin, dengan sejumlah variasi pada parameternya, menggunakan dataset yang diperoleh dari website yahoo finance. Hasil terbaik yang didapatkan adalah nilai RMSE untuk proses training 1621,95 dan test 730,42 dengan menggunakan Dense 3(128, 64, 1), persentase data training/test 90/10, serta jenis optimizer adam.

Kata Kunci: *prediksi harga Bitcoin, RNN, cryptocurrency, mata uang digital.*

PENDAHULUAN

Dalam beberapa tahun terakhir *Cryptocurrency* menjadi semakin populer dan meluas pemakaiannya, walaupun banyak kontroversi dari perkembangannya yang inovatif. *Cryptocurrency* adalah mata uang digital dimana transaksi dapat dilakukan secara online [1]. Salah satu jenis mata uang ini adalah *bitcoin*, diperkenalkan oleh Satoshi Nakamoto pada tahun 2009. Mata uang ini dirancang dengan sistem terdesentralisasi, yang berarti tidak diatur oleh pihak lain selain regulator, serta diaktifkan oleh teknologi *blockchain* dan diterapkan sebagai bentuk pembayaran *peer-to-peer* dan diamankan oleh kriptografi. Namun, pasokan *bitcoin* terbatas karena sifat *cryptocurrency* itu sendiri [2][3].

Dalam beberapa tahun terakhir, ada peningkatan permintaan untuk *bitcoin*, karena sifat dan keterbatasan pasokannya. Berdasarkan kondisi tersebut, *bitcoin* telah menjadi komoditas populer yang digunakan sebagai produk investasi serta dapat diperdagangkan dengan cara yang sama seperti pasar valuta asing atau saham.

Bitcoin adalah salah satu produk investasi dalam pertukaran mata uang kripto,

karena jika diperlakukan sama dengan mata uang lainnya, bisa berubah-ubah. Oleh karena itu, investor masih menggunakan prinsip dasar investasi yang sama yaitu “*buy low, sell high*”. Dengan prinsip ini, investor tidak membabi buta berinvestasi tanpa memperhitungkan risikonya [2].

Salah satu metode umum untuk menghitung risiko investasi adalah analisis pasar teknis. Metode ini memerlukan pengetahuan ahli untuk menganalisis *trend* dan terkadang menjadi sulit ketika datanya menjadi terlalu kompleks dan luas. Pendekatan lain yang mungkin dilakukan adalah menggunakan algoritme *machine learning* yang dapat menghasilkan model prediksi, serta memperkirakan *trend* lebih akurat tanpa pengetahuan ahli.

Saat ini sudah banyak penelitian terkait masalah prediksi bitcoin dan harga saham menggunakan *machine learning*. Xiangxi Jiang [4] melakukan prediksi harga bitcoin berbasis jam dengan menggunakan data dari 24 jam terakhir. Tiga algoritme dalam *machine learning* dibandingkan dalam penelitiannya yaitu *Multi-Layer Perceptron* (MLP), *Long Short-Term Memory* (LSTM) dan *Gated Recurrent*

Network (GRU). Hasilnya adalah kinerja MLP sedikit lebih rendah dibandingkan dengan LSTM dan GRU. Untuk memprediksi urutan estimasi belum dilakukan dalam penelitiannya, yang dapat diterapkan dalam skenario perdagangan bitcoin yang lebih umum.

Hansun dkk [5] dalam penelitian yang dilakukan menggunakan pendekatan prediksi multivariat dan tiga jaringan saraf berulang (RNN) yang berbeda, yaitu LSTM, Bi-LSTM (*bidirectional LSTM*) dan GRU. Selain itu mereka mengusulkan arsitektur jaringan dalam tiga lapisan sederhana untuk tugas regresi. Dari eksperimen pada lima *cryptocurrency* utama termasuk *bitcoin*, diperoleh hasil bahwa Bi-LSTM dan GRU memiliki hasil kinerja yang serupa dalam hal akurasi. Namun dari segi waktu eksekusi, baik LSTM maupun GRU memiliki hasil yang hampir sama, dimana GRU sedikit lebih baik dan rata-rata memiliki variasi hasil yang lebih rendah.

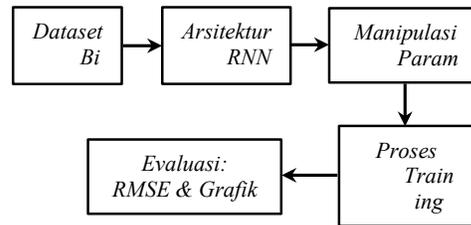
Penelitian lainnya yang terkait dengan algoritme *machine learning* dalam memprediksi harga bitcoin atau saham misalnya adalah Ramadhan dkk [6] dalam penelitiannya mengenai implementasi LSTM-RNN untuk prediksi bitcoin. Suyudi dkk [7] memprediksi harga saham dengan RNN. Shankhdhar dkk [8] mengembangkan sistem peringatan dan prediksi harga bitcoin menggunakan *Multivariate Linear Regression, Theil-Sen Regression, Huber Regression*, LSTM, GRU. Aldi dkk [9] menganalisis dan mengimplementasikan LSTM *neural network* untuk prediksi harga bitcoin. Si Chen [10] menganalisis Risiko Keuangan *Cryptocurrency* berdasarkan Deep Machine Learning. Serta Rcik Dey [11] melakukan prediksi bitcoin dengan LSTM.

Secara umum penelitian yang telah dilakukan sebelumnya, sebagian besar membandingkan metode atau algoritme yang ada dalam *machine learning*, terutama LSTM atau GRU yang merupakan varian dari RNN. Penelitian yang berhubungan dengan pemilihan fitur atau penentuan nilai parameter terbaik, masih sedikit yang melakukan. Padahal tanpa pemilihan fitur dan parameter yang tepat, kinerja suatu metode akan dapat menjadi kurang optimal. Karena itu dalam penelitian ini hanya

menggunakan algoritme RNN untuk memprediksi harga bitcoin dalam periode waktu 1, 2 dan 5 tahun, serta mendapatkan parameter terbaik dengan melakukan variasi pada parameter yang ditentukan.

METODE PENELITIAN

Prediksi harga Bitcoin yang diusulkan pada penelitian ini menggunakan pendekatan desain eksperimen. Metode ini adalah pendekatan ilmiah untuk penelitian yang memanipulasi satu atau lebih variabel yang ada, serta mengontrol dan mengukur setiap perubahan yang terjadi. Gambar 1 mengilustrasikan desain eksperimen yang digunakan dalam penelitian ini.



Gambar 1. Desain Eksperimen

Dataset Bicoin

Data yang digunakan dalam penelitian ini berasal dari *website yahoo finance*, untuk rentang waktu 1, 2 dan 5 tahun. Gambar 2 memperlihatkan dataset Bitcoin selama 1 tahun, dimulai tanggal 4 Agustus 2021 sampai dengan 4 Agustus 2022. Terdapat 7 fitur yang ada pada dataset ini yaitu *Date, Open, High, Low, Close, Adj Close* dan *Volume*.

	Date	Open	High	Low	Close	Adj Close	Volume
0	2021-08-04	38213.332031	39952.296875	37589.164063	39747.503906	39747.503906	25372562724
1	2021-08-05	39744.515625	41341.935694	37458.003906	40869.554688	40869.554688	35185031017
2	2021-08-06	40865.867188	43271.660156	39932.179688	42816.500000	42816.500000	38226483046
3	2021-08-07	42832.796875	44689.859375	42618.566406	44555.800781	44555.800781	40030862141
4	2021-08-08	44574.437500	45282.351563	43331.910156	43798.117188	43798.117188	36302664750
...
361	2022-07-31	23652.070313	24121.042678	23275.703125	23336.896484	23336.896484	23555591896
362	2022-08-01	23336.718750	23464.787109	22890.796875	23314.199219	23314.199219	25849159141
363	2022-08-02	23308.433594	23415.041016	22710.083984	22978.117188	22978.117188	28389250717
364	2022-08-03	22981.302734	23578.650391	22747.835938	22846.507813	22846.507813	26288169966
365	2022-08-04	22848.214844	23198.009766	22485.701172	22930.957031	22930.957031	25120229769

Gambar 2. Dataset Bitcoin

Fitur *Date* adalah tanggal transaksi saat ini di pasar bitcoin. Fitur *Open* adalah harga pembukaan bitcoin pada tanggal tersebut. Fitur *High* adalah nilai bitcoin tertinggi yang terjadi pada hari itu. Fitur *Low* adalah nilai bitcoin terendah yang terjadi pada hari itu. Fitur *Close*, yang

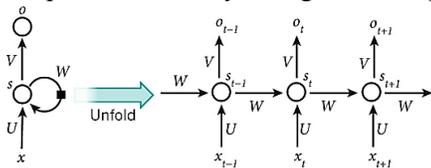
dipergunakan dalam penelitian ini, adalah harga penutupan bitcoin pada tanggal tersebut. Atribut *Adj Close* adalah harga saham penutupan yang disesuaikan. Sedangkan fitur *Volume* adalah jumlah transaksi jual beli bitcoin yang terjadi pada tanggal tersebut.

Arsitektur RNN

Dalam model jaringan saraf tradisional (*artificial neural network*), dari lapisan *input* ke lapisan tersembunyi dan kemudian ke lapisan *output*, lapisan sepenuhnya terhubung, dan *node* antara setiap lapisan tidak terhubung. Model jaringan saraf seperti ini tidak berdaya untuk masalah yang berhubungan dengan proses data berurutan (*sequential data*).

Masalah pada data yang berurutan umumnya diselesaikan dengan jenis jaringan saraf lain yang dikenal dengan RNN. Model jaringan saraf ini memproses data berurutan, yang berarti bahwa keluaran saat ini dari suatu urutan terkait dengan keluaran sebelumnya. Secara teori, RNN dapat memproses data urutan dengan panjang berapa pun.

Seperti dapat dilihat pada Gambar 3, nilai dari lapisan tersembunyi RNN tidak hanya tergantung pada *input* saat ini, tetapi juga tergantung pada nilai dari lapisan tersembunyi terakhir. Dalam hal ini, t adalah waktu, x adalah lapisan input, s adalah lapisan tersembunyi, o adalah lapisan keluaran, dan matriks W adalah nilai terakhir dari lapisan tersembunyi sebagai bobot input.



Gambar 3. Proses RNN

Proses pelatihan atau *training* pada RNN juga menggunakan algoritma propagasi balik (*back propagation*), tetapi ada sedikit perbedaan. Dalam proses pelatihan, parameter W , U , V dibagikan, serta dalam menggunakan algoritma *gradient descent*, *output* dari setiap langkah tidak hanya tergantung pada langkah

jaringan saat ini, tetapi juga tergantung pada keadaan langkah jaringan sebelumnya [12].

Pada penelitian ini, arsitektur RNN yang diujicobakan hanya untuk 3 lapisan. Hal ini berdasarkan pengamatan dan sebagai studi awal penelitian sudah memberikan hasil yang cukup memadai. Dalam eksperimen yang dilakukan akan dipergunakan tiga varian arsitektur yaitu Dense 3(32, 16, 1), Dense 3(64, 32, 1) dan Dense 3(128, 64, 1). Pada arsitektur Dense 3(32, 16, 1) berarti bahwa lapisan tersembunyi pertama terdiri dari 32 *neuron*, lapisan tersembunyi kedua 16 *neuron* serta 1 nilai pada keluarannya.

Manipulasi Parameter

Parameter yang menjadi perhatian utama dalam penelitian ini, untuk dapat dilihat pengaruhnya terhadap hasil yang diperoleh adalah banyak data yang digunakan untuk periode 1, 2 dan 5 tahun, perbandingan data training dan testing, jenis optimizer adam dan SGD, serta ukuran neuron pada Dense layer.

Proses Training dan Testing

Dalam proses *training* dan *testing*, dipergunakan jumlah persentase data dengan perbandingan 60/40, 70/30, 80/20 dan 90/10. Jumlah datanya diambil untuk tiga periode yang ditentukan yaitu 1, 2 dan 5 tahun.

Jika dipergunakan data untuk periode 1 tahun, maka jumlah dataset yang tersedia, sesuai dengan jumlah hari dalam setahun adalah 365. Jumlah data ini kemudian akan dibagi menjadi Data *Training* dan *Test* sesuai dengan perbandingan persentasenya. Untuk perbandingan 80/20, maka jumlah data yang dipakai untuk proses *training* adalah $365 \times 80\% = 292$, sedangkan untuk proses *testing* adalah $365 \times 20\% = 73$.

Evaluasi

Kinerja model dari arsitektur RNN yang dipergunakan dalam penelitian ini dievaluasi menggunakan RMSE (*Root Mean Square Error*), baik untuk data *training* maupun data *test*. Metrik RMSE mengevaluasi seberapa baik model dapat memprediksi nilai kontinu. Semakin kecil

RMSE, semakin baik kinerja model. Secara matematis persamaan untuk RMSE adalah sebagai berikut.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}}$$

Dimana n adalah jumlah total data pengamatan, y_i adalah nilai sebenarnya, sedangkan \hat{y}_i adalah nilai prediksi.

Selain menggunakan RMSE untuk mengevaluasi kinerja model arsitektur RNN yang ditentukan, data aktual, hasil proses *training* dan proses *testing* juga diperlihatkan secara bersamaan. Hal ini dilakukan untuk dapat melihat secara kualitatif melalui visual, apakah proses *training* dan *testing* yang dihasilkan dapat mengikuti prediksi pergerakan harga bitcoin dengan baik.

HASIL DAN PEMBAHASAN

Secara umum ada 4 (empat) parameter yang diujicobakan dalam penelitian prediksi harga Bitcoin ini, untuk melihat pengaruhnya terhadap arsitektur RNN yang telah ditentukan. Parameter pertama adalah banyaknya data yang digunakan, kedua adalah perbandingan data *training* dan *testing*, ketiga adalah jenis optimizer yang dipakai, serta keempat adalah ukuran neuron pada Dense layer.

Banyaknya data

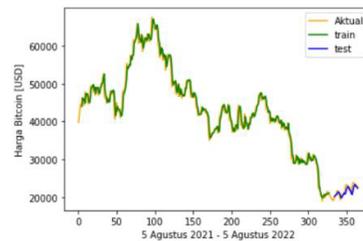
Parameter pertama yang diujicobakan dalam penelitian ini adalah banyaknya data yang dipergunakan, pada rentang data 1, 2 dan 5 tahun. Pada ketiga percobaan yang dilakukan, dipergunakan optimizer adam, persentase data *training* dan *testing* 90/10 serta Dense 3(64, 32, 1).

Seperti diperlihatkan pada Tabel 1, nilai RMSE untuk hasil *training* terbaik diperoleh untuk data 5 tahun (1168,82). Sedangkan untuk hasil *testing* terbaik didapatkan pada data dengan rentang waktu 1 tahun (874, 76). Hal ini menunjukkan bahwa pemilihan data yang tidak terlalu besar perlu dipertimbangkan untuk menghasilkan prediksi yang baik. Secara umum seperti diperlihatkan pada Gambar 4,

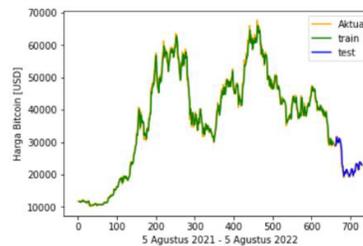
5 dan 6, pola pada grafik memperlihatkan bahwa hasil *training* maupun *testing* mengikuti data aktual yang ada.

Tabel 1. RMSE untuk data 1, 2 dan 5 tahun

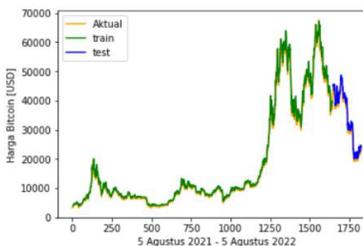
No	Banyak data	RMSE	
		Training	Test
1	1 tahun	1580,61	874,76
2	2 tahun	1630,04	1060,33
3	5 tahun	1168,82	1711,11



Gambar 4. Percobaan data 1 tahun



Gambar 5. Percobaan Data 2 tahun



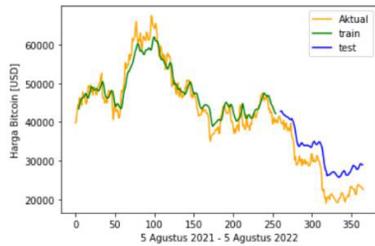
Gambar 6. Percobaan Data 5 tahun

Data Training/Testing

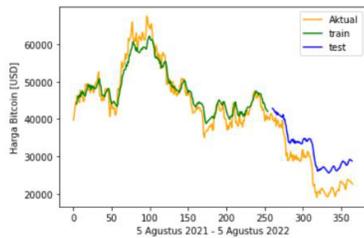
Parameter kedua yang diujicobakan adalah perbandingan data *training* dan *testing*, dengan persentase 60/40, 70/30, 80/20 dan 90/10. Pada keempat percobaan yang dilakukan, digunakan data untuk periode 1 tahun, dengan optimize SGD, serta Dense 3(64, 32, 1).

Tabel 2. RMSE Training dan Test

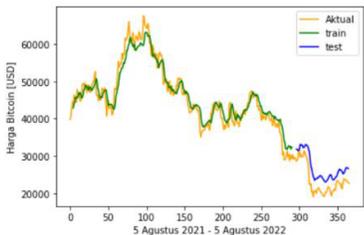
No	Training dan Testing	RMSE	
		Training	Test
1	60/40	2711,10	5404,28
2	70/30	2474,67	5263,59
3	80/20	2371,01	3662,84
4	90/10	2008,19	1145,32



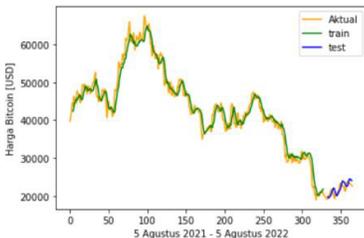
Gambar 7. Training/Testing: 60/40



Gambar 8. Training/Testing: 70/30



Gambar 9. Training/Testing: 80/20



Gambar 10. Training/Test: 90/10

Seperti diperlihatkan pada Tabel 2, nilai RMSE terbaik diperoleh untuk perbandingan persentase 90/10, baik untuk hasil *training* (2008,19) maupun *testing*

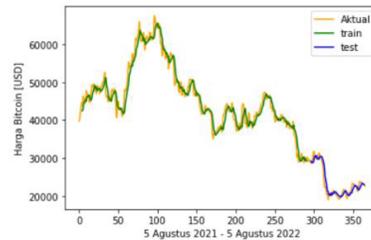
(1145,32). Hasil ini memperlihatkan proses *training* dengan data yang lebih banyak menghasilkan prediksi yang lebih baik. Secara umum pola grafik yang dihasilkan seperti diperlihatkan pada Gambar 7, 8, 9 dan 10 menunjukkan pergerakan grafik *training* maupun *testing* mengikuti pola data aktual yang ada.

Jenis Optimizer

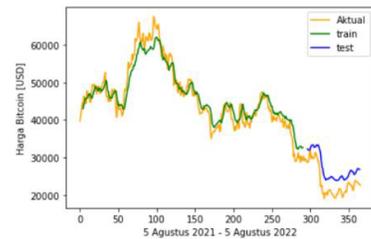
Parameter ketiga diujicobakan untuk pemakaian optimizer adam dan SGD. Percobaan yang dilakukan adalah pada periode 1 tahun, dengan Dense 3(64, 32, 1) serta persentase *training* dan *testing* masing-masing adalah 90/10 dan 80/20.

Tabel 3. RMSE Optimizer

No	Optimizer	RMSE	
		Training	Testing
1	adam80/20	1875,96	1248,29
2	SGD80/20	2553,22	3955,49
3	adam90/10	1718,58	855,57
4	SGD90/10	1964,84	1021,37



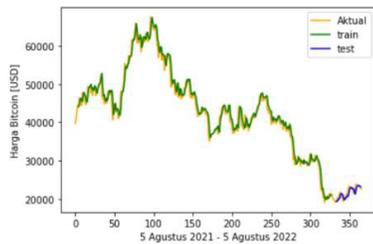
Gambar 11. Optimizer adam80/20



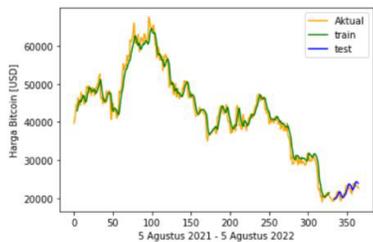
Gambar 12. Optimizer SGD80/20

Seperti diperlihatkan pada Tabel 3, nilai RMSE terbaik diperoleh untuk pemakaian optimizer adam, baik pada percobaan dengan persentase *training* dan *testing* 90/10 (1718,58/855,57) maupun 80/10 (1875,96/1248,29). Hasil yang diperoleh ini menunjukkan pentingnya pemilihan optimizer yang tepat pada setiap

percobaan yang dilakukan, bergantung pada masalah yang dihadapi. Gambar 11, 12, 13 dan 14, secara umum memperlihatkan bahawa pola grafik *training* maupun *testing* mengikuti data aktual yang diberikan.



Gambar 13. Optimizer adam90/10



Gambar 14. Optimizer SGD90/10

Dense Layer

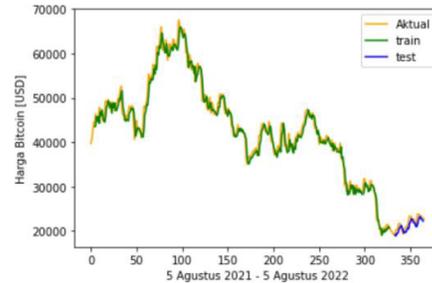
Ujicoba terakhir adalah parameter keempat yang berhubungan dengan ukuran *neuron*, menggunakan Dense 3(32, 16, 1), Dense 3(64, 32, 1) dan Dense 3(128, 64, 1). Percobaan yang dilakukan menggunakan data untuk periode 1 tahun, persentase *training* dan *testing* 80/20, serta optimize adam.

Tabel 4. RMSE Dense Layer

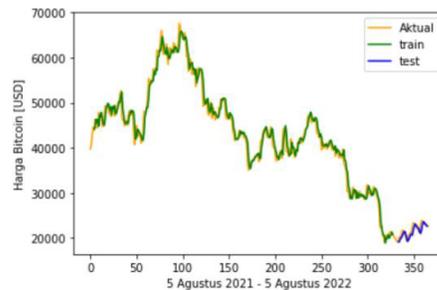
No	Dense	RMSE	
		Training	Test
1	3(32, 16, 1)	1653,26	1022,01
2	3(64, 32, 1)	1623,06	887,05
3	3(128, 64, 1)	1621,95	730,42

Hasil ujicoba yang dilakukan seperti diperlihatkan Tabel 4, dimana RMSE terbaik diperoleh untuk optimizer dengan menggunakan Dense 3(128, 64, 1), dengan nilai proses *training* dan *testing* adalah 1842,89 dan 1449,42. Hasil ini memperlihatkan jumlah neuron yang lebih besar pada lapisan tersembunyi dapat

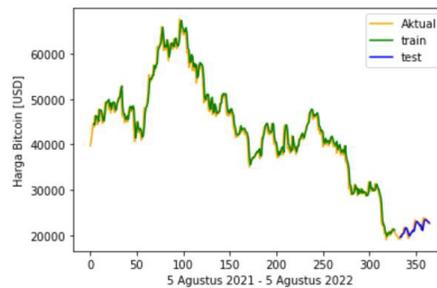
menghasilkan nilai prediksi yang lebih baik. Secara umum seperti dapat dilihat pada Gambar 15, 16 dan 17, pola grafik yang dihasilkan pada ketiga percobaan, baik *training* maupun *testing* mengikuti data aktual yang diberikan.



Gambar 15. Dense 3(32, 16, 1)



Gambar 16. Dense 3(64, 32, 1)



Gambar 17. Dense 3(128, 64, 1)

Secara keseluruhan berdasarkan *trend* grafik yang diperoleh, berdasarkan ujicoba pada penelitian yang dilakukan, menunjukkan bahwa hasil proses *training* dan maupun *testing* mengikuti data aktual yang ada. Hasil ini menunjukkan bahwa arsitektur RNN yang diusulkan dapat bekerja dengan baik.

PENUTUP

Berdasarkan hasil penelitian yang dilakukan untuk prediksi harga bitcoin, banyaknya data pada periode tertentu,

perbandingan data *training* dan *testing* yang digunakan, ukuran dari Dense serta jenis optimizer yang dipakai, mempengaruhi kinerja dari arsitektur RNN yang telah ditentukan. Secara umum untuk setiap percobaan yang dilakukan, pola grafik yang dihasilkan memperlihatkan bahwa pada proses *training* maupun *testing* dapat mengikuti data aktual yang ada. Hal ini menunjukkan bahwa desain algoritme RNN yang dipergunakan dapat memprediksi pergerakan harga bitcoin dengan baik.

Nilai RMSE terbaik yang dapat diperoleh dari penelitian yang dilakukan adalah 1621,95 dan 730,42 untuk proses *training* dan *testing*. Hasil ini tentu saja masih dapat diperbaiki, misalnya dengan menambah jumlah Dense layer dengan parameter yang tepat, atau menggunakan varian lain dari algoritme RNN, seperti LSTM (*Long Short-Term Memory*) dan GRU (*Gated Recurrent Unit*).

DAFTAR PUSTAKA

- [1] Ferdiansayah dkk, “ A LSTM-Method for Bitcoin Price Prediction: A Case Study Yahoo Finance Stock Market”, *International Conference on Electrical Engineering and Computer Science (ICECOS)*, pp. 206 -210, 2019.
- [2] A. M. Ramadhani, Kim Na Rang, Lee Tai Hun, dan Ryu Seung Eui, “Bitcoin Price Forecasting Using Neural Decomposition and Deep Learning”, *Journal of the Korea Industrial Information Systems Research* Vol. 23 No. 4, 81-92, Aug. 2018.
- [3] Patrick Jaquart, D. Dann, dan C. Weinhardt, “Short-term bitcoin market prediction via machine learning”, *The Journal of Finance and Data Science*, 7, 45 – 66, 2021.
- [4] Xiangxi Jiang, “Bitcoin Price Prediction Based on Deep Learning Methods. *Journal of Mathematical Finance*, 10, 132-139, 2022. <https://doi.org/10.4236/jmf.2020.101009>
- [5] Seng Hansun, Arya Wicaksana dan A. Q. M> Khaliq,” Multivariate cryptocurrency prediction: comparative analysis of three recurrent neural networks approaches”, *Journal of Big Data*, 9:50, 2022.
- [6] N.G. Ramadha, N.A.F. Tanjung dan F.D. Adhinata, “ Implementation of LSTM-RNN for Bitcoin Prediction”, *Ind. Journal on Computing* Vol. 6, Issue. 3, pp. 17-24, December 2021.
- [7] M A. D. Suyudi, Esmeralda C. Djamil dan Asri Maspupah, “Prediksi Harga Saham menggunakan Metode Recurrent Neural Network”, *Seminar Nasional Aplikasi Teknologi Informasi (SNATi) 2019* ISSN: 1907 – 5022 Yogyakarta, 03 Agustus 2019.
- [8] Ashutosh Shankhdhar, A. K. Singh, S. Naugraiya dan P. K. Saini,” Bitcoin Price Alert and Prediction System using various Models”, *IOP Conf. Ser.: Mater. Sci. Eng.* 1131 012009, 2021.
- [9] M. W. P. Aldi, Jondri, Annisa Aditsania, “Analisis dan Implementasi Long Short-Term Memory Neural Network untuk Prediksi harga Bitcoin”, *e-Proceeding of Engineering*: Vol.5, No.2 Agustus 2018.
- [10] Si Chen, “Cryptocurrency Financial Risk Analysis Based on Deep Machine Learning”, *Complexity*, Hindawi, Volume 2022, Article ID 2611063, 2022.
- [11] Rcik Dey, Saurabh Shukla, Sarthak Jasani, Hezal Lopes, “ Bitcoin Price Prediction Using LSTM”, *International Research Journal of Engineering and Technology (IRJET)*, Volume 09, Issue 04, April 2022.
- [12] Yongqiong Zhu, “Stock price prediction using the RNN model”, *J. Phys.: Conf. Ser.* 1650 032103, 2020.