

PERBANDINGAN ARIMA OUTLIER, NAÏVE, NEURAL NETWORK DALAM PERAMALAN BITCOIN

Monika Refiana Nurfadila¹, Mayandah Farmita², Hani Khaulasari³

¹UIN Sunan Ampel Surabaya, monikarefiana00@gmail.com

² UIN Sunan Ampel Surabaya, mayyanda30@gmail.com

³ UIN Sunan Ampel Surabaya, hani.khaulasari@uinsby.ac.id

Abstrak. Perkembangan teknologi yang semakin canggih mengakibatkan masyarakat lebih memilih sistem yang efektif dan efisien misalnya dalam sistem mata uang. Dewasa ini masyarakat lebih memilih mata uang virtual seperti Bitcoin yang termasuk kedalam transaksi *Cryptocurrency*. Bitcoin saat ini digunakan sebagai investasi jangka panjang. Maka perlu dilakukan peramalan menggunakan metode time series untuk mengetahui harga Bitcoin pada periode selanjutnya guna menjadi pandangan bagi para investor dalam melakukan transaksi. Dalam penelitian ini menggunakan data harga bitcoin bulanan mulai September 2017 hingga Juni 2022 dengan menggunakan tiga metode peramalan yaitu *Naïve*, *ARIMA outlier* dan *Neural Network*. Didapatkan hasil perbandingan dari ketiga metode tersebut dengan menggunakan MAPE. Masing-masing mendapatkan MAPE 19.22%, 18.58% dan 19.39%, sehingga metode *ARIMA outlier* yang digunakan dalam meramalkan harga bitcoin.

Kata kunci: *ARIMA outlier*, *Bitcoin*, *Naïve*, *Neural Network*

Abstrak. The development of increasingly sophisticated technology has resulted in people preferring an effective and efficient system, for example in the currency system. Nowadays, people prefer virtual currencies such as Bitcoin which are included in *Cryptocurrency* transactions. Bitcoin is currently used as a long-term investment. So it is necessary to do forecasting using the time series method to find out the price of Bitcoin in the next period to be a view for investors in making transactions. This study used monthly bitcoin price data from September 2017 to June 2022 using three forecasting methods, namely *Naïve*, *ARIMA outlier* and *Neural Network*. The results of the comparison of the three methods using MAPE were obtained. They get MAPE 19.22%, 18.58% and 19.39%, respectively, so the *ARIMA outlier* method used in forecasting the price of bitcoin.

Keywords: *ARIMA outlier*, *Bitcoin*, *Naïve*, *Neural Network*

1. Pendahuluan

Globalisasi saat ini berkembang sangat pesat yang mempengaruhi perkembangan dalam seluruh penjuru dunia baik negara berkembang maupun negara maju. Fenomena globalisasi juga mempengaruhi kemajuan berbagai sektor kehidupan seperti teknologi. Adanya perkembangan dalam sektor tersebut mengakibatkan masyarakat meninggalkan sistem-sistem lama guna memenuhi kebutuhannya secara efisien dan efektif [1]. Terdapat satu contoh sistem baru yang mulai diterapkan dalam kehidupan masyarakat yaitu sistem mata uang. Sekarang masyarakat lebih memilih mata uang yang tidak berbentuk kertas atau tunai yaitu mata uang virtual yang dapat diakses secara online, biasa disebut dengan *e-commerce* [2]. Mata uang virtual yang telah marak digunakan oleh masyarakat salah satunya yaitu *Bitcoin*.

Bitcoin termasuk dalam mata uang digital terdesentralisasi yang memperbolehkan pengguna untuk melakukan transaksi dalam jaringan yang dapat dilakukan sendiri tanpa melalui perantara [2],[3]. *Bitcoin* merupakan *Cryptocurrency* peer-to-peer yang dapat diakses pada perangkat lunak, dimana dalam transaksi *Bitcoin* lebih sederhana dibandingkan dengan transaksi *e-commerce* lainnya sebab tidak membutuhkan rekening bank maupun kartu kredit [4]. Dalam transaksi *Bitcoin* menggunakan teknologi blockchain [5], transaksi dengan *Bitcoin* memiliki keuntungan yaitu tidak dikenai biaya perantara [6]. Sedangkan, dalam bertransaksi secara umum dikenakan biaya perantara sebesar 6% hingga 10% [4].

Bitcoin merupakan transaksi terbesar pertama *Cryptocurrency* sebab banyak digunakan dan ditemukan di berbagai bursa *Cryptocurrency* seluruh dunia [4]. Sesuai dengan penelitian yang dilakukan oleh [7] telah mengidentifikasi bahwa *Bitcoin* dapat melindungi aset keuangan. Dari adanya penelitian tersebut mendorong masyarakat untuk berinvestasi menggunakan *Bitcoin*. Namun, data yang diperoleh dari [8] pada tahun 2021 bulan Maret tercatat harga bitcoin Rp. 879.995.222,05, sedangkan pada tahun 2022 bulan yang sama sebesar Rp. 681.743.703,75. Berdasarkan data yang diperoleh pergerakan harga dari *Bitcoin* cenderung mengalami kenaikan ataupun penurunan yang tidak terduga [9]. Jika harga *Bitcoin* turun secara terus menerus maka para investor akan mengalami kerugian.

Disamping itu, kondisi pandemi COVID-19 berdampak pada bertambahnya investor terhadap aset mata uang digital ini. Dikarenakan kondisi masyarakat yang mengalami pemberhentian kerja maupun pengurangan jumlah pendapatan, sehingga melakukan trading maupun investasi untuk memenuhi kebutuhan hidup. Tercatat rata-rata volume perdagangan sebesar 109 USD per hari dengan transaksi *Bitcoin* yang mendominasi sebesar 59,5% [10]. Dari adanya fenomena tersebut perlu dilakukan peramalan terkait harga *Bitcoin* untuk meminimalisir kerugian bagi para investor ketika melakukan transaksi. Dalam melakukan peramalan terdapat beberapa metode yang dapat digunakan yaitu model ARIMA, *Linear Regression*, *Exponential Smoothing* dan *Moving Average* [11]. Selain itu, terdapat model peramalan berbasis kecerdasan buatan antara lain klasifikasi, *Neural Network*, simulated annealing dan algoritma genetik [12].

Sesuai dengan penelitian terdahulu yang dilakukan oleh [13] terkait peramalan harga *Bitcoin* menggunakan ARIMA menghasilkan model ARIMA (0,2,1) dengan hasil prediksi mendekati data asli dan nilai error MAPE sebesar 4,753%. Selanjutnya, penelitian dari [14] terkait peramalan harga *Bitcoin* menggunakan metode ANN dan ARIMA menghasilkan model ARIMA (3,1,2) dengan nilai MAPE 4,198% dan hasil peramalan menggunakan ANN menghasilkan MAPE sebesar 4,0556%. Penelitian lain oleh [15] mengenai peramalan jumlah penumpang kereta api di PT KAI Semarang menggunakan metode deteksi *outlier* menghasilkan model ARIMA *Outlier* ([1],0,1) dengan menambahkan 4 *outlier*. Di lain sisi, penelitian yang dilakukan oleh [16] terkait prediksi jumlah keberangkatan penumpang pesawat di Bandara Soekarno-Hatta menggunakan metode ARIMA *outlier* yang menghasilkan nilai MAPE sebesar 7,08%.. Penelitian berikutnya oleh [17] mengenai prediksi kemiskinan menggunakan metode *naïve* dan *moving average* menghasilkan metode *naïve* lebih akurat dikarenakan nilai MAPE lebih kecil dibandingkan metode *moving average* yaitu sebesar 0,043.

Berdasarkan penelitian terdahulu terkait peramalan maka penelitian ini dilakukan dengan tujuan mengetahui harga *Bitcoin* kedepannya. Sebab urgensi dari penelitian ini yaitu harga *Bitcoin* yang cenderung naik turun. Penelitian ini menggunakan metode yang beracuan dengan penelitian sebelumnya yang memiliki tingkat akurasi yang tinggi yaitu metode *Neural Network*, ARIMA *Outlier*, dan *naïve*. Dimana dalam hasil peramalan harga *Bitcoin* menggunakan metode tersebut dapat menjadi pandangan investor dalam mengambil keputusan yang tepat saat transaksi.

2. Kajian Teori

2.1 Bitcoin

Bitcoin adalah uang tunai yang disimpan di komputer dan dapat digunakan untuk menukar uang tunai dalam transaksi jual beli online. Ini berbeda dengan mata uang online lainnya yang terhubung ke bank dan menggunakan sistem pembayaran seperti Paypal. Bitcoin didistribusikan langsung di antara pengguna tanpa perlu perantara [18].

2.2 ARIMA

Metode Autoregressive Integrated Moving Average biasa disingkat dengan ARIMA adalah bagian dari metode peramalan untuk data runtun waktu yang bersifat stasioner [19]. ARIMA adalah model yang digunakan untuk menganalisis deret waktu berdasarkan nilai-nilai pada masa lalu yaitu nilai lag dan nilai residual dari peramalan, kemudian menghasilkan persamaan yang dapat digunakan dalam meramalkan nilai-nilai priode selanjutnya [20]. Model ARIMA disempurnakan oleh George Box Gwilym Jenki pada tahun 1976, dimana lebih dikenal dengan metode Box-Jenkins [21]. Metode ARIMA pada jangka pendek sangat akurat, namun pada jangka panjang keakuratan tersebut menurun [22]. Terdapat beberapa model dari ARIMA yaitu model AR (autoregressive), model MA (moving average) dan ARMA (autoregressive dan moving average) [23]. Model ARIMA didasarkan pada asumsi bahwa data waktu sekarang dipengaruhi oleh data dan nilai residual dari data waktu sebelumnya. Secara umum model dari ARIMA yaitu (p,d,q) [24]. Dimana p adalah urutan dari model autoregressive (regresi linear yang menggabungkan data periode sebelumnya dengan data periode mendatang), d adalah derajat dari differencing (pembedaan, agar data dalam keadaan stasioner) dan q adalah urutan model moving average (korelasi antara data sebelumnya dalam menduga kesalahan nilai data selanjutnya pada data runtun waktu) [25], [26]. Model umum ARIMA dapat dituliskan sesuai persamaan di bawah ini:

$$\phi(B)Z_t = \theta(B)w_t \quad (1)$$

Dimana,

Z_t : nilai dari variabel X saat waktu ke-t

B : operator pergeseran ke belakang

w_t : nilai kesalahan pada waktu ke-t

Persamaan modelnya adalah:

$$Z_t = (1 + \phi_1)Z_{t-1} + (\phi_1 - \phi_2)Z_{t-2} + \dots + (\phi_p - \phi_{p-1})Z_{t-p} + w_t - \theta_q w_{t-1} - \dots - \theta_q w_{t-q} \quad (2)$$

Dimana,

Z_t : nilai dari variabel X pada waktu ke-t,

θ_q : parameter *moving average* ke-q,

ϕ_p : pameteter *autoregressive* ke-p,

w_t : nilai error pada saat ke-t

Data yang dapat digunakan dalam model ARIMA harus stasioner dengan artian bahwa tidak ada kenaikan maupun penurunan dalam data. Data diharuskan horizontal terhadap poros waktu, sehingga dapat dikatakan bahwa kenaikan data berda pada nilai mean dan varians yang stabil dengan waktu. Ketika data yang digunakan tidak stasioner maka diperlukan differencing untuk mendapatkan data yang stasioner [27].

2.3 Deteksi Outlier

Outlier adalah pengamatan yang tidak konsisten terhadap data deret waktu atau nilai yang berbeda secara signifikan dengan data lainnya. Ada empat jenis *outlier*, yaitu *Innovative Outlier* (IO), *Additive Outlier* (AO), *Temporary Change* (TC) dan *Level Shift* (LS).

AO adalah kejadian yang mempengaruhi data runtun waktu hanya dalam satu periode, yaitu pengamatan ke- T . Bentuk umum AO pada proses ARMA didefinisikan sebagai berikut:

$$\begin{aligned} Z_t &= \begin{cases} X_t & t \neq T \\ X_t + \omega & t = T \end{cases} \\ &= X_t + \omega I_t^{(T)} \\ &= \frac{\theta(B)}{\phi(B)} a_t + \omega I_t^{(T)} \end{aligned} \quad (3)$$

Dimana

$$I_t^{(T)} = \begin{cases} 1 & t \neq T \\ 0 & t = T \end{cases}$$

Merupakan variabel indikator yang menunjukkan ada tidaknya *outlier* pada waktu T .

IO adalah peristiwa yang mengikuti proses ARMA. Bentuk umum IO didefinisikan sebagai berikut:

$$\begin{aligned} Z_t &= X_t + \frac{\theta(B)}{\phi(B)} \omega I_t^{(T)} \\ &= \frac{\theta(B)}{\phi(B)} (a_t + \omega I_t^{(T)}) \end{aligned} \quad (4)$$

LS adalah peristiwa yang mempengaruhi deret pada titik waktu tertentu dan menyebabkan perubahan permanen yang tiba-tiba. Model *outlier* LS digambarkan sebagai berikut:

$$Z_t = X_t + \frac{1}{(1-B)} \omega I_t^{(T)} \quad (5)$$

TC adalah suatu kejadian dimana *outlier* menimbulkan efek awal pada waktu t sebesar ω , kemudian perlahan-lahan besarnya sesuai δ . Model TC dapat ditulis sebagai berikut:

$$Z_t = X_t + \frac{1}{(1-\delta B)} \omega I_t^{(T)} \quad (6)$$

Jika $\delta = 0$ maka TC adalah kasus *additive outlier*. Pada $\delta = 1$ maka TC adalah kasus level shift [28].

2.4 Naïve

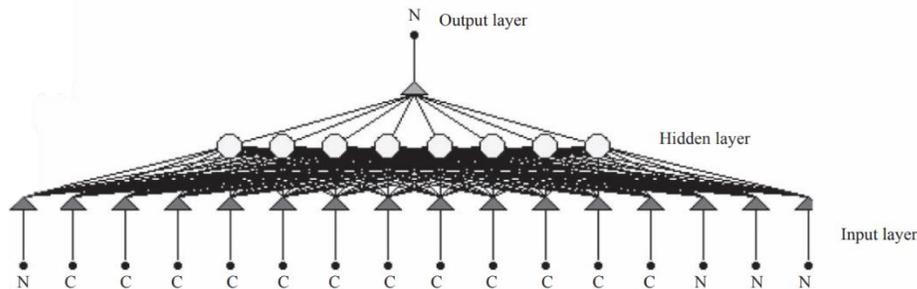
Metode *naïve* merupakan salah satu metode peramalan, dimana hasil peramalan dimasa mendatang sama dengan data pada periode terakhir [29]. Metode *naïve* biasanya digunakan sebagai perbandingan dengan metode lain [30], dikarenakan metode *naïve* mudah dalam menghasilkan hasil peramalan. Secara sistematis model *naïve* dapat dituliskan sebagai berikut :

$$X_{t+1} = X_t \quad (7)$$

Dimana X_t merupakan data asli pada periode ke- t . Dengan demikian, hasil dari peramalan data asli sebelumnya akan sama dengan data yang selanjutnya.

2.5 Neural Network

Artificial Neural Network atau jaringan saraf tiruan merupakan metode pemodelan berbasis data yang memiliki karakteristik pada kemampuannya dalam belajar dari sekumpulan contoh data yang terbatas [31]. Dapat diartikan pula bahwa *Artificial Neural Network* merupakan metode matematika, dimana sistem kerja dari metode ini meniru otak atau syaraf manusia [32]. Secara umum metode ini memiliki 3 layer atau neuron dalam tahapan perhitungannya yang terdiri dari layer input, layer serta layer output [33] sesuai yang tertera pada gambar dibawah ini.



Gambar 1. Arsitektur Neural Network

2.6 Nilai Keakuratan Model

Tingkat kesalahan rata-rata total (MAPE) dihitung dengan membagi kesalahan aktual untuk setiap periode dengan pengukuran aktual untuk periode tersebut. Nilai MAPE dapat ditemukan menggunakan rumus berikut [34]:

$$MAPE = \left(\frac{100\%}{n} \right) \sum_{t=1}^n \frac{|X_t - F_t|}{X_t} \quad (8)$$

Dengan

X_t : Data aktual pada periode t

F_t : nilai prediksi pada periode t

Estimasi keakuratan model dikategorikan berdasarkan skor MAPE sebagai berikut:

1. < 10% : prediksi sangat baik
2. 10% - 20% : prediksi baik
3. 20% - 50% : prediksi cukup baik
4. > 50% : prediksi buruk

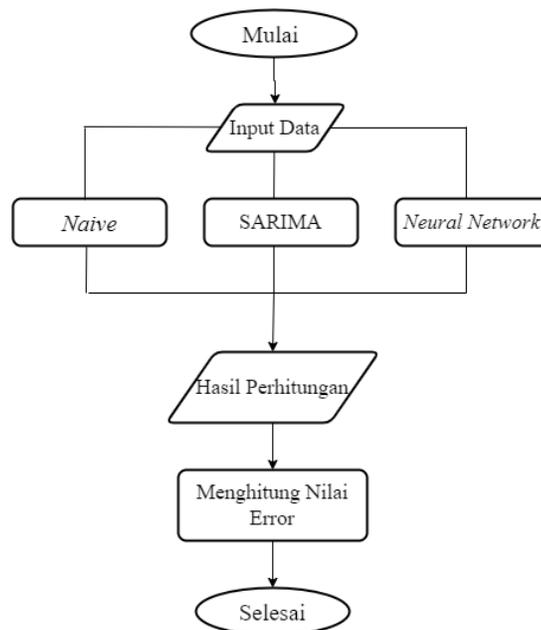
3. Metode Penelitian

Pada penelitian ini menggunakan data bulanan harga *Bitcoin* yang diperoleh dari website [8] dengan satu variabel. Data yang digunakan mulai dari bulan September tahun 2017 hingga bulan Juni tahun 2022 dengan total 58 data. Peramalan harga *Bitcoin* menggunakan beberapa metode yaitu *naïve*, SARIMA, dan *neural network*. Dimana akan dilakukan perbandingan dari ketiga metode tersebut dengan memilih metode yang memiliki nilai galat terkecil [35]. Dibawah ini akan ditampilkan data yang digunakan dalam penelitian.

Tabel 1. Sampel data penelitian

Tahun	Bulan	Harga Bitcoin
2017	September	57801700
2018	Januari	140500000
2019	Januari	48582000
2020	Januari	127444000
2021	Januari	465246016
2022	Juni	314558016

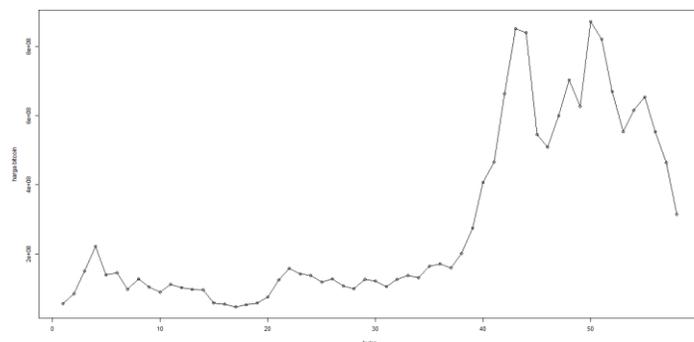
Perhitungan peramalan dan pemodelan dilakukan dengan menggabungkan semua data pada bagian training dan testing. Berikut alur penelitian yang ditampilkan dalam bentuk *flowchart*.



Gambar 2. Alur penelitian

4. Hasil dan Pembahasan

Analisis awal dalam penelitian ini yaitu dengan melihat pola data harga bitcoin. Pola data harga bitcoin dapat dilihat melalui plot time series. Plot harga bitcoin dalam bulanan akan ditampilkan sebagai berikut.



Gambar 3. Plot Time Series Harga Bitcoin

Berdasarkan Gambar 3, pola data harga bitcoin terlihat yaitu cenderung mengalami kenaikan yang pesat. Sehingga pola data harga bitcoin dapat dikatakan memiliki pola siklik. Maka dalam perhitungan peramalan harga bitcoin untuk periode berikutnya harus menggunakan metode yang sesuai dengan pola data harga bitcoin. Berikut beberapa hasil perhitungan peramalan harga bitcoin dengan tiga metode yang berbeda.

4.1 Naïve

Telah diketahui bahwa hasil peramalan menggunakan metode *naïve* sama dengan periode sebelumnya. Berikut hasil peramalan harga bitcoin menggunakan rumus pada persamaan (2.5).

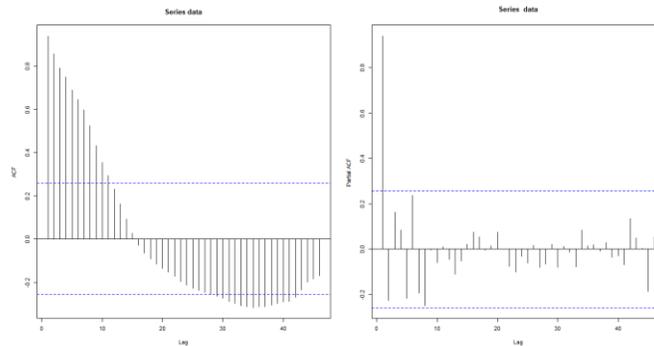
Tabel 2. Hasil Peramalan Naïve

Tahun	Bulan	Data Aktual	Metode Naïve
2017	9	57801700	0
:	:	:	:
2017	12	222592992	150999104
2018	1	140500000	222592992
:	:	:	:
2018	12	54953000	58850000
2019	1	48582000	54953000
:	:	:	:
2019	12	100402000	107848000
2020	1	127444000	100402000
:	:	:	:
2020	12	406377984	274848992
2021	1	465246016	406377984
:	:	:	:
2021	12	668630016	820182016
2022	1	552563008	668630016
:	:	:	:
2022	12	0	314558016

Berdasarkan Tabel 2, peramalan harga bitcoin selama 6 bulan kedepan menunjukkan angka yang konstan yaitu sebesar 314558016. Dalam perhitungan peramalan harga bitcoin menggunakan metode *naïve* menghasilkan nilai MAPE sebesar 19.22%. Dimana nilai keakuratan model termasuk dalam kategori baik.

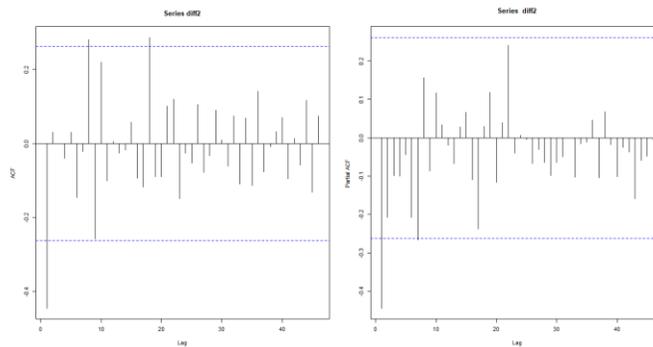
4.2 ARIMA Outlier

Tahap awal pemodelan menggunakan ARIMA yaitu mengidentifikasi pola data terlebih dahulu. Berdasarkan Gambar 3, bahwa pola data termasuk dalam pola siklik. Maka tahap selanjutnya yaitu pengujian kestasioneran data terhadap varians maupun rata-rata. Pengujian kestasioneran data dapat dilihat berdasarkan plot ACF dan Dickey Fuller. Didapatkan hasil dari perhitungan Dickey Fuller sebesar -1.8531 dengan $p\text{-value } 0.634 > \alpha$. Disamping itu, berdasarkan plot ACF dapat dilihat pada gambar dibawah ini.



Gambar 4. Plot ACF dan PACF

Berdasarkan Gambar 4, terlihat bahwa data tidak stasioner terhadap rata-rata. Sehingga diperlukan differencing data harga bitcoin terlebih dahulu untuk mendapatkan data yang stasioner dalam rata-rata maupun varians. Diperlukan dua kali proses differencing terhadap data harga bitcoin. Dikarenakan dalam differencing pertama data belum menunjukkan kestasioneran. Berikut hasil differencing data yang ditampilkan melalui plot ACF dan PACF.



Gambar 5. Plot ACF dan PACF setelah differencing

Berdasarkan Gambar 5, ditinjau dari plot ACF bahwa data telah stasioner terhadap rata-rata. Sedangkan, dengan pengujian Dickey Fuller setelah differencing didapatkan bahwa nilai $p - value < 0.05$. Sehingga dapat dikatakan bahwa data harga bitcoin telah stasioner dalam mean maupun varians. Disamping itu, sesuai dengan plot ACF dan PACF didapatkan model tentatif antara lain ARIMA (1,2,1), ARIMA (0,2,1), ARIMA (1,2,0), ARIMA (1,2,[8]), ARIMA (1,2,[18]), ARIMA (1,2,[1,8]), ARIMA(1,2,[1,18]), ARIMA(0,2,[1,8]), ARIMA(0,2,[0,18]), ARIMA(0,2,[8]) dan ARIMA(0,2,[18]). Dari beberapa model yang telah didapat perlu dilakukan pengujian signifikansi parameter, uji *White Noise* dan pengujian distribusi normal.

4.2.1 Pengujian Signifikansi Parameter

Total terdapat 11 model tentatif yang akan melalui tahap pengujian signifikansi parameter. Dengan menggunakan taraf signifikansi atau α sebesar 5% didapatkan bahwa model ARIMA (0,2,1) yang memenuhi syarat uji signifikansi parameter. diperoleh nilai $p - value$ sebesar 2.2×10^{-16} .

4.2.2 Uji White Noise

Setelah dilakukan pengujian signifikansi parameter maka harus beralih ke tahap pengujian uji *white noise*. Berdasarkan hasil dari pengujian *white noise* bahwa diperoleh nilai *p-value* sebesar $0.0893 > \alpha$, sehingga model ARIMA (0,2,1) memenuhi uji *white noise*.

4.2.3 Pengujian Distribusi Normal

Dalam tahap pengujian distribusi normal menggunakan uji *Kolmogorov-Smirnov* dengan nilai α sebesar 0.05. berdasarkan hasil pengujian distribusi normal bahwa model ARIMA (0,2,1) menghasilkan nilai *p-value* sebesar 0.0004202. Maka disimpulkan bahwa model ARIMA (0,2,1) tidak berdistribusi normal, sehingga diperlukan pendeteksian *outlier*.

4.2.4 Deteksi Outlier

Berdasarkan hasil pengujian untuk mendeteksi *outlier*, didapatkan total *outlier* sesuai dengan tabel berikut.

Tabel 3. Hasil Pendeteksian Outlier

Obs	Periode	Type	Estimasi	<i>p-value</i>
51	November 2021	Additive	0.00032406	0.71868
45	Mei 2021	Innovational	-0.00329812	0.02114
50	Oktober 2021	Innovational	0.00164556	0.25450

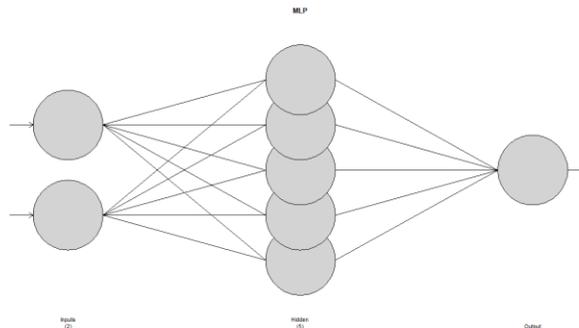
Sesuai dengan tabel diatas, bahwa terdapat tiga *outlier* yang terdeteksi. Selanjutnya dilakukan penambahan *outlier* pada model ARIMA (0,2,1) secara satu persatu. Dengan penambahan tiga *outlier* ternyata model tetap signifikan dengan nilai *p-value* sebesar 3.935×10^{-7} . Disamping itu, model ARIMA menjadi berdistribusi normal dengan *p-value* 0.2033. Sehingga didapatkan model akhir ARIMA *outlier* sebagai berikut:

$$\hat{Z}_t = 0.1482 + 0.00032406 AO_1 - (0.75162069e_{t-1})(0.00329812 OI_1 - 0.00164556 OI_2)$$

Setelah didapatkan model ARIMA (0,2,1) dengan penambahan *outlier*, dilakukan peramalan harga bitcoin untuk 6 bulan kedepan. Dari hasil peramalan tersebut dilakukan evaluasi keakuratan metode dalam melakukan prediksi. Didapatkan nilai MAPE sebesar 18.58% dimana termasuk dalam kategori baik.

4.3 Neural Network

Perhitungan peramalan harga bitcoin dengan *neural network* menggunakan metode *multilayer perceptrons*. Tahap awal yang dilakukan yaitu memasukkan data dalam model MLP, berikut model yang terbentuk dalam proses perhitungan.



Gambar 6. Arsitektur MLP

Berdasarkan Gambar 6, dalam pemrosesan data dengan metode *multilayer perceptron* terdapat dua inputan data. Setelah itu, data diproses dalam hidden layer, dimana terdapat hidde layer dalam proses perhitungan. Sehingga menghisalkan satu keluaran yang merupakan prediksi harga bitcoin dalam periode selanjutnya. Hasil peramalan harga bitcoin untuk bulan ke depan akan dievaluasi keakuratannya dengan menggunakan MAPE. Didapatkan nilai MAPE dalam perhitungan menggunakan metode ini sebesar 19.39% yang termasuk dalam kategori baik.

4.4 Perbandingan Metode

Setelah dilakukan peramalan harga bitcoin dengan menggunakan tiga metode yaitu *naïve*, *ARIMA outlier* dan *neural network* maka selanjutnya dilakukan perbandingan metode untuk menentukan metode mana yang cocok untuk digunakan peramalan harga bitcoin. Dalam membandingkan ketiga metode tersebut dengan melihat nilai MAPE yang diperoleh. Berikut daftar perolehan MAPE dari ketiga metode.

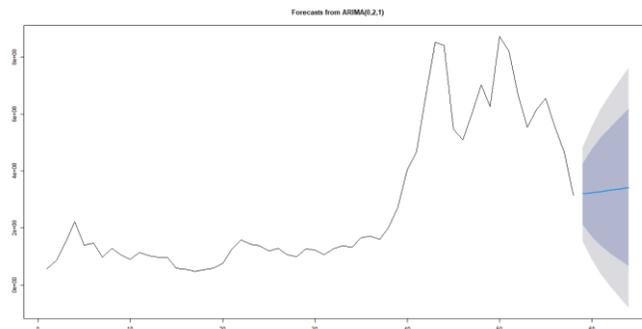
Tabel 4. Hasil Perbandingan

Metode	MAPE (%)
<i>Naïve</i>	19.22
<i>ARIMA Outlier</i>	18.58
<i>Neural Network</i>	19.39

Berdasarkan Tabel 4, bahwa nilai MAPE terkecil pada metode *ARIMA outlier*. Dengan demikian, metode yang terpilih untuk meramalkan harga bitcoin yaitu metode *ARIMA outlier*. Berikut hasil peramalan harga bitcoin untuk 6 bulan kedepan menggunakan metode terpilih dan grafiknya.

Tabel 5. Hasil Peramalan Harga Bitcoin

Periode	Hasil Prediksi
Juli 2022	319062422
Agustus 2022	323566828
September 2022	328071233
Oktober 2022	332575639
November 2022	337080045
Desember 2022	341584451



Gambar 7. Grafik Hasil Peramalan

5. Simpulan

Berdasarkan hasil dari analisis data harga bitcoin bahwa memiliki pola data siklik. Sehingga dalam melakukan peramalan harga bitcoin periode selanjutnya harus menggunakan metode yang sesuai. Dimana metode yang digunakan yaitu *naïve*, *ARIMA outlier* dan *neural network*. Dari ketiga metode tersebut dibandingkan untuk mendapatkan satu metode yang terbaik. Perbandingan dilakukan dengan melihat nilai MAPE terkecil. Diperoleh metode yang cocok yaitu *ARIMA outlier* dengan MAPE sebesar 18.58%.

Referensi

- [1] N. Rumondang, “Interaksionisme Simbolik Michalowski dalam Memandang Bitcoin sebagai Kejahatan,” *J. Kriminologi Indones.*, vol. 15, no. 1, pp. 11–18, 2020.
- [2] K. G. Pudjastuti and I. K. Westra, “Legalitas Mata Uang Virtual Bitcoin Dalam Transaksi Online Di Indonesia,” *Kertha Wicara J. Ilmu Huk.*, vol. 9, no. 11, pp. 1–10, 2021.
- [3] S. Abul and P. Sadorsky, “Machine Learning with Applications Forecasting Bitcoin price direction with random forests: How important are interest rates , inflation , and market volatility?,” *Mach. Learn. with Appl.*, vol. 9, no. June, p. 100355, 2022, doi: 10.1016/j.mlwa.2022.100355.
- [4] M. Ali, S. Yudono, and M. Artiyasa, “Bitcoin USD Closing Price (BTC-USD) Comparison Using Simple Moving Average And Radial Basis Function Neural Network Methods,” *Tek. Elektro*, vol. 4, no. 2, pp. 29–34, 2022.
- [5] A. Kaur, A. Nayyar, and P. Singh, “Blockchain: A Path to the Future,” *Cryptocurrencies Blockchain Technol. Appl.*, pp. 25–42, 2020, doi: 10.1002/9781119621201.ch2.
- [6] P. Kayal and P. Rohilla, “Bitcoin in the economics and finance literature: a survey,” *SN Bus. Econ.*, vol. 1, no. 7, pp. 1–21, 2021, doi: 10.1007/s43546-021-00090-5.
- [7] S. J. Hussain Shahzad, E. Bouri, D. Roubaud, and L. Kristoufek, “Safe haven, hedge and diversification for G7 stock markets: Gold versus bitcoin,” *Econ. Model.*, vol. 87, no. July, pp. 212–224, 2020, doi: 10.1016/j.econmod.2019.07.023.
- [8] “Bitcoin Historical Data.” .
- [9] R. M. A. Ilyasa and R. Arifin, “Transaksi Bitcoin Dalam Perspektif Hukum Islam dan Hukum Positif Indonesia,” *Kaji. Huk. Islam*, vol. 4, no. 1, pp. 26–35, 2019.
- [10] M. K. D. Putra, “Dampak Covid-19 Pada Tren Perkembangan Perdagangan Kriptografi Studi Kasus Bitcoin di Indonesia,” *J. EKOBIS Kaji. Ekon. dan Bisnis*, vol. 5, no. 1, pp. 61–75, 2021.
- [11] S. M. Robial, “Perbandingan Model Statistik pada Analisis Metode Peramalan Time Series (Studi Kasus: PT. Telekomunikasi Indonesia, Tbk Kandatel Sukabumi),” *J. Ilm. SANTIKA*, vol. 8, no. 2, pp. 1–17, 2018.
- [12] N. L. A. K. Yuniastari and I. W. W. Wirawan, “Peramalan Permintaan Produk Perak Menggunakan Metode Simple Moving Average Dan Single Exponential Smoothing,” *Sist. dan Inform.*, vol. 9, no. 1, pp. 97–106, 2016.
- [13] N. Salwa, N. Tatsara, R. Amalia, and A. F. Zohra, “Peramalan Harga Bitcoin Menggunakan Metode ARIMA (Autoregressive Integrated Moving Average),” *J. Data Anal.*, vol. 1, no. 1, pp. 21–31, 2018, doi: 10.24815/jda.v1i1.11874.
- [14] C. Chian Tun and N. Majid, “Comparison between artificial neural network and autoregressive integrated moving average model in bitcoin price forecasting,” *J. Qual. Meas. Anal. JQMA*, vol. 14, no. 2, pp. 45–53, 2018.
- [15] A. F. Saputri, A. Hoyyi, and Sugito, “PREDIKSI JUMLAH PENUMPANG KERETA API MENGGUNAKAN MODEL VARIASI KALENDER DENGAN DETEKSI OUTLIER (Studi Kasus : PT. Kereta Api Indonesia DAOP IV Semarang),” *J. Gaussian*, vol. 6, no. 3, pp. 281–289,

- 2017.
- [16] A. Waldira, A. Hoyyi, and D. Ispriyanti, “PREDIKSI JUMLAH KEBERANGKATAN PENUMPANG PESAWAT TERBANG MENGGUNAKAN MODEL VARIASI KALENDER DAN DETEKSI OUTLIER (Studi Kasus di Bandara Soekarno-Hatta),” *GAUSSIAN*, vol. 9, no. 3, pp. 336–345, 2020.
- [17] A. Kumila, B. Sholihah, E. Evizia, N. Safitri, and S. Fitri, “Perbandingan Metode Moving Average dan Metode Naïve Dalam Peramalan Data Kemiskinan,” *JTAM / J. Teor. dan Apl. Mat.*, vol. 3, no. 1, p. 65, 2019, doi: 10.31764/jtam.v3i1.764.
- [18] M. S. Honggowongso and M. Kholil, “Legalitas Bitcoin Dalam Transaksi E-Commerce Sebagai Pengganti Uang Rupiah,” *J. Priv. Law*, vol. 9, no. Vol 9, No 1 (2021): Januari-April, pp. 143–154, 2021, [Online]. Available: <https://jurnal.uns.ac.id/privatlaw/article/view/28942/pdf>.
- [19] D. Nurlaily, M. Silfiani, and N. F. Hayati, “Perbandingan Metode Arima, Dan Triple Exponential Smoothing Pada Studi Kasus Data Ekspor Non Migas Di Kalimantan Timur,” *J. SNATI*, vol. 1, 2022.
- [20] F. Konsumsi, B. Barang, P. Storage, H. Dengan, M. Autoregressive, and M. Average, “FORECASTING KONSUMSI BARANG BARANG PADA STORAGE MOVING AVERAGE,” *J. Comasie*, vol. 03, 2021.
- [21] Nurviana, R. P. Sari, U. Nabilla, and T. Talib, “Forecasting Rice Paddy Production in Aceh Using ARIMA and Exponential Smoothing Models,” *CAUCHY*, vol. 7, no. 2, pp. 281–292, 2022.
- [22] A. A. Kurniasi, M. A. Saptari, and V. Ilhadi, “Aplikasi Peramalan Harga Saham Perusahaan LQ45 dengan Menggunakan Metode ARIMA,” *J. Sist. Inf.*, vol. 5, no. 1, pp. 13–26, 2021.
- [23] D. Gunawan and W. Astika, “The Autoregressive Integrated Moving Average (ARIMA) Model for Predicting Jakarta Composite Index,” *J. Inform. Ekon. Bisnis*, vol. 4, no. January 2020, pp. 2–7, 2022, doi: 10.37034/infneb.v4i1.114.
- [24] L. Farosanti and H. Mubarak, “Analisa Peramalan Penjualan Alat Kesehatan dan Laboratorium di PT . Tristania Global Indonesia Menggunakan Metode ARIMA,” *J. Inform. Merdeka Pasuruan*, vol. 7, no. 1, pp. 14–18, 2022, doi: <http://dx.doi.org/10.37438/jimp.v7i1.428>.
- [25] F. Zuhdi, Y. Zurriyati, and E. Novriandeni, “Peramalan Populasi Sapi di Provinsi Riau dan Indonesia Menggunakan Pendekatan ARIMA (Autoregressive Integrated Moving Average),” *J. Peternak.*, vol. 18, no. 2, p. 87, 2021, doi: 10.24014/jupet.v18i2.11558.
- [26] A. Qalbi, K. Nurfadilah, and W. Alwi, “Comparison of Fuzzy Time Series Methods and Autoregressive Integrated Moving Average (ARIMA) for Inflation Data,” *Eig. Math. J.*, vol. 4, no. 2, 2021, [Online]. Available: <https://www.eigen.unram.ac.id/index.php/eigen/article/view/122%0Ahttps://www.eigen.unram.ac.id/index.php/eigen/article/download/122/91>.
- [27] R. N. Putri, M. Usman, Warsono, Widiarti, and E. Virginia, “Modeling Autoregressive Integrated Moving Average (ARIMA) and Forecasting of PT Unilever Indonesia Tbk Share Prices during the COVID-19 Pandemic Period,” *J. Phys. Conf. Ser.*, vol. 1751, no. 1, 2021, doi: 10.1088/1742-6596/1751/1/012027.
- [28] A. F. Sa’adah, D. Ispriyanti, and Suparti, “PREDIKSI TINGGI PASANG AIR LAUT DI KOTA SEMARANG DENGAN MENGGUNAKAN METODE SEASONAL AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (SARIMA) DAN DETEKSI OUTLIER,” *GAUSSIAN*, vol. 3, no. 3, pp. 301–316, 2014, doi: 10.15797/concom.2019..23.009.
- [29] Hernadewita, Y. K. Hadi, M. J. Syaputra, and D. Setiawan, “Peramalan Penjualan Obat Generik Melalui Time Series Forecasting Model Pada Perusahaan Farmasi di Tangerang: Studi Kasus,” *J. Ind. Eng. Manag. Res. (Jiemar)*, vol. 1, no. 2, pp. 35–49, 2020.
- [30] A. Arnita, “Comparison of Single Exponential Smoothing, Naive Model, and SARIMA Methods for Forecasting Rainfall in Medan,” *J. Mat. Stat. dan Komputasi*, vol. 17, no. 1, pp. 117–128, 2020, doi: 10.20956/jmsk.v17i1.10236.

- [31] A. A. Loutfi, M. Sun, I. Loutfi, and P. B. Solibakke, “Empirical study of day-ahead electricity spot-price forecasting: Insights into a novel loss function for training neural networks,” *Appl. Energy*, vol. 319, no. July 2021, p. 119182, 2022, doi: 10.1016/j.apenergy.2022.119182.
- [32] M. Rahman, “Prediksi Pembayaran Tagihan Listrik Menggunakan Model Artificial Neural Network,” *JUSTINDO (Jurnal Sist. dan Teknol. Inf. Indones.)*, vol. 4, no. 1, p. 7, 2019, doi: 10.32528/justindo.v4i1.2417.
- [33] H. M. Nawawi, J. J. Purnama, and A. B. Hikmah, “Komparasi Algoritma Neural Network Dan Naïve Bayes Untuk Memprediksi Penyakit Jantung,” *J. Pilar Nusa Mandiri*, vol. 15, no. 2, pp. 189–194, 2019, doi: 10.33480/pilar.v15i2.669.
- [34] M. I. Rizki and T. A. Taqiyyuddin, “Penerapan Model SARIMA untuk Memprediksi Tingkat Inflasi di Indonesia,” *J. Sains Mat. dan Stat.*, vol. 7, no. 2, pp. 62–72, 2021, doi: 10.24014/jsms.v7i2.13168.
- [35] W. Sutopo, A. H. Quarrota A’yun, H. Ardian, M. K. Nunuh, S. Immanuella, and Y. Yuniaristanto, “Pemilihan Metode Peramalan Jumlah Permintaan Koran dengan Tingkat Kesalahan Terendah,” *Matrik*, vol. 21, no. 2, p. 91, 2021, doi: 10.30587/matrik.v21i2.1325.