

# Pembuatan *Dashboard* Peramalan Menggunakan *Business Intelligence* pada *Cryptocurrency* Guna Pengambilan Keputusan

Faza Murtadho, Khakim Gozali, dan Raden Venantius Hari Ginardi  
Departemen Teknologi Informasi, Institut Teknologi Sepuluh Nopember (ITS)  
*e-mail*: khakim@is.its.ac.id

**Abstrak**—Penggunaan mata uang kripto untuk transaksi internet yang semakin populer beberapa tahun terakhir menyebabkan banyaknya orang tertarik untuk menjadi *trader* atau sekedar berinvestasi. Ketiadaan lembaga seperti bank sentral untuk mengatur nilai menyebabkan mata uang kripto fluktuatif. Dikarenakan nilai mata uang kripto yang fluktuatif, maka diperlukan sebuah metode peramalan untuk memprediksi tren harga dari mata uang kripto. Pada buku ini penulis menggunakan metode peramalan *Autoregressive Integrated Moving Average* (ARIMA) untuk memprediksi tren harga tersebut. *Dashboard* peramalan dengan bantuan *Business Intelligence* akan memvisualisasikan data yang telah diolah menggunakan metode *Autoregressive Integrated Moving Average* (ARIMA) yang dimasukkan pengguna menjadi data berbentuk diagram sehingga dapat mempermudah pengguna untuk mengambil suatu keputusan dalam melakukan *trading* ataupun investasi mata uang kripto.

**Kata Kunci**—ARIMA, *Business Intelligence*, *Dashboard*, Kripto, *Trading*.

## I. PENDAHULUAN

PERDAGANGAN mata uang kripto semakin populer selama beberapa tahun terakhir dengan peningkatan jumlah perdagangan dan arah penelitian setiap tahunnya [1]. Penggunaan mata uang kripto yang dipergunakan untuk transaksi internet menyebabkan banyaknya orang tertarik untuk menjadi *trader* atau sekedar berinvestasi. Investasi dan *trading* tentunya tidak dapat dipisahkan dari ketidakpastian. Ketiadaan lembaga seperti bank sentral untuk mengatur nilai menyebabkan mata uang kripto fluktuatif.

Penerapan *Business Intelligence* dalam melakukan *forecasting* mata uang kripto dapat memudahkan individu maupun organisasi untuk mengambil keputusan ketika melakukan *trading*. Untuk menampilkan visualisasi *forecasting* tersebut maka dibentuk suatu rancangan *dashboard* yang dapat memuat beberapa mata uang kripto yang memuat informasi berdasarkan skema candle OHLC (*Open Price*, *High Price*, *Low Price*, *Close Price*), volume transaksi pada 24 jam terakhir dan nilai tukar saat itu dengan US Dollar.

## II. TINJAUAN PUSTAKA

### A. *Business Intelligence*

*Business Intelligence* adalah suatu sistem pendukung berbasis fakta untuk meningkatkan pengambilan keputusan bisnis yang didalamnya termasuk arsitektur, *tools*, *database*, aplikasi, dan metodologi. *Business Intelligence* mengkonversi data menjadi informasi yang berguna dan melalui analisis manusia menjadi pengetahuan. Salah satu

tugas yang dilakukan oleh *Business Intelligence* adalah membuat peramalan berdasarkan data historis [2].

### B. *Ekonometrika pada Mata Uang Kripto Menggunakan Metode ARMA*

Metode ekonometrik pada mata uang kripto mengaplikasikan statistik dan teori ekonomi untuk mengestimasi dan memprediksi nilainya [3]. Ketika mempelajari perdagangan mata uang kripto menggunakan ekonometrik, peneliti menggunakan model statistik pada data time-series seperti model *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH) dan BEKK untuk mengestimasi fluktuasi pada mata uang kripto [4] atau model yang paling sering digunakan dalam analisis time-series dalam peramalan adalah model *Autoregressive Integrated Moving Average* (ARIMA) [5].

### C. *Endpoint API*

Jumlah layanan yang menyediakan web *Application Programming Interfaces* (APIs) secara publik telah berkembang pesat. Beberapa penelitian menunjukkan pengembang telah berpindah dari *Simple Object Access Protocol* (SOAP) atau *Remote Procedure Call* (RPC) untuk menyebarkan layanan web *Representational State Transfer* (REST) sebagai sarana bagi konsumen untuk menggunakan layanan tersebut. Hal ini menyiratkan bahwa telah dilakukan pengambilan keputusan oleh pengembang untuk mengekspos layanan APIs yang menyebabkan APIs yang sangat beragam sehingga pihak lain dapat mengembangkan aplikasi dari *database* mereka sendiri [6].

### D. *Peramalan Menggunakan Metode ARIMA*

Model ARMA dapat merepresentasikan deret waktu stasioner maupun non-stasioner untuk menghasilkan peramalan berdasarkan deskripsi dari data historis dengan variabel tunggal. Dikarenakan model ARIMA tidak mengasumsikan pola tertentu pada data historis deret waktu yang akan diprediksi, model ini berbeda dari beberapa model lain yang digunakan untuk melakukan peramalan. Pendekatan metodologi *Box-Jenkins* untuk membangun model ARIMA mempunyai tiga langkah dasar, yaitu tahap identifikasi, tahap penaksiran dan pengujian dan pemeriksaan diagnostik. Identifikasi model melibatkan penentuan ordo (p, d, dan q) dari komponen *Autoregressive* (AR) dan *Moving Average* (MA) pada model. Selanjutnya model ARIMA dapat digunakan untuk melakukan peramalan jika model yang diperoleh memadai [7].

### E. *Uji Stasioneritas Augmented Dickey Fuller Test (ADF)*

Uji stasioneritas *Augmented Dickey-Fuller* (ADF) adalah

pengujian yang dilakukan terhadap data deret waktu (*time series*) untuk mengetahui apakah data deret waktu tersebut stasioner atau tidak. Hipotesa *null* pada *Augmented Dickey Fuller* sama seperti *Dickey Fuller*, yaitu dengan mengasumsikan keberadaan akar satuan  $\alpha = 1$ , *p-value* yang didapat harus kurang dari 0,05 untuk menolak hipotesa *null* tersebut. Pada *Augmented Dickey Fuller Test* dikarenakan istilah kesalahan yang ditemukan tidak mungkin *white noise*, ADF memperluas tes dengan menambah lag yang bergantung pada variabel untuk mengeleminasi masalah pada autokorelasi. Secara sederhana, dengan menambahkan nilai lag yang bergantung pada variabel pada model yang telah secara terus menerus hingga autokorelasi tereliminasi. Nilai seberapa banyak dilakukan ADF untuk mencapai nilai mendekati 0,05 dapat digunakan untuk menentukan model dari *Integrated I(d)* [8].

Untuk permodelan matematika *Augmented Dickey Fuller* (ADF) dapat dilihat sebagai berikut:

$$\Delta Y_t = \alpha + \beta t + \gamma Y_{t-1} + \sum_{i=1}^p \beta_i \Delta Y_{t-i} + \epsilon_t \quad (1)$$

Keterangan :

- $Y(t - 1)$  = lag 1 dalam deret waktu
- $\Delta Y(t - 1)$  = diferensiasi pertama dari deret waktu ( $t - 1$ )
- $\alpha$  = konstanta
- $\beta$  = koefisien pada deret waktu
- $\gamma$  = hipotesa *null* sehingga  $\gamma = 0$
- $\epsilon_t$  = proses kesalahan stasioner

#### F. Penentuan Model Autoregressive dengan Menggunakan Autocorrelation Function Test (ACF)

*Autocorrelation Function* (ACF) adalah koefisien yang menunjukkan keeratan hubungan antara nilai variabel yang sama tetapi pada waktu yang berbeda. Uji autokorelasi ini dapat didefinisikan sebagai korelasi antara anggota serangkaian observasi yang diurutkan menurut waktu atau ruang. Fungsi uji autokorelasi adalah untuk mengetahui ada atau tidaknya penyimpangan asumsi klasik autokorelasi yaitu korelasi yang terjadi antara residual pada satu pengamatan dengan pengamatan lain pada model regresi [9].

Dalam ARIMA itu sendiri suatu nilai koefisien autokorelasi dikatakan tidak berbeda secara signifikan dari nol apabila nilainya berada dalam batas interval dan dikatakan berbeda secara signifikan dari nol jika nilai koefisien autokorelasi berada diluar batas interval. Nilai koefisien autokorelasi yang melebihi interval batas penerimaan dapat digunakan untuk menentukan model dari *Moving Average* (MA(q) [9].

Untuk permodelan matematika dari *Autocorrelation Function* (ACF) dapat dilihat sebagai berikut:

$$\rho_k = \frac{\sum_{t=k+1}^n (Z_t - \bar{Z})(Z_{t-k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2} \quad (2)$$

Keterangan:

- $\rho_k$  = nilai koefisien autokorelasi untuk *time lag* 1, 2, 3, ..., k
- $Z_t$  = data aktual periode t
- $\bar{Z}$  = mean data aktual
- $Z_{t-k}$  = data aktual periode lag k

#### G. Penentuan Model Moving Average dengan Menggunakan Partial Autocorrelation Function Test (PACF)

Korelasi parsial adalah pengukuran hubungan antara dua

variabel dengan mengontrol atau menyesuaikan efek dari satu atau lebih variabel lain. *Partial Autocorrelation Function* (PACF) merupakan koefisien autokorelasi parsial yang mengukur derajat hubungan antara nilai – nilai sekarang dengan nilai – nilai sebelumnya, sedangkan pengaruh nilai variabel *time lag* yang lain dianggap konstan. Fungsi autokorelasi parsial digunakan untuk mendefinisikan fase pada model *autoregressive* (AR(p)), plot autokorelasi parsial dapat digunakan untuk menentukan model regresi pada ARIMA.

#### H. Mean Absolute Percentage Error (MAPE)

*Mean Absolute Percentage Error* (MAPE) merupakan salah satu perhitungan yang populer untuk digunakan dalam mengukur akurasi peramalan. MAPE merepresentasikan rata – rata dari *absolute percentage errors* dari tiap *entry* dalam dataset. MAPE merupakan metrik langsung, yang berarti 10% MAPE merepresentasikan rata – rata deviasi antara nilai peramalan dan nilai aktual [10].

Untuk pemodelan matematika *Mean Absolute Percentage Error* (MAPE) dapat dilihat sebagai berikut:

$$MAPE = \frac{1}{N} \sum_{t=1}^N \left| \frac{A_t - F_t}{A_t} \right| \times 100 \quad (3)$$

Keterangan:

- N = Ukuran sampel
- $A_t$  = Data aktual pada saat t
- $F_t$  = Data peramalan pada saat t

#### I. Power BI

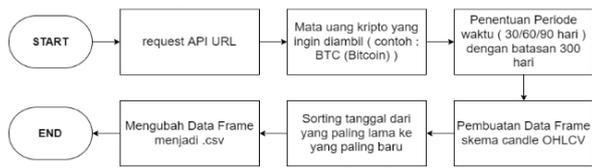
*Power BI* merupakan aplikasi untuk menganalisis data dan membagikan *insight* untuk mendapatkan jawaban terhadap pengambilan keputusan dengan lebih cepat melalui visualisasi data yang interaktif. Dari sisi teknologi, *Power BI* adalah suatu pendekatan dan alat untuk mengubah data mentah menjadi *insight* bisnis yang lebih bermakna [11].

### III. METODE PENELITIAN

#### A. Metode Pengambilan Data

Pada tahap ini dataset didapatkan dari *website coinbase*. Data yang akan didapat melalui *request API URL* “<https://api.pro.coinbase.com>” tersebut akan berbentuk JSON (*JavaScript Object Notation*) yang dimana telah ditentukan mata uang kripto apa yang ingin diambil dan ditentukan periode waktu yang akan diambil. Data yang diambil akan mempunyai periode waktu 30 hari, dimulai dari hari saat pengambilan data hingga 30 hari sebelumnya. Data tersebut kemudian akan diolah menggunakan *dataframe* menjadi skema *candle OHLCV* (*Open Price, High Price, Low Price, Close Price, dan Volume*), skema *candle OHLCV* tersebut akan diurutkan berdasarkan tanggal dari yang paling lama hingga ke yang paling terkini. *Dataframe* tersebut akan menghasilkan keluaran akhir berbentuk “.csv”. Dalam pengambilan data maka akan dipergunakan bahasa *Python* dengan *library pandas* untuk mengubah data JSON menjadi *dataframe*. Untuk alur pelaksanaan pengambilan dataset melalui *endpoint API* dapat dilihat pada Gambar 1.

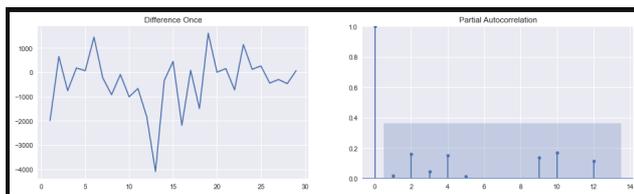
Dilakukan request terhadap HTTP API website yang dituju (*coinbase.com*) dilanjutkan dengan pembuatan *dataframe* skema *candle OHLCV* dengan periode waktu 30 hari dimulai dari hari saat pengambilan data hingga 30 hari kebelakang



Gambar 1. Alur pelaksanaan pengambilan data melalui endpoint API.

[3]:	date	low	high	close	volume
0	6/1/2022	29308.01	31964.56	29788.79	26857.462630
1	6/2/2022	29558.61	30655.00	30433.75	18519.126080
2	6/3/2022	29213.47	30674.95	29670.85	15016.781850
3	6/4/2022	29454.14	29952.00	29843.18	6390.759430
4	6/5/2022	29505.65	30158.44	29901.54	5482.496324

Gambar 2. Dataframe skema candle OHLCV.



Gambar 6. Grafik PACF dataset BTC.csv.

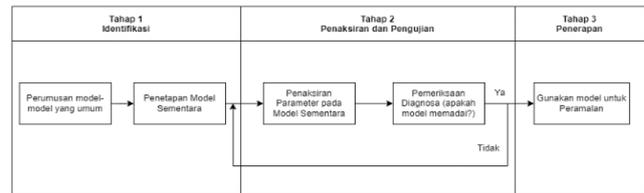
seperti Gambar 2.

### B. Metode Pengolahan Data

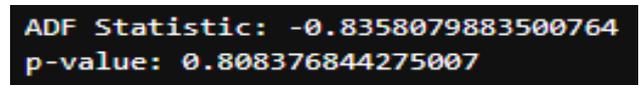
Pada tahap ini, dataset yang telah terkumpul dan berbentuk ekstensi “.csv” akan diolah menggunakan bahasa pemrograman *Python* untuk dilakukan peramalan dengan metode *Autoregressive Integrated Moving Average*. Input atau masukan untuk peramalan adalah data harga saat *closing price* dan akan menghasilkan output berupa model peramalan yang dibangun dengan metodologi *Box-Jenkins*, model tersebut kemudian akan divisualisasikan menggunakan aplikasi *Power BI*. Pendekatan metodologi *Box-Jenkins* untuk membangun model ARIMA mempunyai tiga langkah dasar, yaitu tahap identifikasi, tahap penaksiran & pengujian, dan pemeriksaan diagnostik. Identifikasi model melibatkan penentuan ordo ( $p$ ,  $d$ , dan  $q$ ) dari komponen *Autoregressive* (AR) dan *Moving Average* (MA) pada model yang kemudian akan ditetapkan sebagai model sementara. Pada tahap penaksiran dan pengujian, model ARIMA sementara yang telah didapatkan dapat dilakukan pemeriksaan diagnostik apakah model tersebut memadai dengan melihat nilai AIC dan BIC mana yang paling kecil. Selanjutnya model ARIMA dapat digunakan untuk melakukan peramalan jika model yang diperoleh memadai. Alur metodologi *Box-Jenkins* dapat dilihat pada Gambar 3. Pada penelitian yang dilakukan digunakan dataset “BTC.csv” sebagai acuan untuk pengolahan dataset lain.

### C. Menentukan Urutan Diferensiasi ( $d$ ) pada Model ARIMA

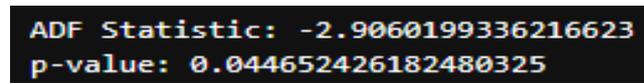
Uji stasioneritas *Augmented Dickey-Fuller* (ADF) adalah pengujian yang dilakukan terhadap data deret waktu (*time series*) untuk mengetahui apakah data deret waktu tersebut stasioner atau tidak. Hipotesa *null* pada tes ADF menjelaskan bahwa deret waktu tersebut tidak stasioner, sehingga jika *p-value* yang di uji kurang dari 0,05 maka hipotesa *null* tidak digunakan dan dapat disimpulkan deret waktu telah stasioner. Perlu diketahui untuk tidak melakukan *over-differencing* pada seri data. Dikarenakan seri data *over-differencing* dapat



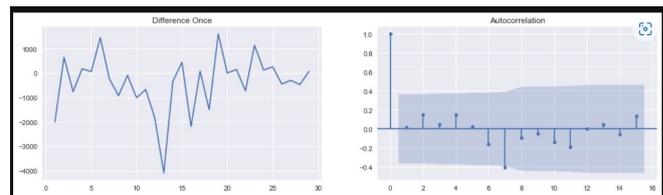
Gambar 3. Metodologi *Box-Jenkins*.



Gambar 4. ADF test pada data aktual.



Gambar 5. ADF test pada dferensiasi pertama.



Gambar 7. Grafik ACF dataset BTC.csv.

menjadi stasioner yang dimana akan mempengaruhi parameter pada model [12].

Berdasarkan beberapa gambar tersebut, dataset aktual pada Gambar 4 memiliki *p-value* lebih dari 0,05, hal ini berarti dataset tersebut tidak stasioner. Dikarenakan dataset tidak stasioner maka dilakukan diferensiasi pertama seperti pada Gambar 5 dan didapatkan *p-value* kurang dari 0,05 sehingga urutan nilai diferensiasi pertama dapat digunakan sebagai nilai  $d$  untuk model ARIMA.

### D. Menentukan Urutan Autoregressive ( $p$ ) pada Model ARIMA Menggunakan Plot Partial Autocorrelation Function (PACF)

Langkah berikutnya untuk menentukan model diperlukan urutan *Autoregressive* (AR), untuk mencari AR dapat melihat plot *Partial Autocorrelation Function* (PACF). *Partial Autocorrelation Function* merupakan korelasi antara seri data dan lag-nya setelah mengecualikan kontribusi dari lag menengah. Secara sederhana PACF menyampaikan korelasi murni antara lag dan seri data.

*Partial Autocorrelation Function Test* digunakan untuk menentukan nilai *Moving Average* ( $p$ ) pada ARIMA. Grafik pada Gambar 6 menunjukkan bahwa tidak ada lag yang melebihi batas autokorelasi sehingga dapat digunakan lag 5 dikarenakan kondisi PACF sama seperti kondisi ACF, yaitu pada lag 5 angka jatuh ke 0.

### E. Menentukan Urutan Moving Average ( $q$ ) pada Model ARIMA Menggunakan Plot Autocorrelation Function (ACF)

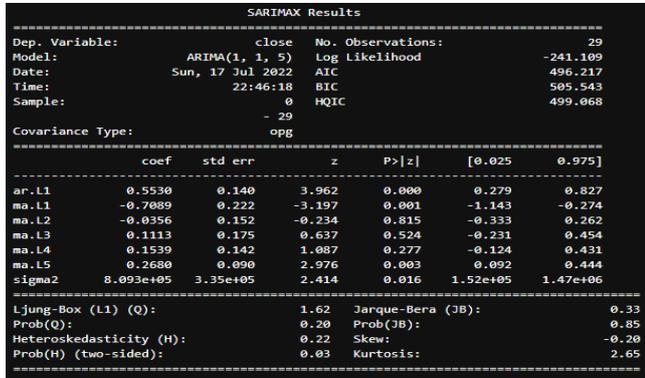
*Autocorrelation Function Test* digunakan untuk menentukan nilai *Moving Average* ( $q$ ) pada ARIMA. Pada Gambar 7, dikarenakan yang melebihi nilai batas hanya lag 7 dan bernilai negatif maka dapat digunakan lag 5 dimana pada lag tersebut nilai jatuh ke nol.

### F. Pemilihan Model ARIMA ( $p$ , $q$ , $d$ ) untuk Peramalan

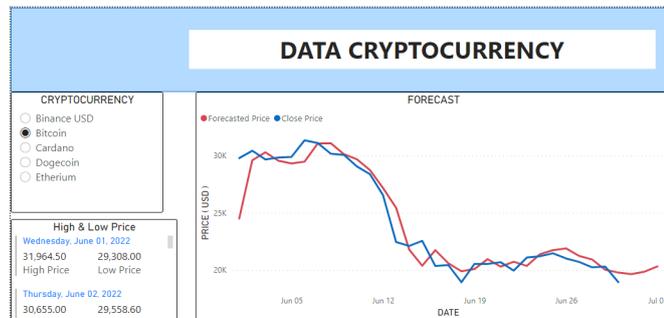
Pada grafik *Partial Autocorrelation Function* (PACF) dapat dilihat nilai jatuh ke nol pada lag 5 akan tetapi tidak ada yang negatif sehingga perlu dilakukan pengujian terhadap lag

Tabel 1.  
Nilai AIC dan BIC pada Model ARIMA

Model ARIMA	AIC	BIC
(5, 1, 5)	559.992	564.472
(4, 1, 5)	546.066	559.388
(3, 1, 5)	536.939	540.614
(2, 1, 5)	518.194	528.852
(1, 1, 5)	496.217	499.068



Gambar 8. Model ARIMA (1, 1, 5).



Gambar 11. Grafik forecast mata uang kripto Bitcoin.

1 hingga lag 5, hal serupa juga terjadi pada nilai Autocorrelation Function (ACF) yang jatuh ke nol pada lag 5. Pada uji stasioneritas menggunakan *Augmented Dickey Fuller* (ADF) didapatkan nilai kurang dari 0,05 pada diferensiasi pertama sehingga nilai  $d=1$ . Dapat disimpulkan bahwa terdapat beberapa model *Autoregressive Moving Average* (ARMA) yang memungkinkan pada diferensiasi pertama deret data *Bitcoin*. Adapun beberapa model ARMA tersebut adalah sebagai berikut:

1. Model ARMA(0, 5), merupakan model *Moving Average* dimana  $q=5$  dikarenakan autokorelasi jatuh ke nol setelah lag 5.
2. Model ARMA(p,q), merupakan model gabungan antara p dan q dikarenakan autokorelasi dan autokorelasi parsial jatuh ke nol.

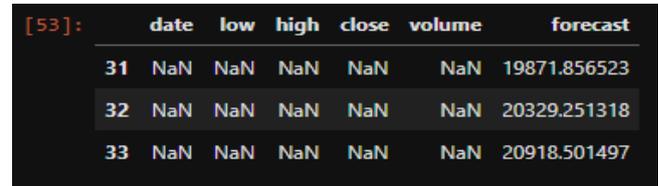
Berdasarkan kondisi tersebut maka didapat beberapa model ARIMA(p, d, q), antara lain adalah model ARIMA(5, 1, 5), model ARIMA(4, 1, 5), model ARIMA(3, 1, 5), model ARIMA(2, 1, 5), dan model ARIMA(1, 1, 5).

Untuk mendapatkan model yang paling sesuai untuk peramalan, maka dapat dipilih model dengan nilai BIC (*Bayesian Information Criterion*) dan AIC (*Akaike Information Criterion*) yang paling rendah. Dapat dilihat pada Tabel 1 dan Gambar 8, model ARIMA(1, 1, 5) memiliki nilai AIC dan BIC paling rendah sehingga dapat digunakan sebagai model prediksi.

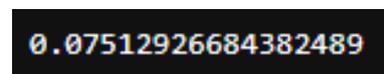
Setelah ditentukan model ARIMA yang akan digunakan, dilakukan peramalan menggunakan fungsi *plot\_predict* dari

Tabel 2.  
Penjelasan visualisasi yang digunakan pada dashboard Power BI

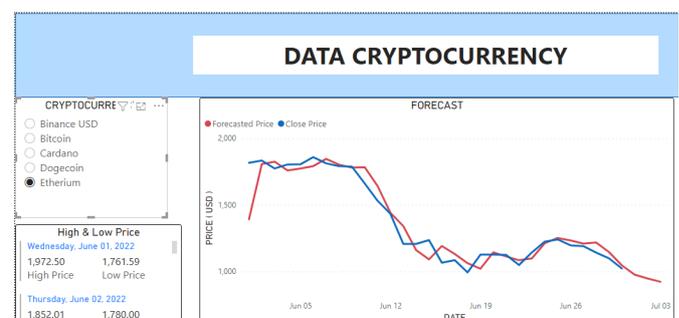
No	Nama Visualisasi	Data yang digunakan
1	<i>Slicer</i>	Simbol/jenis mata uang kripto
2	<i>Line Chart</i>	<i>Close price</i> , tanggal, data <i>close price</i> setelah dilakukan peramalan
3	<i>Clustered Column Chart</i>	Volume yang diperdagangkan selama 24 jam terakhir
4	<i>Card</i>	Simbol/jenis mata uang kripto
5	<i>Card</i>	Nilai MAPE
6	<i>Multi-row Card</i>	Tanggal, <i>high price</i> , dan <i>low price</i>



Gambar 9. Dataframe peramalan ARIMA(1, 1, 5) dataset BTC.csv.



Gambar 10. Nilai MAPE pada peramalan BTC.csv.



Gambar 12. Grafik forecast mata uang kripto Ethereum.

paket *statsmodels* yang kemudian nilai dari *forecast* tersebut dapat ditampilkan ke dalam *dataframe* dan dapat langsung di salin ke dalam "file.csv" dimana terdapat nilai harga yang telah dilakukan peramalan hari ke 31 hingga hari ke 33, seperti yang ditunjukkan oleh Gambar 9.

### G. Perhitungan Mean Absolute Percentage Error

Pada Tahapan ini dilakukan perhitungan *Mean Absolute Percentage Error* (MAPE) untuk mengukur akurasi peramalan yang telah dilakukan menggunakan *Autoregressive Integrated Moving Average* (ARIMA). MAPE merepresentasikan rata – rata kesalahan absolut dari setiap entri pada dataset. Untuk menghitung MAPE digunakan fungsi MAPE dari paket *sklearn* dimana pada fungsi tersebut menghitung menggunakan data aktual pada *dataframe* "close" dan data peramalan pada *dataframe* "forecast" yang akan menghasilkan keluaran seperti pada Gambar 10 dan dapat disimpulkan bahwa presentase kesalahan pada peramalan ARIMA(1, 1, 5) dataset BTC.csv sebesar 7,5%.

### H. Visualisasi Dashboard Power BI

Setelah data disiapkan, selanjutnya dapat dilakukan visualisasi data tersebut ke dalam *dashboard* dengan memasukkan ke dalam atribut yang diinginkan. Pada *dashboard* mata uang kripto berisikan beberapa informasi, yaitu jenis mata uang kripto, *high price*, *low price*, *close price*, harga setelah dilakukan peramalan, volume yang



Gambar 13. Grafik volume mata uang kripto Bitcoin.



Gambar 14. Grafik tren harga pada Bitcoin.



Gambar 15. High & low price dalam 1 hari pada Bitcoin.

diperdagangkan selama 24 jam terakhir, dan nilai MAPE tiap mata uang kripto. Tabel 2 menjelaskan tentang jenis visualisasi yang digunakan untuk menampilkan data.

#### IV. PEMBAHASAN

Dari *dashboard* mata uang kripto yang telah dibuat, seorang individu atau organisasi dapat mengambil keputusan sebagai berikut:

##### A. Forecast

Pada grafik *forecast* menampilkan data harga aktual dan data harga setelah dilakukan peramalan dengan periode waktu selama 30 hari untuk data harga aktual dan 3 hari kemudian untuk data harga setelah dilakukan peramalan. Dengan visualisasi ini, seorang individu atau organisasi mampu melihat tren harga dari tiap mata uang kripto. Pada visualisasi peramalan harga Gambar 11 dan Gambar 12 dapat dilihat grafik *forecast* pada mata uang kripto Bitcoin (BTC) mengalami kenaikan tren harga pada harga yang diramalkan (tanggal 1 Juli 2022 – 3 Juli 2022) sedangkan pada grafik *forecast* mata uang kripto Ethereum (ETH) mengalami penurunan tren harga pada harga yang diramalkan. Skenario yang dapat dilakukan pihak pengambilan keputusan berdasarkan grafik tersebut adalah sebagai berikut:

1. Jika pengambil keputusan telah membeli aset pada mata uang kripto Bitcoin sebelum 30 Juni 2022, maka berdasarkan grafik *forecast* tersebut pengambil keputusan dapat menahan aset atau membeli aset tambahan dikarenakan akan ada kenaikan tren harga yang tidak terlalu curam pada tanggal 3 Juli 2022 sehingga dapat menghasilkan *margin profit* positif jika menjual aset pada tanggal tersebut.
2. Jika pengambil keputusan telah membeli aset pada mata uang kripto Ethereum sebelum 30 Juni 2022, maka berdasarkan grafik *forecast* tersebut pengambil keputusan dapat menjual aset dengan *margin profit* negatif dikarenakan akan ada penurunan tren harga lebih lanjut hingga tanggal 3 Juli 2022.
3. Terlepas dari kepemilikan aset, pengambil keputusan dapat menahan pembelian aset Ethereum pada tanggal 30 Juni 2022 dikarenakan akan terjadi penurunan tren harga hingga 3 Juli 2022, sedangkan pada Bitcoin pengambil keputusan dapat membeli aset pada tanggal 30 Juni 2022 dikarenakan akan terjadi kenaikan tren harga hingga 3 Juli 2022.

##### B. Volume

Menampilkan volume yang diperdagangkan selama 24 jam terakhir dengan periode waktu selama 30 hari. Tujuan penampikan volume ini dapat membantu individu atau organisasi mengetahui akan kapan trader mata uang kripto lain melakukan transaksi terhadap asetnya. Pada visualisasi peramalan Bitcoin (BTC) Gambar 13 dapat dilihat bahwa volume yang diperdagangkan naik drastis pada tanggal 13 Juni 2022 dikarenakan terdapat tren penurunan harga seperti pada Gambar 14 sehingga *trader* melakukan jual beli mata uang kripto di tanggal tersebut.

Terdapat dua jenis skenario sebagai acuan untuk pengambilan keputusan dalam melakukan transaksi mata uang kripto pada titik tersebut, yaitu sebagai berikut:

1. *Trader* yang melakukan penjualan akan menjual aset mereka dikarenakan penurunan tren harga dapat terus berlangsung.
2. *Trader* yang melakukan pembelian akan membeli aset baru dikarenakan penurunan harga yang drastis sehingga *trader* dapat membeli aset dengan harga murah sehingga dapat dijual dikemudian hari dengan *margin profit* yang lebih tinggi

##### C. High & Low Price

Menampilkan harga paling tinggi dan rendah pada hari tersebut dengan periode selama 30 hari. Dari data ini, seorang individu atau organisasi dapat mengetahui lonjakan harga setiap hari guna pengambilan keputusan lebih lanjut ketika melakukan transaksi mata uang kripto.

Pada Gambar 15, dapat dilihat harga terendah dan tertinggi Bitcoin pada hari tersebut. Hal ini dapat membantu pengambil keputusan untuk menjual aset dengan acuan harga tertinggi pada hari sebelumnya dan membeli aset dengan acuan harga terendah sebelumnya untuk memperoleh *margin profit* yang lebih tinggi.

#### V. KESIMPULAN

Kesimpulan yang didapat dari penelitian ini adalah pengambilan data menggunakan *endpoint* API memudahkan pengambilan dataset dalam jumlah besar dalam waktu yang singkat dan melalui metode ARIMA didapatkan presentase nilai kesalahan peramalan sebesar 7,5%, hal ini berarti presentase dari model mempunyai keakuratan sebesar 92,5% untuk memprediksi 3 hari kedepan. Selain itu, telah dibuat

sistem *Business Intelligence* berupa *dashboard* peramalan *Business Intelligence* untuk mata uang kripto yang meliputi data harga aktual, data setelah dilakukan peramalan dengan metode ARIMA, volume yang diperdagangkan selama 24 jam terakhir, dan nilai MAPE. Dengan adanya pembuatan dashboard tersebut, dapat memudahkan individu atau organisasi dalam mengambil keputusan terkait dengan harga mata uang kripto.

#### DAFTAR PUSTAKA

- [1] R. Farrell, "An Analysis of the Cryptocurrency Industry," Business, University of Pennsylvania, Philadelphia, 2015.
- [2] C. Vercellis, *Business Intelligence: Data Mining and Optimization for Decision Making*. New York: Wiley, 2009. doi: 10.1002/9780470753866.
- [3] E. Vogelpang, *Econometrics: Theory and Applications with EViews*. Harlow (England): FT Prentice Hall (Pearson Education), 2005.
- [4] M. Caporin and M. McAleer, "Do we really need both BEKK and DCC? A tale of two multivariate GARCH models," *SSRN Electronic Journal*, 2010, doi: 10.2139/ssrn.1549167.
- [5] B. Choi, *ARMA Model Identification - Springer Series in Statistics*, 1st ed. USA: Springer-Verlag New York Inc., 2012.
- [6] A. Neumann, N. Laranjeiro, and J. Bernardino, "An analysis of public REST web service APIs," *IEEE Trans Serv Comput*, vol. 14, no. 4, pp. 957–970, Jul. 2021, doi: 10.1109/TSC.2018.2847344.
- [7] M. Kumar and M. Anand, "An application of time series arima forecasting model for predicting sugarcane production in India," *Studies in Business and Economics*, vol. 9, no. 1, pp. 81–94, Apr. 2014.
- [8] R. Mushtaq, "Augmented dickey fuller test," *SSRN Electronic Journal*, Aug. 2011, doi: 10.2139/ssrn.1911068.
- [9] G. M. Tinungki, "The analysis of partial autocorrelation function in predicting maximum wind speed," *IOP Conf Ser Earth Environ Sci*, vol. 235, no. 1, p. 012097, Feb. 2019, doi: 10.1088/1755-1315/235/1/012097.
- [10] S. Kim and H. Kim, "A new metric of absolute percentage error for intermittent demand forecasts," *Int J Forecast*, vol. 32, no. 3, pp. 669–679, Jul. 2016, doi: 10.1016/j.ijforecast.2015.12.003.
- [11] A. Bansal and A. K. Upadhyay, "Microsoft power BI," *International Journal of Soft Computing and Engineering (IJSCE)*, vol. 7, no. 1, Jul. 2017.
- [12] Z. Hossain, A. Rahman, M. Hossain, and J. H. Karami, "Over-differencing and forecasting with non-stationary time series data," *Dhaka University Journal of Science*, vol. 67, no. 1, pp. 21–26, Jan. 2019, doi: 10.3329/dujs.v67i1.54568.