

Pemodelan Harga *Cryptocurrency* Menggunakan *Markov Switching Autoregressive*

⁽¹⁾Akhmad Ridho Ashariansyah, ⁽²⁾Nur Iriawan, dan ⁽³⁾Adatul Mukarromah

⁽¹⁾⁽²⁾⁽³⁾Departemen Statistika, Fakultas Sains dan Analitika Data

Institut Teknologi Sepuluh Nopember (ITS)

Jl. Arief Rahman Hakim, Surabaya 60111 Indonesia

e-mail: ⁽¹⁾akhmadridhoashariansyah@gmail.com ⁽²⁾nur_i@statistika.its.ac.id ⁽³⁾adatul@statistika.its.ac.id

Abstrak— *Perdagangan merupakan sebuah kegiatan tukar menukar barang atau jasa yang dilakukan manusia untuk memenuhi kebutuhan hidup. Perkembangan sistem pembayaran yang dilakukan umat manusia dimulai dari sistem pertukaran barang atau barter, logam mulia seperti emas dan perak, koin, uang kartal, uang giral, dan uang elektronik (e-money). Selain itu, muncul cryptocurrency yaitu mata uang digital dengan sistem kriptografi dalam setiap proses transaksi datanya tanpa melalui pihak ketiga. Namun cryptocurrency memiliki kelemahan perubahan harga yang sangat besar dalam waktu yang sangat cepat. Pergerakan harga yang berfluktuasi sangat tinggi tersebut menyebabkan kekhawatiran pemilik aset kripto mengalami kerugian, maka pemodelan harga cryptocurrency sangat penting untuk dilakukan agar meminimalisir risiko kerugian. Berdasarkan pola pergerakan harga yang berfluktuasi sangat tinggi yang berbeda tiap periodenya maka dilakukanlah pemodelan harga cryptocurrency menggunakan Markov Switching Autoregressive (MSAR) dengan algoritma Expectation Maximization. Selain meminimalkan risiko kerugian, penelitian ini juga ingin mengetahui model MSAR mana yang mampu mengklasifikasikan state dengan baik. Data yang digunakan yaitu harga harian cryptocurrency dengan nilai kapitalisasi pasar terbesar dari September 2015 hingga Januari 2020. Hasil penelitian menunjukkan bahwa bitcoin dan ripple menggunakan model MS(8)AR(1), sedangkan ethereum menggunakan model MS(9)AR(1). Selain itu model MS(8)AR(1) pada data ripple menjadi model dengan nilai akurasi tertinggi dibandingkan model lainnya dalam hal klasifikasi state.*

Kata kunci: *Cryptocurrency, Fluktuasi, MSAR*

I. PENDAHULUAN

Perdagangan ialah sebuah kegiatan tukar menukar barang atau jasa yang dilakukan manusia untuk memenuhi kebutuhan hidup. Perkembangan sistem pembayaran yang dilakukan umat manusia dimulai dari sistem pertukaran barang atau barter, logam mulia seperti emas dan perak, koin, uang kartal, uang giral, dan uang elektronik (*e-money*) [1]. Sistem pembayaran *e-money* memunculkan kekhawatiran terhadap penyalahgunaan data oleh pihak ketiga, untuk itulah muncul gagasan desentralisasi terhadap pihak ketiga dengan munculnya *cryptocurrency*. *Cryptocurrency* merupakan mata uang digital dengan sistem kriptografi dalam setiap proses transaksi datanya tanpa melalui pihak ketiga [2]. *Cryptocurrency* pertama yang terdesentralisasi secara penuh diberi nama *bitcoin*. Selain menjadi alat pembayaran *bitcoin* juga dapat dijadikan alat penyimpanan kekayaan, serta sebagai alat investasi [3]. Beberapa jenis *cryptocurrency* memiliki batas ketersediaan pasokan, sebagai contoh batas pasokan *bitcoin* hanya

terdapat 21 juta unit [4]. Keterbatasan pasokan ini menjadi salah satu faktor fluktuasi harga *cryptocurrency*. Fluktuasi harga *cryptocurrency* dapat merubah harga secara signifikan dalam waktu yang sangat cepat. Hal ini dapat dilihat dari harga *bitcoin* saat pertama kali digunakan pada bulan Juli 2010 hanya bernilai 0,05 USD/*bitcoin*, sedangkan harga *bitcoin* pada akhir tahun 2019 sebesar 7234,44 USD/*bitcoin* [4]. Perkembangan harga *bitcoin* yang berfluktuasi sangat tinggi tersebut menyebabkan pola data yang berbeda tiap periodenya. Pola data yang sangat berbeda membuat harga *cryptocurrency* tidak dapat diselesaikan dengan analisis deret waktu (*time series*) klasik, sedangkan pemodelan harga *cryptocurrency* sangat penting untuk dilakukan agar meminimalisir risiko kerugian pemilik aset kripto.

Banyaknya pola data yang terbentuk dari data harga *cryptocurrency* yang berkaitan dengan deret waktu serta adanya transisi kondisi (*regime switching*) yang diasumsikan sebagai proses stokastik yang membangkitkan peubah acak tidak teramati bersifat diskrit disebut rantai markov, yang kemudian dikombinasikan dengan model autoregresi sehingga menjadi model *Markov Switching Autoregressive* (MSAR). Model MSAR diestimasi dengan menggunakan algoritma *Expectation Maximization* (EM). Algoritma EM terdiri dari dua tahapan. Tahapan pertama yaitu *expectation* yang mana tahapan ini melibatkan algoritma *filtering* dan *smoothing*, untuk menghasilkan estimasi peluang *smoothed* dari variabel yang tidak teramati. Tahapan selanjutnya *maximization*, dengan menurunkan hasil *smoothing* menggunakan fungsi likelihood. Hasil tahapan *maximization* kemudian dijadikan parameter baru untuk di gunakan ke tahapan *expectation* kembali, yang mengakibatkan nilai fungsi likelihood selalu meningkat [5]. Penelitian ini bertujuan untuk memodelkan harga *cryptocurrency* agar tidak mengalami kerugian yang disebabkan oleh fluktuasi harga yang sangat cepat menggunakan *Markov Switching Autoregressive* dengan algoritma EM dalam pembentukan model. Pada penelitian ini juga ingin diketahui model MSAR mana yang mampu mengklasifikasikan *state* dengan baik. Data yang digunakan adalah data sekunder berupa historis harga *cryptocurrency* yang memiliki kapitalisasi pasar terbesar pada Januari 2020, antara lain *bitcoin*, *ripple*, dan *ethereum*.

II. TINJAUAN PUSTAKA

A. Analisis Time Series

Time series merupakan serangkaian observasi terhadap suatu variabel yang diambil secara beruntun berdasarkan interval waktu tertentu [6]. Peramalan *time series* dapat disebut sebagai tindakan memprediksi masa depan dengan memahami masa lalu [7]. Rangkaian data pada pengamatan *time series* dinyatakan dengan variabel Y_t dimana t adalah indeks waktu urutan pengamatan.

B. Uji Stasioneritas

Stasioneritas dapat diartikan tidak terdapat perubahan yang drastis pada data. Stasioneritas terbagi menjadi dua yaitu stasioneritas dalam *mean* dan varians. Stasioneritas dalam *mean* diidentifikasi dengan plot *time series*, plot *Autocorrelation Function* (ACF), serta uji *Augmented Dickey-Fuller* (ADF). Data dikatakan tidak stasioner ketika plot *time series* menunjukkan data berfluktuasi tidak berada disekitar sumbu horizontal, sedangkan pada plot ACF terdapat pola yang turun secara lambat. Sedangkan stasioneritas dalam varians diidentifikasi dengan plot *box-cox*. Data dikatakan tidak stasioner dalam varians ketika nilai lambda tidak sama dengan 1. Ketidakstasioneran dalam varians dapat diatasi dengan cara transformasi data.

Uji ADF dilakukan dengan hipotesis sebagai berikut:

H_0 : $\delta = 0$ (data tidak stasioner)

H_1 : $\delta \neq 0$ (data stasioner)

Statistik uji yang digunakan dituliskan pada persamaan (1).

$$t = \frac{\hat{\delta}}{SE(\hat{\delta})} \tag{1}$$

Keputusan yang didapatkan akan Tolak H_0 jika $|t| > t_{\alpha,df}$ atau $p\text{-value} < \alpha$.

Ketidakstasioneran pada data dapat diatasi dengan cara transformasi, salah satu bentuk transformasi yang digunakan yaitu *log return*, dapat dituliskan pada persamaan (2) [8].

$$r_t = \ln(y_t) - \ln(y_{t-1}) = \ln \frac{y_t}{y_{t-1}} \tag{2}$$

C. Model Autoregressive (AR)

Model *autoregressive* (AR) adalah model yang menggambarkan variabel dependen dipengaruhi oleh variabel dependen pada periode sebelumnya [9]. Bentuk umum dari proses *autoregressive* dapat dituliskan pada persamaan (3).

$$Y_t = \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + u_t \tag{3}$$

dimana Y_t merupakan nilai pengamatan, ϕ_t merupakan koefisien, u_t merupakan residual.

D. Autocorrelation Function (ACF)

Fungsi autokorelasi (ACF) mengukur bagaimana urutan pengamatan dalam deret waktu berkorelasi satu sama lain. Fungsi autokorelasi antara Y_t dan Y_{t+k} dapat dituliskan pada persamaan (4) [10].

$$ACF(k) = \rho_k = \frac{Cov(Y_t, Y_{t+k})}{Var(Y_t) Var(Y_{t+k})} = \frac{\gamma_k}{\gamma_0} \tag{4}$$

dimana,

$$\gamma_k = Cov(Y_t, Y_{t+k}) = E(Y_t - \mu)(Y_{t+k} - \mu) \tag{5}$$

E. Markov Switching Autoregressive (MSAR)

Model *markov switching* digunakan untuk pemodelan data runtun waktu yang mengalami perubahan kondisi. Perubahan kondisi dalam model *markov switching* dianggap sebagai peristiwa variabel tak teramati yang disebut dengan *state*. Model *Markov Switching* dikombinasikan dengan model runtun waktu *Autoregressive* untuk mengetahui perubahan kondisi atau pola data runtun waktu. Model MSAR dapat dituliskan pada persamaan (6) [11].

$$y_t - \mu_{s_t} = \phi_1 (y_{t-1} - \mu_{s_{t-1}}) + \dots + \phi_p (y_{t-p} - \mu_{s_{t-p}}) + u_t \tag{6}$$

dengan $u_t \sim IIDN(0, \sigma_{st}^2)$, dimana Y_t merupakan nilai

pengamatan, ϕ_t merupakan koefisien, μ_{s_t} merupakan *mean* yang dipengaruhi perubahan *state*, e_t merupakan residual.

Estimasi parameter dilakukan untuk menduga nilai dari masing-masing parameter pada model. Estimasi parameter model MSAR menggunakan algoritma *Expectation-Maximization* (EM) [12]. Langkah pertama yang dilakukan sebelum menggunakan algoritma EM yaitu dengan menentukan fungsi densitas. Fungsi densitas model MSAR sebanyak 2 *state* dapat dituliskan pada persamaan (7).

$$f(y_t | s_t, s_{t-1}, \psi_{t-1}) = \frac{1}{\sigma_k \sqrt{2\pi}} \exp \left[-\frac{((y_t - \mu_k) - \phi_t (y_{t-1} - \mu_{k-1}))^2}{2\sigma_k^2} \right] \tag{7}$$

dimana ψ_{t-1} merupakan nilai pengamatan. *State* yang tidak teramati dapat diatasi dengan cara sebagai berikut.

1. Menurunkan fungsi densitas gabungan y_t , s_t , dan s_{t-1} , bersyarat pengamatan sebelumnya

$$f(y_t, s_t, s_{t-1} | \psi_{t-1}) = f(y_t | s_t, s_{t-1}, \psi_{t-1}) P[s_t, s_{t-1} | \psi_{t-1}] \tag{8}$$

2. Menentukan fungsi desitas y_t bersyarat pengamatan sebelumnya dengan menjumlahkan semua kemungkinan densitas bersama dari s_t dan s_{t-1} .

$$\begin{aligned} f(y_t | \psi_{t-1}) &= \sum_{s_t=1}^M \sum_{s_{t-1}=1}^M f(y_t, s_t, s_{t-1} | \psi_{t-1}) \\ &= \sum_{s_t=1}^M \sum_{s_{t-1}=1}^M f(y_t | s_t, s_{t-1}, \psi_{t-1}) P[s_t, s_{t-1} | \psi_{t-1}] \end{aligned} \tag{9}$$

Nilai peluang $P[s_t = j, s_{t-1} = i | \psi_{t-1}]$ dihitung menggunakan proses *filtering* dan *smoothing* sebagai berikut.

1. *Filtering*

Filtering adalah suatu proses yang digunakan untuk mendapatkan nilai peluang suatu *state* pada waktu ke t berdasarkan nilai pengamatan, dengan langkah-langkah sebagai berikut.

- a. Diketahui $P[s_{t-1} = i | \psi_{t-1}]$, dengan $i = 1, 2, \dots, M$, pada awal waktu t atau pada iterasi ke- t . Sedangkan $P[s_t = j, s_{t-1} = i | \psi_{t-1}]$ dihitung sebagai berikut.

$$P[s_t = j, s_{t-1} = i | \psi_{t-1}] = P[s_t = j | s_{t-1} = i] P[s_{t-1} = i | \psi_{t-1}] \tag{10}$$

- b. Saat y_t diamati pada akhir waktu t , atau pada akhir iterasi ke- t .

$$\begin{aligned} P[s_t = j, s_{t-1} = i | \psi_t] &= \frac{f(s_t = j, s_{t-1} = i, y_t | \psi_{t-1})}{f(y_t | \psi_{t-1})} \\ &= \frac{f(y_t | s_t = j, s_{t-1} = i, \psi_{t-1}) P[s_t = j, s_{t-1} = i | \psi_{t-1}]}{\sum_{s_t=1}^M \sum_{s_{t-1}=1}^M f(y_t | s_t = j, s_{t-1} = i, \psi_{t-1}) P[s_t = j, s_{t-1} = i | \psi_{t-1}]} \end{aligned} \tag{11}$$

diperoleh hasil dari proses *filtering*

$$P[s_t = j | \psi_t] = \sum_{s_{t-1}=1}^M P[s_t = j, s_{t-1} = i | \psi_t] \tag{12}$$

2. *Smoothing*

Pada proses *smoothing* nilai probabilitas *state* dihitung berdasarkan seluruh pengamatan sehingga menghasilkan nilai probabilitas *state* yang lebih baik dibandingkan proses *filtering*. Hasil peluang dari proses *filtering* dilanjutkan dengan pendekatan *Kim* untuk mendapatkan peluang *smoothed* [13].

$$\begin{aligned} P[s_t = j, s_{t+1} = k | \psi_T] &= P[s_{t+1} = k | \psi_T] P[s_t = j | s_{t+1} = k, \psi_T] \\ &= \frac{P[s_{t+1} = k | \psi_T] P[s_t = j | \psi_t] P[s_{t+1} = k | s_t = j]}{P[s_{t+1} = k | \psi_t]} \end{aligned} \tag{13}$$

diperoleh hasil dari proses *smoothing*

$$P[s_t = j | \psi_T] = \sum_{k=1}^M P[s_t = j, s_{t+1} = k | \psi_T] \tag{14}$$

Setelah mendapatkan nilai peluang s_t melalui proses *filtering* dan *smoothing* maka dapat diperoleh fungsi densitas dari y_t sebagai berikut.

$$f(y_t | s_t, s_{t-1}, \psi_T) = \sum_{j=1}^M \sum_{i=1}^M f(y_t | s_t, s_{t-1}, \psi_{t-1}) P[s_t, s_{t-1} | \psi_T] \quad (15)$$

Fungsi *log-likelihood* dapat dituliskan sebagai berikut.

$$\ln L = \sum_{t=1}^T f(y_t | s_t, s_{t-1}, \psi_t) \quad (16)$$

Nilai masing-masing parameter dapat dihitung dengan memaksimalkan fungsi *log-likelihood* dengan cara mendiferensialkan fungsi *log-likelihood* terhadap masing-masing parameter $\theta = (\mu_k, \sigma_k^2, \phi_p)$, didapatkan masing-masing parameter sebagai berikut.

$$\hat{\mu}_k = \frac{\sum_{t=1}^T y_t P[s_t = j | y_t]}{\sum_{t=1}^T P[s_t = j | y_t]} \quad (17)$$

$$\hat{\sigma}_k^2 = \frac{\sum_{t=1}^T (y_t - \hat{\mu}_k)^2 P[s_t = j | y_t]}{\sum_{t=1}^T P[s_t = j | y_t]} \quad (18)$$

$$\hat{\phi}_p = \frac{\sum_{t=1}^T \left(\sum_{j=1}^N (y_t - \hat{\mu}_k) P[s_t = j | \psi_T] \right)}{\sum_{t=1}^T \left(\sum_{j=1}^N P[s_t = j | \psi_T] \right)} \quad (19)$$

Peluang perpindahan *state* dibentuk ke dalam matriks transisi karena rantai markov pada matriks transisi menyatakan nilai sekarang dipengaruhi oleh nilai pada periode sebelumnya [14]. Matriks peluang transisi dapat dituliskan pada persamaan (20).

$$[P_{i,j}]_{i,j \in S} = \begin{bmatrix} P_{0,0} & P_{0,1} & \dots & P_{0,j} \\ P_{1,0} & P_{1,1} & \dots & P_{1,j} \\ \vdots & \vdots & \ddots & \vdots \\ P_{i,0} & P_{i,1} & \dots & P_{i,j} \end{bmatrix} \quad (20)$$

Semakin sedikit perpindahan *state* yang terjadi maka semakin sedikit juga perpindahan pola data, menunjukkan model yang terbentuk baik. Model MSAR juga dapat menghitung lama durasi rata-rata dari masing-masing *state*. Elemen diagonal dari matriks peluang transisi mengandung informasi mengenai durasi rata-rata yang diharapkan dari suatu *state* akan bertahan. Durasi rata-rata *state* dapat dituliskan pada persamaan (21).

$$E(\bar{D}) = \frac{1}{1 - P_{jj}} \quad (21)$$

dimana P_{jj} merupakan diagonal matriks peluang transisi.

F. Uji Signifikansi Parameter

Pengujian signifikansi parameter dilakukan dengan cara uji parsial terhadap setiap parameter. Berikut merupakan pengujian signifikansi parameter dengan menggunakan hipotesis yang dituliskan sebagai berikut [6].

H_0 : $\phi_i = 0$ (parameter tidak signifikan)

H_1 : $\phi_i \neq 0$ (parameter signifikan)

Statistik uji yang digunakan dituliskan pada persamaan (22).

$$t = \frac{\hat{\phi}_i}{SE(\hat{\phi}_i)} \quad (22)$$

Keputusan yang didapatkan akan Tolak H_0 jika $|t| > t_{\alpha,df}$ atau $p\text{-value} < \alpha$.

G. Akaike's Information Criterion (AIC)

Akaike's Information Criterion digunakan sebagai kriteria pemilihan model terbaik, dikarenakan kriteria ini konsisten dalam menduga parameter model. AIC dapat dituliskan pada persamaan (23) [15].

$$AIC = -2 \log(L) + 2k \quad (23)$$

dimana L merupakan nilai maksimum fungsi *likelihood*, k merupakan banyaknya parameter pada model.

H. Evaluasi Hasil Klasifikasi

Pengukuran ketepatan klasifikasi dilakukan untuk melihat performa klasifikasi yang telah dilakukan. Ketepatan klasifikasi dapat dievaluasi dengan menghitung jumlah kelas positif yang terklasifikasi dengan benar (*true positive*), jumlah kelas negatif yang terklasifikasi dengan benar (*true negative*), jumlah kelas negatif yang salah terklasifikasi ke dalam kelas positif (*false positive*) atau jumlah kelas positif yang salah terklasifikasi ke dalam kelas negatif (*false negative*) [16].

Keempat jenis perhitungan ini dapat dilihat melalui sebuah matriks yang sering disebut dengan *confusion matrix*. Penilaian ketepatan klasifikasi untuk *multiclass classification* didefinisikan perkelas secara individual. Kualitas keseluruhan klasifikasi dapat dinilai dengan dua cara yakni melalui rata-rata dari tiap kriteria yang dihitung untuk setiap kelasnya (*macro-averaging*) atau jumlah penghitungan untuk mendapatkan kumulatif TP, FN, TN, dan FP (*micro-averaging*) [16]. Nilai TP pada kasus *multiclass classification* terdapat pada diagram matriks yang digambarkan pada Tabel 1.

Tabel 1 *Confusion Matrix Multiclass*

Kelas Aktual	Kelas Prediksi				Total
	C_1	C_1	C_1	C_1	
C_1	n_{11}	n_{12}	n_{13}	n_{14}	n_1
C_2	n_{21}	n_{22}	n_{23}	n_{24}	n_2
C_3	n_{31}	n_{32}	n_{33}	n_{34}	n_3
C_4	n_{41}	n_{42}	n_{43}	n_{44}	n_4
Total	$n_{.1}$	$n_{.2}$	$n_{.3}$	$n_{.4}$	$N_{..}$

Pada kasus *multiclass* kinerja klasifikasi dapat diukur dengan menggunakan *accuracy*, *precision*, *sensitivity*, dan *Fscore*. *Accuracy* adalah banyaknya pengamatan yang terklasifikasi secara tepat. *Fscore* didapatkan dari nilai kombinasi antara *precision* dan *sensitivity*. *Precision* adalah banyaknya pengamatan yang tepat terprediksi positif dari keseluruhan dengan hasil prediksi positif, sedangkan *sensitivity* adalah banyaknya pengamatan yang tepat diklasifikasikan sesuai kategorinya [16]. Perhitungan *accuracy*, *precision*, *sensitivity*, dan *Fscore* dapat dilakukan dengan menggunakan persamaan-persamaan berikut.

$$accuracy = \frac{1}{K} \sum_{k=1}^K \frac{TP_k + TN_k}{TP_k + FN_k + FP_k + TN_k} \quad (24)$$

$$sensitivity = \frac{1}{K} \sum_{k=1}^K \frac{TP_k}{TP_k + FN_k} \quad (25)$$

$$precision = \frac{1}{K} \sum_{k=1}^K \frac{TP_k}{TP_k + FP_k} \quad (26)$$

$$F = \frac{2 \times precision \times sensitivity}{precision + sensitivity} \quad (27)$$

I. Cryptocurrency

Istilah *cryptocurrency* tercipta pada tahun 1982, seseorang yang bernama David Chaum mempublikasikan ide pembuatan sebuah metode pembayaran berbasis kriptografi yang dapat menjaga kerahasiaan data pemiliknya, karena tidak bisa dilacak oleh pihak ketiga [17]. Kemudian pada tahun 2008 seorang programmer yang bernama Satoshi Nakamoto membuat mata uang digital berbasis kriptografi yang diberi nama *bitcoin* [18]. *Bitcoin* inilah yang menjadi pionir munculnya jenis *cryptocurrency* baru seperti *ethereum* dan *ripple*. Beberapa jenis *cryptocurrency* memiliki jumlah pasokan yang terbatas, seperti halnya *bitcoin* 21 juta dan *ripple* 100 miliar. Keterbatasan pasokan ini menjadi salah satu faktor berubahnya harga *cryptocurrency*. Fluktuasi pada harga *cryptocurrency* dapat merubah harga secara signifikan dalam waktu yang sangat cepat.

Cryptocurrency di Indonesia diakui keberadaannya sejak tanggal 2 Oktober 2018 dengan terbitnya Peraturan Menteri Perdagangan Republik Indonesia No. 99 Tahun 2018 Tentang Kebijakan Umum Penyelenggaraan Perdagangan Berjangka Aset Kripto (*Crypto Asset*), yang mana pada pasal 1 berbunyi aset kripto ditetapkan sebagai Komoditi yang dapat dijadikan Subjek Kontrak Berjangka yang diperdagangkan di Bursa Berjangka.

III. METODOLOGI PENELITIAN

A. Sumber Data

Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari situs CryptoCompare. Data diambil pada tanggal 1 Februari 2020 dari situs <https://www.cryptocompare.com>. Data yang digunakan berupa harga harian *cryptocurrency* dengan nilai kapitalisasi pasar tertinggi yang dimulai dari tanggal 1 September 2015 sampai 31 Januari 2020. Jenis *cryptocurrency* yang digunakan yaitu *bitcoin*, *ethereum*, dan *ripple*.

B. Variabel Penelitian

Variabel penelitian yang digunakan adalah harga harian ketiga jenis *cryptocurrency* dengan nilai kapitalisasi pasar tertinggi. Variabel penelitian tercantum pada Tabel 2.

Tabel 2 Variabel Penelitian

Variabel	Keterangan	Skala
Y ₁	Harga <i>Bitcoin</i> (BTC)	Rasio
Y ₂	Harga <i>Ethereum</i> (ETH)	Rasio
Y ₃	Harga <i>Ripple</i> (XRP)	Rasio

Ketiga variabel penelitian ini tidak terkait satu sama lain dan data dibagi menjadi data *training* dan *testing*. Struktur data pada penelitian ini ditunjukkan pada Tabel 3.

Tabel 3 Struktur Data Penelitian

Data	Tanggal	Y ₁	Y ₂	Y ₃
<i>Training</i>	01-09-2015	Y _{1,1}	Y _{2,1}	Y _{3,1}
	02-09-2015	Y _{1,2}	Y _{2,2}	Y _{3,2}
	⋮	⋮	⋮	⋮
	28-02-2019	Y _{1,1277}	Y _{2,1614}	Y _{3,1614}
<i>Testing</i>	01-03-2019	Y _{1,1278}	Y _{2,1278}	Y _{3,1278}
	02-03-2019	Y _{1,1279}	Y _{2,1279}	Y _{3,1279}
	⋮	⋮	⋮	⋮
	31-01-2020	Y _{1,1614}	Y _{2,1614}	Y _{3,1614}

C. Langkah Analisis

Langkah-langkah analisis dalam penelitian ini dituliskan sebagai berikut :

- Mengumpulkan data harga harian *bitcoin*, *ethereum*, dan *ripple* dengan cara mengunduh data pada situs <https://cryptocompare.com>.
- Melakukan eksplorasi data dengan menghitung statistika deskriptif dan membuat plot *time series* pada data harga harian *bitcoin*, *ethereum*, dan *ripple* untuk mengetahui karakteristik data, penghitungan statistika deskriptif antara lain menghitung *mean*, varians, nilai maksimum, dan nilai minimum.
- Membagi data harga harian *bitcoin*, *ethereum*, dan *ripple* menjadi data *training* dan *testing* dengan proporsi 80:20.
- Melakukan uji stasioneritas pada masing-masing data *training* harga harian *bitcoin*, *ethereum*, dan *ripple*.
 - Membuat plot *Autocorrelation Function* (ACF) data penelitian.
 - Melakukan uji *root test* dengan uji *Augmented Dickey-Fuller* (ADF) untuk menguji stasioner terhadap *mean*.
 - Membuat plot *box-cox* data penelitian untuk menguji stasioner terhadap varians.
- Jika data tidak stasioner, maka perlu melakukan transformasi *log return* dengan cara *differencing log* data penelitian.
- Menaksir estimasi parameter model *Markov Switching Autoregressive* dengan menggunakan nilai *states/regime* dari 2 hingga 9 *states* serta melakukan perulangan sebanyak 5 kali setiap *state*, pada setiap data penelitian dengan algoritma *Expectation-Maximization* (EM).
- Memilih model terbaik untuk setiap harga *bitcoin*, *ethereum*, dan *ripple* berdasarkan nilai AIC minimum.
- Menentukan anggota tiap *state* model terbaik untuk setiap harga *bitcoin*, *ethereum*, dan *ripple* dengan menggunakan data prediksi AR(1) dan data *testing*.
- Membandingkan performa klasifikasi *state* pada setiap model terbaik antara *state* data prediksi AR(1) dan *state* data *testing* berdasarkan nilai *accuracy*, *precision*, *sensitivity*, dan *Fscore*.
- Menarik kesimpulan dan saran terkait hasil analisis yang telah dilakukan.

IV. ANALISIS DAN PEMBAHASAN

A. Eksplorasi Data


Statistika deskriptif harga harian ketiga jenis *cryptocurrency* dari tanggal 1 September 2015 sampai tanggal 31 Januari 2020 ditunjukkan pada Tabel 4.

Tabel 4 Statistika Deskriptif Harga Harian *Cryptocurrency*

Variabel	Rata-rata	Varians	Nilai Maksimum	Nilai Minimum
<i>Bitcoin</i>	4583,6	15644068	19346,6	226,2
<i>Ethereum</i>	205,19	57480,4558	1385,02	0,42
<i>Ripple</i>	0,2678	0,11021	2,78	0,0039


Cryptocurrency dengan rata-rata harga harian tertinggi dari tanggal 1 September 2015 sampai 31 Januari 2020 adalah *bitcoin* yaitu sebesar 4.583,6 dolar Amerika. Disusul dengan *ethereum* dengan rata-rata harga sebesar 205,19 dan *ripple* sebesar 0,2678 dolar Amerika. Harga harian *bitcoin* sangat berfluktuatif dilihat dari nilai varians sebesar 15.644.068, dengan harga terendah 226,2 dolar dan harga tertinggi 19.346,6 dolar.

Puncak harga tertinggi *bitcoin* terjadi pada tanggal 17 Desember 2017, untuk harga tertinggi *ethereum* pada tanggal 14 Januari 2018, sedangkan harga tertinggi *ripple* tanggal 8 Januari 2018. Harga terendah *bitcoin* terjadi pada tanggal 4 September 2015, untuk harga *ethereum* pada tanggal 22 Oktober 2015, sedangkan harga *ripple* tanggal 1 Desember 2015. Pola data harian *cryptocurrency* dapat dilihat dengan plot *time series*. Berikut plot *time series* dari ketiga data harian *cryptocurrency*.




Gambar 1 Plot Time Series Bitcoin

Plot *time series bitcoin* yang ditunjukkan Gambar 1 terdapat pola stagnan di bulan September 2015 hingga Agustus 2017, pada bulan ini munculnya pergerakan harga *bitcoin* yang mulai merangkak naik hingga mencapai puncaknya dengan harga 19.346,6 dolar Amerika di pertengahan bulan Desember 2017. Namun harga harian *bitcoin* tidak mampu meningkat lagi, bahkan terjadi tren menurun secara terus menerus hingga bulan Januari 2019, dan mulai merangkak naik kembali setelahnya, namun harga *bitcoin* tidak bisa melebihi 13.000 dolar Amerika.



Gambar 2 Plot Time Series Ethereum

Plot *time series ethereum* yang ditunjukkan Gambar 2 tidak berbeda dengan pola data harga *bitcoin* yang stagnan, namun pada bulan Mei 2017 harga *ethereum* mulai menunjukkan kenaikan harga walaupun sesekali mengalami penurunan harga hingga mencapai puncak tertinggi harga *ethereum* pada bulan Januari 2018. Harga *ethereum* mengalami penurunan harga yang drastis pada bulan April 2018, sempat berbalik harga di bulan Mei 2018 namun tidak bertahan lama harga *ethereum* kembali turun secara terus menerus. Kemudian harga *ethereum* bulan Januari 2019 hingga Januari 2020 berfluktuasi di range harga *ethereum* 100 sampai 330 dolar Amerika.




Gambar 3 Plot Time Series Ripple

Pola data harga *ripple* tidak jauh berbeda dengan 2 harga *cryptocurrency* sebelumnya, yaitu terdapat pola stagnan hingga di akhir bulan Maret 2017, pada titik inilah

harga *ripple* mulai menunjukkan pergerakannya. Berdasarkan gambar 3 harga *ripple* mengalami kenaikan harga yang signifikan dari bulan Desember 2017 hingga mencapai puncaknya pada Januari 2018. Serupa dengan kenaikan harga yang signifikan dengan cepat hal ini juga terjadi pada penurunan harga yang cepat juga. Harga *ripple* mulai mengalami fluktuasi yang normal pada bulan Juni 2018 hingga Januari 2020 dengan batas bawah harga 0,18 dan batas atas 0,58 dolar Amerika.

B. Uji Stasioneritas

Stasioneritas dapat diartikan tidak terdapat perubahan yang drastis pada data. Sebelum melakukan uji stasioneritas data penelitian dibagi menjadi dua bagian terlebih dahulu, yaitu data *training* dan data *testing*. Data *training* dimulai dari tanggal 1 September 2015 sampai tanggal 28 Februari 2019, sedangkan data *testing* tanggal 1 Maret 2019 hingga 31 Januari 2020. Data yang digunakan pada uji stasioneritas dan pembentukan model yaitu data *training*. Maka dibentuklah plot ACF untuk melihat ketidakstasioneran data.



Gambar 4 Plot ACF (a) Bitcoin (b) Ethereum (c) Ripple

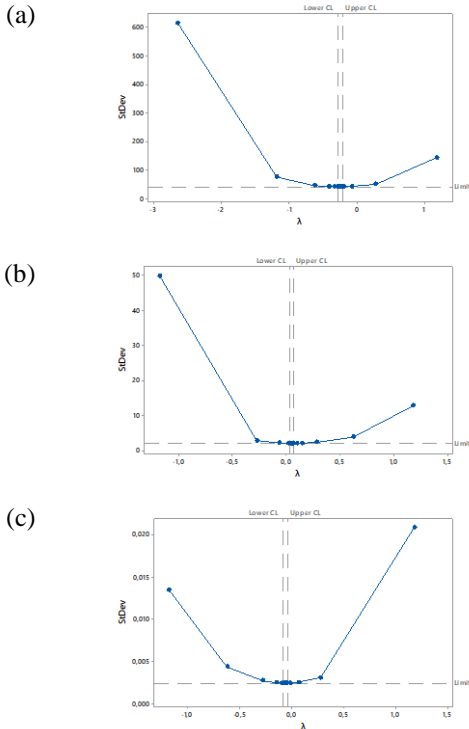
Terlihat bahwa plot ACF data harga harian ketiga *cryptocurrency* cenderung turun secara lambat sehingga dapat dikatakan tidak stasioner terhadap *mean* dan *varians*. Alternatif lain untuk mengetahui ketidakstasioneran data dengan melakukan uji *unit root* dengan uji *Augmented Dickey-Fuller* (ADF).

Tabel 5 Uji ADF Harga Harian Cryptocurrency

Variabel	Dickey-Fuller	p-value
Bitcoin	-2,2512	0,472
Ethereum	-1,411	0,827
Ripple	-3,6033	0,032

Hasil uji ADF pada Tabel 5 menunjukkan adanya ketidakstasioneran data terhadap *mean* pada harga harian *bitcoin* dan *ethereum*, karena *p-value* dari kedua variabel tersebut lebih dari $\alpha(0,05)$. Kemudian untuk mengetahui stasioner atau tidaknya data terhadap *varians* dengan

membuat plot *box-cox*, yang ditampilkan pada Gambar 5 sebagai berikut.



Gambar 5 Plot *Box-Cox* (a) *Bitcoin* (b) *Ethereum* (c) *Ripple*

Dari ketiga plot *box-cox* diatas tidak ada harga harian yang nilai lambdanya 1, maka dapat dikatakan ketiga harga harian diatas tidak stasioner terhadap varians. Data yang tidak stasioner tersebut dapat diatasi dengan transformasi *log return*. Berikut merupakan hasil uji ADF setelah dilakukan transformasi.

Tabel 6 Uji ADF Transformasi *Log Return* Harga Harian *Cryptocurrency*

Variabel	Dickey-Fuller	p-value
<i>Bitcoin</i>	-9,9126	< 0,01
<i>Ethereum</i>	-9,8305	< 0,01
<i>Ripple</i>	-9,1311	< 0,01

Hasil uji ADF setelah transformasi yang dapat dilihat pada Tabel 6 menunjukkan ketiga data sudah stasioner, karena *p-value* dari ketiga variabel tersebut kurang dari $\alpha(0,05)$.

C. *Markov Switching Autoregressive Bitcoin*

Data harga harian *bitcoin* merupakan data yang paling drastis dalam perubahan harganya dibandingkan kedua variabel lainnya. Hal ini dapat dilihat dari pola plot *time series bitcoin* yang memiliki 2 puncak, serta dapat dilihat juga dari nilai varians yang sangat besar. Percobaan model *Markov Switching Autoregressive* (MSAR) pada *bitcoin* dengan *state* 2 sampai 9 dapat dilihat pada tabel dibawah.

Tabel 7 Ukuran Keباikan Model MSAR *Bitcoin*

Model	AIC
MS(2)AR(1)	-5157,23
MS(3)AR(1)	-5266,28
MS(4)AR(1)	-5300,37
MS(5)AR(1)	-5308,62
MS(6)AR(1)	-5325,04
MS(7)AR(1)	-5331,48
MS(8)AR(1)	-5352,23
MS(9)AR(1)	-5344,10

Ukuran kebaikan model MSAR *bitcoin* dapat dilihat pada Tabel 7 menunjukkan 8 *state* sebagai model terbaik,

dikarenakan nilai AIC dari model tersebut lebih kecil dibandingkan model lainnya, dengan model yang terbentuk sebagai berikut.

$$(Y_t - \mu_{s_t}) = -0.0084(Y_{t-1} - \mu_{s_{t-1}}) + e_t$$

dengan rata-rata masing-masing *state* sebagai berikut.

$$\mu_{s_t} \begin{cases} \mu_1 = -0.0883, & \mu_5 = -0.1932 \\ \mu_2 = -0.0595, & \mu_6 = -0.2691 \\ \mu_3 = 0.5876, & \mu_7 = 0.0128 \\ \mu_4 = -0.2762, & \mu_8 = 0.2568 \end{cases}$$

Tabel 8 Estimasi Parameter Model MS(8)AR(1) *Bitcoin*

Parameter	Koefisien	p-value	Parameter	Koefisien
$\hat{\phi}_1$	-0,0084	0,765	σ_1	0,0617
$\hat{\mu}_1$	-0,0883	0,751	σ_2	0,0213
$\hat{\mu}_2$	-0,0595	0,499	σ_3	0,0559
$\hat{\mu}_3$	0,5876	1,02e-06	σ_4	0,0647
$\hat{\mu}_4$	-0,2762	0,015	σ_5	0,0055
$\hat{\mu}_5$	-0,1932	<2,2e-16	σ_6	0,0231
$\hat{\mu}_6$	-0,2691	0,002	σ_7	0,0311
$\hat{\mu}_7$	0,0128	0,809	σ_8	0,0165
$\hat{\mu}_8$	0,2568	<2,2e-16		

Estimasi parameter model MS(8)AR(1) menunjukkan adanya *state* yang memiliki *p-value* lebih dari $\alpha(0,05)$ yang dapat diartikan koefisien rata-rata pada beberapa *state*, diantaranya *state* 1, 2, dan 7 tidak berpengaruh signifikan terhadap model yang terbentuk. Nilai rata-rata dari masing-masing *state* memiliki nilai yang kecil serta mayoritas *state* yang terbentuk memiliki nilai negatif, menandakan model yang terbentuk lebih sering meningkat pada saat pergantian *state*. Nilai standar deviasi yang kecil setiap *state* menandakan pengelompokan data observasi masing-masing *state* memiliki nilai yang serupa. Hasil *output* peluang matriks transisi juga dapat digunakan untuk menghitung lama durasi masing-masing *state*, dapat dilihat pada tabel berikut.

Tabel 9 Lama Durasi Setiap *State* Model MS(8)AR(1) *Bitcoin*

State	Peluang State	Durasi Kondisi State
1	0,145	1,170
2	0,804	5,103
3	0,070	1,076
4	0,101	1,112
5	0,531	2,133
6	0,118	1,133
7	0,142	1,166
8	0,439	1,782

Dapat dilihat pada Tabel 9 bahwa rata-rata lama durasi setiap *state* memiliki nilai yang serupa, kecuali pada *state* 2 yang berdurasi 5,103 hari sekaligus menjadi *state* yang paling lama bertahan. Sedangkan *state* dengan durasi tercepat terjadi pada *state* 3 sebesar 1,076 hari.

D. *Markov Switching Autoregressive Ethereum*

Data harga harian *ethereum* sama halnya dengan *bitcoin* yang memiliki nilai varians besar. Percobaan model *Markov Switching Autoregressive* (MSAR) pada *ethereum* dengan *state* 2 sampai 9 dapat dilihat pada tabel dibawah.

Tabel 10 Ukuran Keباikan Model MSAR *Ethereum*

Model	AIC
MS(2)AR(1)	-3552,46
MS(3)AR(1)	-3572,53
MS(4)AR(1)	-3621,02
MS(5)AR(1)	-3636,36
MS(6)AR(1)	-3640,68

Tabel 10 Ukuran Keباikan Model MSAR *Ethereum* (Lanjutan)

Model	AIC
MS(7)AR(1)	-3652,79
MS(8)AR(1)	-3660,69
MS(9)AR(1)	-3668,54

Dapat dilihat pada Tabel 10 nilai AIC dari model MSAR *ethereum* tidak berbeda jauh satu sama lainnya. Nilai AIC terkecil pada data *ethereum* terjadi ketika menggunakan 9 *state*, yang menjadikan MS(9)AR(1) model terbaik, dengan model sebagai berikut.

$$(Y_{2_t} - \mu_{s_t}) = -0.0618 (Y_{2_{t-1}} - \mu_{s_{t-1}}) + e_t$$

dengan rata-rata masing-masing *state* sebagai berikut.

$$\mu_{s_t} \begin{cases} \mu_1 = 0.2837, & \mu_6 = -0.8234 \\ \mu_2 = -0.2031, & \mu_7 = -0.1521 \\ \mu_3 = -0.1734, & \mu_8 = 0.7313 \\ \mu_4 = 1.1162, & \mu_9 = 0.2993 \\ \mu_5 = -0.0738, & \end{cases}$$

Tabel 11 Estimasi Parameter Model MS(9)AR(1) *Ethereum*

Parameter	Koefisien	p-value	Parameter	Koefisien
$\hat{\phi}_1$	-0,0618	0,027	σ_1	0,0808
$\hat{\mu}_1$	0,2837	0,272	σ_2	0,0233
$\hat{\mu}_2$	-0,2031	2,2e-10	σ_3	0,0445
$\hat{\mu}_3$	-0,1734	0,390	σ_4	0,1010
$\hat{\mu}_4$	1,1162	1,4e-08	σ_5	0,0072
$\hat{\mu}_5$	-0,0738	0,004	σ_6	0,0264
$\hat{\mu}_6$	-0,8234	<2,2e-16	σ_7	0,1105
$\hat{\mu}_7$	-0,1521	0,037	σ_8	0,0529
$\hat{\mu}_8$	0,7313	0,001	σ_9	0,0409
$\hat{\mu}_9$	0,2993	0,005		

Estimasi parameter model MS(9)AR(1) pada Tabel 11 dapat dilihat koefisien rata-rata yang signifikan, namun masih terdapat rata-rata *state* yang tidak signifikan, yang terdapat pada *state* 1 dan *state* 3 dikarenakan *p-value* dari kedua *state* tersebut lebih dari $\alpha(0,05)$. Nilai rata-rata pada masing-masing *state* bervariasi dimana dengan batas bawah dan batas atas secara berturut-turut, sebesar -0,8234 dan 1,1162. Persebaran data masing-masing *state* pada data *log return* bagus karena nilai varians yang relatif kecil berada diantara 0,0072 hingga 0,1105. Diagonal peluang matriks transisi dapat digunakan untuk menghitung lama durasi masing-masing *state*, yang dapat dilihat pada tabel dibawah.

Tabel 12 Lama Durasi Setiap *State* Model MS(9)AR(1) *Ethereum*

State	Peluang State	Durasi Kondisi State
1	0,110	1,123
2	0,170	1,205
3	0,633	2,728
4	0,006	1,006
5	0,384	1,624
6	0,112	1,126
7	0,714	3,492
8	0,184	1,226
9	0,230	1,298

Dapat dilihat pada Tabel 12 bahwa rata-rata lama durasi setiap *state* memiliki nilai yang relatif sama, mayoritas hanya bertahan 1 hari, kecuali pada *state* 3 dan 7. *State* 7 menjadi yang paling lama bertahan dengan durasi 3,492 hari, sedangkan *state* 4 dengan durasi tercepat sebesar 1,006 hari.

E. *Markov Switching Autoregressive Ripple*

Berbanding terbalik dengan data harga harian *bitcoin* yang memiliki perubahan harga yang sangat signifikan data harga harian *ripple* menjadi data yang stabil pergerakannya

jika dilihat dari nilai varians yang kecil, yaitu sebesar 0,11. Percobaan model *Markov Switching Autoregressive* (MSAR) pada data *ripple* dengan jumlah *state* yang digunakan antara 2 hingga 9 *state* dapat dilihat pada tabel dibawah.

Tabel 13 Ukuran Keباikan Model MSAR *Ripple*

Model	AIC
MS(2)AR(1)	-3591,36
MS(3)AR(1)	-3727,43
MS(4)AR(1)	-3744,04
MS(5)AR(1)	-3759,00
MS(6)AR(1)	-3748,45
MS(7)AR(1)	-3771,65
MS(8)AR(1)	-3785,51
MS(9)AR(1)	-3774,12

Nilai AIC *state* 8 dan 9 model *Markov Switching Autoregressive* (MSAR) pada data *ripple* menunjukkan nilai AIC terkecil ketika menggunakan 8 *state*, sama halnya seperti model MSAR *bitcoin* menggunakan 8 *state* sebagai model terbaik, dan model yang terbentuk sebagai berikut.

$$(Y_{3_t} - \mu_{s_t}) = -0.1068 (Y_{3_{t-1}} - \mu_{s_{t-1}}) + e_t$$

dengan rata-rata masing-masing *state* sebagai berikut.

$$\mu_{s_t} \begin{cases} \mu_1 = -0.2978, & \mu_5 = -0.1949 \\ \mu_2 = 0.4171, & \mu_6 = -0.6451 \\ \mu_3 = 0.2571, & \mu_7 = 0.5524 \\ \mu_4 = -0.1822, & \mu_8 = -0.3453 \end{cases}$$

Tabel 14 Estimasi Parameter Model MS(8)AR(1) *Ripple*

Parameter	Koefisien	p-value	Parameter	Koefisien
$\hat{\phi}_1$	-0,1068	0,0001	σ_1	0,0608
$\hat{\mu}_1$	-0,2978	0,077	σ_2	0,0602
$\hat{\mu}_2$	0,4171	0,422	σ_3	0,0495
$\hat{\mu}_3$	0,2571	0,064	σ_4	0,0168
$\hat{\mu}_4$	-0,1822	0,043	σ_5	0,0263
$\hat{\mu}_5$	-0,1949	9,5e-06	σ_6	0,0397
$\hat{\mu}_6$	-0,6451	<2,2e-16	σ_7	0,0222
$\hat{\mu}_7$	0,5524	0,049	σ_8	0,0897
$\hat{\mu}_8$	-0,3453	5,9e-05		

Estimasi parameter model MS(8)AR(1) pada Tabel 14 dapat diketahui mayoritas *state* memiliki *p-value* kurang dari $\alpha(0,05)$, sedangkan *state* 1, 2, dan 3 tidak berpengaruh signifikan terhadap model yang terbentuk karena *p-value* lebih dari $\alpha(0,05)$. Nilai rata-rata dari masing-masing *state* memiliki nilai yang hampir sama. Diagonal matriks peluang transisi selanjutnya digunakan untuk menghitung lama durasi masing-masing *state* yang dapat dilihat pada tabel dibawah.

Tabel 15 Lama Durasi Setiap *State* Model MS(8)AR(1) *Ripple*

State	Peluang State	Durasi Kondisi State
1	0,064	1,068
2	0,268	1,366
3	0,224	1,289
4	0,826	5,740
5	0,296	1,421
6	0,096	1,107
7	0,541	2,179
8	0,127	1,145

Lama durasi *state ripple* yang ditunjukkan pada Tabel 15 cenderung berada di antara 1-2 hari, namun tidak halnya dengan *state* 4 dengan lama durasi 5,74 hari sekaligus menjadi yang terlama dan *state* 1 menjadi durasi tercepat.

F. *Perbandingan Performa Klasifikasi State*

Sebelum melakukan perbandingan performa klasifikasi *state* model *Markov Switching Autoregressive* (MSAR) maka

diperlukan data aktual dan data prediksi untuk diterapkan ke dalam model MSAR. Data yang digunakan pada data aktual yaitu data *testing*, sedangkan data prediksi menggunakan data ramalan model *Autoregressive* (AR) berorde 1. Hasil anggota masing-masing *state* dengan data ramalan AR(1) tersebut dibandingkan dengan data *testing* untuk mengetahui performa klasifikasi *state* model MSAR yang dapat dilihat pada tabel sebagai berikut.

Tabel 16 Perbandingan Performa Klasifikasi *State* Model MSAR

Variabel	Akurasi	Precision Macro	Sensitivity Macro	Fscore Macro
BTC	42,90%	47,05%	41,96%	37,66%
ETH	65,98%	43,97%	65,11%	52,49%
XRP	85,80%	63,34%	67,67%	65,43%

Nilai performa klasifikasi *state* masing-masing model MSAR ditunjukkan pada Tabel 16, dapat dilihat bahwa model MSAR dengan variable *ripple* menghasilkan performa lebih baik dibandingkan *bitcoin* dan *ethereum*. Hal ini dapat dilihat dari keempat pengukuran hasil klasifikasi pada variabel *ripple* lebih baik dibandingkan dua variabel lainnya. Dapat dikatakan juga perbandingan klasifikasi antara data prediksi AR(1) dengan data *testing* banyak memiliki kesamaan klasifikasi *state*. Maka model MS(8)AR(1) pada data *ripple* menjadi model terbaik dalam hal klasifikasi *state*.

V. KESIMPULAN DAN SARAN

Kesimpulan yang diperoleh dari hasil analisis yang telah dilakukan adalah sebagai berikut.

1. *Cryptocurrency* dengan rata-rata harga paling besar adalah *bitcoin* yaitu 4583,6 dolar. Harga harian *bitcoin* paling berfluktuatif dilihat dari nilai varians sebesar 15644068, dengan harga terendah 226,2 dolar dan harga tertinggi 19346 dolar. Pola data *bitcoin* memiliki 2 puncak setelah terjadi penurunan harga yang signifikan sebelumnya, berbeda dengan pola data *ethereum* setelah mengalami kenaikan harga yang signifikan harga cenderung turun setiap waktunya, sedangkan pola data *ripple* mengalami peningkatan harga yang sangat cepat dan besar, begitu pula dengan penurunan harganya, namun harganya cenderung stabil setelah itu.
2. Model *Markov Switching Autoregressive* (MSAR) yang terpilih berdasarkan nilai AIC minimum diperoleh data *bitcoin* dan *ripple* menggunakan model MS(8)AR(1), sedangkan *ethereum* menggunakan model MS(9)AR(1).
3. Nilai kebaikan hasil klasifikasi *state* setiap model terbaik ketiga jenis *cryptocurrency* diperoleh data *ripple* yang memiliki nilai kinerja paling baik dengan nilai akurasi sebesar 85,8%.

Berdasarkan kesimpulan yang diperoleh, dapat dirumuskan saran sebagai pertimbangan penelitian selanjutnya yaitu dengan menentukan model *Autoregressive* yang sesuai dengan data pengamatan, serta semua parameter dalam uji signifikansi terpenuhi agar menghasilkan model yang lebih baik.

DAFTAR PUSTAKA

[1] I. Nubika, BITCOIN: Mengenal Cara Baru Berinvestasi Generasi Milenial, Bantul: Genesis Learning, 2018.
 [2] E. Dourado dan J. Brito, "Cryptocurrency," *The New Palgrave Dictionary of Economics, Online Edition*, 2014.

[3] S. Nakamoto, "Bitcoin: A Peer-to-Peer Electronic Cash System," 2009. [Online]. Available: <http://bitcoin.org>. [Diakses 21 Januari 2020].
 [4] CryptoCompare, "Live Cryptocurrency Prices, Trades, and Forums," 2020. [Online]. Available: <http://cryptocompare.com>. [Diakses 16 Januari 2020].
 [5] M. P. Clements dan H.-M. Krolzig, "A Comparison of the Forecast Performance of Markov-Switching and Threshold Autoregressive Models of US GNP," University of Warwick, Coventry, 1997.
 [6] W. W. S. Wei, *Time Series Analysis: Univariate and Multivariate Methods*, Second Edition, New York: Pearson, 2006.
 [7] R. Adhikari dan R. K. Agrawal, *An Introductory Study on Time Series Modeling and Forecasting*, Saarbrücken: LAP Lambert Academic Publishing, 2013.
 [8] R. S. Tsay, *Analysis of Financial Time Series*, Canada: John Wiley & Sons, 2002.
 [9] J. D. Cryer dan K.-S. Chan, *Time Series Analysis with Applications in R*, New York: Springer Science+Business Media, LLC, 2008.
 [10] A. Katchova, "Time Series ARIMA Models," 2013. [Online]. Available: <http://sites.google.com/site/econometricsacademy>. [Diakses 22 Januari 2020].
 [11] S. Fruhwirth-Schnatter, *Finite Mixture and Markov Switching Models*, New York: Springer, 2006.
 [12] J. D. Hamilton, "A New Approach to the Economic Analysis of Nonstationary Time Series and the Business Cycle," *Econometrica*, vol. 57, no. 2, pp. 357-384, 1989.
 [13] C.-J. Kim, "Dynamic Linear Models with Markov Switching," *Journal of Econometrics*, vol. 60, pp. 1-22, 1994.
 [14] C.-J. Kim dan C. R. Nelson, *State-Space Models with Regime Switching: Classical and Gibbs-Sampling Approaches with Applications*, Cambridge: The MIT Press, 1999.
 [15] H. Akaike, "A Bayesian Analysis of the Minimum AIC Procedure," *Ann. Inst. Statist. Math.*, vol. 30, pp. 9-14, 1978.
 [16] M. Sokolova dan G. Lapalme, "A Systematic Analysis of Performance Measures for Classification Tasks," *Information Processing and Management*, vol. 45, pp. 427-437, 2009.
 [17] D. Chaum, "Blind Signatures for Untraceable Payments," *Advances in Cryptology Proceedings of Crypto 82*, pp. 199-203, 1982.
 [18] F. Mulyanto, "Pemanfaatan Cryptocurrency Sebagai Penerapan Mata Uang Rupiah Kedalam Bentuk Digital Menggunakan Teknologi Bitcoin," *Indonesian Journal on Networking and Security*, pp. 19-26, 2015.