

ANALISIS PERBANDINGAN PERAMALAN HARGA EMAS MENGGUNAKAN METODE ARIMA-GARCH DAN FUZZY TIME SERIES MARKOV CHAIN

Yusril Hamid¹, Ristu Haiban Hirzi², Ayu Septiani³
yusrilhamid1234@gmail.com¹, ristuastalavista@hamzanwadi.ac.id²,
septianisuccespg@gmail.com³
Universitas Hamzanwadi

ABSTRAK

Emas merupakan salah satu logam mulia yang sudah dikenal luas, baik untuk tujuan investasi, sebagai koleksi atau simpanan jangka panjang maupun sebagai perhiasan. Investasi emas termasuk salah satu jenis investasi yang banyak diminati masyarakat. Komoditas emas dipandang oleh sebagian besar investor sebagai alat investasi aman dan sudah dilakukan sejak dulu. Emas memiliki *supply* yang terbatas dan tidak pernah berkurang. Hal ini menjadikan nilai atau harga emas cenderung meningkat. Data yang digunakan pada penelitian ini bersumber dari *website logammulia.com* yaitu data harga emas di Indonesia dari tahun 2018-2023. Metode peramalan yang digunakan pada penelitian ini adalah metode ARIMA-GARCH dan *Fuzzy Time Series Markov Chain*. Tujuan dari penelitian ini adalah membandingkan kedua metode tersebut dalam memprediksi harga emas di Indonesia dengan tujuan memperoleh nilai kesalahan yang rendah. Hasil analisis menunjukkan metode ARIMA-GARCH memiliki nilai kesalahan peramalan lebih rendah dibandingkan metode *Fuzzy Time Series Markov Chain*, metode ARIMA-GARCH dengan model terbaik ARIMA(1,2,2)-GARCH(2,2) menghasilkan nilai *error* MAPE sebesar 1,680441 sedangkan metode *Fuzzy Time Series Markov Chain* diperoleh 15 himpunan *Fuzzy* menghasilkan nilai *error* MAPE 3,886557.

Kata Kunci: Harga Emas, Peramalan, ARIMA-GARCH, *Fuzzy Time Series Markov Chain*.

PENDAHULUAN

Kebebasan finansial pada masa tua merupakan harapan dan keinginan setiap orang, dimana ketika masa tua nanti, tidak perlu berusaha keras lagi dalam mencari sumber pendapatan. Untuk mencapai kebebasan finansial, salah satu caranya adalah dengan mengalokasikan pendapatan bukan hanya untuk memenuhi kebutuhan hidup, tetapi juga untuk investasi (Illahi, D.T., et al., 2021:319).

Investasi merupakan komitmen sejumlah dana atau sumber daya lainnya yang dilakukan saat ini, dengan tujuan untuk memperoleh keuntungan di masa depan (Salsabila, 2020:3). Keputusan investasi yang diambil setiap investor akan berbeda-beda tergantung pada tujuan investasi dan keberanian investor menanggung risiko dari investasi yang dilakukan. Investor dapat memilih berbagai jenis aset dalam berinvestasi seperti emas, tanah, properti, saham, obligasi, reksadana, dan lain-lain. Salah satu instrumen investasi favorit karena nilainya yang cenderung meningkat yaitu emas atau biasa disebut dengan logam mulia (Kurniawan, I., 2019:16).

Emas merupakan salah satu logam mulia yang sudah dikenal luas, baik untuk tujuan investasi, sebagai koleksi atau simpanan jangka panjang maupun sebagai perhiasan (Aguston, I.N.S., 2019:2). Menurut Rizkiyati (2015:1) Emas adalah logam mulia yang pernah digunakan sebagai alat perdagangan sama seperti uang saat ini. Penggunaan emas di zaman modern tahun 2017 sudah tidak digunakan lagi sebagai alat tukar perdagangan. Akan tetapi, fungsi emas satu-satunya yang masih bertahan sampai sekarang adalah sebagai perhiasan dan koleksi jangka panjang. Emas tidak hanya memiliki fungsi sebagai perhiasan maupun koleksi akan tetapi berfungsi sebagai bahan baku industri teknologi dan kesehatan

(Raehanun, M., 2021:1).

Investasi emas merupakan salah satu jenis investasi yang banyak diminati masyarakat. Komoditi emas dipandang oleh sebagian besar investor sebagai alat investasi aman dan sudah dilakukan sejak dulu. Di samping itu, emas juga digunakan sebagai standar keuangan atau ekonomi, cadangan devisa dan alat pembayaran yang paling utama di beberapa negara (Simbolon, L.D., 2022:31). Emas pada hakikatnya berfungsi untuk menahan inflasi. Sejak tahun 1998 hingga tahun 2010, harga emas mengalami kenaikan secara kumulatif jauh di atas perubahan kumulatif inflasi. Selama terjadi krisis finansial 2008-2009, banyak harga komoditi mengalami penurunan kurang lebih 40%, tetapi harga emas global cenderung naik rata-rata 6% (Simbolon, L.D., 2022:31).

Emas memiliki supply yang terbatas dan tidak mudah didapat, sementara permintaan terhadap emas tidak pernah berkurang. Hal ini menjadikan nilai atau harga emas yang cenderung meningkat, sehingga menjadi permasalahan bagi para investor. Kenaikan harga emas ini mendorong investor untuk lebih memilih berinvestasi emas dari pada pasar modal (Izati, N.A., et al., 2019:171). Berdasarkan data dari website logammulia.com, menunjukkan bahwa harga emas di Indonesia dari tahun 2018 sampai tahun 2023 mengalami kenaikan setiap tahunnya. Mengingat Investasi emas yang menjanjikan keuntungan yang cukup besar maka sangat perlu dilakukan studi yang mendalam tentang harga emas.

Salah satu cara untuk memprediksi harga emas dengan menggunakan teknik analisis peramalan. Teknik peramalan adalah suatu teknik yang digunakan untuk memperkirakan sesuatu yang akan terjadi pada masa yang akan datang (Hikmah, N.F.N., 2018:3). Terdapat beberapa metode peramalan yang dapat digunakan untuk meramalkan harga emas di Indonesia antara lain metode peramalan ARIMA dengan efek GARCH dan Fuzzy Time Series Markov Chain.

ARIMA adalah model yang digunakan untuk meramalkan data waktu yang memiliki trend dan musiman, sedangkan GARCH adalah model yang digunakan untuk memodelkan volatilitas data yang tidak konstan (heteroskedastisitas) (Meilania, G. T., et al., 2024:166). Jadi, ARIMA-GARCH adalah model yang efektif untuk meramalkan data yang memiliki trend dan musiman dalam data, serta volatilitas yang tidak konstan, sehingga memberikan prediksi yang lebih akurat. Karena data pada penelitian ini mengandung heteroskedastisitas dan memiliki pola data trend, maka ARIMA-GARCH ini adalah solusi yang terbaik untuk penelitian ini.

Metode Fuzzy Time Series Markov Chain (FTSMC) merupakan metode yang tidak mensyaratkan asumsi yang ketat seperti yang diperlukan dalam banyak model statistik tradisional (Biringallo, M., & Abapihi, B., 2017:86). FTSMC dapat digunakan tanpa memerlukan asumsi normalitas, linearitas, atau stasionaritas pada data, yang membuatnya lebih fleksibel dalam menangani data yang mengandung heteroskedastisitas (Puspitasari, D. I., et al., 2017:14). Dengan demikian, metode ini sangat cocok untuk analisis data yang kompleks dan berfluktuasi, tanpa terikat pada asumsi yang mungkin tidak terpenuhi dalam data tersebut.

METODOLOGI

1. Stasioneritas Data

Stasioner pada data time series apabila rata-rata dan variansnya konstan, tidak terdapat unsur trend dalam data dan tidak ada unsur musiman (Hikmah, N.F.N., 2018:11). Suatu data dapat dikatakan stasioner yaitu ketika *mean* dan *varians* dari data yang digunakan berada pada kondisi yang konstan atau tidak terdapat perubahan yang sistematis dari kedua ciri data tersebut. Apabila data tidak stasioner terhadap *mean* maka perlu dilakukan

differencing.

Differencing adalah mencari selisih antar data pengamatan. Differencing untuk selisih pertama secara matematis dapat ditulis (Firdaus, 2006):

$$W_t = Z_t - Z_{t-1} \quad (1)$$

Keterangan:

W_t = Barisan selisih (*differencing*) tingkat pertama

Z_t = Data pada waktu ke t

Z_{t-1} = Data pada waktu t - 1

2. ACF dan PACF

a. Autocorrelation Function (ACF)

Koefisien autokorelasi deret waktu dengan selisih waktu (*lag*) 0, 1, 2 periode atau lebih, autokorelasi menghitung dan membuat plot nilai autokorelasi dari suatu data deret waktu. Untuk menghitung koefisien korelasi antar dua variabel X dan Y yang dinotasikan sebagai r_{xy} untuk n pasang observasi $(X_i, Y_i), i=1,2,3,\dots,n$ digunakan rumus sebagai berikut (Hikmah, N.F.N., 2018:13):

$$r_{xy} = \frac{cov_{xy}}{\sqrt{cov_{xx}cov_{yy}}} = \frac{cov_{xy}}{S_x S_y} \quad (2)$$

Dengan:

r_{xy} : korelasi antara variabel acak X dan variabel acak Y

cov_{xy} : kovariansi variabel acak X dan variabel acak Y

S_x : standar deviasi variabel acak X

S_y : standar deviasi variabel Y

b. Partial Autocorrelation Function (PACF)

Partial Autocorrelation Function (PACF) adalah himpunan autokorelasi parsial untuk berbagai *lag* yang ditulis dengan $(\varphi_{kk}; j = 1, 2, 3, \dots, k)$ yaitu himpunan autokorelasi parsial untuk berbagai *lag* k fungsi autokorelasi parsial digunakan untuk mengatur tingkat keeratan antara X_t dan X_{t-k} , apabila pengaruh dari selisih waktu 1, 2, 3, ..., k-1 dianggap terpisah. Didefinisikan sebagai berikut (Hikmah, N.F.N., 2018:16):

$$\varphi_{kk} = \frac{\rho_{\sim k}^*}{\rho_{\sim k}} \quad (3)$$

Dengan:

$\rho_{\sim k}$ adalah matrik autokorelasi k x k

$\rho_{\sim k}^*$ adalah $\rho_{\sim k}$ adalah kolom terakhir

3. Pengujian Asumsi

a. Uji Normalitas Galat

Untuk mengetahui galat berdistribusi normal atau tidak maka perlu dilakukan uji normalitas residual. Jika galat berdistribusi normal maka residu berada disekitar garis diagonal. Sebaliknya, jika residu tidak berdistribusi normal, maka residu akan menyebar (Hikmah, N.F.N., 2018:19).

b. Uji Ljung-Box

Uji ini dikenal sebagai uji *Ljung-Box* Q dan terkait erat dengan uji *Box Pierce*. Faktanya, statistik uji *Ljung-Box* dijelaskan secara eksplisit yang mengarah pada penggunaan statistik *Box-Pierce*. Uji *Ljung-Box* dapat didefinisikan sebagai berikut (Octavian, E., 2018:23):

$$Q = n(n + 2) \sum_{k=1}^h \frac{\hat{\rho}_k^2}{n-k} \quad (4)$$

Keterangan:

n = ukuran sampel

$\hat{\rho}_k^2$ = autokorelasi sampel pada *lag* k

h = jumlah *lag* yang diuji.

c. Uji Homoskedastisitas Galat (*error*)

Deteksi adanya heteroskedastisitas dapat dilakukan secara grafis dengan melihat apakah terdapat pola nonacak dari plot residual atau residual kuadratis terhadap suatu variabel independen atau terhadap nilai tersuai (*fitted*) variabel dependen (dengan model yang diestimasi).

4. Model Autoregressive Integrated Moving Average (ARIMA)

Model *Autoregressive Integrated Moving Average* (ARIMA) merupakan model tidak stasioner dari model *Autoregressive Moving Average* (ARMA) yang telah dilakukan *differencing* sehingga menjadi stasioner (Hikmah, N.F.N., 2018:21). Terdapat beberapa model ARIMA yang dapat digunakan pada data deret waktu, yaitu:

a. Model *Autoregressive* (AR)

Autoregressive (AR) merupakan nilai sekarang suatu proses dinyatakan sebagai jumlah tertimbang nilai-nilai yang lalu ditambah nilai guncangan random. Model AR dengan orde- p dinotasikan dengan AR(p). Bentuk umum dari model AR(p) sebagai berikut:

$$X_t = a_0 + a_1 X_{t-1} + a_2 X_{t-2} + \dots + a_p X_{t-p} + e_t \quad (5)$$

Order AR yang sering digunakan adalah $p=1$ (AR(1)) atau $p=2$ (AR(1)) atau (AR(2)).

1) Model AR(1)

Bentuk umum model AR(1) adalah sebagai berikut:

$$X_t = a_1 X_{t-1} + e_t \quad (6)$$

2) Model AR(2)

Bentuk umum model AR(2) adalah sebagai berikut:

$$X_t = a_1 X_{t-1} + a_2 X_{t-2} + e_t \quad (7)$$

b. Model *Moving Average* (MA)

Moving Average (MA) adalah nilai *time series* pada waktu t yang dipengaruhi oleh unsur kesalahan pada saat ini dan unsur kesalahan terbobot pada masa lalu.

Model *Moving Average* (MA) orde q , dinotasikan menjadi MA(q). Secara umum, model MA(q) sebagai berikut:

$$X_t = e_t - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q} \quad (8)$$

Dengan:

X_t : nilai variabel pada waktu ke- t

θ_1 : parameter model *moving average* (MA)

e_t : nilai galat pada waktu ke- t

e_{t-q} : nilai kesalahan pada saat $t-q$

q : order MA.

5. ARCH-GARCH

Model GARCH adalah suatu model runtun waktu yang dapat digunakan untuk menggambarkan sifat dinamik fungsi volatilitas dari data. Model GARCH orde (p, q) menyatakan bahwa variansi dari y_t kondisional terhadap informasi masa lalu dan akan mengikuti bentuk:

$$\text{var}(y_t | \mathcal{I}_{t-1}) = E(\varepsilon_{t-j}^2 | \mathcal{I}_{t-1}) = \sigma_t^2 \quad (9)$$

Dengan:

$$\sigma_t^2 = \omega + \sum_{j=1}^p a_j \varepsilon_{t-j}^2 + \sum_{i=1}^q \beta_i \sigma_{t-i}^2 \quad (10)$$

Jika $q=0$ maka memiliki model ARCH Engle, jika $p=q=0$ maka memiliki model *white noise* dengan variansi ω . Dalam model GARCH (p, q) proses ε_t dinyatakan sebagai berikut:

$$\varepsilon_t = \sqrt{\sigma_t} v_t \quad (11)$$

σ_t adalah akar dari σ_t^2 dan v_t adalah proses i.i.d (*independent and identically distributed*) sering diasumsikan berdistribusi normal standar $N(0,1)$. Koefisien model GARCH (p, q) bersifat seperti berikut:

1. $\omega > 0$
2. $a_i \geq 0$ untuk $i=1, 2, \dots, p$
3. $\beta_j \geq 0$ untuk $j=1, 2, \dots, q$
4. $\sum_{j=1}^p \sum_{i=1}^q (a_i + \beta_j) < 1$

6. Fuzzy Time Series

Fuzzy Time Series merupakan konsep baru yang diusulkan oleh Song dan Chissom berdasarkan teori *Fuzzy Set* dan konsep variabel linguistik dan aplikasinya oleh Zadeh (Tholaby, 2017:3). Metode ini menggunakan data historis yaitu nilai-nilai linguistik dalam menyelesaikan masalah peramalan.

7. Fuzzy Time Series Markov Chain

Fuzzy Time Series Markov Chain merupakan konsep baru yang pertama kali diusulkan oleh Tsaur dalam penelitiannya untuk menganalisis keakuratan prediksi nilai tukar mata uang Taiwan dengan dolar US (Wajdi, 2022:1716). *Fuzzy Time Series Markov Chain* adalah metode yang dapat digunakan untuk menganalisis data linguistik atau data time series sampel kecil untuk lebih meningkatkan hasil prediksi (Hidayah, 2021:86). Kelebihan dari *Fuzzy Time Series Markov Chain* yaitu dapat menganalisis data linguistik atau data time series sampel kecil diusulkan supaya keakuratan prediksi lebih tinggi dengan mentransfer data *time series* ke grup *Fuzzy*, dan menggunakannya untuk mendapatkan matriks peluang transisi Rantai Markov kemudian digunakan untuk peramalan (Jatipaningrum, 2019:32). Berikut ini adalah langkah-langkah peramalan dengan menggunakan *Fuzzy Time Series Markov Chain*:

1. Mengumpulkan data historis dan mendefinisikan himpunan semesta U .

Langkah awal adalah menentukan nilai minimum (D_{min}) dan maksimum (D_{max}) dari data historis. Kemudian menentukan nilai D_1 dan D_2 , secara bebas oleh peneliti selama kedua nilai bilangan tersebut masih *real* positif. Nilai D_1 dan D_2 bertujuan untuk mempermudah dalam pembentukan interval. Rumus himpunan semesta pembicaraan yaitu:

$$U = [D_{min} - D_1, D_{max} + D_2] \quad (12)$$

2. Menentukan jumlah dan panjang interval.

Himpunan semesta U dipartisi menjadi beberapa bagian dengan interval yang sama dengan rumus sebagai berikut:

$$n = 1 + 3.322 \log N \quad (13)$$

Dimana N adalah banyaknya data historis. Selanjutnya menghitung panjang interval. Berikut adalah rumus panjang interval (l):

$$l = \frac{[(D_{max} + D_2) - (D_{min} - D_1)]}{n} \quad (14)$$

3. Menentukan himpunan *Fuzzy* pada semesta pembicaraan U .

Dengan beberapa aturan sebagai berikut:

- a. Jika data historis (Y_t) adalah u_i , maka derajat keanggotaan u_i adalah 1, u_{i+1} adalah 0.5 dan lainnya adalah 0.
- b. Jika data historis (Y_t) adalah u_i , $1 < i < n$, maka derajat keanggotaan u_i adalah 1, u_{i-1} dan u_{i+1} adalah 0.5 dan lainnya adalah 0.

Sehingga himpunan *fuzzy* untuk seluruh himpunan semesta U dapat dinyatakan sebagai berikut:

$$A_1 = \frac{1}{u_1}, \frac{0.5}{u_2}, \frac{0}{u_3}, \frac{0}{u_4}, \dots, \frac{0}{u_n}$$

$$A_2 = \frac{0.5}{u_1}, \frac{1}{u_2}, \frac{0.5}{u_3}, \frac{0}{u_4}, \dots, \frac{0}{u_n},$$

$$\vdots$$

$$A_n = \frac{0}{u_1}, \frac{0}{u_2}, \frac{0}{u_3}, \frac{0}{u_4}, \dots, \frac{0}{u_{n-1}}, \frac{1}{u_n}.$$

4. Melakukan *fuzzyfikasi* terhadap data historis.

Fuzzyfikasi merupakan proses mengidentifikasi data ke dalam *Fuzzy Set*. Jika sebuah data historis yang dikumpulkan termasuk ke dalam interval u_i , maka data tersebut difuzzyfikasi ke dalam A_i .

5. Menentukan *fuzzy logical relationship* (FLR) dan *fuzzy logical relationship group* (FLRG).

Jika himpunan fuzzy sekarang adalah A_i , dan grup relasi logika fuzzy A_i adalah tidak diketahui, misal $A_i \rightarrow \neq$, maka \neq akan merujuk kepada himpunan fuzzy A_i .

6. Membuat matriks probabilitas transisi Markov.

Probabilitas transisional untuk *state* tersebut dapat dituliskan sebagai berikut:

$$P_{ij} = \frac{M_{ij}}{M_i}, i, j = 1, 2, 3, \dots, n. \quad (16)$$

Probabilitas transisi dari *state* ke satu langkah adalah P_{ij} . Jumlah data dari *state* adalah M_i . Waktu transisi dari keadaan ke satu langkah adalah M_{ij} . Matriks probabilitas transisi R dari suatu *state space* ditulis sebagai berikut:

$$R = \begin{bmatrix} P_{11} & P_{12} & \dots & P_{1n} \\ P_{21} & P_{22} & \dots & P_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ P_{n1} & P_{n2} & \dots & P_{nn} \end{bmatrix} \quad (17)$$

7. Menghitung hasil peramalan atau hasil pemodelan awal.

Nilai pemodelan awal dapat dihitung berdasarkan matriks probabilitas yang diperoleh pada langkah sebelumnya dengan aturan sebagai berikut:

Aturan 1. Jika *Fuzzy Logical Relation Group* (FLRG) dari A_i bertransisi ke himpunan kosong ($A_i \rightarrow \phi$), maka peramalan dari $F(t)$ adalah m_i , yaitu nilai tengah dari u_i dengan persamaan:

$$F(t) = m_i \quad (18)$$

Aturan 2. Jika *Fuzzy Logical Relation Group* (FLRG) dari A_i bertransisi satu ke satu ($A_i \rightarrow A_k$ dengan $P_{ij} = 0$ dan $P_{ik} = 1, j \neq k$), maka hasil pemodelan $F(t)$ adalah m_k yaitu nilai tengah dari u_k dengan persamaan:

$$F(t) = m_k P_{ik} = m_k \quad (19)$$

Aturan 3. Jika *Fuzzy Logical Relation Group* (FLRG) dari A_j bertransisi satu ke banyak ($A_j \rightarrow A_1, A_2, \dots, A_n, j = 1, 2, \dots, n$) dan kumpulan data $X(t-1)$ pada saat $t-1$ yang berada pada *state* A_j , maka hasil pemodelan $F(t)$ sebagai berikut:

$$F(t) = m_1 P_{j1} + m_2 P_{j2} + \dots + m_{j-1} P_{j(j-1)} + X(t-1) P_{jj} + m_{j+1} P_{j(j+1)} + \dots + m_n P_{jn} = m_k \quad (20)$$

Dengan $m_1, m_2, \dots, m_{j-1}, m_{j+1}, \dots, m_n$ merupakan titik tengah dari $u_1, u_2, \dots, u_{j-1}, u_{j+1}, \dots, u_n$ dan m_j disubstitusikan ke $X(t-1)$ agar diperoleh informasi dari *state* A_j saat $t-1$.

8. Menghitung nilai penyesuaian pada pemodelan (*Adjusted Value*).

Tujuan dari tahap ini adalah memperbaiki *error* peramalan yang disebabkan oleh matrik *Markov Chain* yang bias. Bias pada matrik ini biasanya disebabkan oleh ukuran sampel yang lebih kecil ketika memodelkan model *Fuzzy Time Series Markov Chain*. Oleh karena itu, berikut prinsip-prinsip dalam menghitung nilai penyesuaian (D_t) pada peramalan:

- a. Jika *state* A_i berhubungan dengan A_i , mulai dari *state* A_i pada waktu $t - 1$ sebagai $F(t - 1) = A_i$, dan mengalami peningkatan transisi menuju *state* A_j pada waktu t , ($i < j$), maka nilai D_t adalah:

$$D_{t1} = \left(\frac{1}{2}\right) \quad (21)$$

- b. Jika *state* A_i berhubungan dengan A_i , mulai dari *state* A_i pada waktu $t - 1$ sebagai $F(t - 1) = A_i$, dan mengalami penurunan transisi menuju *state* A_j pada waktu t , ($i < j$), maka nilai D_t adalah:

$$D_{t1} = -\left(\frac{1}{2}\right) \quad (22)$$

- c. Jika transisi dimulai dari *state* A_i pada waktu $t - 1$ sebagai $F(t - 1) = A_i$, dan mengalami lompatan transisi ke depan (maju) menuju *state* A_{i+s} pada waktu t , ($1 \leq s \leq n - i$), maka nilai D_t adalah:

$$D_{t2} = \left(\frac{1}{2}\right) s, (1 \leq s \leq n - i) \quad (23)$$

Dimana

s = jumlah lompatan ke depan.

- d. Jika transisi dimulai dari *state* A_i pada waktu $t - 1$ sebagai $F(t - 1) = A_i$, dan mengalami lompatan transisi ke belakang (mundur) menuju *state* A_{i+v} pada waktu t , ($1 \leq v \leq i$), maka nilai D_t adalah:

$$D_{t2} = -\left(\frac{1}{2}\right) v, (1 \leq v \leq i) \quad (24)$$

Dimana

v = jumlah lompatan ke belakang.

9. Menentukan hasil ramalan yang cocok (*Adjusted Forecasting Value*) atau hasil pemodelan akhir.

Pemodelan akhir merupakan hasil dari pemodelan awal yang dijumlahkan dengan nilai penyesuaian. Bentuk umum dari hasil pemodelan akhir $F'(t)$ adalah

$$F'(t) = F(t) \pm D_{t1} \pm D_{t2} \quad (25)$$

Dimana

$F'(t)$: nilai peramalan akhir pada periode ke- t

$F(t)$: nilai peramalan awal pada periode ke- t

D_t : nilai penyesuaian

10. Pengukuran kesalahan peramalan

Pengukuran kesalahan peramalan dilakukan dengan membandingkan hasil peramalan dengan kenyataan yang terjadi. Teknik peramalan yang paling baik digunakan yaitu teknik peramalan yang menghasilkan penyimpangan terkecil. Berikut adalah ukuran kesalahan yang digunakan dalam penelitian ini sebagai berikut:

Mean Absolute Error (MAE) adalah rata-rata mutlak dari kesalahan meramal, tanpa menghiraukan tanda positif dan negatif dengan persamaan sebagai berikut:

$$MAE = \frac{\sum X_t - F_t}{n} \quad (26)$$

Selain itu terdapat metode lain yaitu *Mean Square Error* (MSE). Berikut adalah rumus untuk MSE

$$MSE = \frac{1}{n} (X(t) - F'(t))^2 \quad (27)$$

Mean Absolute Percentage Error (MAPE) adalah rata-rata dari keseluruhan persentase kesalahan antara data aktual dengan data peramalan. Berikut adalah persamaan dari MAPE:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|X(t) - F(t)|}{Y(t)} \times 100\% \quad (28)$$

Selain MAPE terdapat metode lain yaitu *Root Mean Squared Error* (RMSE) dengan

persamaan sebagai berikut:

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (X_t - F_t)^2}{n}} \quad (29)$$

Dengan

X_t : Data aktual

F_t : Data peramalan

n : Jumlah data

HASIL DAN PEMBAHASAN

1. Gambaran Umum Data

Gambaran umum data harga emas di Indonesia dari tahun 2018 sampai 2023 dapat dilihat pada grafik berikut:

Berdasarkan Gambar 1. dapat dilihat bahwa grafik harga emas periode 2018-2023 mengalami kenaikan setiap tahunnya. Pada tahun 2020 harga emas melonjak tinggi disebabkan oleh pandemi Covid-19 yang membuat banyak investor mencari aset yang lebih aman seperti emas untuk menghindari kerugian terlalu besar.

2. Peramalan Metode ARIMA-GARCH dan Fuzzy Time Series Markov Chain

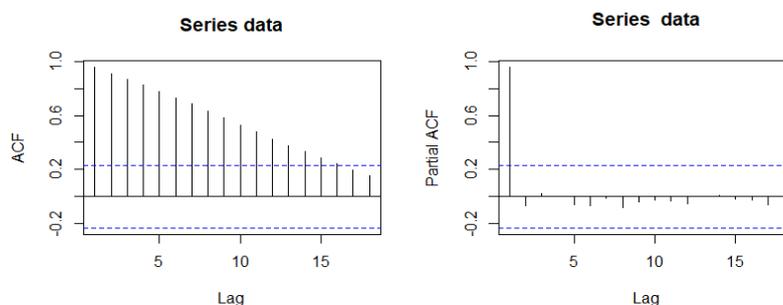
Langkah selanjutnya yaitu melakukan peramalan. Berikut adalah analisis peramalan masing-masing metode:

a. ARIMA-GARCH

Langkah awal untuk melakukan peramalan metode ARIMA-GARCH yaitu dengan melihat kestasioneran data dengan melihat plot ACF dan PACF seperti gambar berikut:



Gambar 1. Grafik harga emas di Indonesia periode 2018-2023



Gambar 2. ACF dan PACF data

Berdasarkan Gambar 2. plot ACF menunjukkan bahwa grafik cenderung turun secara melambat atau secara linear. Sehingga dapat dikatakan bahwa data harga emas

tidak stasioner. Sedangkan pada plot PACF menunjukkan bahwa terdapat lag atau data yang keluar dari batas stasioner sehingga dapat disimpulkan bahwa data tidak stasioner. Untuk lebih jelasnya dapat dilakukan uji ADF (*Augmented Dickey-Fuller*) dari data harga emas sebagai berikut:

Tabel 1. Hasil uji ADF sebelum *differencing*

<i>Dickey-Fuller</i>	-1,9124
<i>Lag Order</i>	4
<i>P-value</i>	0,611

Berdasarkan uji hipotesis menggunakan uji ADF tersebut didapatkan kesimpulan bahwa data tidak stasioner karena nilai *p-value* > 0,05. Maka dilakukan uji ADF kembali dari data yang sudah dilakukan transformasi. Hasil dari uji ADF setelah dilakukan *differencing* pertama terdapat pada Tabel 2.

Tabel 2. Hasil uji ADF setelah *differencing* pertama

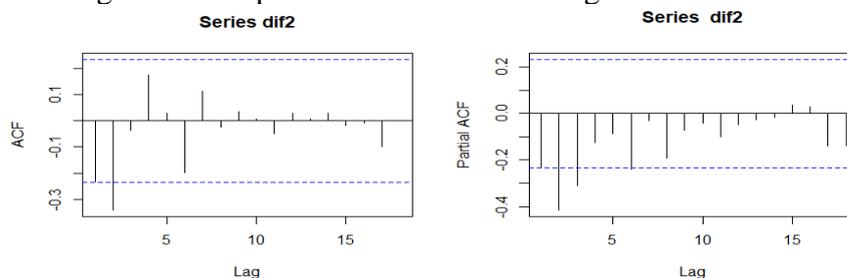
<i>Dickey-Fuller</i>	-3,3622
<i>Lag Order</i>	4
<i>P-value</i>	0,06888

Berdasarkan uji hipotesis menggunakan uji ADF pada tranformasi pertama didapatkan kesimpulan bahwa masih terdapat akar unit atau data tidak stasioner, maka dilakukan transformasi kedua.

Tabel 3. Hasil uji ADF setelah *differencing* kedua

<i>Dickey-Fuller</i>	-5,3185
<i>Lag Order</i>	4
<i>P-value</i>	0,01

Berdasarkan uji hipotesis untuk uji ADF tersebut didapatkan kesimpulan bahwa data stasioner sehingga dapat dilakukan estimasi model. Estimasi model dapat dilakukan dengan melihat plot ACF dan PACF sebagai berikut.



Gambar 3. ACF dan PACF data stasioner

Berdasarkan Gambar 3. plot ACF menunjukkan bahwa terdapat 2 *lag* keluar yang berarti mengandung MA (2). Sedangkan untuk plot PACF menunjukkan terdapat beberapa *lag* yang keluar dan menurun secara perlahan dan tidak langsung menuju nol (*Tails Off*) yang artinya bernilai nol atau AR (0). Untuk lebih jelasnya bisa dilihat plot EACF pada Gambar 12. berikut:

AR/MA	0	1	2	3	4	5	6	7	8	9	10	11	12	13
0	o	x	o	o	o	o	o	o	o	o	o	o	o	o
1	x	x	o	o	o	o	o	o	o	o	o	o	o	o
2	x	x	o	o	o	o	o	o	o	o	o	o	o	o
3	x	o	o	x	o	o	o	o	o	o	o	o	o	o
4	x	o	x	o	o	o	o	o	o	o	o	o	o	o
5	x	x	o	o	o	o	o	o	o	o	o	o	o	o
6	o	x	x	o	o	o	o	o	o	o	o	o	o	o
7	o	x	o	o	x	o	o	o	o	o	o	o	o	o

Gambar 4. EACF data stasioner

Berdasarkan Gambar 4. didapatkan kandidat model utama yaitu ARIMA (0,2,2) dan ARIMA (1,2,2). Untuk mengetahui model yang terbaik maka dilakukan *overfitting*

model disekitar model utama. Peneliti melakukan uji kecocokan model ARIMA (0,2,2), ARIMA (0,2,1), ARIMA (1,2,2), ARIMA (1,2,1) dan ARIMA (1,2,0) berturut-turut dapat dilihat sebagai berikut:

Tabel 4. Hasil uji kecocokan model ARIMA (0,2,2)

<i>Variable</i>	<i>Coefficient</i>	<i>s. e</i>	<i>T</i>	<i>p-value</i>
MA (1)	-0,63086	0,12441	-5,0708	3,962e-07
MA (2)	-0,36913	0,11737	-3,1450	0,0016

Tabel 5. Hasil uji kecocokan model ARIMA (0,2,1)

<i>Variable</i>	<i>Coefficient</i>	<i>s.e</i>	<i>T</i>	<i>p-value</i>
MA (1)	-0,9999	0,0601	-16,628	< 2,2e-16

Tabel 6. Hasil uji kecocokan model ARIMA (1,2,2)

<i>Variable</i>	<i>Coefficient</i>	<i>s. e</i>	<i>T</i>	<i>p-value</i>
AR (1)	-0,4494	0,1133	-3,9644	7,359e-05
MA (1)	-0,5035	0,1077	-4,6757	2,930e-06
MA (2)	-0,2982	0,1111	-2,6829	0,0072

Tabel 7. Hasil uji kecocokan model ARIMA (1,2,1)

<i>Variable</i>	<i>Coefficient</i>	<i>s.e</i>	<i>T</i>	<i>p-value</i>
AR (1)	0,2681	0,1161	2,3095	0,0209
MA (1)	-0,9999	0,0440	-22,7256	<2e-16

Tabel 8. Hasil uji kecocokan model ARIMA (1,2,0)

<i>Variable</i>	<i>Coefficient</i>	<i>s. e</i>	<i>T</i>	<i>p-value</i>
AR (1)	-0,2273	0,1154	-1,9694	0,0489

Untuk melihat hasil uji kecocokan model secara keseluruhan maka disajikan pada Tabel 9. berikut:

Tabel 9. Hasil estimasi parameter ARIMA

Model	<i>P-value</i>		Signifikan
	AR(p)	MA(q)	
ARIMA(0,2,2)			Iya
ARIMA(0,2,1)			Iya
ARIMA(1,2,2)	7,539e-05	2,930e-06	Iya
ARIMA(1,2,1)	0,0209	< 2e-16	Iya
ARIMA(1,2,0)	0,0489		Iya

Berdasarkan Tabel 9. semua model signifikan yaitu ARIMA (0,2,2), ARIMA (0,2,1), ARIMA (1,2,2), ARIMA (1,2,1) dan ARIMA (1,2,0). Untuk mengetahui model terbaik yang akan digunakan untuk peramalan maka dilakukan uji diagnostik residual data. Terdapat tiga uji diagnostik residual data yaitu uji normalitas, uji homoskedastisitas, dan uji no autokorelasi. Hasil dari uji diagnostik residual model yang signifikan ARIMA (0,2,2) sebagai berikut:

1. Uji Normalitas

Tabel 10. Nilai Jarque Bera Test ARIMA (0,2,2)

<i>X-squared</i>	7.1243
<i>Df</i>	2
<i>P-value</i>	0,0283

Berdasarkan uji hipotesis tersebut didapatkan kesimpulan bahwa residual data tidak berdistribusi normal sehingga asumsi normalitas belum terpenuhi.

2. Uji No Autokorelasi

Nilai *p-value* dari *Ljung-Box* dapat dilihat sebagai berikut:

Tabel 11. Nilai *Ljung-Box Test* ARIMA (0,2,2)

<i>X-squared</i>	0,1208
<i>Df</i>	1
<i>P-value</i>	0,7282

Berdasarkan uji hipotesis tersebut didapatkan kesimpulan bahwa tidak terdapat autokorelasi pada data sehingga asumsi no autokorelasi terpenuhi.

3. Uji Homoskedastisitas

Nilai *p-value* dari uji *Ljung-Box* sebagai berikut:

Tabel 12. Nilai *Ljung-Box Test* residual kuadrat model ARIMA (0,2,2)

<i>X-squared</i>	7,5809
<i>Df</i>	1
<i>P-value</i>	0,0058

Berdasarkan uji hipotesis tersebut didapatkan kesimpulan bahwa terdapat heteroskedastisitas pada data sehingga asumsi homoskedastisitas belum terpenuhi.

Uji diagnostik model yang signifikan kedua yaitu ARIMA (0,2,1). Hasil dari uji diagnostik residual model yang signifikan ARIMA (0,2,1) sebagai berikut:

1. Uji Normalitas

Tabel 13. Nilai *Jarque Bera Test* ARIMA (0,2,1)

<i>X-squared</i>	20,232
<i>Df</i>	2
<i>P-value</i>	4,044e-05

Berdasarkan uji hipotesis tersebut didapatkan kesimpulan bahwa residual data tidak berdistribusi normal sehingga asumsi normalitas belum terpenuhi.

2. Uji No Autokorelasi

Nilai *p-value* dari *Ljung-Box* dapat dilihat sebagai berikut:

Tabel 14. Nilai *Ljung-Box Test* ARIMA (0,2,1)

<i>X-squared</i>	4,7086
<i>Df</i>	1
<i>P-value</i>	0,03001

Berdasarkan uji hipotesis tersebut didapatkan kesimpulan bahwa terdapat autokorelasi pada data sehingga asumsi no autokorelasi belum terpenuhi.

3. Uji Homoskedastisitas

Nilai *p-value* dari uji *Ljung-Box* sebagai berikut:

Tabel 15. Nilai *Ljung-Box Test* residual kuadrat model ARIMA (0,2,1)

<i>X-squared</i>	12,699
<i>Df</i>	1
<i>P-value</i>	0,00036

Berdasarkan uji hipotesis tersebut didapatkan kesimpulan bahwa terdapat heteroskedastisitas pada data sehingga asumsi homoskedastisitas belum terpenuhi.

Uji diagnostik model yang signifikan ketiga yaitu ARIMA (1,2,2). Hasil dari uji diagnostik residual model yang signifikan ARIMA (1,2,2) sebagai berikut:

1. Uji Normalitas

Tabel 16. Nilai *Jarque Bera Test* ARIMA (1,2,2)

<i>X-squared</i>	5,9782
<i>Df</i>	2
<i>P-value</i>	0,0503

Berdasarkan uji hipotesis tersebut didapatkan kesimpulan bahwa residual data berdistribusi normal sehingga asumsi normalitas terpenuhi.

2. Uji No Autokorelasi

Nilai *p-value* dari *Ljung-Box* dapat dilihat sebagai berikut:

Tabel 17. Nilai *Ljung-Box Test* ARIMA (1,2,2)

<i>X-squared</i>	0,0248
<i>Df</i>	1
<i>P-value</i>	0,8748

Berdasarkan uji hipotesis tersebut didapatkan kesimpulan bahwa tidak terdapat autokorelasi pada data sehingga asumsi no autokorelasi terpenuhi.

3. Uji Homoskedastisitas

Nilai *p-value* dari uji *Ljung-Box* sebagai berikut:

Tabel 18. Nilai *Ljung-Box Test* residual kuadrat model ARIMA (1,2,2)

<i>X-squared</i>	7,5102
<i>Df</i>	1
<i>P-value</i>	0,0061

Berdasarkan uji hipotesis tersebut didapatkan kesimpulan bahwa terdapat heteroskedastisitas pada data sehingga asumsi homoskedastisitas belum terpenuhi.

Uji diagnostik model yang signifikan ketiga yaitu ARIMA (1,2,1). Hasil dari uji diagnostik residual model yang signifikan ARIMA (1,2,1) sebagai berikut:

1. Uji Normalitas

Tabel 19. Nilai *Jarque Bera Test* ARIMA (1,2,1)

<i>X-squared</i>	7,2541
<i>Df</i>	2
<i>P-value</i>	0,0265

Berdasarkan uji hipotesis tersebut didapatkan kesimpulan bahwa residual data tidak berdistribusi normal sehingga asumsi normalitas belum terpenuhi.

2. Uji No Autokorelasi

Nilai *p-value* dari *Ljung-Box* dapat dilihat sebagai berikut:

Tabel 20. Nilai *Ljung-Box Test* ARIMA (1,2,1)

<i>X-squared</i>	0,1505
<i>Df</i>	1
<i>P-value</i>	0,698

Berdasarkan uji hipotesis tersebut didapatkan kesimpulan bahwa tidak terdapat autokorelasi pada data sehingga asumsi no autokorelasi terpenuhi.

3. Uji Homoskedastisitas

Nilai *p-value* dari uji *Ljung-Box* sebagai berikut:

Tabel 21. Nilai *Ljung-Box Test* residual kuadrat model ARIMA (1,2,1)

<i>X-squared</i>	15,922
<i>Df</i>	1
<i>P-value</i>	6,602e-05

Berdasarkan uji hipotesis tersebut didapatkan kesimpulan bahwa terdapat heteroskedastisitas pada data sehingga asumsi homoskedastisitas belum terpenuhi.

Uji diagnostik model yang signifikan keempat yaitu ARIMA (1,2,0). Hasil dari uji diagnostik residual model yang signifikan ARIMA (1,2,0) sebagai berikut:

1. Uji Normalitas

Tabel 22. Nilai *Jarque Bera Test* ARIMA (1,2,0)

<i>X-squared</i>	42,268
<i>Df</i>	2
<i>P-value</i>	6,631e-10

Berdasarkan uji hipotesis tersebut didapatkan kesimpulan bahwa residual data tidak berdistribusi normal sehingga asumsi normalitas belum terpenuhi.

2. Uji No Autokorelasi

Nilai *p-value* dari *Ljung-Box* dapat dilihat sebagai berikut:

Tabel 23. Nilai *Ljung-Box Test* ARIMA (1,2,0)

<i>X-squared</i>	0,7366
<i>Df</i>	1
<i>P-value</i>	0,3907

Berdasarkan uji hipotesis tersebut didapatkan kesimpulan bahwa tidak terdapat autokorelasi pada data sehingga asumsi no autokorelasi terpenuhi.

3. Uji Homoskedastisitas

Nilai *p-value* dari uji *Ljung-Box* sebagai berikut:

Tabel 24. Nilai *Ljung-Box Test* residual kuadrat model ARIMA (1,2,0)

<i>X-squared</i>	0,1761
<i>Df</i>	1
<i>P-value</i>	0,6747

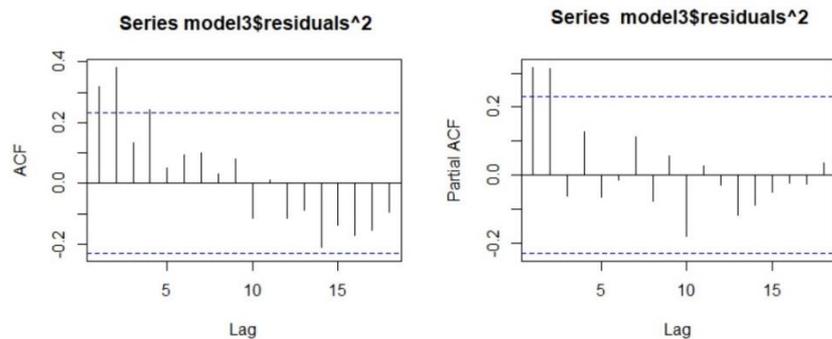
Berdasarkan uji hipotesis tersebut didapatkan kesimpulan bahwa tidak terdapat heteroskedastisitas pada data sehingga asumsi homoskedastisitas terpenuhi.

Berdasarkan uji diagnostik pada model yang signifikan maka dapat disajikan dalam Tabel 25. berikut:

Tabel 25. Hasil uji diagnostik

Model	Normalitas	No Autokorelasi	Homoskedastisitas
ARIMA (0,2,2)	Tidak	Iya	Tidak
ARIMA (0,2,1)	Tidak	Tidak	Tidak
ARIMA (1,2,2)	Iya	Iya	Tidak
ARIMA (1,2,1)	Tidak	Iya	Tidak
ARIMA (1,2,0)	Tidak	Iya	Iya

Berdasarkan hasil uji diagnostik pada Tabel 28. terdapat satu model yaitu ARIMA (1,2,2) yang memiliki asumsi yaitu memenuhi asumsi normalitas, no autokorelasi, dan tidak memenuhi homoskedastisitas. Dengan kata lain, model tersebut bersifat heteroskedastisitas. Oleh karena itu, perlu dianalisis lebih lanjut menggunakan metode ARCH-GARCH.



Gambar 5. ACF dan PACF *squared* residual ARIMA (1,2,2)

Berdasarkan plot ACF dan PACF kuadrat residual pada Gambar 5. dapat dilihat bahwa masing-masing terdapat 2 lag keluar dari batas interval. Sehingga dapat ditentukan model GARCH untuk estimasi yaitu model GARCH (p,q) adalah (2,2). Oleh karena itu, akan dilakukan estimasi yang pertama dari model GARCH (2,2). Hasil dari estimasi model GARCH (2,2) dapat dilihat pada Tabel 26. berikut:

Tabel 26. Hasil estimasi model GARCH (2,2)

Parameter	<i>Estimate</i>	<i>S. E</i>	<i>t-value</i>	<i>Pr(> t)</i>
μ	6,277e-02	4,485e-03	13,996	<2e-16
ω	1,017e-04	5,895e-05	1,725	0,0846
α_1	1,679e-01	1,081e-01	1,554	0,1203
α_2	7,404e-01	2,285e-01	3,240	0,0012
β_1	1,143e-01	1,467e-01	0,779	0,4360

β_2	1,000e-08	2,500e-02	0,000	1,000
-----------	-----------	-----------	-------	-------

Berdasarkan estimasi parameter pada Tabel 26. diperoleh nilai *p-value* ($Pr(>|t|)$) komponen μ dan α_2 signifikan karena memiliki nilai *p-value* lebih kecil dari 0,05. Selanjutnya estimasi kedua pada model GARCH (2,1). Hasil dari estimasi model GARCH (2,1) dapat dilihat pada Tabel 27. berikut:

Tabel 27. Hasil estimasi model GARCH (2,1)

Parameter	Estimate	S.E	t-value	Pr(> t)
μ	0,0627	-	-	-
ω	0,0001	-	-	-
α_1	0,1679	0,0464	3,615	0,0003
α_2	0,7404	-	-	-
β_1	0,1142	0,1367	0,835	0,4034

Berdasarkan estimasi parameter pada Tabel 27. diperoleh nilai *p-value* ($Pr(>|t|)$) komponen α_1 signifikan karena memiliki nilai *p-value* lebih kecil dari 0,05. Selanjutnya estimasi ketiga pada model GARCH (1,2). Hasil dari estimasi model GARCH (1,2) dapat dilihat pada Tabel 28. berikut:

Tabel 28. Hasil estimasi model GARCH (1,2)

Parameter	Estimate	S.E	t-value	Pr(> t)
μ	9,839e-02	1,249e-02	7,875	3,33e-15
ω	1,257e-04	5,114e-05	2,458	0,0140
α_1	2,432e-01	-	-	-
β_1	5,225e-01	-	-	-
β_2	1,000e-08	-	-	-

Berdasarkan estimasi parameter pada Tabel 28. diperoleh nilai *p-value* ($Pr(>|t|)$) komponen μ dan ω signifikan karena memiliki nilai *p-value* lebih kecil dari 0,05. Berdasarkan pengujian model GARCH (p,q) maka dapat disajikan dalam Tabel 29. berikut.

Tabel 29. Hasil estimasi model GARCH

Model	Parameter	Estimate	Pr(> t)	Sign.	AIC
GARCH (2,2)	μ	6,277e-02	<2e-16	Iya	-4,680
	ω	1,017e-04	0,0846	Tidak	
	α_1	1,679e-01	0,1203	Tidak	
	α_2	7,404e-01	0,0012	Iya	
	β_1	1,143e-01	0,4360	Tidak	
	β_2	1,000e-08	1,000	Tidak	
GARCH (2,1)	μ	0,0627	-	Tidak	-4,707
	ω	0,0001	-	Tidak	
	α_1	0,1679	0,0003	Iya	
	α_2	0,7404	-	Tidak	
	β_1	0,1142	0,4034	Tidak	
GARCH (1,2)	μ	9,839e-02	3,33e-15	Iya	-4,597
	ω	1,257e-04	0,0140	Iya	
	α_1	2,432e-01	-	Tidak	
	β_1	5,225e-01	-	Tidak	
	β_2	1,000e-08	-	Tidak	

Berdasarkan Tabel 29. diperoleh model GARCH yang terbaik yaitu GARCH (2,2) karena terdapat parameter yang signifikan dan nilai *p-value* tidak ada yang kosong. Sehingga model yang diperoleh yaitu ARIMA (1,2,2)-GARCH (2,2). Selanjutnya dilakukan uji diagnostik yang meliputi uji normalitas, uji autokorelasi, dan uji

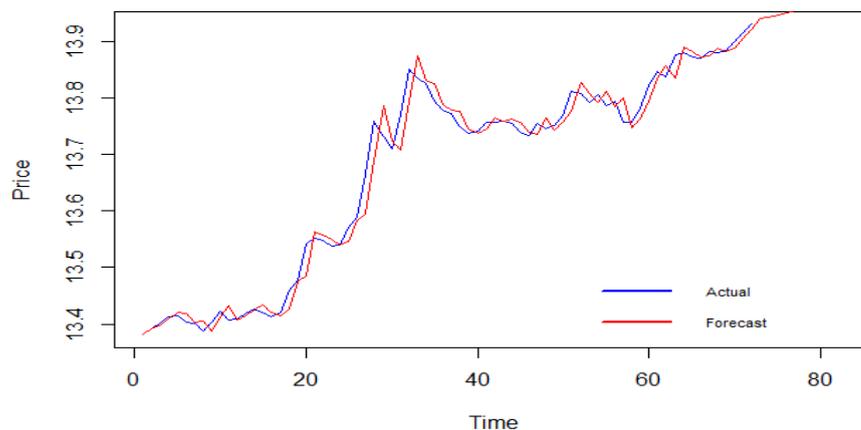
heteroskedastisitas. Hasil dari uji diagnostik model ARIMA (1,2,2)-GARCH (2,2) sebagai berikut:

Tabel 30. Hasil uji diagnostik model ARIMA (1,2,2)-GARCH (2,2)

Pengujian	R	Simbol	Statistic	P-value
Jarque-Bera Test	R	X^2	4,0175512	0,13415283
Shapiro-Wilk Test	R	W	0,9671824	0,05690766
Ljung-Box Test	R	Q(10)	8,2832485	0,60119097
Ljung-Box Test	R	Q(15)	12,0927029	0,67199902
Ljung-Box Test	R	Q(20)	18,4212734	0,55967819
Ljung-Box Test	R ²	Q(10)	6,4728673	0,77409487
Ljung-Box Test	R ²	Q(15)	12,2188410	0,66239461
Ljung-Box Test	R ²	Q(20)	13,8621915	0,83741382
LM Arch Test	R	TR ²	5,4239428	0,94230140

Berdasarkan Tabel 30. pada nilai *p-value Jarque Bera Test, Ljung-Box Test, dan Ljung-Box Test R²* lebih dari nilai α yaitu 0,05 sehingga residual model ARIMA (1,2,2)-GARCH (2,2) memenuhi asumsi normalitas, no autokorelasi dan bebas dari gejala heteroskedastisitas. Uji *LM Arch Test* memiliki nilai *p-value* lebih dari 0,05, yang berarti model tidak mengandung efek ARCH atau bebas dari gejala heteroskedastik pada residual kuadrat. Oleh karena itu, metode ARIMA-GARCH dapat digunakan dalam melakukan prediksi harga emas negara Indonesia. Berikut adalah grafik hasil peramalan dengan metode ARIMA-GARCH.

Time Series Plot



Gambar 6. Grafik hasil peramalan ARIMA-GARCH

Berdasarkan Gambar 6. terlihat bahwa grafik hasil peramalan mengikuti pola data aktual dan dapat dikatakan bahwa hasil peramalan tersebut baik untuk digunakan. Grafik tersebut juga menunjukkan hasil peramalan untuk dua belas bulan kedepan cenderung meningkat. Untuk lebih jelasnya dapat dilihat pada Tabel 34. berikut.

Tabel 31. Hasil peramalan dua belas bulan ke depan

Periode (2024)	Harga (Rp)
Januari	1128478
Februari	1132740
Maret	1136575
April	1140389
Mei	1144215
Juni	1148020
Juli	1151838
Agustus	1155645
September	1159442

Oktober	1163251
November	1167038
Desember	1170837

b. *Fuzzy Time Series Markov Chain*

Langkah-langkah pemodelan dan perhitungan peramalan harga emas menggunakan metode *Fuzzy Time Series Markov Chain* adalah sebagai berikut:

Langkah 1. menentukan himpunan semesta U dari data harga emas tahun 2018 sampai tahun 2023 didapatkan data nilai minimum (D_{min}) = 647555 terdapat pada bulan Januari 2018 dan nilai maksimum (D_{max}) = 1121344 terdapat pada bulan Desember 2024. Berdasarkan nilai D_{min} dan D_{max} maka dapat ditentukan D_1 dan D_2 yang merupakan bilangan positif yang sesuai, nilai yang digunakan masing-masing sebesar 0. Sehingga himpunan semesta yang dihasilkan yaitu sebagai berikut:

$$U = [D_{min} - D_1 ; D_{max} + D_2]$$

$$U = [647555 - 0 ; 1121344 + 0]$$

$$U = [647555 ; 1121344]$$

Langkah 2. membagi (partisi) himpunan semesta U menjadi beberapa bagian dengan interval (n) yang sama dengan menggunakan rumus *Sturges* sebagai berikut:

$$n = 1 + 3,322 * \log(n)$$

$$= 1 + 3,322 * \log(72)$$

$$= 15,20708 \approx 15$$

Dari hasil perhitungan diperoleh nilai jumlah interval yaitu 15. Maka diperoleh nilai panjang interval (l) sebagai berikut:

$$l = \frac{[(D_{max} + D_2) - (D_{min} + D_1)]}{n}$$

$$= \frac{[(1121344 + 0) - (647555 + 0)]}{15}$$

$$= 31585,93$$

Setelah didapatkan jumlah kelas interval sebesar 15 dan panjang interval sebesar 31585.93, maka data akan dibagi menjadi 15 sesuai dengan jumlah interval menjadi U_1 , sampai U_{15} , yang merupakan interval-interval dari himpunan semesta (U) dengan nilai tengah (m) seperti Tabel 32 berikut:

Tabel 32. Interval himpunan semesta (U)

No	Interval	Nilai Tengah (m)
1	$U_1 = [647555.0; 679140.9]$	663348.0
2	$U_2 = [679140.9; 710726.9]$	694933.9
3	$U_3 = [710726.9; 742312.8]$	726519.8
⋮	⋮	⋮
13	$U_{13} = [1026586.2; 1058172.1]$	1042379.2
14	$U_{14} = [1058172.1; 1089758.1]$	1073965.1
15	$U_{15} = [1089758.1; 1121344.0]$	1105551.0

Langkah 3. menentukan himpunan-himpunan *Fuzzy* dan himpunan semesta U . Berdasarkan banyaknya interval yang didapatkan, maka diperoleh 15 himpunan-himpunan *Fuzzy* yang terbentuk.

Langkah 4. menentukan *fuzzyfikasi* pada data historis. Hasil *fuzzyfikasi* data harga emas dapat dilihat pada Tabel 33. berikut:

Tabel 33. *Fuzzyfikasi*

Bulan	Harga Emas	<i>Fuzzyfikasi</i>
Jan-18	647555	A1
Feb-18	654217	A1
Mar-18	661076	A1

⋮	⋮	⋮
Okt-23	1087548	A14
Nov-23	1104533	A15
Des-23	1121344	A15

Langkah 5. Menentukan *fuzzy logical relation* (FLR) dan *fuzzy logical relation group* (FLRG). Setelah mendapatkan hasil *fuzzyfikasi*, maka dapat ditentukan FLR.

Tabel 34. *Fuzzy Logical Relation* (FLR)

Bulan	Harga Emas	Fuzzyfikasi	FLR
Jan-18	647555	A1	A1→A1
Feb-18	654217	A1	A1→A1
Mar-18	661076	A1	A1→A1
⋮	⋮	⋮	⋮
Okt-23	1087548	A14	A14 →A14
Nov-23	1104533	A15	A14 →A15
Des-23	1121344	A15	A15 →A15

Berdasarkan Tabel 34. setelah mendapatkan FLR selanjutnya menentukan FLRG. FLRG merupakan pengelompokan dari setiap perpindahan state yang bertujuan untuk mempermudah perhitungan FLR yang sudah ada dan sejalan dengan prinsip dasar rantai *Markov*. Berikut adalah FLRG dari seluruh data:

Tabel 35. *Fuzzy Logical Relation Group* (FLRG)

Curent State (State Saat Ini)	Next State (State Selanjutnya)
A1	16(A1), 1(A2)
A2	1(A3)
A3	1(A4)
A4	4(A4), 1(A5)
A5	1(A1), 1(A7)
A7	1(A10)
A8	1(A10)
A9	1(A8), 2(A9), 3(A10)
A10	4(A9), 7(A10), 1(A11), 1(A12), 1(A13)
A11	2(A10), 4(A11), 1(A12)
A12	2(A11), 1(A12), 1(A13), 1(A14)
A13	2(A12), 1(A13), 1(A14)
A14	1(A13), 4(A14), 1(A15)

Langkah 6. Menghitung hasil peramalan. Pada tahap ini akan dibentuk matrik probabilitas transisi *Markov* berorde 14 x 14 dari FLRG yang sudah ditentukan pada tahap sebelumnya. Berikut matrik probabilitas transisi *Markov* yang didapatkan:

$$R = \begin{bmatrix} 16/17 & 1/17 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1/1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1/1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 4/5 & 1/5 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1/2 & 1/2 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1/1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1/1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1/6 & 2/6 & 3/6 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 4/14 & 7/14 & 1/14 & 1/14 & 1/14 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 2/7 & 4/7 & 1/7 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 2/5 & 1/5 & 1/5 & 1/5 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 2/4 & 1/4 & 1/4 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1/6 & 4/6 & 1/6 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1/1 \end{bmatrix}$$

Setelah mendapatkan matrik probabilitas transisi *Markov*, selanjutnya akan dilakukan peramalan awal. Hasil peramalan awal sebagai berikut.

Tabel 36. Hasil peramalan awal

Bulan	Peramalan
Jan-18	NA
Feb-18	650341,8
Mar-18	656612.0
⋮	⋮
Okt-23	1068033.0
Nov-23	1066032.0
Des-23	1071266.0

Langkah 7. menghitung nilai penyesuaian pada peramalan Berikut nilai penyesuaian yang didapatkan.

Tabel 37. Nilai Penyesuaian

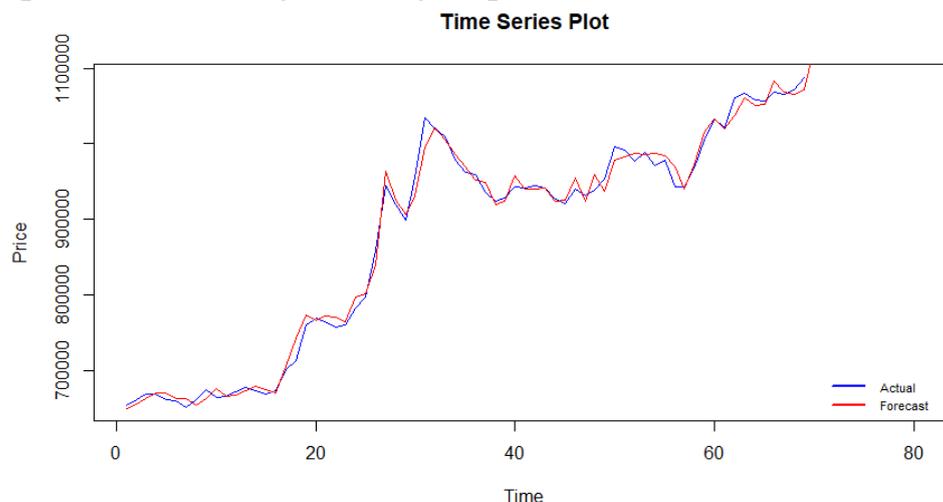
Bulan	Adjusted
Jan-18	NA
Feb-18	0
Mar-18	0
⋮	⋮
Agu-23	0
Sep-23	0
Okt-23	31585.93

Langkah 8. menentukan hasil peramalan akhir. Hasil peramalan akhir hasil peramalan awal yang dijumlahkan dengan nilai penyesuaian yang didapatkan dari langkah sebelumnya.

Tabel 38. Hasil peramalan akhir

Bulan	Peramalan
Jan-18	NA
Feb-18	650341,8
Mar-18	656612.0
⋮	⋮
Agu-23	1068033
Sep-23	1066032
Okt-23	1071266

Visualisasi grafik perbandingan antara data aktual dengan nilai peramalan menggunakan FTSMC dapat dilihat pada gambar berikut:



Gambar 7. Perbandingan grafik data aktual dengan peramalan akhir Berdasarkan Gambar 7. dapat dilihat bahwa grafik hasil peramalan akhir hampir

mengikuti pola data aktual dan dapat dikatakan bahwa hasil peramalan tersebut cukup baik untuk digunakan. Grafik tersebut juga menunjukkan hasil peramalan untuk 12 bulan kedepan cenderung meningkat. Untuk lebih jelasnya dapat dilihat pada Tabel 39. berikut.

Tabel 39. Hasil peramalan dua belas bulan ke depan

Periode (2024)	Peramalan
Januari	1126957
Februari	1132570
Maret	1138184
April	1143798
Mei	1149411
Juni	1155025
Juli	1160639
Agustus	1166252
September	1171866
Oktober	1177480
November	1183093
Desember	1188707

3. *Perbandingan Nilai akurasi pada Metode ARIMA-GARCH dan Fuzzy Time Series Markov Chain*

Setelah mendapatkan hasil peramalan dari masing-masing metode, lalu dilakukan uji ketepatan metode peramalan yaitu dengan melihat nilai error (MAPE) untuk melihat model yang terbaik dalam meramalkan harga emas di Indonesia di masa mendatang. Hasil perhitungan nilai MAPE bisa dilihat pada tabel berikut.

Tabel 40. Ukuran ketepatan

Metode	MAPE
ARIMA-GARCH	1,680441
FTSMC	3,886557

Dari Tabel 40. Menunjukkan bahwa metode ARIMA-GARCH lebih layak digunakan untuk meramalkan harga emas di masa mendatang dibandingkan dengan metode *Fuzzy Time Series Markov Chain*, karena memiliki nilai MAPE lebih kecil yaitu 1,680441.

KESIMPULAN

Berdasarkan hasil analisis yang sudah dilakukan dapat disimpulkan:

- Harga emas periode 2018-2023 mengalami kenaikan setiap tahunnya. Pada tahun 2020 harga emas melonjak tinggi disebabkan oleh pandemi Covid-19 yang membuat banyak investor mencari aset yang lebih aman seperti emas untuk menghindari kerugian terlalu besar.
- Model peramalan menggunakan metode ARIMA-GARCH diperoleh model terbaik yaitu ARIMA(1,2,2)-GARCH(2,2) dan menghasilkan nilai peramalan mendekati nilai data aktual. Hasil peramalan menggunakan metode Fuzzy Time Series Markov Chain menggunakan lima belas himpunan Fuzzy menghasilkan peramalan hampir mendekati nilai data actual.
- Metode ARIMA-GARCH merupakan metode terbaik yang digunakan untuk meramalkan harga emas di studi kasus dibandingkan dengan metode Fuzzy Time Series Markov Chain, karena memiliki nilai MAPE lebih kecil yaitu 1,680441.

Saran

- Untuk mendapatkan hasil analisis yang lebih baik diharapkan kepada penelitian selanjutnya menggunakan data harga emas dalam jumlah yang lebih banyak seperti data harian sehingga pengolahan hasil peramalan dapat mendekati kenyataan yang

diharapkan.

- b. Penelitian selanjutnya diharapkan dapat menggunakan metode peramalan Fuzzy Time Series lainnya sebagai model perbandingan.

DAFTAR PUSTAKA

- Aguston, I. N. S. (2019). Pengaruh Harga Emas Terhadap Pencapaian Laba Pada Pt. Pegadaian (Persero) Cabang Takalar Sulawesi-Selatan (Doctoral Dissertation, Universitas Negeri Makassar).
- Biringallo, M., & Abapihi, B. (2022, July). Perbandingan Akurasi Penggunaan Metode Fuzzy Time Series Markov-Chain Dan Cheng Pada Peramalan Jumlah Kecelakaan Lalulintas Di Kota Kendari. In Seminar Nasional Sains dan Terapan VI (Vol. 6, pp. 85-99).
- Hidayah, D. Y., & Sugiman, S. (2021). Peramalan Nilai Tukar Rupiah terhadap Dollar Amerika dengan Metode Fuzzy Time Series (FTS) Markov Chain. *Unnes Journal of Mathematics*, 85-96.
- Hikmah, N. F. N. (2018). Perbandingan Metode Arima-Garch Dan Fuzzy Time Series Markov Chain Dalam Peramalan Data Harga Minyak Mentah Dunia (Studi Kasus: Data Harga Minyak Mentah Dunia Tahun 2001-2017).
- Illahi, DT, Nirmalasari, IS, Rachman, SF, & Pramesti, S. (2021). Kebebasan finansial bagi generasi milenial dengan berinvestasi. 1(2), 318–325. <http://openjournal.unpam.ac.id/index.php/PD/article/view/15940/8506>
- Jatipaningrum, M. T., Suryowati, K., & Un, L. M. M. E. (2019). Prediksi Kurs Rupiah Terhadap Dolar Dengan FTS-Markov Chain Dan Hidden Markov Model. *Jurnal Derivat: Jurnal Matematika dan Pendidikan Matematika*, 6(1), 32-41.
- Kurniawan, I. (2019). Analisis Keuntungan Investasi Emas dengan IHSG. *Jurnal manajemen bisnis dan kewirausahaan*, 3(2), 16.
- Meilania, G. T., Septiani, A. V., Erianti, E., Notodiputro, K. A., & Angraini, Y. (2024). Pemodelan ARIMA-GARCH dalam Peramalan Kurs Rupiah Terhadap Yen dengan Masalah Keheterogenan Ragam. *Ekonomis: Journal of Economics and Business*, 8(1), 165-180.
- Octavian, E. (2018). Analisis Penjualan Produk Peninggi Badan Di Jawa Tengah Dan Daerah Istimewa Yogyakarta Menggunakan Metode ARIMA.
- Puspitasari, D. I., & Afianto, M. A. (2017). Implementasi Fuzzy Time Series Markov Chain Model (Ftsmcm) Dalam Prediksi Jumlah Produksi Ayam Potong. *Jurnal Teknologi Informasi Universitas Lambung Mangkurat (JTIULM)*, 2(2), 45-50.
- Raehanun, M. (2021). Analisis Support Vector Machine (SVM) Dalam Prediksi Permintaan Emas Perhiasan (Studi Kasus: Permintaan Emas Perhiasan dari Beberapa Negara Tertentu Periode Tahun 2000-2021).
- Rizkiyati, A., Tripalupi, L. E., & Meitriana, M. A. (2015). Faktor yang Mendorong Masyarakat Membeli Emas di Kota Singaraja. *Jurnal Pendidikan Ekonomi Undiksha*, 5(1), 1.
- Salsabila, N. E. P. A. (2020). Pengaruh Overconfidence, Illusion of Control, Loss Aversion Bias, dan Regret Aversion Bias Terhadap Pengambilan Keputusan Investasi (Doctoral dissertation, STIE Perbanas Surabaya).
- Simbolon, L. D. (2022). Penerapan Model Arima Dalam Memprediksi Harga Emas. *Mes: Journal of Mathematics Education and Science*, 7(2), 30-41.
- Tholaby, A. T., & Djunaidy, A. (2017). Pencarian Metode Eliminasi Pencilan Terbaik Untuk Memperbaiki Kinerja Fuzzy Time Series Pada Peramalan Harga Saham Bursa Efek Indonesia. *Jurnal Mikrotek*, 2(4), 1-10.
- Wajdi, S. (2022). Pemodelan Harga Saham BSI dengan Metode Fuzzy Time Series Markov Chain., 6(1), 1715-1724.