

## PERBANDINGAN KINERJA METODE ARIMA, *MULTI-LAYER PERCEPTRON*, DAN *RANDOM FOREST* DALAM PERAMALAN HARGA LOGAM MULIA BERJANGKA YANG MENGANDUNG PENCILAN

Teguh Prasetyo<sup>\*1</sup>, Rizki Alifah Putri<sup>2</sup>, Dini Ramadhani<sup>3</sup>, Yenni Angraini<sup>4</sup>, Khairil Anwar Notodiputro<sup>5</sup>

<sup>1,2,3,4,5</sup>Institut Pertanian Bogor, Bogor

Email: <sup>1</sup>teguhprasetyo@apps.ipb.ac.id, <sup>2</sup>rizkialifah@apps.ipb.ac.id, <sup>3</sup>diniramadhani@apps.ipb.ac.id,

<sup>4</sup>y\_angraini@apps.ipb.ac.id, <sup>5</sup>khairil@apps.ipb.ac.id

<sup>\*</sup>Penulis Korespondensi

(Naskah masuk: 22 Juni 2023, diterima untuk diterbitkan: 04 April 2024)

### Abstrak

Akurasi peramalan sebagai tolok ukur kinerja metode deret waktu bergantung beberapa hal, antara lain karakteristik data, pemilihan metode, fluktuasi data, dan keberadaan pencilan dalam data. Keberadaan pencilan tersebut sering kali tidak dapat dihindari sehingga dapat mengganggu akurasi peramalan. Mempertimbangkan hal tersebut dalam penelitian ini dibahas tentang perbandingan kinerja metode *Autoregressive Integrated Moving Average* (ARIMA), *Multi-Layer Perceptron* (MLP), dan *Random Forest* (RF) dalam peramalan data deret waktu yang mengandung pencilan, menggunakan studi kasus data harga logam mulia berjangka (emas, perak, dan platina) berdasarkan nilai *Mean Absolute Percentage Error* (MAPE). Ditunjukkan bahwa kinerja metode ARIMA dengan Interpolasi Linier mampu menekan pengaruh pencilan lebih baik dibanding metode ARIMA dengan *Winsorized Mean* dan ARIMA tanpa penanganan data pencilan dengan nilai MAPE rata-rata berturut-turut sebesar 10,67% dibanding 12,33% dan 11,79% ketika dievaluasi menggunakan data uji. Metode MLP memiliki kinerja yang tidak lebih baik dibanding ARIMA dengan Interpolasi Linier dengan nilai MAPE rata-rata sebesar 11,13% ketika dievaluasi menggunakan data uji. Secara keseluruhan kinerja terbaik dihasilkan oleh metode RF, dengan nilai MAPE rata-rata jauh lebih kecil dibanding metode lainnya, yakni 2,85% ketika dievaluasi menggunakan data uji. Dalam kajian ini disimpulkan Metode RF memiliki kinerja terbaik dibandingkan semua metode. Hal tersebut disebabkan metode RF menggunakan prinsip *decision tree* sehingga lebih *robust* terhadap kehadiran pencilan dalam data. Berdasarkan hasil penelitian, metode RF dapat menjadi opsi untuk pemodelan data deret waktu yang mengandung pencilan.

**Kata Kunci:** peramalan deret waktu, pencilan, ARIMA, *Multi-Layer Perceptron*, *Random Forest*

## COMPARISON OF THE PERFORMANCE OF THE ARIMA, *MULTI-LAYER PERCEPTRON*, AND *RANDOM FOREST* METHODS IN FORECASTING PRECIOUS METAL FUTURES PRICES THAT CONTAIN OUTLIERS

### Abstract

Forecasting accuracy as a benchmark for the performance of time series methods depends on several things, including data characteristics, method selection, data fluctuations, and the existence of outliers in the data. The existence of these outliers is often unavoidable so it can interfere with the accuracy of forecasting. Considering this, this research discusses the comparison of the performance of the *Autoregressive Integrated Moving Average* (ARIMA), *Multi-Layer Perceptron* (MLP), and *Random Forest* (RF) methods in forecasting time series data containing outliers, using a case study of precious metal futures price data (gold, silver, and platinum) based on the *Mean Absolute Percentage Error* (MAPE) value. It is shown that the performance of the ARIMA method with Linear Interpolation is able to suppress the influence of outliers better than the ARIMA method with *Winsorized Mean* and ARIMA without handling outlier data with the average MAPE value was obtained respectively at 10.67% compared to 12.33% and 11.79% when evaluated using test data. The MLP method has no better performance than ARIMA with Linear Interpolation with an average MAPE value of 11.13% when evaluated using test data. Overall, the best performance was produced by the RF method, which had a much smaller average MAPE value than the other methods, namely 2.85% when evaluated using test data. In this study it appears that the RF method has the best performance compared to all methods. This is because the RF method is based on *decision tree* principle so it is more *robust* to the presence of outliers in the data. Based on the research results, the RF method can be an option for modeling time series data that contains outliers.

**Keywords:** time series forecasting, outliers, ARIMA, *Multi-Layer Perceptron*, *Random Forest*

## 1. PENDAHULUAN

Data deret waktu merupakan data yang didapatkan dari hasil pengamatan berdasarkan urutan waktu. Penelitian terkait data deret waktu memiliki dua tujuan utama pada umumnya, yakni untuk memahami atau memodelkan mekanisme/faktor stokastik pada data, dan untuk meramal nilai amatan pada beberapa waktu ke depan berdasarkan nilai amatan historisnya (Cryer & Chan, 2008). Montgomery, et al (2015) menjelaskan bahwa asumsi umum yang melandasi pemodelan pada data deret waktu adalah data deret waktu terdiri dari komponen deterministik dan komponen stokastik. Salah satu asumsi yang paling penting yakni sisaan model saling bebas dan menyebar identik secara acak, meskipun praktiknya asumsi ini sering tidak dapat dipenuhi. Pemodelan deret waktu dengan menggunakan metode pemulusan eksponensial dalam kondisi seperti menjadi tidak efisien dan tidak layak, sehingga perlu pendekatan lain yakni menggunakan metode *Autoregressive Integrated Moving Average* (ARIMA). Peramalan merupakan bagian penting dari analisis deret waktu. Kinerja peramalan menggunakan metode ARIMA dapat menghasilkan nilai yang kurang bagus jika terdapat pencilan dalam data deret waktu (Li et al., 2021). Pencilan didefinisikan sebagai nilai amatan yang muncul karena kesalahan pengukuran dan/atau perubahan sementara dari proses peristiwa yang diamati (Cryer & Chan, 2008). Pencilan tersebut seringkali muncul sebagai bentuk kejadian yang mengganggu, seperti kejadian sosial dan politik, krisis ekonomi, maupun perang.

Pada tahun 2019, dunia sedang diguncang oleh peristiwa masif di bidang kesehatan, yakni pandemi COVID-19. Pandemi ini awalnya bersifat lokal di negara China, namun lambat laun menular ke negara lain melalui tersebarnya virus secara signifikan. Pandemi COVID-19 tidak hanya mempengaruhi sisi kesehatan manusia saja, namun juga menggerus perekonomian global hingga merembet ke sektor kehidupan lainnya. Pandemi COVID-19 menyebabkan kepanikan finansial serta gejolak ekonomi. Di Indonesia sendiri, sejak pemerintah mengumumkan kasus COVID-19 pertama kali pada 02 Maret 2020, sejumlah harga barang menjadi melonjak tidak terkendali. Salah satu dampak COVID-19 terhadap perekonomian adalah ketidakpastian ekonomi itu sendiri, sehingga menyebabkan masyarakat menjadi sangat berhati-hati dalam menginvestasikan hartanya (Abdelrhim, et al., 2020). Emas adalah pilihan aman dalam berinvestasi, sehingga menjadi pilihan banyak orang. Hal tersebut disebabkan karena emas memiliki banyak keuntungan, antara lain mudah diuangkan kembali jika dibutuhkan sewaktu-waktu (Apergis, 2016). Kenaikan harga emas tersebut bersifat sementara mengikuti perkembangan COVID-19.

Ketika wabah tersebut mereda, maka kenaikan harga emas juga akan melambat atau berhenti (Setiyono, et al., 2022). Emas juga salah satu komoditas penting dalam perdagangan dan bisnis internasional (Singh & Sharma, 2018). Emas memiliki sejarah panjang dalam perdagangan dan diperdagangkan dalam waktu ribuan tahun serta dapat diterima oleh banyak kebudayaan negara di dunia (Baranova, et al., 2020). Hal ini menjadikan emas memiliki stabilitas dan reliabilitas yang tidak dimiliki oleh jenis investasi yang lain (Białkowski, et al., 2015).

Penelitian yang dilakukan oleh (Yousef & Shehadeh, 2020) dan (Koh & Baffes, 2022) menyimpulkan bahwa pandemi COVID-19 mempengaruhi harga emas karena ketidakstabilan ekonomi, yang menyebabkan investor berinvestasi pada emas karena sifatnya cenderung aman. Selain itu pada penelitian (Lamouchi & Badkook, 2020) menyebutkan bahwa harga emas memiliki kecenderungan naik pada kondisi ketidakpastian ekonomi dan berita pasar dengan sentimen negatif, seperti pada kasus perang teluk dan penyerangan *World Trade Center* pada 2001. Emas tergolong sebagai logam mulia. Selain emas masih terdapat logam lain yang juga lazim diperjualbelikan sebagai alat investasi, misalkan perak dan platina. Penelitian Yuandong, et al (2022), menyimpulkan tidak ada korelasi antara harga logam mulia (emas, palladium, perak, dan platina) dengan pandemi COVID-19 secara linier. Namun hasil pengujian non parametrik menunjukkan hal sebaliknya, bahwa terdapat korelasi antara harga logam mulia (emas, palladium, perak, dan platina) dengan pandemi COVID-19. Investor ataupun perusahaan harus mampu meramalkan kondisi nilai tukar suatu alat investasi (dalam hal ini emas sebagai salah satu logam mulia) dengan akurat. Kinerja model deret waktu dalam peramalan dipengaruhi keberadaan pencilan dalam data.

Di tengah ketidakpastian kondisi perekonomian pasca pandemic COVID-19 berdasarkan uraian di atas, berdampak pada pola data deret waktu, yakni salah satunya keberadaan pencilan. Untuk memberikan solusi terkait pemodelan data deret waktu yang mengandung pencilan tersebut, maka pada penelitian ini digunakan beberapa pendekatan metode deret waktu (*ARIMA*, *Multi-Layer Perceptron (MLP)*, dan *Random Forest (RF)*) dalam peramalan data deret waktu yang mengandung pencilan. Data harga logam mulia (emas, perak, dan platina) digunakan dalam penelitian ini karena harga logam mulia diindikasikan memiliki pencilan akibat dampak pandemi COVID-19. Tahapan penelitian dimulai dengan eksplorasi data untuk melihat informasi pola pada data, kemudian identifikasi dan penanganan pencilan, pra-pemrosesan data, pemodelan, diagnostik model, sampai dengan evaluasi kinerja model.

## 2. TINJAUAN PUSTAKA

### 2.1 Pencilan

Pencilan merupakan amatan yang memiliki nilai yang jauh dari ukuran pemusatan suatu data, dan juga dapat mengganggu proses analisis dari metode tertentu. Secara garis besar, pencilan dalam deret waktu dapat dikategorikan menjadi pencilan titik (*Point Outliers*), pencilan subsekuen (*Subsequence Outliers*), dan pencilan deret waktu keseluruhan (*Time Series Outliers*) (Blázquez-García et al., 2021). Pendeteksian pencilan dalam data deret waktu dapat menggunakan beberapa metode, misalkan dengan visualisasi maupun dengan perhitungan statistik tertentu. Pada penelitian Akpan dan Moffat (2019), dijelaskan metode untuk mendeteksi pencilan dengan berbasis pada model ARIMA. Pendeteksian tersebut menghasilkan beberapa tipe pencilan, yakni *Additive Outliers* (AO), *Innovative Outliers* (IO), *Level Shifts* (LS), *Temporary Change* (TC), dengan formula yang dijabarkan pada (1):

$$y^*_t = \sum_{j=1}^m \omega_j L_j(B) I_t(t_j) + \frac{\theta(B)}{\phi(B)\alpha(B)} \alpha_t \quad (1)$$

Di mana  $I_t(t_j)$  merupakan indikator peubah yang mengandung nilai 1 pada amatan ke- $t_j$  yang memiliki pencilan ke- $j$ ,  $\phi(B)$  merupakan polinomial autoregresif dengan semua akar di luar *unit circle*,  $\theta(B)$  merupakan polinomial *moving average* dengan semua akar di luar *unit circle*, dan  $\alpha(B)$  merupakan polinomial autoregresif dengan semua akar pada *unit circle*. Keberadaan pencilan diuji menggunakan nilai statistik t dengan formula yang dijabarkan pada (2):

$$\pi(B)y^*_t \equiv \hat{\varepsilon}_t = \sum_{j=1}^m \omega_j \pi(B) L_j(B) I_t(t_j) + \alpha_t \quad (2)$$

Di mana  $\pi(B) = \sum_{i=0}^{\infty} \pi_i B^i$  (López-de-Lacalle, 2016). Tipe pencilan deret waktu tersebut memiliki dampak yang berbeda-beda, misalnya AO dan LS adalah tipe pencilan yang mirip dengan TC namun memiliki batasan efek dinamis yang berbeda. Dampak AO cenderung pada satu amatan saja, sedangkan LS memiliki dampak pada hampir keseluruhan amatan setelahnya. Sedangkan TC adalah pencilan yang memiliki dampak secara menurun pada pengamatan setelahnya. Untuk IO memiliki dampak yang lebih rumit dibanding tipe pencilan lainnya. Pada data deret waktu yang stasioner IO memiliki dampak yang menurun pada pengamatan setelahnya, namun pada data deret waktu yang tidak stasioner dampak tersebut dapat berbeda.

### 2.2 Penanganan Pencilan

Penanganan pencilan dapat dilakukan dengan beberapa cara, antara lain dengan tetap mengikutkan pencilan dalam model, membuang pencilan, mengganti nilai amatan pencilan, maupun dengan memodelkannya menggunakan model tertentu seperti fungsi transfer atau model intervensi.

Pencilan dalam model dapat menyebabkan beberapa dampak, antara lain membuat uji statistik menjadi bias karena cenderung untuk menolak Hipotesis Nol, serta membuat asumsi model parametrik (kenormalan sisaan dan kehomogenan ragam sisaan) menjadi tidak terpenuhi, khususnya pada data dengan jumlah pengamatan yang kecil (Leys, et al., 2019). Penanganan pencilan dengan membuangnya juga dapat berdampak pada model jika terdapat informasi yang berharga pada pencilan tersebut, terlebih jika pencilan termasuk dalam tipe pencilan karena informasi tertentu (*Interesting Outliers*).

a. Metode imputasi *winsorized mean* merupakan salah satu pengukuran statistik *winsorized* dari ukuran pemusatan suatu data, seperti nilai tengah dan median. Mahir & Al-Khazaleh (2009) menjelaskan bahwa perhitungan *winsorized mean* dilakukan setelah mengganti nilai ekstrim pada ujung atas dan bawah dari sebaran data yang dijelaskan pada formula (3):

$$\bar{y}_w = \frac{1}{n} ((r+1)y_{r+1} + \sum_{i=r+2}^{n-s-1} (y_i - \bar{y}_w)^2 + (s+1)(y_{n-s} - \bar{y}_w)^2) \quad (3)$$

b. Metode interpolasi linier merupakan salah satu metode interpolasi berbasis polinomial berderajat satu yang termasuk dalam metode deterministic sesuai dengan formula (4) dan (5) (Lepot, et al., 2017):

$$Y_i = \frac{y_A - y_B}{a - b} (i - b) + y_B \quad (4)$$

$$Y_i = (1 - \alpha)y_B + \alpha y_A \quad (5)$$

Di mana  $\alpha$  merupakan faktor interpolasi dari 0 sampai dengan 1

### 2.3 Metode ARIMA

Metode ARIMA merupakan metode probabilistik yang diperkenalkan oleh Box dan Jenkins pada 1970. Nilai amatan untuk beberapa waktu ke depan dari suatu peubah diasumsikan sebagai fungsi linier dari beberapa pengamatan masa lalu dan sisaan yang bersifat acak. Proses ARIMA memiliki formula yang dijabarkan pada (6):


$$y_t = \theta_0 + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (6)$$

$y_t$  dan  $\varepsilon_t$  adalah nilai aktual dan sisaan yang bersifat acak pada waktu ke  $t$ . Sisaan tersebut diasumsikan menyebar secara independen dan identik dengan rata-rata nol dan varian konstan. Selain itu harus diperiksa terlebih dahulu kestasioneran data, dan jika belum terpenuhi maka hendaknya dilakukan *differencing*.  $\phi_i$  dan  $\theta_i$  adalah parameter model.  $p$  sebagai order komponen *autoregressive* dan  $q$  sebagai order komponen *moving average* yang optimal berdasarkan nilai AIC (*Akaike Information Criterion*) atau BIC (*Bayesian Information Criterion*) model terkecil (Luo dan

Gong, 2023). Metode ARIMA dibangun berdasarkan asumsi probabilistik, sehingga pencilaan di dalam data akan diimputasi sebelum pembangunan model guna meminimalisir dampak pencilaan terhadap model yang terbentuk. Imputasi tersebut yakni *Winsorized Mean* dan Interpolasi Linier.

#### 2.4 Metode Multi-Layer Perceptron (MLP)

MLP adalah salah satu metode dalam *Deep Learning Neural Network*/Jaringan Syaraf Tiruan yang lazim digunakan untuk pemodelan. *Multi-layer* adalah bentuk lapisan pada *perceptron*/jaringan syaraf yang digabungkan dengan menambahkan lebih banyak lapisan dan *neuron* pada tiap lapisan, sehingga MLP salah satu arsitektur yang paling banyak digunakan untuk jaringan saraf tiruan. Arsitektur MLP diilustrasikan pada Gambar 1 (Sen, et al., 2020):



Gambar 1. Arsitektur MLP

Gambar 1 menjelaskan konsep arsitektur MLP, dengan perhitungan input nilai dan bobot dari lapisan input ke *hidden layer* serta ke lapisan output disebut *forward propagation*. Jumlah input nilai dan bobot serta bias dihitung pada setiap lapisan. Kemudian dengan menggunakan fungsi aktivasi, nilai dan bobot tersebut digunakan pada lapisan berikutnya dalam bentuk *hidden layer* ataupun *output layer*.

Proses penentuan nilai dan bobot yang bersesuaian dengan setiap *neuron* pada masing-masing lapisan disebut proses pembelajaran atau *training*, dengan detail sebagai berikut:

1. Melakukan proses inialisasi bobot dengan suatu nilai awal yang cukup kecil atau bahkan bisa nol.
2. Melakukan proses runut maju (*forward propagation*)
3. Melakukan proses runut mundur (*backward propagation*)
4. Menghitung bobot berdasarkan fungsi aktivasi,
5. Mengupdate bobot dengan mengurangi rasio dari gradien bobot

MLP dilatih menggunakan data latih melalui proses yang disebut dengan *backpropagation*. Prinsip kerja proses tersebut yakni dengan cara memperbaiki kesalahan secara progresif sesaat setelah terdeteksi, sehingga pada MLP proses *forward propagation* maupun *back propagation* dari lapisan *input* ke *output* diulang beberapa kali sampai

nilai kesalahan tersebut di bawah batas yang telah ditentukan (Jin et al., 2022).

#### 2.5 Metode Random Forest (RF)

Menurut Schonlau dan Zou (2020) metode *Random Forest* merupakan pengembangan dari metode berbasis *decision tree*, yang kemudian disusun secara paralel dengan memanfaatkan prinsip *bootstrapping* dan *aggregating* untuk menghasilkan nilai prediksi. Tahap *bootstrapping* dimaksud berarti dataset awal dilakukan *resampling* dengan pengembalian dengan tujuan agar setiap *decision tree* saling bebas/unik (Misra dan Li, 2019). Menurut Josso et al. (2023), kinerja model RF dari pembentukan beberapa *decision tree* dievaluasi dengan menggunakan mekanisme *out-of-bag* (OOB) yang memiliki 2 keunggulan yakni evaluasi kinerja model tanpa menggunakan dataset baru, dan dapat digunakan untuk menghitung *relative importance* antar peubah bebas.

RF bekerja dengan prinsip sebagai berikut (Faradibah et al., 2023):

1. Tahapan *bootstrap*, yaitu melakukan penarikan contoh acak berukuran  $n$  dengan pemulihan pada gugus data.
2. Tahapan *random subsetting* yaitu membangun pohon tanpa pemangkasan sampai mencapai ukuran maksimum
3. Lakukan proses langkah 1 dan 2 secara berulang sebanyak  $k$  kali sehingga terbentuk sebuah hutan yang terdiri atas  $k$  pohon.
4. Lakukan pendugaan gabungan berdasarkan  $k$  buah pohon tersebut.

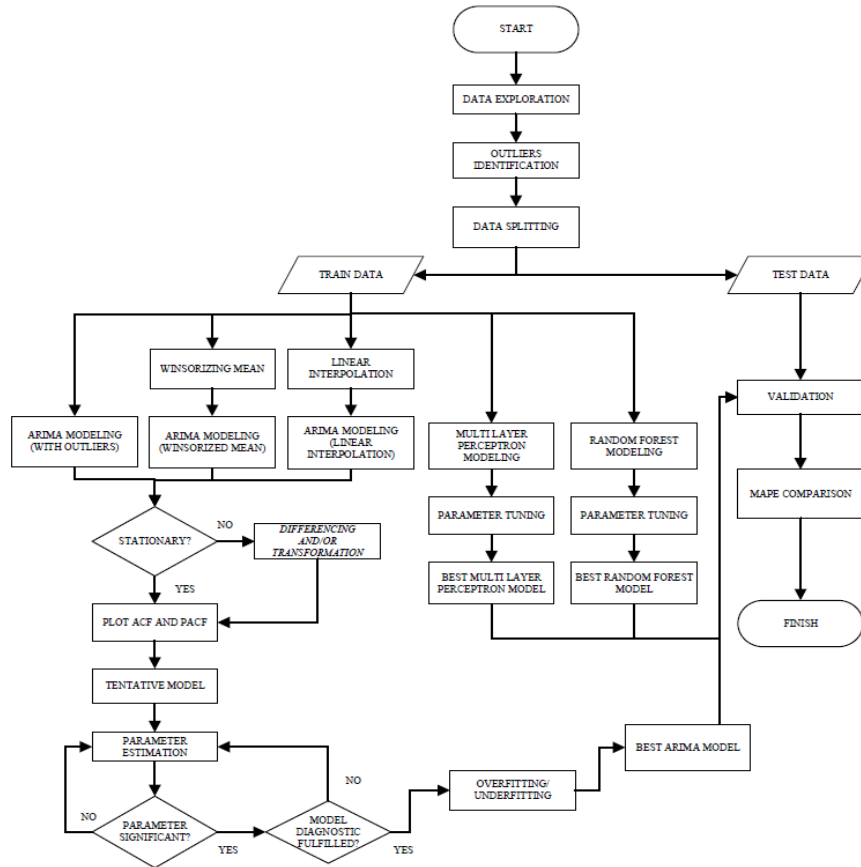
Ukuran yang digunakan dalam menentukan peubah penting pada RF yakni *Mean Decrease Gini* (MDG). MDG adalah rasio antara penjumlahan dari impuritas tereduksi yang disebabkan oleh peubah penjelas ke- $s$  dengan banyak nya pohon yang terbentuk. Semakin besar nilai MDG menandakan peubah penjelas tersebut berperan penting dalam pembangunan pohon klasifikasi. Menurut Sandri & Zuccoloto (2006) perhitungan MDG dijelaskan pada formula (7):

$$MDG_s = \frac{1}{k} \sum_t [\Delta(s, t) I(s, t)] \quad (7)$$

$k$  adalah banyaknya pohon klasifikasi yang terbentuk,  $\Delta(s, t)$  merupakan impuritas tereduksi yang disebabkan oleh peubah penjelas ke- $s$  pada simpul ke- $t$ .  $I(s, t)$  adalah fungsi indikator yang memiliki nilai 1 apabila peubah penjelas ke- $s$  digunakan dalam penyekatan serta bernilai 0 apabila sebaliknya.

#### 2.6 Evaluasi Model

Model terbaik dari tahap sebelumnya digunakan untuk melakukan peramalan menggunakan data uji dan dihitung nilai MAPE sebagai evaluasi dalam perbandingan kinerja model pada penelitian ini.



Gambar 2. Diagram Alir Penelitian

MAPE adalah nilai rata-rata persentase sisaan mutlak, yang dijabarkan pada formula (8) (Choi et al., 2023):

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \times 100\% \quad (8)$$

Di mana  $y_t$  adalah nilai amatan sebenarnya,  $\hat{y}_t$  adalah nilai amatan hasil peramalan, dan  $n$  adalah banyaknya pengamatan dalam data.

### 3. METODE PENELITIAN

#### 3.1 Jenis dan Sumber Data

Data pada penelitian ini merupakan data empiris sekunder harga logam mulia (emas, perak, dan platina) berjangka dalam satuan dolar Amerika Serikat per 1 Troy Ons yang bersumber dari <https://id.investing.com/>. Data tersebut adalah data harga berjangka yang diperdagangkan di bursa berjangka tanpa ada bentuk fisiknya, sehingga perubahan harganya lebih fluktuatif karena ditransaksikan setiap saat seperti jual-beli saham. Periode data berupa mingguan dengan dua jenis harga, yakni data harga maksimal mingguan dan minimal mingguan untuk tiap jenis logam mulia.

### 4. TAHAPAN ANALISIS

#### 4.1 Eksplorasi Data

Tahap awal sebelum pemodelan dan peramalan adalah visualisasi data menggunakan grafik deret

waktu, yang bertujuan untuk memahami pola umum pada data. Informasi awal yang dihasilkan diharapkan dapat menambah informasi dalam melakukan proses pemodelan dan peramalan.

#### 4.2 Identifikasi dan Penanganan Pencilan

Proses identifikasi pencilan pada penelitian ini menggunakan bantuan perangkat lunak R, yang akan menghasilkan jenis serta titik amatan yang dikategorikan sebagai pencilan. Sebagaimana disebutkan pada tinjauan pustaka terkait penanganan pencilan, maka pada penelitian ini menggunakan penanganan pencilan dengan mengganti nilai amatan pencilan berdasarkan metode imputasi *winsorized mean* dan interpolasi linier.

#### 4.3 Pra Pemrosesan Data

Tahap pemrosesan data diawali dengan membagi data latih dan data uji. Mengingat data merupakan deret waktu, proses pembagian harus memperhatikan pola dari data dan efek autokorelasi antar amatan. Penelitian ini menggunakan metode Segmentasi Ketetanggaan (*Segment Neighbourhood*) untuk menentukan titik optimal dalam pembagian data latih dan data uji.

#### 4.4 Pemodelan

Tahap selanjutnya yakni pemodelan menggunakan bantuan perangkat lunak R.

### 4.5 Diagnostik Model

Pemilihan model terbaik pada metode ARIMA menggunakan nilai AIC pada data latih, sedangkan model MLP dan RF tidak dilakukan tahap pendugaan parameter dan uji signifikansi karena kedua model tersebut dibangun tidak berdasarkan asumsi probabilistik. Setelah didapatkan model terbaik ARIMA, kemudian dilakukan pengujian sisaan dari model. Sisaan dihitung dari selisih antara nilai duga amatan dengan nilai sebenarnya. Model yang baik akan menghasilkan sisaan yang tidak saling berkorelasi antar amatan, memiliki ragam homogen, serta diharapkan sisaan menyebar normal. Asumsi sisaan menyebar normal tidak menjadi prioritas dalam proses diagnostik model ARIMA karena jumlah amatan pada data sudah cukup banyak (sekitar 400 amatan untuk tiap data).


### 4.6 Evaluasi Model

Validasi peramalan menggunakan data uji berdasarkan nilai MAPE. Semakin rendah nilai MAPE, maka kemampuan model peramalan yang digunakan semakin baik. Tahapan penelitian secara garis besar dijabarkan pada Gambar 2


## 5. HASIL DAN PEMBAHASAN

### 5.1 Eksplorasi Data

Sebelum dilakukan tahap analisis, untuk mengetahui gambaran dan informasi awal dari data deret waktu, dilakukan eksplorasi data menggunakan grafik deret waktu yang dijelaskan pada Gambar 3, 4, dan 5:




Gambar 3. Pergerakan Harga Emas



Gambar 4. Pergerakan Harga Perak

Gambar 3, 4, dan 5 menunjukkan bahwa data harga logam mulia berjangka (emas, perak, dan platina) yang diklasifikasikan berdasarkan harga maksimal dan minimal mingguan, memiliki pola yang hampir sama/tidak jauh terpaut.



Gambar 5. Pergerakan Harga Platina

Hal ini memberikan informasi bahwa harga maksimal dan mingguan logam mulia dengan periode mingguan memiliki karakteristik yang hampir sama. Namun apabila dilihat berdasarkan periode tahun, nampak bahwa emas dan perak memiliki harga terendah di tahun 2015, sedangkan platina pada 2020. Pergerakan harga emas cenderung memiliki tren naik dari 2015 sampai dengan 2023, sedangkan perak mengalami kenaikan harga sampai dengan 2020 kemudian menurun kembali sampai dengan 2023. Platina memiliki pergerakan harga dengan tren turun dari 2015 sampai dengan awal 2020. Pandemi COVID-19 sudah mulai menyebar ke seluruh dunia pada awal tahun 2020, sehingga mengakibatkan kepanikan masal dari semua sektor, terutama sektor kesehatan dan perekonomian. Hal tersebut juga berdampak pada harga logam mulia berjangka, di mana pada awal 2020 mengalami peningkatan harga.

### 5.2 Identifikasi dan Penanganan Pencilan

Pencilan pada enam jenis data diidentifikasi untuk mengetahui tipe dan besar nilai pencilan. Hasil pendeteksian disajikan pada Tabel 1:

Sumber Data	Tipe Pencilan				Total
	AO	IO	TC	LS	
Emas - Maksimal	5	5	1	2	13
Emas - Minimal	1	1	0	1	3
Perak - Maksimal	3	4	2	1	10
Perak - Minimal	0	1	3	1	5
Platina - Maksimal	1	1	1	0	3
Platina - Minimal	0	1	2	0	3

Berdasarkan Tabel 1 diketahui bahwa tipe pencilan AO dan IO mendominasi dalam tiap data. Data Emas Maksimal dan Perak Maksimal memiliki total pencilan paling banyak dibanding data lain.

### 5.3 Pemodelan

Tahap selanjutnya yakni memodelkan data deret waktu menggunakan metode ARIMA, MLP, dan RF dengan ringkasan hasil dijabarkan pada Tabel 2:

Sumber Data	Model	Penanganan Pencilan
Emas - Maksimal	ARIMA(1,0,0)	Dengan Pencilan
	ARIMA(1,1,1)	Winsorized Mean
	ARIMA(0,1,1)	Interpolasi Linier
	MLP	Dengan Pencilan
Emas - Minimal	RF	Dengan Pencilan
	ARIMA(0,1,1)	Dengan Pencilan

Sumber Data	Model	Penanganan Pencilan
Minimal	ARIMA(1,1,1)	<i>Winsorized Mean</i>
	ARIMA(1,1,0)	Interpolasi Linier
	MLP	Dengan Pencilan
	RF	Dengan Pencilan
Perak - Maksimal	ARIMA(0,1,1)	Dengan Pencilan
	ARIMA(0,1,1)	<i>Winsorized Mean</i>
	ARIMA(0,1,1)	Interpolasi Linier
	MLP	Dengan Pencilan
Perak - Minimal	RF	Dengan Pencilan
	ARIMA(1,1,1)	Dengan Pencilan
	ARIMA(3,1,3)	<i>Winsorized Mean</i>
	ARIMA(0,1,1)	Interpolasi Linier
Platina - Maksimal	MLP	Dengan Pencilan
	RF	Dengan Pencilan
	ARIMA(0,1,1)	Dengan Pencilan
	ARIMA(2,0,1)	<i>Winsorized Mean</i>
Platina - Minimal	ARIMA(1,1,0)	Interpolasi Linier
	MLP	Dengan Pencilan
	RF	Dengan Pencilan
	ARIMA(1,1,1)	Dengan Pencilan
Platina - Maksimal	ARIMA(2,1,2)	<i>Winsorized Mean</i>
	ARIMA(0,0,12)	Interpolasi Linier
	MLP	Dengan Pencilan
	RF	Dengan Pencilan

Hasil pemodelan pada Tabel 2 menunjukkan bahwa dengan menggunakan metode ARIMA, diketahui data keenam logam mulia dapat dimodelkan dengan tiga jenis penanganan pencilan, yakni Tanpa Penanganan, dengan *Winsorized Mean*, dan dengan Interpolasi Linier dengan nilai parameter dugaan signifikan pada taraf nyata 0,05. Pemodelan secara probabilistik ini hanya berlaku untuk model ARIMA saja, yang termasuk dalam metode parametrik. Pada metode MLP dan RF, pemodelan dilakukan secara numerik, karena jumlah parameter model tidak dapat ditentukan dengan pasti sehingga tidak didapatkan nilai dugaannya (metode non-parametrik).

#### 5.4 Diagnostik Model

Model ARIMA yang telah terbentuk pada tahap sebelumnya, kemudian dilakukan pemeriksaan/ diagnostik sisaan model. Diagnostik sisaan ini hanya berlaku pada metode parametrik

saja, karena proses pemodelan dilandasi pada asumsi probabilistik. Harapannya adalah sisaan model ARIMA bersifat acak dan memenuhi prinsip *white noise*, yang memiliki nilai tengah nol dan ragam tertentu. Hasil diagnostik model ARIMA disajikan pada Tabel 3.

Tabel 3 menunjukkan hasil pengujian asumsi pada diagnostik model ARIMA, yakni asumsi kenormalan sisaan, asumsi bebas autokorelasi sisaan, dan asumsi kehomogenan ragam sisaan. Hasil uji asumsi kenormalan sisaan menunjukkan beberapa model ARIMA tidak memenuhinya, namun hal tersebut dapat diabaikan mengingat banyaknya amatan data pada penelitian ini sudah lebih dari cukup. Hasil uji asumsi bebas autokorelasi sisaan dan kehomogenan ragam sisaan menunjukkan bahwa telah terpenuhi, sehingga model ARIMA layak digunakan untuk tahap peramalan selanjutnya.

#### 5.5 Evaluasi Model

Evaluasi kinerja model yang telah terbentuk dari setiap jenis data menggunakan nilai MAPE, disajikan pada Tabel 4.

Metode ARIMA (Tanpa Penanganan Pencilan, *Winsorized Mean*, dan Interpolasi Linier) dan MLP menghasilkan nilai MAPE jauh lebih tinggi pada data uji harga Perak dan Platina (baik harga Tertinggi maupun Terendah Mingguan) dibanding data latih. Sedangkan metode RF menghasilkan nilai MAPE yang relatif hampir sama pada data uji dibandingkan data latih. Semua metode menghasilkan nilai MAPE yang jauh lebih tinggi pada data uji harga Tertinggi Emas Mingguan dibandingkan data latih. Hal ini dicurigai sebagai akibat dari banyaknya pencilan yang muncul pada data latih harga Tertinggi Emas Mingguan dibandingkan pada data latih harga Perak maupun Platina.

Tabel 3. Diagnostik Model ARIMA

Sumber Data	Model	Kenor-malan Sisaan	Bebas Autokore-lasi Sisaan	Kehomo-genan Ragam Sisaan
Emas - Maksimal	ARIMA (1,0,0)	Terpenuhi	Terpenuhi	Terpenuhi
	ARIMA (1,1,1)	Terpenuhi	Terpenuhi	Terpenuhi
	ARIMA (0,1,1)	Terpenuhi	Terpenuhi	Terpenuhi
Emas - Minimal	ARIMA (0,1,1)	Terpenuhi	Terpenuhi	Terpenuhi
	ARIMA (1,1,1)	Terpenuhi	Terpenuhi	Terpenuhi
	ARIMA (1,1,0)	Terpenuhi	Terpenuhi	Terpenuhi
Perak -Maksimal	ARIMA (0,1,1)	Tidak Terpenuhi	Terpenuhi	Terpenuhi
	ARIMA (0,1,1)	Tidak Terpenuhi	Terpenuhi	Terpenuhi
	ARIMA (1,1,1)	Tidak Terpenuhi	Terpenuhi	Terpenuhi
Perak - Minimal	ARIMA (3,1,3)	Tidak Terpenuhi	Terpenuhi	Terpenuhi
	ARIMA (0,1,1)	Tidak Terpenuhi	Terpenuhi	Terpenuhi
	ARIMA (0,1,1)	Terpenuhi	Terpenuhi	Terpenuhi
Platina - Maksimal	ARIMA (2,0,1)	Tidak Terpenuhi	Terpenuhi	Terpenuhi
	ARIMA (1,1,0)	Terpenuhi	Terpenuhi	Terpenuhi
	ARIMA (1,1,1)	Tidak Terpenuhi	Terpenuhi	Terpenuhi
Platina -Minimal	ARIMA (2,1,2)	Tidak Terpenuhi	Terpenuhi	Terpenuhi
	ARIMA (0,0,12)	Tidak Terpenuhi	Terpenuhi	Terpenuhi

Tabel 4. Perbandingan Kinerja Model

Sumber Data	Model	MAPE (%) ↓	
		Data Latih	Data Uji
Emas - Maksimal	ARIMA(1,0,0)	1,28	13,36
	ARIMA(1,1,1)	1,09	14,10
	ARIMA(0,1,1)	1,14	5,90
	MLP	1,30	8,21
	RF	0,07	4,92
Emas - Minimal	ARIMA(0,1,1)	1,16	5,90
	ARIMA(1,1,1)	1,05	14,09
	ARIMA(1,1,0)	1,14	5,85
	MLP	1,15	10,31
	RF	0,06	6,37
Perak - Maksimal	ARIMA(0,1,1)	2,30	12,81
	ARIMA(0,1,1)	2,07	12,57
	ARIMA(0,1,1)	2,18	13,02
	MLP	2,23	18,65
	RF	0,07	1,43
Perak - Minimal	ARIMA(1,1,1)	2,23	13,91
	ARIMA(3,1,3)	4,81	13,76
	ARIMA(0,1,1)	2,02	13,82
	MLP	2,21	18,15
	RF	0,08	0,91
Platina - Maksimal	ARIMA(0,1,1)	2,17	11,60
	ARIMA(2,0,1)	1,97	6,86
	ARIMA(1,1,0)	2,16	11,62
	MLP	2,12	5,84
	RF	0,06	0,09
Platina - Minimal	ARIMA(1,1,1)	2,37	13,16
	ARIMA(2,1,2)	1,96	12,79
	ARIMA(0,0,12)	2,30	5,60
	MLP	2,25	7,96
	RF	0,09	0,06

Metode ARIMA *Winsorized Mean* hanya mampu menghasilkan nilai MAPE yang lebih kecil pada data harga Tertinggi Platina Mingguan dibandingkan metode ARIMA Tanpa Penanganan Pencilan. Metode ARIMA Interpolasi Linier mampu menghasilkan nilai MAPE yang lebih kecil pada harga Emas Mingguan (Tertinggi dan Terendah) dan data Terendah Platina Mingguan dibandingkan metode ARIMA Tanpa Penanganan Pencilan.

Metode MLP mampu menghasilkan nilai MAPE yang lebih kecil pada harga Tertinggi Emas Mingguan dan data Platina Mingguan (Tertinggi dan Terendah) dibandingkan metode ARIMA Tanpa Penanganan Pencilan. Metode RF mampu menghasilkan nilai MAPE yang lebih kecil pada semua jenis data dibandingkan metode ARIMA Tanpa Penanganan Pencilan. Metode ARIMA dan MLP menghasilkan nilai MAPE di kisaran 1% s.d. 4% pada data latih dan 5% s.d. 18% pada data uji, sedangkan metode RF menghasilkan nilai MAPE di bawah 1% pada data latih dan di bawah 10% pada data uji.

Dalam kajian ini nampak bahwa Metode RF memiliki kinerja terbaik dibandingkan semua metode dalam peramalan data deret waktu yang mengandung pencilan. Hal tersebut disebabkan metode RF berbasis *machine learning – bagging* yang menggunakan prinsip *tree* sehingga lebih *robust* terhadap kehadiran pencilan dalam data.

## 6. KESIMPULAN

Jenis dan banyaknya pencilan data empiris pada penelitian ini diindikasikan mempengaruhi

kinerja metode yang dihasilkan. Dari semua metode, disimpulkan metode RF menghasilkan nilai MAPE paling kecil dan konsisten untuk keseluruhan jenis data. Hal tersebut membuat metode RF sebagai metode dengan kinerja terbaik dalam peramalan data deret waktu yang mengandung pencilan pada data empiris penelitian ini. Sebagai masukan untuk penelitian selanjutnya, perlu dikaji lebih dalam pengaruh jenis dan banyaknya pencilan deret waktu terhadap kinerja model yang dihasilkan menggunakan data empiris yang lain serta data simulasi.

## DAFTAR PUSTAKA

- ABDEL RHIM, M., ELSAYED, A., MOHAMED, M., & FAROUH, M., 2020. Investment Opportunities in The Time Of (COVID-19) Spread: The Case of Cryptocurrencies and Metals Markets. SSRN Electronic Journal, pp.1–19. <https://doi.org/10.2139/ssrn.3640333>.
- AKPAN, E.A. dan MOFFAT, I.U., 2019. Modeling the Effects of Outliers on the Estimation of Linear Stochastic Time Series Model. International Journal of Analysis and Applications, 17(4), pp.530–547. <https://doi.org/10.28924/2291-8639-17-2019-530>.
- APERGIS, N., 2016. Gold returns: Do business cycle asymmetries matter? Evidence from an international country sample. 57, pp.164–170. Doi: <https://doi.org/10.1016/j.econmod.2016.04.020>.
- BARANOVA, V., SERGIENKO, O., STEPURINA, S., & LYASHENKO, V., 2020. Price Environment for Gold and Silver in the Context of the Development of COVID-19. Journal of Asian Multicultural Research for Economy and Management Study, 1(2), pp.25–32.
- BIAŁKOWSKI, J., BOHL, M. T., STEPHAN, P. M., & WISNIEWSKI, T. P., 2015. The gold price in times of crisis. International Review of Financial Analysis, 41, pp.329–339. <https://doi.org/10.1016/j.irfa.2014.07.00>.
- BLÁZQUEZ-GARCÍA, A., CONDE, A., MORI, U. dan LOZANO, J.A., 2021. A Review on Outlier/Anomaly Detection in Time Series Data. ACM Computing Surveys, 54(3). <https://doi.org/10.1145/3444690>.
- CHOI, B.J., HOSELTON, S., NJAU, G.N., IDAMAWATTA, I.G.C.G., CARSON, P. dan MCEVOY, J., 2023. Estimating the prevalence of COVID-19 cases through the analysis of SARS-CoV-2 RNA copies derived from wastewater samples from North Dakota. Global Epidemiology, [online] 6(October), p.100124. <https://doi.org/10.1016/j.gloepi.2023.100124>.



- CRYER, J.D., & CHAN, K.S., 2008. *Time Series Analysis with Applications in R* (2nd ed.). New York: Springer.
- FARADIBAH, A., WIDYAWATI, D., SYAHAR, A.U.T., JABIR, S.R., 2023. Comparison Analysis of Random Forest Classifier, Support Vector Machine, and Artificial Neural Network Performance in Multiclass Brain Tumor Classification. *Indonesian Journal of Data and Science*, 4(2), pp.54–63. <https://doi.org/10.56705/ijodas.v4i2.73>.
- JIN, H., KIM, Y.G., JIN, Z., RUSHCHITC, A.A. dan AL-SHATI, A.S., 2022. Optimization and analysis of bioenergy production using machine learning modeling: Multi-layer perceptron, Gaussian processes regression, K-nearest neighbors, and Artificial neural network models. *Energy Reports*, [online] 8, pp.13979–13996. <https://doi.org/10.1016/j.egyr.2022.10.334>.
- JOSSO, P., HALL, A., WILLIAMS, C., LE BAS, T., LUSTY, P. dan MURTON, B., 2023. Application of random-forest machine learning algorithm for mineral predictive mapping of Fe-Mn crusts in the World Ocean. *Ore Geology Reviews*, [online] 162(September), p.105671. <https://doi.org/10.1016/j.oregeorev.2023.105671>.
- KOH, W.C., & BAFFES, J., 2020. Gold Shines Bright Throughout the COVID-19 Crisis. [online] Tersedia di: <<https://blogs.worldbank.org/opendata/gold-shines-bright-throughout-covid-19-crisis>> [Diakses 2 April 2023].
- LAMOUCHE, R.A., & BADKOOK, R.O., 2020. Gold Prices Volatility among Major Events and During the Current COVID-19 Outbreak. *Journal of Statistical and Econometric Methods*, 9(4), pp.39– 52.
- LEPOT, M., AUBIN, J.-B. dan CLEMENS, F., 2017. Interpolation in Time Series: An Introductory Overview of Existing Methods, Their Performance Criteria and Uncertainty Assessment. *Water*, [online] 9(10), p.796. <https://doi.org/10.3390/w9100796>.
- LEYS, C., DELACRE, M., MORA, Y.L., LAKENS, D. dan LEY, C., 2019. How to classify, detect, and manage univariate and multivariate outliers, with emphasis on pre-registration. *International Review of Social Psychology*, 32(1). <https://doi.org/10.5334/irsp.289>.
- LI, J., ZHENG, L., ZHU, Y. dan HE, J., 2021. Outlier Impact Characterization for Time Series Data. 35th AAAI Conference on Artificial Intelligence, AAAI 2021, 13A (Fox 1972), pp.11595–11603. <https://doi.org/10.1609/aaai.v35i13.17379>.
- LÓPEZ-DE-LACALLE, J., 2016. *tsoutliers* R Package for Detection of Outliers in Time Series.
- LUO, J. dan GONG, Y., 2023. Air pollutant prediction based on ARIMA-WOA-LSTM model. *Atmospheric Pollution Research*, [online] 14(6), p.101761. <https://doi.org/10.1016/j.apr.2023.101761>.
- MAHIR, A.R., & AL-KHAZALEH, A.M.H., 2009. New method to estimate missing data by using the asymmetrical winsorized mean in a time series. *Applied Mathematical Sciences* (Ruse). 3.
- MISRA, S. dan LI, H., 2019. Noninvasive fracture characterization based on the classification of sonic wave travel times. [online] *Machine Learning for Subsurface Characterization*. Elsevier Inc. <https://doi.org/10.1016/B978-0-12-817736-5.00009-0>.
- MONTGOMERY, D.C., JENNINGS C.L., KULAHCI M., 2015. *Introduction to Time Series Analysis and Forecasting: Second Edition*. New Jersey: Wiley.
- SANDRI, M., ZUCCOLOTTO, P., 2006. Variable Selection Using Random Forest. *Data Analysis, Classification and the Forward Search*, pp.263–270. [https://doi.org/10.1007/3-540-35978-8\\_30](https://doi.org/10.1007/3-540-35978-8_30).
- SEN, S., SUGIARTO, D., & ROCHMAN, A., 2020. Komparasi Metode Multilayer Perceptron (MLP) dan Long Short-Term Memory (LSTM) dalam Peramalan Harga Beras. *ISSN 2085-4552*.
- SETIYONO, A.T., GHASSANI, H., & DEWI, S., 2022. Determinan Covid-19 Terhadap Harga Emas. 14(1). <https://doi.org/10.33747>.
- SINGH, N. P., & SHARMA, S., 2018. Phase-wise analysis of dynamic relationship among gold, crude oil, US dollar and stock market. *Journal of Advances in Management Research*, 15(4), pp.480–499. <https://doi.org/10.1108/JAMR-12-2017-0124>.
- SCHONLAU, M. dan ZOU, R.Y., 2020. The random forest algorithm for statistical learning. *Stata Journal*, 20(1), pp.3–29. <https://doi.org/10.1177/1536867X2090968>.
- YUANDONG, S., KHASKHELI, A., RAZA, S.A., YOUSUFI, S.Q., 2022. How COVID-19 influences prices of oil and precious metals: Comparison between data extracted from online searching trends and actual events. *International Journal of Forecasting*, pp.231-240. <https://doi.org/10.1016/j.resourpol.2022.102916>.
- YOUSEF, I. dan SHEHADEH, E., 2020. The Impact of COVID-19 on Gold Price Volatility. *International Journal of Economics and*

Business Administration, 4(4), pp.353–364.

<https://doi.org/10.35808/ijeba/592>.

*Halaman ini sengaja dikosongkan*