

BAB III

METODE PENELITIAN

3.1 Jenis Penelitian

Penelitian yang akan dilakukan termasuk ke dalam golongan penelitian statistika terapan karena merupakan kegiatan ilmiah yang mengungkapkan gejala alam maupun kehidupan yang perlu diperbaiki karena adanya kekurangan dengan metode objektif dan dapat dipertanggungjawabkan (Nawawi & Martini, 2005).

3.2 Sumber Data

Pada penelitian ini digunakan data sekunder berupa data indeks harga saham properti Indonesia (IDXPROPERT) Data yang digunakan merupakan data harian dari periode 25 Januari 2021 sampai 28 Juni 2024 yang diperoleh dari situs id.tradingview.com.

3.3 Variabel Penelitian

Variabel penelitian yang akan digunakan yaitu variabel *input* berupa data *return* penutupan indeks harga saham properti Indonesia (IDXPROPERT). *Return* harian penutupan harga saham ialah tingkat pengembalian saham atas investasi yang dilakukan oleh investor setiap harinya.

3.4 Langkah Analisis

Langkah analisis data diolah dengan menggunakan bantuan *software Eviews dan Python* dengan *Google Colaboratory*. Adapun langkah-langkah analisis yang dilakukan pada penelitian ini adalah sebagai berikut

3.4.1 Pemrosesan Data

Langkah-langkah yang dilakukan pada penelitian ini adalah sebagai berikut:

1. Pra-pemrosesan data meliputi data *cleaning* dan penanganan *missing value* atau nilai yang hilang.
2. Melakukan analisis data secara deskriptif seperti membuat plot data untuk melihat dan mempelajari karakteristiknya.
3. Membagi data menjadi dua bagian, yaitu data *training* (latih) dan data *testing* (uji) dengan skema pembagian data sebesar 81,72% data *training* dan 18,28% data *testing*. Data latih menggunakan data pada rentang 25 Januari 2021 sampai

31 Oktober 2023, sementara data uji pada rentang 1 November 2023 sampai 28 Juni 2024.

3.4.2 Pembentukan Model GJR-GARCH

1. Memeriksa kestasioneran data dengan Uji *Augmented Dickey-Fuller*.
 - a. Jika data stasioner, maka menentukan model *Box-Jenkins* yaitu model AR, MA, ARMA.
 - b. Jika data tidak stasioner, maka dilakukan proses *differencing* ataupun transformasi terhadap data sehingga diperoleh data yang sudah stasioner. Jika data yang telah dilakukan proses *differencing* ataupun transformasi sudah stasioner, maka menentukan model *Box-Jenkins*.
2. Mengidentifikasi model ARIMA *Box-Jenkins* yang terbentuk dengan grafik FAK dan FAKP.
3. Melakukan pengujian estimasi parameter model ARIMA.
4. Melakukan uji diagnostik model ARIMA.
5. Pemilihan model ARIMA terbaik berdasarkan nilai *Akaike Information Criterion* (AIC).
6. Melakukan uji heteroskedastisitas pada model ARIMA terbaik. Jika terdapat efek ARCH, maka identifikasi model ARCH/GARCH.
7. Melakukan pengujian estimasi parameter model ARCH/GARCH yang terbentuk.
8. Pemilihan model ARCH/GARCH terbaik berdasarkan nilai *Akaike Information Criterion* (AIC).
9. Melakukan pengujian efek asimetris pada data. Jika terdapat efek asimetris, maka identifikasi model GJR-GARCH
10. Melakukan pengujian estimasi parameter model GJR-GARCH.
11. Pemilihan model GJR-GARCH terbaik berdasarkan nilai *Akaike Information Criterion* (AIC).
12. Melakukan peramalan pada data *test* indeks harga saham properti Indonesia.

3.4.3 Pembentukan Model GJR-GARCH-GRU

1. Melakukan perhitungan nilai sisaan atau residual yang merupakan selisih antara data prediksi model GJR-GARCH dengan data aktual, sebagai *input* pada model GRU.

Yusfrilina Aisyah Setyanto, 2024

METODE HYBRID GLOSTEN-JAGANNATHAN-RUNKLE GENERALIZED AUTOREGRESSIVE CONDITIONAL HETEROSCEDASTICITY DAN GATED RECURRENT UNIT (GJR-GARCH - GRU)

Universitas Pendidikan Indonesia | repository.upi.edu | perpustakaan.upi.edu

- Melakukan normalisasi data *train* dengan menggunakan metode *minimax scaler* untuk menghasilkan data yang bernilai antara 0-1. Dengan rumus sebagai berikut:

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (3.1)$$

dengan:

- x' : data normalisasi
- x : data asli
- x_{max} : nilai maksimum dari data asli
- x_{min} : nilai minimum dari data asli

- Menentukan inialisasi kombinasi *Hyperparameter* GRU yang sesuai, termasuk jumlah layer, jumlah unit di setiap layer, fungsi aktivasi dan parameter lainnya
- Melatih model GRU dengan data *training* (latih). Selama proses *training* dilakukan monitor metrik evaluasi seperti *loss function*, akurasi, atau metrik lainnya untuk melacak performa model.
- Penyetelan (*Tuning*) parameter model GRU untuk meningkatkan performa prediksi, hal ini melibatkan penyesuaian parameter arsitektur GRU seperti jumlah *layer*, *learning rate*, *epoch*, dan *dropout*. Tujuan penyetelan parameter adalah untuk mengevaluasi kinerja model dan identifikasi area yang perlu diperbaiki
- Menggunakan model GJR-GARCH untuk membuat prediksi komponen linear dan model GRU untuk membuat prediksi komponen non-linear pada data residual.
- Menggabungkan prediksi dari kedua model tersebut untuk mendapatkan hasil prediksi akhir dengan persamaan.
- Melakukan proses denormalisasi untuk mengembalikan hasil prediksi agar dibandingkan dengan data aktual. Ketika hasil prediksi didapatkan sebelum dilakukan perhitungan akurasi dari hasil prediksi perlu dilakukan denormalisasi data, dikarenakan data hasil prediksi masih dalam bentuk rentang interval pada saat normalisasi data. Berikut adalah persamaan untuk proses denormalisasi data: (Giusti dkk., 2018)

$$X_t = X'(X_{max} - X_{min}) + X_{min} \quad (3.2)$$

dengan,

X_t : nilai hasil denormalisasi

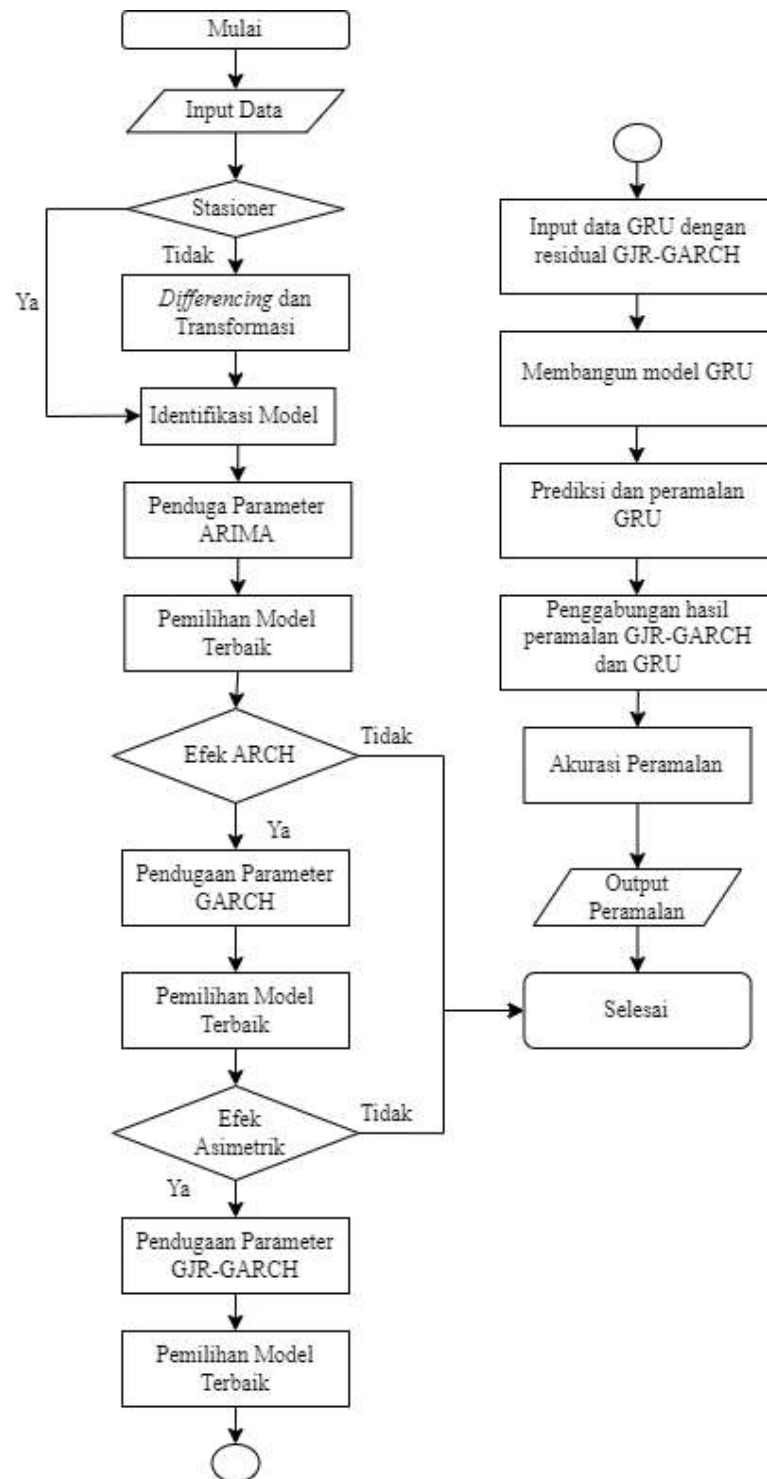
X' : nilai data normalisasi

X_{max} : nilai maksimal data aktual

X_{min} : nilai minimal data aktual

9. Evaluasi model menggunakan data *testing* (uji) untuk menguji performa model GJR-GARCH-GRU yang telah dilatih dengan menghitung nilai RMSE untuk mengukur tingkat akurasi prediksi model.

3.5 Alur Penelitian



Gambar 3. 1 Alur Penelitian

Yusfrilina Aisyah Setyanto, 2024

METODE HYBRID GLOSTEN-JAGANNATHAN-RUNKLE GENERALIZED AUTOREGRESSIVE CONDITIONAL HETEROSCEDASTICITY DAN GATED RECURRENT UNIT (GJR-GARCH - GRU)

Universitas Pendidikan Indonesia | repository.upi.edu | perpustakaan.upi.edu