

## **PEMODELAN DATA DERET WAKTU DENGAN AUTOREGRESSIVE INTEGRATED MOVING AVERAGE DAN LOGISTIC SMOOTHING TRANSITION AUTOREGRESSIVE**

**Gusti Ayu Made Arna Putri<sup>1</sup>, Ni Putu Nanik Hendayanti<sup>2</sup>, Maulida Nurhidayati<sup>3</sup>,  
STMIK STIKOM Bali<sup>1,2</sup>**

Institut Agama Islam Negeri Ponorogo<sup>3</sup>

<sup>1</sup>gustiayu.arna@gmail.com, <sup>2</sup>nanik@stikom-bali.ac.id, <sup>3</sup>nurhidayatimaulida@gmail.com

### **Abstract**

*Time series analysis is a statistical analysis that can be applied on data related to time. Modeling of time series data is widely associated with the process of forecasting a certain characteristics in the coming period. Most inflation data modeling is done using a linear time series models such as Autoregressive Integrated Moving Average (ARIMA). In fact only the ARIMA model can be applied to models of linear time series data. Models of ARIMA hasn't been able to give good results when the data being analyzed is a nonlinear time series data. The inflation data, data that has a tendency to form patterns of nonlinear data so the application of nonlinear time series models can be done on the inflation data. Logistic model Smoothing Threshold Autoregressive (LSTAR) is a time series model can be applied to data that follow nonlinear model. LSTAR then developed on data-financial and economic data such as inflation. If the inflation data are modelled with expected LSTAR approach can get a better result because already done smoothing in it. This research aims to know the best model that can be used to perform data modeling inflation. The results showed that the results of the comparison of the MSE and the RMSE for the model of ARIMA and LSTAR. Based on these results it is known that the model MSE has a value and LSTAR RMSE smaller compared to ARIMA. So the model more appropriate LSTAR is used to model the data of inflation*

**Key Words:** ARIMA, LSTAR, Inflation

### **Abstrak**

Analisis deret waktu adalah suatu analisis statistika yang dapat diterapkan pada data yang berhubungan dengan waktu. Pemodelan dari data deret waktu ini banyak dikaitkan dengan proses peramalan suatu karakteristik tertentu pada periode mendatang. Pemodelan data inflasi kebanyakan dilakukan dengan menggunakan model deret waktu linier seperti *Autoregressive Integrated Moving Average (ARIMA)*. Pada kenyataannya model ARIMA hanya dapat diterapkan pada model-model data deret waktu linier. Model ARIMA belum mampu memberikan hasil yang baik ketika data yang dianalisis merupakan suatu data deret waktu nonlinier. Data inflasi, merupakan suatu data yang memiliki kecenderungan membentuk pola data yang nonlinier sehingga penerapan model deret waktu nonlinier dapat dilakukan pada data inflasi tersebut. Model *Logistic Smoothing Threshold Autoregressive (LSTAR)* adalah model deret waktu yang dapat diterapkan pada data yang mengikuti model nonlinier. LSTAR kemudian dikembangkan pada data-data ekonomi dan keuangan seperti inflasi. Jika data inflasi dimodelkan dengan pendekatan LSTAR diharapkan bisa mendapatkan hasil yang lebih baik karena sudah dilakukan penghalusan didalamnya. Penelitian ini bertujuan untuk mengetahui model terbaik yang dapat digunakan untuk melakukan pemodelan data inflasi. Hasil penelitian menunjukkan bahwa hasil perbandingan MSE dan RMSE untuk model ARIMA dan LSTAR. Berdasarkan hasil tersebut diketahui bahwa model LSTAR memiliki nilai MSE dan RMSE yang lebih kecil dibandingkan dengan ARIMA. Sehingga model LSTAR lebih sesuai digunakan untuk memodelkan data inflasi.

**Kata Kunci:** ARIMA, LSTAR, Inflasi

## **I. PENDAHULUAN**

Runtun waktu (*Time Series*) adalah serangkaian pengamatan terhadap suatu variabel yang diambil dari waktu ke waktu dan dicatat secara berurutan menurut urutan kejadiannya dengan interval waktu yang tetap [1]. Analisis deret waktu pada dasarnya digunakan untuk melakukan analisis data yang mempertimbangkan pengaruh waktu. Analisis deret waktu dapat dilakukan untuk membantu dalam menyusun perencanaan kedepan. Pemodelan dari data deret waktu ini banyak dikaitkan dengan proses peramalan suatu karakteristik tertentu pada periode mendatang. Peramalan sendiri merupakan suatu pendugaan atau perkiraan suatu keadaan di masa yang akan datang berdasarkan keadaan masa lalu dan sekarang yang diperlukan untuk menetapkan kapan suatu peristiwa akan terjadi, sehingga tindakan yang tepat dapat dilakukan

Pada kebanyakan peramalan data deret waktu, metode yang paling sering digunakan adalah *exponential smoothing*, *Autoregressive Integrated Moving Average* (ARIMA) atau regresi. Beberapa pendekatan tersebut banyak digunakan pada data-data deret waktu yang mengikuti suatu pola yang linier dan menunjukkan hasil yang kurang memuaskan ketika data yang dianalisis merupakan suatu data yang mengalami gangguan *noise* atau data-data yang berfluktuasi secara ekstrim. Adanya data ekstrim pada suatu data time series mengakibatkan analisis yang dilakukan seringkali menjadi bias, atau tidak mencerminkan fenomena yang sebenarnya.

Pada kenyataannya model ARIMA hanya dapat diterapkan pada model-model data deret waktu linier. Model ARIMA belum mampu memberikan hasil yang baik ketika data yang dianalisis merupakan suatu data deret waktu nonlinier. Data inflasi, merupakan suatu data yang memiliki kecenderungan membentuk pola data yang nonlinier sehingga penerapan model deret waktu nonlinier dapat dilakukan pada data inflasi tersebut.

Model *Logistic Smoothing Transition Autoregressive* (LSTAR) adalah model deret waktu yang dapat diterapkan pada data yang mengikuti model nonlinier. LSTAR kemudian dikembangkan pada data-data ekonomi dan keuangan seperti

inflasi. Jika data inflasi dimodelkan dengan pendekatan LSTAR diharapkan bisa mendapatkan hasil yang lebih baik karena sudah dilakukan penghalusan didalamnya.

Pada tahun 2011 [2] melakukan penelitian tentang SETAR untuk pemodelan data deret waktu yang nonlinier. [3] menerapkan metode LSTAR untuk data-data yang mengikuti data deret waktu nonlinier untuk menentukan suatu estimasi yang *robust*. Pada tahun 2011, [4] menggunakan model deret waktu nonlinier LSTAR untuk memodelkan data nilai tukar dan melakukan peramalan berdasarkan model yang diperoleh.

Membandingkan performa tiga model (AR, ESTAR dan LSTAR) untuk peramalan *return* saham Malaysia Airlines (MA) dan mendapatkan model LSTAR sebagai model terbaik dengan nilai  $p$  terendah dan nilai statistik LM yang lebih tinggi dari kedua model lainnya [5].

Inflasi adalah proses meningkatnya harga-harga. Definisi lain mengatakan bahwa inflasi adalah terjadinya kenaikan tingkat harga konsumen dan/atau menurunnya nilai uang. Angka inflasi diperoleh dari perubahan indeks harga konsumen (IHK). Untuk menghitung IHK saat ini 774 komoditas atas dasar survey biaya hidup tahun 2007 yang dilakukan di 66 kota. Dampak besaran angka inflasi akan bergantung pada struktur konsumsi dan kualitas barang yang dikonsumsi oleh suatu rumah tangga.

Inflasi memiliki dampak positif dan negative tergantung pada besar kecilnya nilai inflasi. Apabila inflasi itu ringan (kecil), justru mempunyai pengaruh yang positif dalam arti dapat mendorong perekonomian menjadi lebih baik, yaitu meningkatnya pendapatan nasional yang membuat orang bergairah untuk bekerja, menabung, dan mengadakan investasi. Sebaliknya, inflasi yang parah(besar) yaitu pada saat terjadi inflasi yang tak terkendali, keadaan ekonomi menjadi kacau dan lesu.

Inflasi sangat penting untuk diketahui secara lebih spesifik karena akan berpengaruh terhadap perekonomian. Perkiraan nilai inflasi ini akan memberikan gambaran bagaimana keadaan perekonomian pada masa yang akan datang sehingga pengambilan kebijakan untuk stabilitas ekonomi dapat dilakukan.

Berdasarkan paparan diatas dan pentingnya mengetahui prediksi dari inflasi, pada penelitian ini dilakukan pemodelan data inflasi dengan menggunakan model ARIMA dan LSTAR sehingga diperoleh model yang memiliki error yang kecil.

### A. Analisis Deret Waktu

Data deret waktu adalah sebuah kumpulan observasi terhadap nilai-nilai sebuah variabel dari beberapa periode yang reguler, seperti harian, mingguan, bulanan, kuartalan, tahunan, dll. Data deret waktu yang merupakan data harian dapat berupa data harga saham, dan laporan cuaca. Data mingguan dapat berupa informasi uang yang beredar. Data kuartalan dapat berupa data PDRB dan data tahunan dapat berupa data anggaran pemerintah.

Suatu data yang dimodelkan dengan analisis deret waktu dapat diasumsikan bahwa data tersebut dalam keadaan stasioner. Artinya tidak terjadi trend dalam mean dan varian. Dalam analisis deret waktu, data diharapkan mengikuti proses stokastik yaitu suatu proses yang dinyatakan dalam suatu variabel random  $Z(t)$  dinotasikan dengan  $Z_t$  yang mempunyai fungsi kepadatan  $f(Z_t)$ . Artinya data deret waktu pada  $t_1, t_2, \dots, t_n$  mempunyai nilai  $Z_{t_1}, Z_{t_2}, \dots, Z_{t_n}$  secara acak dari suatu distribusi probabilitas  $f(Z_{t_i})$ .

### B. Fungsi Autokovarian dan Fungsi Autokorelasi

Suatu proses yang stasioner  $\{Z_t\}$  memiliki mean  $E(Z_t) = \mu$  dan varian  $Var(Z_t) = E(Z_t - \mu)^2 = \sigma^2$  yang masing-masing merupakan suatu konstanta kemudian covarian  $Cov(Z_t, Z_s)$  merupakan suatu fungsi dari perbedaan waktu  $|t - s|$ . Covarian antara  $Z_t$  dan  $Z_{t+k}$  didefinisikan sebagai berikut:

$$\chi_k = Cov(Z_t, Z_{t+k}) = E(Z_t - \mu)(Z_{t+k} - \mu) \quad (1)$$

Korelasi antara  $Z_t$  dan  $Z_{t+k}$  adalah

$$\dots_k = \frac{Cov(Z_t, Z_{t+k})}{\sqrt{Var(Z_t)}\sqrt{Var(Z_{t+k})}} = \frac{\chi_k}{\chi_0} \quad (2)$$

dengan  $Var(Z_t) = Var(Z_{t+k}) = \chi_0$ .

Untuk suatu proses yang stasioner, fungsi autokovarian  $\chi_k$  dan fungsi autokorelasi  $\rho_k$  memiliki sifat-sifat sebagai berikut:

1.  $\chi_0 = Var(Z_t); \dots_0 = 1$ .
2.  $|\chi_k| \leq \chi_0; |\dots_k| \leq 1$ .

$\chi_k = \chi_{-k}$  dan  $\dots_k = \dots_{-k}$  untuk semua k.  $\chi_k$  dan  $\dots_k$  adalah fungsi genap yang simetris pada lag k=0. Berdasarkan sifat tersebut, fungsi autokorelasi selalu digambarkan pada lag yang tidak negatif yang selanjutnya disebut sebagai *correlogram* [1].

### C. Fungsi Autokorelasi Parsial

Autokorelasi parsial digunakan untuk mengukur korelasi antara  $Z_t$  dan  $Z_{t+k}$  setelah menghilangkan atau memisahkan dependensi linier pada variabel  $Z_{t+1}, Z_{t+2}, \dots, Z_{t+k-1}$  terhadap  $Z_{t+k}$  dan dinyatakan sebagai:

$$Corr(Z_t, Z_{t+k} | Z_{t+1}, Z_{t+2}, \dots, Z_{t+k-1}) \quad (3)$$

Autokorelasi parsial dapat diperoleh berdasarkan model regresi dengan variabel dependen adalah  $Z_{t+k}$  dan variabel independen adalah  $Z_{t+k-1}, Z_{t+k-2} + \dots + Z_t$  sehingga model yang terbentuk adalah

$$Z_{t+k} = w_{k1} Z_{t+k-1} + w_{k2} Z_{t+k-2} + \dots + w_{kk} Z_t + e_{t+k} \quad (4)$$

### D. Proses Autoregressive (AR)

Proses autoregressive digunakan untuk menggambarkan suatu kondisi dimana nilai sekarang dari suatu deret waktu bergantung pada nilai sebelumnya ditambah dengan *random stock*. Menurut [1] bentuk umum dari model autoregressive orde p adalah

$$\dot{Z}_t = w_1 \dot{Z}_{t-1} + w_2 \dot{Z}_{t-2} + \dots + w_p \dot{Z}_{t-p} + a_t \quad (5)$$

atau

$$W_p(B)\dot{Z}_t = a_t \quad (6)$$

dengan

$$W_p(B) = (1 - w_1 B - w_2 B^2 - \dots - w_p B^p)$$

$$\dot{Z}_t = Z_t - \sim$$

### E. Proses Autoregressive Moving Average

Model ARIMA merupakan gabungan antara model Autoregressive (AR) dan Moving Average (MA) serta proses differencing (orde d untuk non musiman, dan D untuk musiman) terhadap data time series.

Secara umum, model ARIMA non musiman dapat ditulis sebagai ARIMA (p,d,q) dengan bentuk umum adalah sebagai berikut [1].

$$W_p(B)(1-B)^d Z_t = \mu_0 + \mu_q(B)a_t \quad (7)$$

dengan

(p,d,q) : orde AR(p), orde differencing (d), dan orde MA (q)

$W_p(B)$  : koefisien komponen AR orde p

$\mu_q(B)$  : koefisien komponen MA orde q

$\mu_0$  : koefisien tren deterministic

$a_t$  : nilai residual pada saat t

Identifikasi model ARIMA dapat dilakukan dengan melihat plot time series, plot ACF, dan PACF. Plot ACF dan PACF digunakan untuk menentukan orde p dan orde q dari model ARIMA non musiman. Secara teoritis, bentuk-bentuk plot ACF dan PACF dari model ARIMA ditunjukkan pada Tabel 1 berikut [1].

**Tabel 1.** Bentuk ACF dan PACF teoritis ARIMA

Model	ACF	PACF
AR(p)	Turun cepat secara eksponensial (dies down)	Terputus setelah lag p
MA(q)	Terputus setelah lag q	Turun cepat secara eksponensial (dies down)
ARMA(p,q)	Turun cepat secara eksponensial	Turun cepat secara eksponensial

	menuju nol	menuju nol
--	------------	------------

Metode estimasi parameter model ARIMA menggunakan metode least square estimation. Untuk model AR(1), model ini dapat dilihat sebagai model regresi. Metode LS merupakan suatu metode yang dilakukan dengan cara mencari nilai parameter yang meminimumkan jumlah kuadrat kesalahan (selisih antara nilai actual dan ramalan) yang dinyatakan dalam persamaan berikut.

$$S(w, \sim) = \sum_{t=2}^n a_t^2 \quad (8)$$

$$= \sum_{t=2}^n [(Y_t - \sim) - w(Y_{t-1} - \sim)]^2$$

Berdasarkan prinsip dari metode LS, penaksiran w dan ~ dilakukan dengan meminimumkan S(w, ~). Hal ini dilakukan dengan menurunkan S(w, ~) terhadap w dan ~ kemudian disamadengankan nol. Meminimumkan S(w, ~) terhadap ~ menghasilkan

$$\frac{\partial S(w, \sim)}{\partial \sim} = \sum_{t=2}^n 2[(Y_t - \sim) - w(Y_{t-1} - \sim)](-1 + w) = 0 \quad (9)$$

Sehingga diperoleh nilai taksiran parameter ~ untuk dari model AR(1) sebagai berikut

$$\hat{\sim} = \frac{\sum_{t=2}^n Y_t - w \sum_{t=2}^n Y_{t-1}}{(n-1)(1-w)} \quad (10)$$

Untuk n besar, dapat ditulis sebagai berikut

$$\frac{\sum_{t=2}^n Y_t}{(n-1)} \approx \frac{\sum_{t=2}^n Y_{t-1}}{(n-1)} \approx \bar{Y} \quad (11)$$

Berdasarkan persamaan (11) bentuk persamaan (10) dapat dituliskan seperti persamaan (12) berikut

$$\hat{\sim} = \frac{\sum_{t=2}^n Y_t - w \sum_{t=2}^n Y_{t-1}}{(n-1)(1-w)} = \frac{\bar{Y} - w\bar{Y}}{1-w} = \frac{\bar{Y}(1-w)}{1-w} = \bar{Y} \quad (12)$$

Dengan cara yang sama, persamaan (8) diturunkan terhadap  $w$  menghasilkan bentuk persamaan (13).

$$\frac{\partial S(w, \sim)}{\partial w} = \sum_{t=2}^n 2[(Y_t - \bar{Y}) - w(Y_{t-1} - \bar{Y})](Y_{t-1} + \bar{Y}) \quad (13)$$

$$= 0$$

Sehingga diperoleh nilai taksiran parameter  $w$  untuk dari model AR(1) sebagai berikut

$$\hat{w} = \frac{\sum_{t=2}^n (Y_t - \bar{Y})(Y_{t-1} - \bar{Y})}{\sum_{t=2}^n (Y_{t-1} - \bar{Y})^2} \quad (14)$$

## F. Uji Stasioneritas

Asumsi stasioneritas data merupakan sifat yang penting. Pada model stasioner, sifat-sifat statistic di masa yang akan datang dapat diramalkan berdasarkan data historis yang telah terjadi dimasa yang lalu. Pengujian stasioneritas dari suatu data *time series* dapat dilakukan dengan beberapa cara. Antara lain [6]:

1. Pendeteksian ketidakstasioneran data dalam mean dapat dilakukan dengan menggunakan plot dari data *time series*, plot PACF, dan plot ACF.
2. Pendeteksian ketidakstasioneran data dalam varian dapat menggunakan plot ACF/PACF dari residual kuadratnya.
3. Pendeteksian ketidakstasioneran data dilakukan dengan menggunakan uji akar unit. Pengujian dengan menggunakan akar unit dilakukan untuk mengamati apakah data *time series* memiliki komponen tren berupa *random walk* dalam data. Salah satu metode yang dapat digunakan adalah Augmented Dickey Fuller. Pengujian dengan ADF dilakukan dengan menggunakan  $H_0: =0$  (terdapat akar unit) dengan persamaan regresinya adalah

$$Z_t = s + ut + \dots Z_{t-1} + \sum_{j=1}^k w_j Z_{t-j} + a_t \quad (15)$$

Hipotesis nol tersebut ditolak jika nilai statistic uji ADF memiliki nilai kurang dari nilai daerah kritisnya. Jika hipotesis nol ditolak, dapat disimpulkan bahwa data stasioner (tidak mengandung akar unit).

Di dalam mengaplikasikan uji ADF, pertama-tama harus menentukan

banyaknya lag dari komponen deferens yang akan dimasukkan ke dalam model. Dalam praktik, biasanya dipilih  $k$  yang dapat menghapus korelasi serial dari residual, yang dapat dilihat dengan lag yang masih signifikan dalam model regresi ADF. Selanjutnya perlu dispesifikasikan apakah dalam model harus dimasukkan komponen konstanta, konstanta ditambah komponen tren, atau memasukkan keduanya. Salah satu pendekatan yang mungkin dilakukan adalah memasukkan kedua komponen konstanta dan tren dalam model karena kedua keadaan lain adalah kasus khusus dari keadaan ini[6].

## G. Proses deret Waktu Nonlinier

Menurut [1] proses deret waktu dapat dituliskan sebagai berikut

$$Z_t = \sum_{i=0}^{\infty} \mathbb{E}_i a_{t-i} + \sum_{i=0}^{\infty} \sum_{j=0}^{\infty} \mathbb{E}_{i,j} a_{t-i} a_{t-j} + \sum_{i=0}^{\infty} \sum_{j=0}^{\infty} \sum_{k=0}^{\infty} \mathbb{E}_{i,j,k} a_{t-i} a_{t-j} a_{t-k} + \dots \quad (16)$$

Jika proses  $Z_t$  pada persamaan (16) hanya terdiri dari suku pertama maka proses yang terjadi adalah proses linier. Jika proses  $Z_t$  pada persamaan (16) terdiri dari suku pertama dan suku yang lain maka proses yang terjadi adalah proses nonlinier [1].

## H. Uji Nonlinier

Uji nonlinieritas dilakukan untuk mengetahui apakah suatu data mengikuti pola linier atau nonlinier. Beberapa uji nonlinieritas yaitu uji terasvirta dan uji white. Kedua uji tersebut termasuk uji nonlinieritas yang tidak mensyaratkan suatu model nonlinieritas tertentu.

### 1. Uji Terasvirta

Uji nonlinieritas yang termasuk uji kelompok *Lagrange Multiplier* yang dikembangkan dari model *neural network*. Prosedur untuk mendapatkan nilai statistik uji F adalah sebagai berikut [7]:

- a) Meregresikan  $Z_t$  dengan  $1, Z_{t-1}, Z_{t-2}, \dots, Z_{t-p}$  dan menghitung

residual  $\hat{a}_t$  serta menghitung jumlah kuadrat residual.

$$SSR_0 = \sum_{t=1}^T \hat{a}_t^2 \quad (8)$$

- b) Meregresikan  $\hat{a}_t$  dengan  $1, Z_{t-1}, Z_{t-2}, \dots, Z_{t-p}$  dan  $m$  prediktor tambahan yang merupakan suku kubik atau kuadratik yang merupakan hasil pendekatan ekspansi Taylor. Menghitung residual  $\hat{v}_t$  serta menghitung jumlah kuadrat residual.

$$SSR = \sum_{t=1}^T \hat{v}_t^2 \quad (9)$$

- c) Menghitung nilai F

$$F = \frac{(SSR_0 - SSR) / m}{SSR / (N - p - 1 - m)} \quad (17)$$

dengan  $N$  adalah jumlah pengamatan

Dibawah hipotesis linieritas dalam mean, nilai F didekati dengan distribusi F dengan derajat bebas  $m$  dan  $N - p - 1 - m$ .

## 2. Uji White

Uji white adalah salah satu uji nonlinier yang [8]. Uji tersebut didasarkan pada teknik pemodelan *neural network* dan merupakan uji dalam kelompok *Lagrange Multiplier (LM)* dengan menambahkan unit tersembunyi (*hidden units*) untuk jaringan linier. Prosedur untuk mendapatkan nilai statistik uji F adalah sebagai berikut

- a) Meregresikan  $Z_t$  dengan  $1, Z_{t-1}, Z_{t-2}, \dots, Z_{t-p}$  dan menghitung residual  $\hat{a}_t$  serta menghitung jumlah kuadrat residual.

$$SSR_0 = \sum_{t=1}^T \hat{a}_t^2 \quad (18)$$

- b) Meregresikan  $\hat{a}_t$  dengan  $1, Z_{t-1}, Z_{t-2}, \dots, Z_{t-p}$  dan  $m$  prediktor tambahan yang merupakan nilai dari fungsi distribusi kumulatif dari logistik

$$\text{yaitu } E(x'w_t) = \left(1 + e^{-x'w_t}\right)^{-1} - \frac{1}{2}.$$

Menghitung residual  $\hat{v}_t$  serta menghitung jumlah kuadrat residual.

$$SSR = \sum_{t=1}^T \hat{v}_t^2 \quad (19)$$

- c) Menghitung nilai F

$$F = \frac{(SSR_0 - SSR) / m}{SSR / (N - p - 1 - m)} \quad (20)$$

dengan  $N$  adalah jumlah pengamatan.

Dibawah hipotesis linieritas dalam mean, nilai F didekati dengan distribusi F dengan derajat bebas  $m$  dan  $N - p - 1 - m$ .

## I. Model Threshold Autoregressive (TAR)

TAR adalah alternatif model untuk mendeskripsikan deret waktu periodik. Model ini dimotivasi oleh beberapa karakteristik nonlinier yang biasa ditemukan dalam kehidupan sehari-hari seperti adanya asimetri dalam pola turun dan naik suatu proses, fenomena lompatan, serta frekuensi ketergantungan amplitudo yang tidak dapat ditangkap oleh model deret waktu linier. Model ini menggunakan *threshold* untuk meningkatkan pendekatan linier.

Model TAR dapat dituliskan sebagai berikut:

$$Z_t = w_0 + \sum_{i=1}^p w_i Z_{t-i} + \left(r_0 + \sum_{i=1}^p r_i Z_{t-i}\right) I\left(\frac{Z_{t-d} - \ddagger}{u}\right) + a_t \quad (21)$$

dengan

$Z_t$  : data deret waktu

$d$  : parameter *delay*

$\ddagger$  : parameter lokasi (*threshold*)

$u$  : parameter skala

$I(\cdot)$  : fungsi penghalus yang dapat berupa suatu

fungsi logistik, eksponensial, maupun suatu fungsi indikator.

## J. Logistic Smoothing Transition Autoregressive (LSTAR)

*Smooth Transition Autoregressive (STAR)* adalah model regime swiching mirip dengan model SETAR namun memungkinkan untuk kelancaran

transisi antara rezime. Telah dikenalkan secara rinci misalnya [7]. Umumnya sebuah proses STAR orde  $p$  didefinisikan oleh

$$Y_t = X_t W^{(1)} (1 - G(Z_t)) + X_t W^{(2)} G(Z_t; x, c) + a_t \quad (22)$$

Dua pilihan populer untuk fungsi *Smooth Transition Autoregressive (STAR)* adalah fungsi logistik dan fungsi eksponensial. Kedua pilihan tersebut memiliki bentuk perbedaan dalam bentuk fungsi transisi penghalus yang digunakan. Fungsi *Logistic Smoothing Transition Autoregressive* dijelaskan pada persamaan berikut:

$$G(S_t; x, c) = \frac{1}{1 + e^{-x(Z_t - c)}}, x > 0 \quad (23)$$

### K. Uji Signifikansi Parameter

Model deret waktu dibangun dengan melakukan identifikasi dan estimasi parameter dari model. Misalkan  $\hat{W}_i$  adalah estimasi dari  $W_i$ . Uji signifikan parameter dapat dilakukan dengan tahapan berikut

1. Menetapkan hipotesis

$$H_0 : W_i = 0$$

$$H_0 : W_i \neq 0, \text{ dengan } i = 1, 2, \dots, k$$

2. Statistik uji

$$t = \frac{\hat{W}_i}{\sqrt{\text{Var}_{W_i}}}$$

Dengan derajat bebas =  $N - M$ ,

$N$  adalah banyaknya pengamatan dan  $M$  adalah banyaknya parameter dalam model.

3. Kriteria penolakan  $H_0$

Tolak  $H_0$  jika  $|t| > t_{r, df}$  dengan  $df = N - M$ ,  $N$  adalah banyaknya pengamatan dan  $M$  adalah banyaknya parameter dalam model.

### L. Kriteria Pemilihan Model Terbaik

*Akaike's Information Criteria (AIC)* adalah suatu kriteria pemilihan model terbaik yang diperkenalkan oleh Akaike dengan mempertimbangkan banyaknya parameter dalam model. Semakin kecil nilai AIC yang diperoleh semakin baik model yang digunakan. Kriteria AIC dapat dirumuskan sebagai berikut:

$$\begin{aligned} AIC(M) &= -2 \ln[\text{maksimum likelihood}] + 2M \\ &= N \ln \left( \frac{SSE}{N} \right) + 2M \end{aligned} \quad (24)$$

dengan

SSE : *sum square error*

$M$  : banyak parameter dalam model

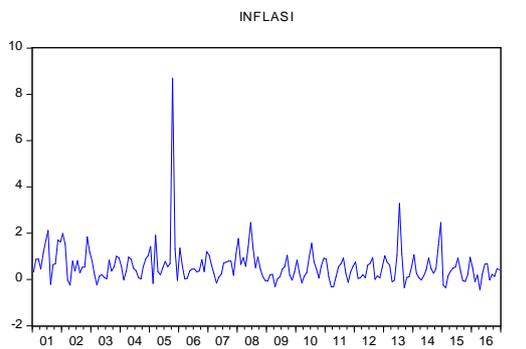
## II. METODOLOGI PENELITIAN

Pada penelitian ini, data yang digunakan adalah data sekunder yang merupakan data *time series* bulanan inflasi nasional periode Januari 2001 hingga Desember 2016. Analisis data dilakukan dalam 2 tahap yaitu pemodelan data inflasi dengan menggunakan model linier ARIMA dan model nonlinier LSTAR. Setelah diperoleh model dari data tersebut selanjutnya dibandingkan dengan menggunakan kriteria AIC minimum untuk memperoleh model yang memberikan hasil meminimumkan error. Analisis dilakukan dengan *software R* dengan *Package tsDyn, tseries*, dan *forecast*.

Langkah-langkah pemodelan data inflasi nasional dengan model linier ARIMA dan model nonlinier LSTAR dijabarkan sebagai berikut

1. Plot *time series*.
2. Pengujian stasioneritas data.
3. Pemodelan dengan ARIMA.
  - Plot ACF dan PACF.
  - Menentukan orde  $p$ ,  $d$ , dan  $q$ .
  - Mencari model ARMA terbaik.
  - Estimasi parameter model.
4. Pemodelan dengan LSTAR
  - Pengujian nonlinieritas dengan *white test*.
  - Plot ACF dan PACF.
  - Menentukan orde LSTAR.
  - Menentukan rentang delay.
  - Mencari model LSTAR terbaik
  - Estimasi parameter model.
5. Pemilihan model terbaik (Perbandingan MSE antara ARIMA dan LSTAR).
6. Interpretasi model.

### III. HASIL DAN PEMBAHASAN



Gambar 1 Inflasi Nasional 2001-2016

Gambar 1 menunjukkan perkembangan inflasi nasional Indonesia dari Januari 2001 hingga Desember 2016. Inflasi nasional Indonesia mengalami perubahan dari waktu ke waktu. Inflasi tertinggi terjadi pada bulan Oktober 2005 yaitu sebesar 8,70 dan berbeda dengan inflasi pada bulan-bulan sebelumnya. Hal ini dapat berakibat data deret waktu yang terbentuk merupakan data deret waktu yang tidak linier (nonlinier). Untuk membuktikan secara statistic dilakukan pengujian nonlinieritas dengan metode White test dan Terasvirta untuk melihat bagaimana pola data deret waktu yang terbentuk.

Tabel 2. Pengujian Nonlinieritas

Metode	$X^2$	p-val
White Test	7,6467	0,02185
Terasvirta	7,4622	0,02397

Tabel 2 menunjukkan hasil pengujian nonlinieritas dari data inflasi dengan menggunakan metode White test dan Terasvirta. Berdasarkan hasil yang diperoleh diketahui bahwa masing-masing metode memiliki nilai p-val yang kurang dari 0,05 sehingga data inflasi nasional periode 2001-2016 meminili pola nonlinier.

Tabel 3. Pengujian Stasioneritas

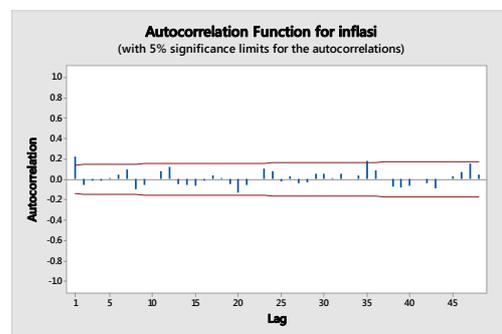
Variabel	Nilai ADF	p-val
Inflasi	-5,5995	0,01

Untuk dapat melakukan analisis lebih lanjut perlu dilakukan pengujian stasioneritas untuk mengetahui apakah data stasioner. Karena data

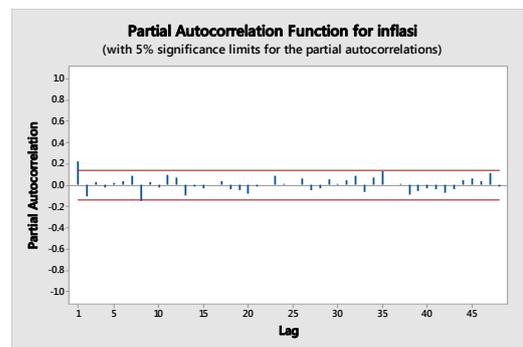
yang stasioner dibutuhkan untuk melakukan analisis dan menghasilkan hasil yang lebih sesuai. Pengujian stasioneritas dilakukan dengan menggunakan metode ADF (Augmented Dickey-Fuller Test). Hasil pengujian dengan ADF dapat dilihat pada Tabel 3. Hasil yang diperoleh menunjukkan bahwa inflasi nasional telah stasioner dalam mean karena nilai p-val yang diperoleh kurang dari 0,05.

#### 1. Pemodelan data inflasi dengan ARIMA

Untuk memodelkan data dengan ARIMA perlu ditentukan terlebih dahulu orde p,d,dan q. orde ini ditentukan berdasarkan ACF dan PACF. Grafik ACF dan PACF ditunjukkan pada Gambar 2 dan Gambar 3.



Gambar 2 Plot ACF



Gambar 3 Plot PACF

Berdasarkan Gambar 2 dan Gambar 3 dapat diduga bahwa orde untuk  $p=1$ ,  $q=1$ , dan  $d=0$  karena data inflasi telah stasioner. Selanjutnya dilakukan pemilihan model terbaik dan diperoleh model terbaik adalah ARIMA (0,0,1). Hasil estimasi parameter mode ARIMA (0,0,1) ditunjukkan pada Tabel 4.

**Tabel 4.** Estimasi Parameter Model ARIMA

	Estimate	Std. Error	t value	Pr(> z )
MA(1)	-0.271	0.070	-3.880	0.000
Const	0.587	0.073	8.000	0.000

Berdasarkan Tabel 4 diketahui bahwa estimasi parameter MA (1) sebesar -0,271 dan konstanta sebesar 0,587. Nilai p-value dari kedua parameter tersebut bernilai kurang dari 0,05 sehingga parameter tersebut signifikan terhadap model. Sehingga model ARIMA yang terbentuk adalah sebagai berikut

$$y_t = a_t + 0,271a_{t-1} + 0,587 \quad (25)$$

## 2. Pemodelan data inflasi dengan LSTAR

Untuk memodelkan data dengan LSTAR perlu ditentukan terlebih dahulu orde m. orde ini ditentukan berdasarkan PACF. Berdasarkan Gambar 3 diketahui bahwa orde m=1. Sehingga estimasi parameter model LSTAR diduga dengan menggunakan m=1. Hasil estimasi parameter model LSTAR ditunjukkan pada Tabel 5.

**Tabel 5.** Estimasi Parameter Model LSTAR

	Estimate	Std. Error	t value	Pr(> z )
const.L	0.268	0.090	2.973	0.003
phiL.1	0.993	0.249	3.991	0.000
const.H	0.346	0.184	1.880	0.060
phiH.1	-0.881	0.265	-3.322	0.001
gamma	100.00	102.423	0.976	0.329
th	0.732	0.039	18.976	2.2e-16

Hasil estimasi parameter menunjukkan bahwa parameter  $delay=1$  dengan 2 transisi. Berdasarkan Tabel 5 diketahui bahwa parameter dari model LSTAR memiliki nilai p-val kurang dari 0,05 yang berarti model signifikan tetapi gamma tidak signifikan. Model LSTAR dapat ditunjukkan pada persamaan 2 berikut

$$y_t = (0,268 + 0,993y_{t-1}) \left( 1 - \frac{1}{1 + e^{-100(y_{t-1} - 0,732)}} \right) + (0,346 - 0,881y_{t-1}) \left( \frac{1}{1 + e^{-100(y_{t-1} - 0,732)}} \right) + a_t$$

## 3. Perbandingan Model ARIMA dan LSTAR

Untuk mengetahui model yang paling baik dilakukan dengan menggunakan kriteria MSE dan RMSE. Hasil perbandingan model ditunjukkan pada Tabel 6 berikut.

**Tabel 6.** Estimasi Parameter Model LSTAR

Model	Kriteria Kebaikan Model	
	MSE	RMSE
ARIMA	0,633	0,796
LSTAR	0,608	0,780

Tabel 6 menunjukkan hasil perbandingan MSE dan RMSE untuk model ARIMA dan LSTAR. Berdasarkan hasil tersebut diketahui bahwa model LSTAR memiliki nilai MSE dan RMSE yang lebih kecil dibandingkan dengan ARIMA. Sehingga model LSTAR lebih sesuai digunakan untuk memodelkan data inflasi.

## IV. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian yang telah dilakukan diperoleh kesimpulan hasil perbandingan MSE dan RMSE untuk model ARIMA dan LSTAR. Berdasarkan hasil tersebut diketahui bahwa model LSTAR memiliki nilai MSE dan RMSE yang lebih kecil dibandingkan dengan ARIMA. Sehingga model LSTAR lebih sesuai digunakan untuk memodelkan data inflasi.

## V. DAFTAR PUSTAKA

- [1] W. W. S. Wei, *Time Series Analysis Univariate and Multivariate Methods*. New York: Pearson, 2006.
- [2] J. Li, "Bootstrap Prediction Intervals for SETAR models," *Int. J. Forecast.*, hal. 320–332, 2011.
- [3] S. Bekiros, "A robust Algorithm for Parameter Estimation in Smooth Transition Autoregressive Models," *Econ. Lett.*, hal. 36–38, 2009.
- [4] J. B. Lin, C. . Liang, dan M. . Yeh, "Examining Nonlinier Dynamics of Exchange rates and Forecasting Performance based on the Exchange rate parity of four Asian Economies," *Jpn. World Econ.*, hal. 79–85, 2011.
- [5] S. Rohani, F. Yusof, dan I. L. Kane, "Nonlinear Smooth Transition Autoregressive (STAR)-Type Modelling and Forecasting on

- Malaysia Airlines (MAS) Stock Returns,” *J. Teknol.*, vol. 11, hal. 137–145, 2015.
- [6] D. Rosadi, *Analisis Ekonometrika dan Runtun Waktu Terapan dengan R*. Yogyakarta: ANDI, 2011.
- [7] T. Terasvirta, C. . Lin, dan C. Granger, “Power of The Neural Network Linearity Test,” *J. Time Ser. Anal.*, hal. 209–220, 1993.
- [8] T. H. Lee, H. White, dan C. Granger, “Testing for Neglected Nonlinearity in Time Series Model,” *J. Econom.*, hal. 269–290, 1993.