

**PENERAPAN MODEL *LOGISTIC SMOOTH TRANSITION*
AUTOREGRESSIVE (LSTAR) UNTUK MERAMALKAN HARGA SAHAM**

(Skripsi)

Oleh

CHATERINA NATALIA GULTOM



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2021**

ABSTRACT

APPLICATION OF LOGISTIC SMOOTH TRANSITION AUTOREGRESSIVE (LSTAR) MODEL TO FORECAST STOCK PRICES

By

Chaterina Natalia Gultom

Models that commonly used for time series data is Autoregressive Integrated Moving Average (ARIMA) model. However, the ARIMA time series model is linear so it's not good enough to be applied to modelling that has a tendency to nonlinear behavior such as the case of stock price data which tends to fluctuate or has a tendency to form nonlinear data patterns. One of the time series models used in the case of data that has a nonlinear tendency is Logistic Smooth Transition Autoregressive (LSTAR). The aim of this study is to predict return data on closing stock prices of PT Indofood Sukses Makmur Tbk using the LSTAR model. The result of this research showed that the best model for forecasting the data is LSTAR(1,1) that is with equation as following:

$$X_t = -0.4304X_{t-1} \left(1 - \frac{1}{1 + e^{-100(X_{t-1} + 0.0608)}} \right) + 0.3831X_{t-1} \left(\frac{1}{1 + e^{100(X_{t-1} + 0.0608)}} \right) + \alpha_t$$

Keywords: *forecast, nonlinear, logistic smooth transition autoregressive*

ABSTRAK

PENERAPAN MODEL LOGISTIC SMOOTH TRANSITION AUTOREGRESSIVE (LSTAR) UNTUK MERAMALKAN HARGA SAHAM

Oleh

Chaterina Natalia Gultom

Model yang umum digunakan untuk data deret waktu adalah model *Autoregressive Integrated Moving Average* (ARIMA). Namun ARIMA model deret waktu yang linier sehingga belum cukup baik untuk diterapkan pada pemodelan yang memiliki kecenderungan perilaku nonlinier seperti kasus data harga saham yang cenderung fluktuatif atau memiliki kecenderungan membentuk pola data nonlinier. Salah satu model deret waktu yang digunakan pada kasus data yang memiliki kecenderungan nonlinier adalah dengan *Logistic Smooth Transition Autoregressive* (LSTAR). Tujuan dari penelitian ini adalah untuk meramalkan data *return* penutupan harga saham PT Indofood Sukses Makmur Tbk dengan menggunakan model LSTAR. Hasil dari penelitian ini didapatkan model terbaik untuk peramalan ragamnya adalah LSTAR (1,1), yaitu dengan persamaan sebagai berikut:

$$X_t = -0.4304X_{t-1} \left(1 - \frac{1}{1 + e^{-100(X_{t-1} + 0.0608)}} \right) + 0.3831X_{t-1} \left(\frac{1}{1 + e^{100(X_{t-1} + 0.0608)}} \right) + \alpha_t$$

Kata kunci: peramalan, nonlinier, *logistic smooth transition autoregressive*

**PENERAPAN MODEL *LOGISTIC SMOOTH TRANSITION*
AUTOREGRESSIVE (LSTAR) UNTUK MERAMALKAN HARGA SAHAM**

Oleh

CHATERINA NATALIA GULTOM

Skripsi

Sebagai Salah Satu Syarat untuk Mencapai Gelar
SARJANA MATEMATIKA

Pada

**Jurusan Matematika
Fakultas Matematika dan Ilmu Pengetahuan Alam**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALA,
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2021**

Judul Skripsi : **PENERAPAN MODEL *LOGISTIC SMOOTH TRANSITION AUTOREGRESSIVE (LSTAR)* UNTUK MERAMALKAN HARGA SAHAM**

Nama Mahasiswa : **Chaterina Natalia Gultom**

Nomor Pokok Mahasiswa : **1717031030**

Jurusan : **Matematika**

Fakultas : **Matematika dan Ilmu Pengetahuan Alam**



1. **Komisi Pembimbing**


Ir. Netti Herawati, M.Sc., Ph.D.
NIP. 196501251990032001


Dra. Dorrah Aziz, M.Si.
NIP. 196101281988112001

2. **Ketua Jurusan Matematika**

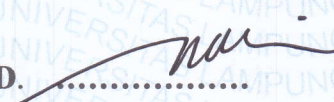

Dr. Aang Nuryaman, S.Si., M.Si.
NIP. 197403162005011001

MENGESAHKAN

1. Tim Penguji:

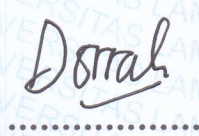
Ketua

: Ir. Netti Herawati, M.Sc., Ph.D.



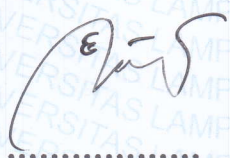
Sekretaris

: Dra. Dorrah Aziz, M.Si.



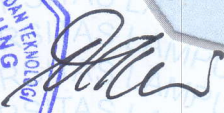
Penguji
Bukan Pembimbing

: Drs. Eri Setiawan, M.Si.



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam

Dr. Eng. Suropto Dwi Yuwono, M.T.
NIP. 1974075 200003 1 001



Tanggal Lulus Ujian Skripsi : 02 September 2021

PERNYATAAN SKRIPSI MAHASISWA

Yang bertanda tangan di bawah ini :

Nama : **Chaterina Natalia Gultom**
Nomor Pokok Mahasiswa : **1717031030**
Jurusan : **Matematika**
Judul Skripsi : **PENERAPAN MODEL *LOGISTIC SMOOTH TRANSITION AUTOREGRESSIVE (LSTAR)* UNTUK MERAMALKAN HARGA SAHAM**

Dengan ini menyatakan bahwa skripsi ini adalah hasil pekerjaan saya sendiri, bukan hasil orang lain, dan semua tulisan yang tertuang dalam skripsi ini telah mengikuti kaidah penulisan karya ilmiah Universitas Lampung. Apabila kemudian hari terbukti bahwa skripsi ini merupakan hasil salinan atau dibuat oleh orang lain, maka saya bersedia menerima sanksi sesuai dengan ketentuan akademik yang berlaku.

Bandar Lampung, 02 September 2021
Penulis,



Chaterina Natalia Gultom

RIWAYAT HIDUP

Penulis bernama lengkap Chaterina Natalia Gultom, anak terakhir dari dua bersaudara yang dilahirkan di Bekasi pada tanggal 23 Desember 1999 oleh pasangan Bapak Parlindungan Gultom dan Ibu Rapmaida Simanjuntak.

Penulis menempuh pendidikan di TK Abdi Negara yang diselesaikan pada tahun 2005, kemudian melanjutkan sekolah di SD Negeri 04 Jatimulya yang diselesaikan pada tahun 2011, kemudian melanjutkan sekolah di SMP Negeri 16 Bekasi yang diselesaikan pada tahun 2014, dan kemudian melanjutkan sekolah di SMA Swasta Yadika 08 Jatimulya yang diselesaikan pada tahun 2017.

Pada tahun 2017 penulis diterima sebagai mahasiswa S1 Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung melalui jalur Seleksi Nasional Masuk Perguruan Tinggi Negeri (SNMPTN). Selama menjadi mahasiswa penulis pernah bergabung menjadi Staf Media dan Informasi (MEDINFO) BEM FMIPA Unila 2018. Pada bulan Januari sampai dengan Februari 2020, penulis melaksanakan program Kuliah Kerja Nyata (KKN) di Desa Muara Dua, Kecamatan Ulu Belu, Kabupaten Tanggamus. Pada bulan Juli sampai dengan Agustus 2020, penulis melaksanakan Kerja Praktik (KP) di Badan Penyelenggara Jaminan Kesehatan (BPJS) Jakarta Utara.

KATA INSPIRASI

Kuatkan dan teguhkanlah hatimu, janganlah takut dan jangan gemetar karena mereka, sebab Tuhan, Allahmu, Dialah yang berjalan menyertai engkau; Ia tidak akan membiarkan engkau dan tidak akan meninggalkan engkau.

(Ulangan 31:6)

Jangan takut kalau hidupmu akan berakhir, takutlah
kalau hidupmu tak pernah dimulai.

(Grace Hansen)

Live life to the fullest, and focus on the positive.

(Matt Cameron)

Berjanjilah padaku, kamu akan selalu ingat. Kamu lebih berani daripada yang kamu yakini, dan lebih kuat dari yang kamu kira, dan lebih pintar dari yang kamu pikirkan.

(A. Milne)

PERSEMBAHAN

Terpujilah Allah, sumber segala hikmat, yang telah menjadi dasar dari segala pengharapan dan senantiasa mengaruniakan damai sejahtera yang melampaui segala akal sehingga penulis dapat menyelesaikan skripsi ini.

Kupersembahkan karya kecilku ini kepada Papa dan Mama, orang tua terhebat didunia versiku. Terima kasih sudah berkorban banyak hal sehingga aku bisa memiliki kesempatan untuk bahagia bersama kalian. Hanya karena doa, dukungan, didikan, dan memberi motivasi kalian yang membawaku bertahan sampai sejauh ini.

Juga kepada kakakku, terima kasih telah menjadi penyemangat dan telah mengajarkan adikmu banyak hal tentang kehidupan untuk mencapai semua mimpiku.

Serta teman-temanku yang menemaniku serta memberikan begitu banyak memori dalam perkuliahan. Hal yang akan kusimpan selalu selama hidup.

SANWACANA

Puji syukur kepada Tuhan Yesus Kristus yang telah memberikan karuni, berkat serta penyertaan-Nya, sehingga penulis dapat menyelesaikan skripsi yang berjudul **“Penerapan Model *Logistic Smooth Transition Autoregressive (LSTAR)* Untuk Meramalkan Harga Saham”**. Penulis menyadari bahwa dalam menyelesaikan skripsi ini, banyak pihak yang telah memberikan bimbingan, saran, dan juga semangat. Dalam kesempatan ini, penulis mengucapkan terima kasih kepada:

1. Ibu Ir. Netti Herawati, M.Sc., Ph.D., selaku dosen pembimbing utama dan dosen pembimbing akademik atas kesediaan waktu, pemikiran dalam memberikan evaluasi, arahan, dan saran yang membangun dalam proses penyusunan skripsi ini.
2. Ibu Dra. Dorrah Azis, M.Si., selaku dosen pembimbing kedua atas kesediaan waktu, saran, dan arahan selama proses penyusunan skripsi ini.
3. Bapak Drs. Eri Setiawan, M.Si., selaku dosen penguji atas kesediaan waktu, saran, dan masukan membangun selama proses penyusunan skripsi ini.
4. Bapak Dr. Aang Nuryaman, S.Si., M.Si., selaku Ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

5. Bapak Dr. Eng. Suropto Dwi Yuwono, M.T., selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
6. Seluruh Dosen dan Staf Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
7. Papa dan mama, serta kakak yang selalu mendoakan, dukungan, kasih sayang, dan pengorbanan kepada penulis.
8. Yulica, Stefani, Nabilla, Dini, Umroh, Rafadhia, Beta, Iqbal yang selalu menemani, membantu, memberi keceriaan, memberikan kenangan indah dan tak terlupakan pada masa perkuliahan serta memberi semangat.
9. Jilan, Ndaru, Kristin, Amel, Bintang, Ka Desi, Ka Linda, Karin, Firman, Apri, Eta, Ega, Horas, Poltak, Felicia, Melak, Ka Dey, Chaca, Kang Mahen, Bang Zi atas canda dan tawanya selama perkuliahan. Manusia-manusia terdekat yang senantiasa memberikan semangat, bantuan, dan doa. Terima kasih tak terhingga untuk segalanya
10. Teman-teman mahasiswa jurusan matematika angkatan 2017 serta seluruh pihak yang tidak dapat penulis sebutkan satu persatu.

Penulis berharap semoga Tuhan Yang Maha Esa membalas kebaikan kalian semua. Semoga skripsi ini dapat bermanfaat bagi semua pihak.

Bandar Lampung, 02 September 2021
Penulis,

Chaterina Natalia Gultom

DAFTAR ISI

Halaman

DAFTAR TABEL	xv
DAFTAR GAMBAR.....	xvi
I. PENDAHULUAN	1
1.1 Latar Belakang dan Masalah.....	1
1.2 Tujuan Penelitian	3
1.3 Manfaat Penelitian	3
II. TINJAUAN PUSTAKA.....	4
2.1 Data Deret Waktu	4
2.2 Stasioneritas	4
2.3 Transformasi <i>Box-Cox</i>	5
2.4 Uji Augmented Dickey Fuller (ADF)	5
2.5 Pembedaan (<i>Differencing</i>)	6
2.6 Fungsi Autokorelasi dan Fungsi Autokorelasi Parsial.....	7
2.6.1 Fungsi Autokorelasi (ACF)	7
2.6.2 Fungsi Autokorelasi Parsial (PACF)	8
2.7 Model Deret Waktu.....	10
2.7.1 Model <i>Autoregressive</i> (AR).....	11
2.7.2 Model <i>Moving Average</i> (MA)	11
2.7.3 Model <i>Autoregressive Moving Average</i> (ARMA).....	12
2.8 Identifikasi Model.....	12
2.9 Estimasi Parameter Model	13
2.9.1 Uji Signifikansi Parameter.....	14
2.10 <i>Akaike's Information Criterion</i> (AIC)	15
2.11 Pemeriksaan Diagnostik.....	16
2.11.1 Uji <i>White Noise</i>	16
2.11.2 Uji Normalitas.....	17
2.11.3 Uji Heteroskedastisitas	18
2.12 Uji Nonlinieritas.....	19
2.13 Model <i>Smooth Transition Autoregressive</i> (STAR).....	20
2.14 Model <i>Logistic Smooth Transition Autoregressive</i> (LSTAR)	21

2.15	Estimasi Parameter Model LSTAR	21
2.16	Saham.....	22
2.16.1	<i>Return</i> Saham.....	23
2.17	Peramalan.....	23
III. METODOLOGI PENELITIAN.....		24
3.1	Waktu dan Tempat.....	24
3.2	Data Penelitian	24
3.3	Metode Penelitian	24
IV. HASIL DAN PEMBAHASAN.....		26
4.1	Deskriptif Data Deret Waktu	26
4.2	Identifikasi Plot Data Pengamatan.....	27
4.3	Pemeriksaan Kestasioneran Data.....	28
4.4	Identifikasi Model <i>Box-Jenkins</i>	29
4.5	Estimasi Parameter Model <i>Box-Jenkins</i>	31
4.6	Pemeriksaan Diagnostik.....	32
4.6.1	Uji <i>White Noise</i>	32
4.6.2	Uji Normalitas.....	33
4.6.3	Uji Heteroskedastisitas	34
4.7	Uji Nonlinearitas	35
4.8	Estimasi Parameter Model LSTAR	36
4.9	Peramalan.....	38
V. KESIMPULAN		40
DAFTAR PUSTAKA		41
LAMPIRAN		

DAFTAR TABEL

Tabel	Halaman
1. Pola ACF dan PACF	12
2. Statistik Deskriptif Data <i>Return</i>	26
3. Uji Stasioneritas <i>Box-Cox</i>	28
4. Uji Stasioneritas <i>Augmented Dickey Fuller</i>	28
5. Estimasi Parameter Model <i>Box-Jenkins</i>	31
6. Hasil Uji <i>Ljung-Box</i>	33
7. Hasil Uji Kolmogorov-Smirnov	34
8. Hasil Uji ARCH <i>Lagrange Multiplier</i>	34
9. Hasil Uji Nonlinearitas Terasvirta	35
10. Estimasi Parameter Model LSTAR	36
11. Peramalan Data <i>Return</i> Saham	38

DAFTAR GAMBAR

Gambar	Halaman
1. Plot Data <i>Return</i> Saham.....	27
2. Plot ACF Data <i>Return</i> Penutupan Saham	30
3. Plot PACF Data <i>Return</i> Penutupan Saham	30
4. Peramalan Ragam <i>Return</i> Saham.....	38

I. PENDAHULUAN

1.1 Latar Belakang dan Masalah

Deret 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 (Wei, 2006). Dalam analisis *time series* nilai masa kini dipengaruhi oleh nilai sejenis dimasa lalu dan dapat dilakukan untuk membantu dalam menyusun perencanaan ke depan. Proses yang terjadi tersebut dinamakan proses *autoregressive* (AR). Model AR dapat disusun dengan metode *Box-Jenkins* atau sering disebut dengan ARIMA (*Autoregressive Integrated Moving Average*). Namun ARIMA merupakan model *time series* stasioner yang linier sehingga tidak bijaksana untuk diterapkan pada pemodelan yang memiliki kecenderungan perilaku nonlinier seperti kasus data saham yang cenderung fluktuatif.

Saham merupakan salah satu bentuk investasi yang paling populer dan salah satu jenis surat berharga yang diperdagangkan di bursa efek. Saham diartikan sebagai bukti penyertaan modal di suatu perseroan, atau merupakan bukti kepemilikan atas suatu perusahaan (Mustafa, 2016). Harga saham yang berbentuk data *time series* telah banyak diteliti dan diramalkan mengingat investor (pelaku saham)

membutuhkan sebuah parameter yang valid sebagai pertimbangan untuk melakukan investasi dengan resiko seminimal mungkin dan keuntungan berupa *return* atau pengembalian yang maksimal dari saham yang dibeli. Pemodelan harga saham yang berfluktuasi atau memiliki kecenderungan nonlinier maka membutuhkan sebuah pendekatan dengan metode khusus.

Sebuah alternatif pemodelan nonlinier yaitu model *Smooth Transition Autoregressive* (STAR) dengan menggunakan uji nonlinearity berupa kelompok uji *Lagrange Multiplier* (LM) yang disebut uji terasvirta (Granger & Terasvirta, 1993). Uji ini dilakukan untuk mengatasi korelasi yang ditunjukkan dalam plot fungsi autokorelasi (ACF) pada model konvensional AR dan membuat model menjadi linier.

Menurut Terasvirta (1994), terdapat beberapa tipe model STAR berdasarkan fungsi transisinya antara lain *Logistic Smooth Transition Autoregressive* (LSTAR) dan *Exponential Smooth Transition Autoregressive* (ESTAR). Model *Logistic Smooth Transition Autoregressive* (LSTAR) adalah model *time series* yang dapat diterapkan pada data yang mengikuti model nonlinier, dan sangat populer dalam terapan bidang ekonomi dan keuangan. Model LSTAR telah diterapkan dalam pemodelan dinamik dari berbagai macam runtun waktu finansial dan ekonomi.

Berdasarkan uraian tersebut, maka pada penelitian ini akan membahas model *Logistic Smooth Transition Autoregressive* (LSTAR) pada data *return* penutupan harga saham PT Indofood Sukses Makmur Tbk.

1.2 Tujuan Penelitian

Penelitian ini memiliki tujuan sebagai berikut:

1. Mempelajari model *Logistic Smooth Transition Autoregressive* (LSTAR).
2. Menentukan model *Logistic Smooth Transition Autoregressive* (LSTAR) yang sesuai pada *return* penutupan harga saham PT Indofood Sukses Makmur Tbk.

1.3 Manfaat Penelitian

Penelitian ini memiliki manfaat sebagai berikut:

1. Dapat mengaplikasikan model *Logistic Smooth Transition Autoregressive* (LSTAR) pada data *return* penutupan harga saham PT Indofood Sukses Makmur Tbk.
2. Melakukan peramalan dengan model *Logistic Smooth Transition Autoregressive* (LSTAR) pada data *return* penutupan harga saham PT Indofood Sukses Makmur Tbk. pada periode-periode selanjutnya.

II. TINJAUAN PUSTAKA

2.1 Data Deret Waktu

Data deret waktu (*time series*) adalah serangkaian pengamatan terhadap suatu variabel yang diambil dari waktu ke waktu dan dicatat secara berurutan menurut urutan waktu kejadian dengan interval waktu yang tetap baik seperti dalam bentuk data harian, mingguan, bulanan, triwulanan, dan tahunan (Wei, 2006). Studi yang berkaitan dengan *time series* disebut analisis *time series*. Analisis *time series* adalah analisis yang menerangkan dan mengukur berbagai perubahan atau perkembangan data selama satu periode (Hasan, 2002).

2.2 Stasioneritas

Menurut Wei (2006), stasioner berarti bahwa tidak terdapat perubahan drastis pada data, yaitu rata-rata dan ragamnya konstan dari waktu ke waktu.

Stasioneritas dibagi menjadi 2 yaitu:

1. Stasioner dalam rata-rata

Stasioner dalam rata-rata adalah fluktuasi data berada di sekitar suatu nilai rata-rata yang konstan, tidak tergantung pada waktu dan variansi dari

fluktuasi tersebut. Dari bentuk plot data seringkali dapat diketahui bahwa data tersebut stasioner atau tidak stasioner.

2. Stasioner dalam variansi

Sebuah data *time series* dikatakan stasioner dalam variansi apabila struktur data dari waktu ke waktu mempunyai fluktuasi data yang tetap atau konstan dan tidak berubah-ubah. Secara visual untuk melihat hal tersebut dapat dibantu dengan menggunakan plot *time series*, yaitu dengan melihat fluktuasi data dari waktu ke waktu.

2.3 Transformasi *Box-Cox*

Untuk menstabilkan ragam dalam suatu data digunakan transformasi *Box-Cox*. Transformasi log dan akar kuadrat merupakan anggota dari keluarga *power transformation* yang disebut *Box-Cox Transformation* yang di definisikan dengan

$$Z_t = \frac{z_t^\lambda - 1}{\lambda} \quad (2.1)$$

dengan:

Z_t = nilai data *time series* pada waktu ke- t

λ = parameter transformasi *Box-Cox*

2.4 Uji Augmented Dickey Fuller (ADF)

Menurut Gujarati & Porter (2009), kestasioneran data dapat juga diuji dengan uji *Augmented Dickey Fuller* (ADF). Adapun persamaan ADF sebagai berikut:

$$\Delta Y_t = \phi Y_{t-1} + \sum_{j=1}^{p-1} \alpha_j^* \Delta Y_{t-j} + \varepsilon_t \quad (2.2)$$

dengan:

ΔY_t = hasil *difference* data pada periode ke- t

ϕ = koefisien, $-\alpha(1)$

α_j^* = suatu konstanta, $-(\alpha_{j+1} + \dots + \alpha_p)$

ε_t = residual pada waktu ke- t

Uji statistik pada ADF berdasarkan pada *t-statistic* dengan koefisien ϕ . Dengan model hipotesis yang diuji sebagai berikut:

$H_0 : \phi = 0$ (data *time series* tidak stasioner)

$H_1 : \phi < 0$ (data *time series* stasioner)

Jika nilai *p-value* $< \alpha$ maka tolak H_0 yang berarti data *time series* yang diamati telah stasioner.

2.5 Pembedaan (*Differencing*)

Menurut Pankratz (1991), ketika data tidak mempunyai rata-rata yang konstan, dapat dilakukan dengan membuat data baru pada rata-rata konstan dengan cara *differencing* data, artinya dengan menghitung perubahan pada data secara berturut-turut. *Differencing* pertama atau $d = 1$ dirumuskan:

$$W_t = X_t - X_{t-1} \quad (2.3)$$

Jika *differencing* pertama $d = 1$ belum membuat deret data mempunyai rata-rata yang konstan, maka dilakukan *differencing* ke-2 atau $d = 2$ yang berarti akan

menghitung *differencing* kedua dari *differencing* pertama. Didefinisikan W_t^* sebagai *differencing* pertama dari t sehingga rumus untuk *differencing* kedua $d = 2$ sebagai berikut:

$$\begin{aligned} W_t &= W_t^* - W_{t-1}^* \\ &= (X_t - X_{t-1}) - (X_{t-1} - X_{t-2}) \end{aligned} \quad (2.4)$$

2.6 Fungsi Autokorelasi dan Fungsi Autokorelasi Parsial

Dalam metode *time series*, alat utama untuk mengidentifikasi model dari data yang akan diramalkan adalah dengan menggunakan fungsi autokorelasi atau *Autocorrelation Function* (ACF) dan fungsi autokorelasi parsial atau *Partial Autocorrelation Function* (PACF).

2.6.1 Fungsi Autokorelasi (ACF)

Fungsi autokorelasi atau *autocorrelation function* (ACF) adalah ketergantungan antara nilai-nilai suatu data *time series* yang sama pada periode waktu yang berlainan yang digunakan untuk menentukan koefisien korelasi pada *time series*. Dari proses stasioner suatu data *time series* (X_t), diperoleh $E(X_t) = \mu$ dan ragam $Var(X_t) = E(X_t - \mu)^2 = \sigma_t^2$ yang konstan dan kovarian $Cov(X_t, X_{t+k})$, yang fungsinya hanya pada perbedaan waktu $|t - (t + k)|$. Oleh karena itu, dapat ditulis kovarian antara X_t dan X_{t+k} yaitu

$$\gamma_k = Cov(X_{t+1}, X_{t+2}) = E[(X_t - \mu)(X_{t+k} - \mu)]$$

$$\gamma_0 = \sqrt{\text{Var}(X_t)\text{Var}(X_{t+k})} = \sqrt{E[(X_t - \mu)^2]}\sqrt{E[(X_{t+k} - \mu)^2]}$$

dan fungsi autokorelasi antara X_t dan X_{t+k} adalah:

$$\begin{aligned}\rho_k &= \frac{\text{Cov}(X_{t+1}, X_{t+2})}{\sqrt{\text{Var}(X_t)\text{Var}(X_{t+k})}} \\ &= \frac{E[(X_t - \mu)(X_{t+k} - \mu)]}{\sqrt{E[(X_t - \mu)^2]}\sqrt{E[(X_{t+k} - \mu)^2]}} = \frac{\gamma_k}{\gamma_0}\end{aligned}\quad (2.5)$$

dimana $\text{Var}(X_t) = \text{Var}(X_{t+k}) = \gamma_0$. Sebagai fungsi dari k , γ_k disebut fungsi autokovarian dan ρ_k disebut fungsi autokorelasi (ACF) (Wei, 2006).

2.6.2 Fungsi Autokorelasi Parsial (PACF)

Fungsi autokorelasi parsial atau *partial autocorrelation function* (PACF)

digunakan untuk mengukur tingkat keeratan antara X_t dan X_{t+k} apabila adanya pengaruh *time lag* 1, 2, 3, ..., dan seterusnya sampai $k - 1$ dianggap terpisah.

Fungsi autokorelasi parsial dapat dinotasikan dengan

$$\text{corr}(X_t, X_{t+1}, X_{t+2}, \dots, X_{t+k})$$

Misalkan X_t adalah proses yang stasioner dengan $E(X_t) = 0$, selanjutnya X_{t+k} dapat dinyatakan sebagai model linier:

$$X_{t+k} = \phi_{k1}X_{t+k-1} + \phi_{k2}X_{t+k-2} + \dots + \phi_{kk}X_t + \varepsilon_{t+k}\quad (2.6)$$

dengan:

$$\phi_{ki} = \text{parameter regresi ke-}i, i = 1, 2, \dots, k$$

$$\varepsilon_{t+k} = \text{nilai kesalahan yang tidak berkorelasi dengan } X_{t+k-j}; j = 1, 2, \dots, k$$

Untuk mendapatkan nilai PACF, langkah pertama yang dilakukan adalah mengalikan persamaan (2.6) dengan X_{t+k-j} pada kedua ruas sehingga diperoleh:

$$X_{t+k-j}X_{t+k} = \phi_{k1}X_{t+k-1}X_{t+k-j} + \phi_{k2}X_{t+k-2}X_{t+k-j} + \cdots + \phi_{kk}X_tX_{t+k-j} \\ + \varepsilon_{t+k}X_{t+k-j}$$

Selanjutnya nilai harapan (*expected value*) adalah

$$E(X_{t+k-j}X_{t+k}) = E(\phi_{k1}X_{t+k-1}X_{t+k-j} + \phi_{k2}X_{t+k-2}X_{t+k-j} + \cdots + \phi_{kk}X_tX_{t+k-j} \\ + \varepsilon_{t+k}X_{t+k-j})$$

Dimisalkan nilai $E(X_{t+k-j}X_{t+k}) = \gamma_j$, $j = 0, 1, \dots, k$ dan karena

$E(\varepsilon_{t+k}X_{t+k-j}) = 0$, maka diperoleh

$$\gamma_j = \phi_{k1}\gamma_{j-1} + \phi_{k2}\gamma_{j-2} + \cdots + \phi_{kk}\gamma_{j-k} \quad (2.7)$$

Persamaan (2.7) dibagi dengan γ_0

$$\frac{\gamma_j}{\gamma_0} = \phi_{k1}\frac{\gamma_{j-1}}{\gamma_0} + \phi_{k2}\frac{\gamma_{j-2}}{\gamma_0} + \cdots + \phi_{kk}\frac{\gamma_{j-k}}{\gamma_0}$$

diperoleh

$$\rho_j = \phi_{k1}\rho_{j-1} + \phi_{k2}\rho_{j-2} + \cdots + \phi_{kk}\rho_{j-k}$$

untuk $j = 1, 2, \dots, k$, diperoleh sistem persamaan sebagai berikut:

$$\begin{aligned} \rho_1 &= \phi_{k1}\rho_0 + \phi_{k2}\rho_1 + \cdots + \phi_{kk}\rho_{k-1} \\ \rho_2 &= \phi_{k1}\rho_1 + \phi_{k2}\rho_0 + \cdots + \phi_{kk}\rho_{k-2} \\ &\vdots \\ \rho_k &= \phi_{k1}\rho_{k-1} + \phi_{k2}\rho_{k-2} + \cdots + \phi_{kk}\rho_0 \end{aligned} \quad (2.8)$$

Bentuk matriks dari sistem persamaan (2.8) yaitu:

$$\begin{bmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-2} \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_{k-3} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & \rho_1 \end{bmatrix} \begin{bmatrix} \phi_{11} \\ \phi_{22} \\ \vdots \\ \phi_{kk} \end{bmatrix} = \begin{bmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_k \end{bmatrix}$$

dengan aturan cramer diperoleh

$$P_k = \begin{bmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_1 \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_2 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & \rho_k \end{bmatrix}$$

Nilai autokorelasi parsial *lag k* hasilnya adalah

$$\phi_{kk} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_1 \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_2 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & \rho_k \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-2} \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_{k-3} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & \rho_1 \end{vmatrix}}$$

Himpunan dari $\phi_{kk}\{\phi_{kk}; k = 1, 2, \dots\}$, disebut sebagai PACF. Fungsi ϕ_{kk} menjadi notasi standar untuk autokorelasi parsial antara observasi X_t dan X_{t+k} dalam analisis *time series*.

2.7 Model Deret Waktu

Menurut Box & Jenkins (1976), adapun macam-macam model deret waktu diantaranya model *Autoregressive* (AR), *Moving Average* (MA), dan *Autoregressive Moving Average* (ARMA).

2.7.1 Model *Autoregressive* (AR)

Model *autoregressive* merupakan bentuk regresi deret X_t terhadap amatan waktu sebelumnya X_{t+k} dari dirinya sendiri, untuk $k = 1, 2, \dots, p$. Model *autoregressive* orde p dinotasikan sebagai $AR(p)$, memiliki persamaan sebagai berikut:

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + \varepsilon_t \quad (2.9)$$

dengan:

- X_t = nilai variabel dependen pada waktu ke- t
- ϕ_p = parameter model *autoregressive*, $i = 1, 2, 3, \dots, p$
- ε_t = nilai galat pada waktu ke- t
- p = order AR

2.7.2 Model *Moving Average* (MA)

Model ini regresinya melibatkan selisih nilai variabel sekarang dengan nilai dari variabel sebelumnya. Model *moving average* dengan order q dinotasikan sebagai $MA(q)$, persamaannya adalah:

$$X_t = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (2.10)$$

dengan:

- X_t = nilai variabel pada waktu ke- t
- ε_t = nilai galat pada waktu ke- t
- θ_q = parameter model *moving average* (MA), $i = 1, 2, 3, \dots, q$
- q = order MA

2.7.3 Model Autoregressive Moving Average (ARMA)

ARMA(p, q) merupakan suatu model yang terdiri dari penggabungan antara model AR dan MA. Dengan kata lain nilai X_t tidak hanya dipengaruhi oleh nilai peubah tersebut, tetapi juga oleh residual peubah tersebut pada periode sebelumnya. Bentuk model ARMA(p, q) adalah sebagai berikut:

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (2.11)$$

2.8 Identifikasi Model

Langkah pertama yang perlu dilakukan dalam membangun model adalah mendeteksi masalah stasioner data yang digunakan. Jika data tidak stasioner pada level, diperlukan proses differensiasi untuk mendapatkan data yang stasioner (baik pada level maupun pada differens). Langkah selanjutnya adalah mengidentifikasi model pada grafik ACF dan PACF. Pemilihan modelnya dengan ACF maupun PACF secara grafis mengikuti ketentuan sebagai berikut:

Tabel 1. Pola ACF dan PACF

Model	Pola ACF	Pola PACF
AR (p)	Menurun secara bertahap atau bergelombang	Menurun drastis pada <i>lag</i> tertentu
MA (q)	Menurun drastis pada <i>lag</i> tertentu	Menurun secara bertahap atau bergelombang
ARMA (p, q)	Menurun secara bertahap atau bergelombang	Menurun secara bertahap atau bergelombang

2.9 Estimasi Parameter Model

Tahap yang dilakukan setelah mengidentifikasi model adalah mengestimasi parameter model AR dan MA. Terdapat beberapa metode estimasi parameter yang digunakan untuk pemodelan *Box-Jenkins*, diantaranya adalah metode *Least Square*. Metode *Least Square* dilakukan dengan cara meminumkan jumlah kuadrat *error* (Cryer & Chan, 2008). Misalkan untuk model AR(1), maka persamaan metode *least square estimation* sebagai berikut

$$\begin{aligned} S(\phi, \mu) &= \sum_{t=p+1}^n \varepsilon_t^2 \\ &= \sum_{t=p+1}^n [(X_t - \mu) - \phi(X_{t-p} - \mu)]^2 \end{aligned} \quad (2.12)$$

Berdasarkan metode *Least Square*, taksiran ϕ dan μ dilakukan dengan meminimumkan fungsi $S(\phi, \mu)$. Oleh karena itu, perlu dilakukan penurunan terhadap ϕ dan μ kemudian masing disamakan dengan nol. Berikut ini merupakan operasi turunan terhadap μ adalah sebagi berikut

$$\frac{\partial}{\partial \mu} = 2 \sum_{t=p+1}^n [(X_t - \mu) - \phi(X_{t-p} - \mu)] [-1 + \phi] = 0$$

Sehingga taksiran parameter μ untuk model AR(1) sebagai berikut

$$\hat{\mu} = \frac{\sum_{t=p+1}^n X_t - \phi \sum_{t=p+1}^n X_{t-p}}{(n-p)(1-\phi)} \quad (2.13)$$

Sedangkan untuk n besar dapat ditulis sebagai berikut

$$\frac{1}{n-p} \sum_{t=p+1}^n X_t \approx \frac{1}{n-p} \sum_{t=p+1}^n X_{t-p} \approx \bar{X}$$

maka penaksir untuk n besar, persamaan (2.12) menjadi berikut

$$\hat{\mu} = \frac{\bar{X} - X}{(1-\phi)} = \bar{X} \quad (2.14)$$

Kemudian untuk parameter ϕ dengan cara yang sama didapatkan operasi turunan sebagai berikut

$$\frac{\partial}{\partial \phi_l} = \sum_{t=p+1}^n [(X_t - \mu) - \phi(X_{t-p} - \mu)](X_{t-p} + \bar{X}) = 0$$

Sehingga taksiran parameter ϕ untuk model AR(1) sebagai berikut

$$\phi = \frac{\sum_{t=p+1}^n (X_t - \bar{X})(X_{t-1} - \bar{X})}{\sum_{t=p+1}^n (X_{t-1} - \bar{X})^2} \quad (2.15)$$

2.9.1 Uji Signifikansi Parameter

Menurut Rosadi (2011), uji ini digunakan untuk mengetahui apakah parameter AR(p) signifikan atau tidak. Jika parameter tersebut signifikan mempengaruhi model data, maka model layak untuk digunakan. Berikut ini adalah uji signifikan parameter:

Hipotesis

$H_0 : \phi_1 = 0$ (parameter tidak signifikan)

$H_1 : \phi_1 \neq 0$ (parameter signifikan)

Statistik uji

$$t_{hitung} = \frac{\hat{\phi}}{SE(\hat{\phi})} \quad (2.16)$$

Dimana $\hat{\phi} = \frac{\sum_{t=1}^{n-k} (X_t - \bar{X})(X_{t+k} - \bar{X})}{\sum_{t=1}^n (X_t - \bar{X})^2}$, $SE(\hat{\phi}) = \sqrt{\frac{1+2\sum_{i=1}^{k-1} \hat{\phi}^2}{n}}$

Kriteria keputusan yaitu jika $|t_{hitung}| >$ nilai t-tabel $t_{(\frac{\alpha}{2}, n-p)}$ atau nilai $p - value < \alpha$ maka tolak H_0 yang berarti parameter telah signifikan.

2.10 Akaike's Information Criterion (AIC)

Berdasarkan hasil pemodelan beberapa model yang telah dibentuk, terdapat banyak kemungkinan model untuk menggambarkan proses yang terjadi dalam data. Oleh sebab itu, selanjutnya dilakukan pemilihan model terbaik dari kemungkinan-kemungkinan model yang telah terbentuk. Model terbaik yang digunakan adalah *Akaike's Information Criterion (AIC)* yang diperkenalkan oleh Akaike dengan mempertimbangkan banyaknya parameter dalam model. Rumus untuk mendapatkan AIC:

$$AIC = n \ln |\hat{\Sigma}_p| + 2pr^2 \quad (2.17)$$

dengan:

n = jumlah pengamatan data pemodelan

r = dimensi dari vektor proses X_t

p = lag yang digunakan

$|\hat{\Sigma}_p|$ = determinan dari matriks kovarian contoh yang bersifat *white noise* pada pemodelan $AR(p)$

Nilai AIC digunakan untuk penyeleksian model *autoregressive* yang *fitt*, sehingga model yang memiliki nilai AIC terkecil merupakan model terbaik untuk memprediksi nilai y secara simultan (Akaike, 1973).

2.11 Pemeriksaan Diagnostik

Setelah mendapatkan model yang signifikan, selanjutnya ialah memeriksa asumsi dari model apakah telah terpenuhi. Asumsi dasarnya ialah residual *white noise*, normalitas dan heteroskedastisitas.

2.11.1 Uji *White Noise*

Suatu proses dikatakan *white noise* jika data terdiri dari variabel acak yang tidak berkorelasi. Proses *white noise* dapat dideteksi menggunakan uji autokorelasi residual pada analisis *error*-nya. Uji korelasi residual digunakan untuk mendeteksi ada tidaknya korelasi residual antar *lag*. Menurut Wei (2006), statistika uji yang digunakan dalam hal ini adalah uji *Ljung Box*. Hipotesis yang digunakan dalam pengujian ini adalah:

$H_0 : \rho_k = 0$ (tidak ada autokorelasi antar residual)

$H_1 : \rho_k \neq 0$ (terdapat autokorelasi antar residual)

Taraf signifikan atau α yang digunakan sebesar 5%.

Statistik uji yang digunakan

$$Q_{LB} = n(n + 2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{n-k} \quad (2.18)$$

dengan:

n = banyaknya data

k = selisih *lag*

K = banyaknya *lag* yang diuji

$\hat{\rho}_k$ = koefisien autokorelasi pada periode ke- k

Kriteria keputusan yaitu jika $Q_{LB} > \chi^2_{(\alpha, (K-p-q))}$ atau $p - value < \alpha$ maka tolak H_0 yang berarti ada autokorelasi antar residual. Jika $Q_{LB} \leq \chi^2_{(\alpha, (K-p-q))}$ atau $p - value > \alpha$ maka tidak tolak H_0 yang berarti tidak ada autokorelasi antar residual.

2.11.2 Uji Normalitas

Uji normalitas residual digunakan untuk melihat apakah residual data mempunyai distribusi normal atau tidak. Menurut Daniel (1989), statistika uji yang digunakan dalam uji normalitas residual adalah Kolmogorov-Smirnov. Hipotesis yang digunakan dalam pengujian ini adalah:

H_0 :Residual berdistribusi normal

H_1 : Residual tidak berdistribusi normal

Taraf signifikan atau α yang digunakan sebesar 5%.

Statistik uji

$$D = KS = \max |F_0(X) - S_n(X)| \quad (2.19)$$

dengan:

$F_0(X)$ = Fungsi distribusi kumulatif pembanding

$S_n(X)$ = Fungsi distribusi kumulatif observasi

Kriteria keputusan yaitu jika $D_{hitung} > D_{(1-\alpha)}$ atau $p - value < \alpha$ maka tolak H_0 yang berarti residual tidak berdistribusi normal. Jika $D_{hitung} < D_{(1-\alpha)}$ atau $p - value > \alpha$ maka tidak tolak H_0 yang berarti residual berdistribusi normal.

2.11.3 Uji Heteroskedastisitas

Uji heteroskedastisitas merupakan suatu keadaan dimana sebuah data memiliki tingkat keragaman tidak konstan atau tingkat *error* dari keragaman tidak homogen, terjadi apabila varian gangguan tidak mempunyai varian yang sama untuk setiap semua observasi. Menurut William (1993), dapat diuji menggunakan uji ARCH *Lagrange Multiplier* (LM). Hipotesis yang digunakan dalam pengujian adalah

H_0 : Tidak terjadi heteroskedastisitas (Homoskedastisitas)

H_1 : Terjadi heteroskedastisitas

Taraf signifikan atau α yang digunakan sebesar 5%.

Statistik uji yang digunakan

$$\chi^2 = nR^2 \quad (2.20)$$

Dimana $R^2 = \frac{\sum_{i=1}^T (\hat{X}_i - \bar{X})^2}{\sum_{i=1}^T (X_i - \bar{X})^2}$

dengan:

n = banyaknya pengamatan

R^2 = koefisien determinasi

χ^2 = distribusi *chi-square*

Kriteria keputusan yaitu jika $\chi^2_{statistic} > \chi^2_{(\alpha,r)}$ atau $p - value < \alpha$ maka tolak

H_0 yang berarti terjadi heteroskedastisitas. Jika $\chi^2_{statistic} < \chi^2_{(\alpha,r)}$ atau

$p - value > \alpha$ maka tidak tolak H_0 yang berarti tidak terjadi heteroskedastisitas.

2.12 Uji Nonlinieritas

Sebelum menerapkan model nonlinier terlebih dahulu lakukan uji nonlinieritas pada data *time series*, hal ini dilakukan untuk memastikan bahwa metode yang digunakan sudah sesuai dengan datanya. Uji Terasvirta merupakan salah satu uji untuk mendeteksi hubungan nonlinier antar variabel yang dikembangkan model *neural network* dan termasuk dalam kelompok uji tipe Lagrange Multiplier dengan ekspansi Taylor (Terasvirta, Lin, & Granger, 1993). Hipotesis yang digunakan dalam pengujian adalah

$H_0 : f(x)$ adalah fungsi linier dalam x (model linier)

$H_1 : f(x)$ adalah fungsi nonlinier dalam x (model nonlinier)

Statistik uji yang digunakan adalah:

$$F = \frac{(SSR_0 - SSR)/m}{SSR/(N-p-1-m)} \quad (2.21)$$

dengan:

SSR_0 = jumlah kuadrat residual dari regresi $f(x)$ dengan x dimana menghasilkan residual ε_t

SSR = jumlah kuadrat residual dari regresi ε_t dengan x dan m

p = jumlah variabel prediktor awal

m = jumlah variabel prediktor kuadratik dan kubik

N = jumlah data

Kriteria keputusan yaitu jika $F_{hitung} > F_{(m, (N-p-1-m))}$ atau $p - value < \alpha$ maka tolak H_0 yang berarti $f(x)$ merupakan fungsi nonlinier dalam x .

2.13 Model *Smooth Transition Autoregressive* (STAR)

Menurut Cahyani (2010), model *Smooth Transition Autoregressive* (STAR) adalah salah satu model runtun waktu nonlinier yang merupakan perluasan dari model AR dimana dalam modelnya terdapat dua rezim dan nilai parameternya dimuluskan dengan pemulusan transisi.

Menurut Terasvirta (1994), model STAR (p, d) untuk runtun waktu univariat yang diobservasi pada saat $t = 1, \dots, T - 1, T$ sebagai berikut:

$$X_t = \phi_1' Y_t (1 - G(s_t; \gamma; c)) + \phi_2' Y_t G(s_t; \gamma; c) + \varepsilon_t \quad (2.22)$$

atau

$$X_t = (\phi_{1,0} + \phi_{1,1}X_{t-1} + \dots + \phi_{1,p}X_{t-p})(1 - G(s_t; \gamma; c)) \\ + (\phi_{2,0} + \phi_{2,1}X_{t-1} + \dots + \phi_{2,p}X_{t-p})G(s_t; \gamma; c) + \varepsilon_t$$

dengan:

- Y_t = log *return* saat periode ke- t
- ϕ_1' = parameter model AR yang menunjukkan *regime* 1
- $G(s_t; \gamma; c)$ = fungsi transisi yang mengatur pergerakan dari satu rezim ke rezim yang lain
- s_t = variabel transisi sehingga X_{t-1}
- γ = parameter kemulusan
- ε_t = nilai residu pada observasi ke- t dari model STAR (p, d)

2.14 Model *Logistic Smooth Transition Autoregressive* (LSTAR)

Model *Logistic Smooth Transition Autoregressive* (LSTAR) merupakan suatu model yang mempunyai fungsi transisi logistik dari model STAR. Menurut Terasvirta (1994), fungsi transisi logistik dapat ditulis sebagai berikut:

$$G(s_t; \gamma; c) = \frac{1}{1 + \exp(-\gamma(s_t - c))}, \gamma > 0 \quad (2.23)$$

dimana $s_t = X_{t-1}$, dengan parameter *delay* l yang merupakan bilangan integer positif $l > 0$. Model yang dihasilkan disebut sebagai model *logistic* STAR atau model LSTAR. Parameter c dapat diinterpretasikan sebagai *threshold*, dan γ menunjukkan derajat kecepatan dan kehalusan transisi.

Bentuk sederhana dari model LSTAR dapat dituliskan sebagai berikut

$$X_t = \phi'_1 Y_t \left(1 - \left(\frac{1}{1 + \exp(-\gamma(s_t - c))} \right) \right) + \phi'_2 Y_t \left(\frac{1}{1 + \exp(-\gamma(s_t - c))} \right) + \varepsilon_t \quad (2.24)$$

dimana X_t merupakan proses yang stasioner dengan ϕ'_1 , ϕ'_2 , dan γ merupakan parameter yang tidak diketahui. Parameter γ menunjukkan derajat kecepatan dan kehalusan transisi dan X_{t-1} merupakan fungsi transisi ketika *lag* $l \geq 1$. *Delay* 1 yang merupakan bilangan integer positif $l = 1$ sehingga $X_{t-1} = X_{t-1}^2$.

2.15 Estimasi Parameter Model LSTAR

Menurut Dijk (1999), untuk mengestimasi parameter dari model LSTAR menggunakan metode *Nonlinear Least Square* (NLS). Estimasi parameter pada

metode NLS ditentukan dengan meminimumkan jumlah kuadrat residual yang didefinisikan sebagai

$$\hat{\theta} = \operatorname{argmin} Q_T(\theta) = \operatorname{argmin} \sum_{t=1}^T (X_t - F(Y_t, \theta))^2 \quad (2.25)$$

dengan

$$F(Y_t, \theta) = \phi_1' Y_t (1 - G(\gamma, c, S_t)) + \phi_2' Y_t G(\gamma, c, S_t)$$

Dengan catatan bahwa minimisasi fungsi objek NLS hanya ditampilkan untuk γ dan c karena ϕ_1' dan ϕ_2' dapat diestimasi dengan menggunakan *least squares* pada saat γ dan c .

2.16 Saham

Saham merupakan salah satu jenis surat berharga yang diperdagangkan di bursa efek. Saham diartikan sebagai bukti penyertaan modal di suatu perseroan, atau merupakan bukti kepemilikan atas suatu perusahaan. Siapa saja yang memiliki saham berarti dia ikut menyertakan modal atau memiliki perusahaan yang mengeluarkan saham tersebut.

Wujud saham adalah selembarnya yang menerangkan bahwa pemilik kertas itu adalah pemilik perusahaan yang menerbitkan kertas tersebut. Jadi sama dengan menabung di bank, setiap kali menabung biasanya akan mendapatkan slip yang menjelaskan bahwa telah melakukan penyetoran sejumlah uang (Mustafa, 2016).

2.16.1 Return Saham

Menurut Ang (2001), *return* saham adalah tingkat keuntungan yang dinikmati oleh pemodal atas suatu investasi yang dilakukannya. Untuk menghitung *return* saham digunakan rumus sebagai berikut:

$$r_t = \ln \left(\frac{S_t}{S_{t-1}} \right) \quad (2.26)$$

dengan:

r_t = *return* dari harga penutupan saham pada hari ini (t)

S_t = harga penutupan saham pada hari ini (t)

S_{t-1} = harga penutupan saham pada hari kemarin ($t - 1$)

2.17 Peramalan

Peramalan pada dasarnya merupakan proses menyusun informasi tentang kejadian masa lampau yang berurutan untuk menduga kejadian di masa depan. Peramalan pada umumnya digunakan untuk memprediksi sesuatu yang kemungkinan besar akan terjadi misalnya kondisi permintaan, banyaknya curah hujan, kondisi ekonomi, dan lain-lain. Atas dasar logika, langkah dalam metode peramalan secara umum adalah mengumpulkan data, menyeleksi dan memilih data, memilih model peramalan, menggunakan model terpilih untuk melakukan peramalan, evaluasi hasil akhir (Frechtling, 2001).

III. METODOLOGI PENELITIAN

3.1 Waktu dan Tempat

Penelitian ini dilakukan pada semester genap tahun akademik 2020/2021 bertempat di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

3.2 Data Penelitian

Data yang digunakan adalah data *time series* sekunder yang diambil dari <https://id.investing.com/equities/indofood> untuk data mingguan *return* penutupan harga saham PT. Indofood Sukses Makmur Tbk. periode 03 Januari 2010 sampai dengan 16 Juni 2019.

3.3 Metode Penelitian

Penelitian ini dilakukan dengan menggunakan studi literatur secara sistematis yang diperoleh dari buku-buku maupun media lain untuk mendapatkan informasi sebanyak mungkin untuk mendukung penulisan skripsi.

Adapun langkah-langkah yang dilakukan dalam penelitian ini adalah sebagai berikut:

1. Melakukan plot data *return* penutupan harga saham PT Indofood Sukses Makmur Tbk.
2. Memeriksa kestasioneran data terhadap varian dilakukan dengan transformasi *Box-Cox* dan untuk stasioner terhadap rata-rata dengan uji *Augmented Dickey Fuller*. Apabila data tidak stasioner terhadap ragam maka data di transformasi, dan apabila data tidak stasioner terhadap rata-rata maka di stasionerkan dengan cara *differencing*. Jika data sudah stasioner terhadap ragam dan rata-rata maka menentukan model *Box-Jenkins*.
3. Mengidentifikasi model *Box-Jenkins* dengan melihat plot ACF dan PACF.
4. Mengestimasi parameter model *Box-Jenkins* terbaik dengan melihat nilai probabilitas dari koefisien parameter dan melihat model terbaik adalah model yang memiliki nilai AIC terkecil.
5. Melakukan pemeriksaan diagnostik pada residual model *Box-Jenkins*.
6. Melakukan uji nonlinieritas.
7. Membentuk model dan mengestimasi parameter model LSTAR
8. Mengevaluasi model LSTAR dengan menggunakan uji perbandingan untuk memilih model terbaik dengan melihat nilai AIC terkecil.
9. Melakukan peramalan menggunakan model LSTAR terbaik pada data *return* penutupan harga saham PT Indofood Sukses Makmur Tbk. periode-periode selanjutnya.

.

V. KESIMPULAN

Kesimpulan dari penelitian ini adalah sebagai berikut:

1. Model LSTAR terbaik untuk data *return* penutupan saham PT Indofood Sukses Makmur Tbk. yang telah diperoleh adalah model LSTAR (1,1).

Dengan persamaan ragamnya:

$$X_t = -0.4304X_{t-1} \left(1 - \frac{1}{1 + e^{-100(X_{t-1} + 0.0608)}} \right) + 0.3831X_{t-1} \left(\frac{1}{1 + e^{100(X_{t-1} + 0.0608)}} \right) + \alpha_t$$

2. Hasil peramalan ragam *return* penutupan saham PT Indofood Sukses Makmur Tbk. dengan menggunakan model LSTAR (1,1) yaitu mengalami penurunan dari periode minggu ke-1 sebesar $-3.1198e-03$ sampai dengan periode minggu ke-5 sebesar $-1.6902e-08$.

DAFTAR PUSTAKA

- Akaike, H. 1973. *Information Theory and an Extension of the Maximum Likelihood Principle*. Ed ke-2. Budepest, Milan.
- Ang, R. 2001. *Buku Pintar Pasar Modal Indonesia*. Mediasoft, Jakarta.
- Box, G.E P. & Jenkins, G.L. 1976. *Time Series Analysis Forecasting and Control*. Holden Day, San Francisco.
- Cahyani, R.N. 2010. *Pemodelan Smooth Transition Autoregressive (STAR) pada Kurs Thai Bath terhadap Rupiah*. Skripsi. Jurusan Matematika FMIPA Universitas Sebelas Maret, Surakarta.
- Cryer, J.D. & Chan, K.S. 2008. *Time Series Analysis with Application in R*. Springer, New York.
- Daniel, W.W. 1989. *Statistika Non Parametrik Terapan*. PT Gramedia, Jakarta.
- Dijk, V. 1999. *Smooth Transition Model Extensions and Outliers Robust Inference*. Tinberg Institute, Amsterdam.
- Frechtling, D.C. 2001. *Forecasting Tourism Demand: Methods and Strategies*. Butterworth-Heinemann, Oxford.
- Gujarati, D.N. & Porter, D.C. 2009. *Basic Econometrics*. Ed ke-5. McGraw-Hill Irwin, New York.
- Granger, C.W.J. & Terasvirta, T. 1993. Power of The Neural Network Linearity Test. *Journal of Time Series Analysis*. **14**: 159-171.
- Hasan, M.I. 2002. *Pokok-Pokok Materi Statistika I (Statistika Deskriptif)*. PT. Bumi Aksara, Jakarta.
- Mustafa. 2016. Makalah Tentang Saham.
<https://mustafatanjong.blogspot.com/2016/12/makalah-tentang-saham.html>.
Diakses pada 01 April 2021.

Pankratz, A. 1991. *Forecasting with Dynamic Regression Models*. John Willey & Sons, Inc., Indiana.

Rosadi, D. 2011. *Analisis Ekonometrika dan Runtun Waktu Terapan*. Kalimedia, Yogyakarta.

Terasvirta, T. 1994. Specification, Estimation, and Evaluation of Smooth Transition Autoregressive Models. *Journal of the American Statistical Association*. **89**(425): 208-218.

Terasvirta, T., Lin, C.F., & Granger, C.W.J. 1993. *Power of The Neural Network Linearity Test*. Blackwell Publishers, USA.

Wei, W.W.S. 2006. *Time Series Analysis Univariate and Multivariate Methods*. Ed ke-2. Pearson Education, Inc., New York.

William, H.G. 1993. *Econometric Analysis*. Pearson Education, Inc., New Jersey.