



TESIS - SS255401

**PEMODELAN SAHAM SEKTOR ENERGI
MENGUNAKAN *NON-HOMOGENEOUS MARKOV
SWITCHING AUTOREGRESSIVE MODELS (NHMS-
AR)***

**ADAM FAHMI FANDISYAH
6003202011**

Dosen Pembimbing :
Prof. Drs. NUR Iriawan, M.IKomp., Ph.D.
Dr. Dra. Kartika Fithriasari, M.Si.

Program Studi Magister Statistika
Departemen Statistika
Fakultas Sains dan Analitika Data
Institut Teknologi Sepuluh Nopember
Surabaya
2025



TESIS - SS255401

**PEMODELAN SAHAM SEKTOR ENERGI
MENGUNAKAN *NON-HOMOGENEOUS MARKOV
SWITCHING AUTOREGRESSIVE MODELS (NHMS-
AR)***

**ADAM FAHMI FANDISYAH
6003202011**

Dosen Pembimbing :
Prof. Drs. NUR Iriawan, M.IKomp., Ph.D.
Dr. Dra. Kartika Fithriasari, M.Si.

Program Studi Magister Statistika
Departemen Statistika
Fakultas Sains dan Analitika Data
Institut Teknologi Sepuluh Nopember
Surabaya
2025



THESIS - SS255401

ENERGY SECTOR STOCK MODELING THROUGH NON-HOMOGENEOUS *MARKOV SWITCHING* AUTOREGRESSIVE MODELS (*NHMS-AR*)

ADAM FAHMI FANDISYAH
6003202011

Supervisors :
Prof. Drs. NUR Iriawan, M.IKomp., Ph.D.
Dr. Dra. Kartika Fithriasari, M.Si.

Master Program of Statistics
Department of Statistics
Faculty of Science and Data Analytics
Institut Teknologi Sepuluh Nopember
Surabaya
2025

LEMBAR PENGESAHAN TESIS

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar
Magister Statistika (M.Stat)

Di
Institut Teknologi Sepuluh Nopember
Oleh:

ADAM FAHMI FANDISYAH
NRP. 6003202011

Tanggal Ujian: 27 Januari 2026
Periode Wisuda: April 2026

Disetujui Oleh:
Pembimbing:

1. Prof. Drs. NUR Iriawan, M.IKomp., Ph.D.
NIP. 19621015 198803 1 002
2. Dr. Dra. Kartika Fithriasari, M.Si.
NIP. 19691212 199303 2 002

Penguji:

1. Prof. Dr.rer.pol. Dedy Dwi Prastyo, S.Si., M.Si.
NIP. 19831204 200812 1 002
2. Dr. Muhammad Sjahid Akbar, S.Si., M.Si.
NIP. 19720705 199802 1 001

Kepala Departemen Statistika
Fakultas Sains dan Analitika Data



Prof. Dr.rer.pol. Dedy Dwi Prastyo, S.Si., M.Si.
NIP. 19831204 200812 1 002

(Halaman ini sengaja dikosongkan)

PEMODELAN SAHAM SEKTOR ENERGI MENGGUNAKAN NON-HOMOGENEOUS *MARKOV SWITCHING* AUTOREGRESSIVE MODELS (*NHMS-AR*)

Nama Mahasiswa : Adam Fahmi Fandisyah
NRP : 6003202011
Pembimbing : Prof. Drs. NUR Iriawan, M.IKomp., Ph.D.
Co-Pembimbing : Dr. Dra. Kartika Fithriasari, M.Si.

ABSTRAK

Investasi saham merupakan salah satu instrumen keuangan yang memiliki potensi *return* tinggi, namun diiringi dengan tingkat risiko dan ketidakpastian yang cukup besar. Dalam beberapa tahun terakhir, saham-saham pada sektor energi menunjukkan tren penguatan. Dinamika tersebut tidak terlepas dari pengaruh faktor internal dan eksternal perusahaan. Oleh karena itu, diperlukan suatu model yang mampu menangkap perubahan struktur dan dinamika *return* saham secara lebih adaptif. Penelitian ini bertujuan untuk menganalisis dinamika *return* saham sektor energi di Indonesia, khususnya PT Perusahaan Gas Negara Tbk (PGAS), PT Alamtri Resources Indonesia Tbk (ADRO), dan PT Medco Energi Internasional Tbk (MEDC), menggunakan pendekatan *Non-Homogeneous Markov Switching AutoRegressive (NHMS-AR)*. Model *NHMS-AR* merupakan pengembangan dari model *MS-AR*. Model ini memungkinkan probabilitas transisi rezim dan/atau persamaan emisi dipengaruhi oleh variabel eksogen. Dalam penelitian ini, dipertimbangkan beberapa spesifikasi model, yaitu *NHTMS-AR (Non-Homogeneous Transition MS-AR)*, *NHEMS-AR (Non-Homogeneous Emission MS-AR)*, dan *NHTEMS-AR (Non-Homogeneous Transition and Emission MS-AR)*. Variabel eksogen yang digunakan meliputi *Climate Risk Index (CRI)*, *Geopolitical Risk Index (GPR)*, dan *Global Economic Policy Uncertainty Index (GEPU)*, yang merepresentasikan faktor ketidakpastian global dan makroekonomi yang relevan terhadap sektor energi. Hasil analisis menunjukkan bahwa model *NHMS-AR* mampu menangkap perubahan rezim *return* saham sektor energi dengan lebih baik dibandingkan model *HMS-AR*. Evaluasi kinerja dilakukan menggunakan *Symmetric Mean Absolute Percentage Error (SMAPE)*, dan hasilnya menunjukkan bahwa model *NHTEMS-AR* menghasilkan nilai *SMAPE* paling kecil dibandingkan dengan model *HMS-AR*, *NHTMS-AR*, dan *NHEMS-AR*. Dengan demikian, penggunaan variabel eksogen pada transisi dan emisi secara simultan memberikan kinerja model yang lebih baik dalam menggambarkan dinamika *return* saham sektor energi.

Kata kunci: *AutoRegressive, Energi, Markov Switching, Non-homogeneous, Time series.*

(Halaman ini sengaja dikosongkan)

ENERGY SECTOR STOCK MODELING THROUGH NON-HOMOGENEOUS *MARKOV SWITCHING* AUTOREGRESSIVE MODELS (*NHMS-AR*)

Name : Adam Fahmi Fandisyah
NRP : 6003202011
Supervisor : Prof. Drs. NUR Iriawan, M.IKomp., Ph.D.
Co-Supervisor : Dr. Dra. Kartika Fithriasari, M.Si.

ABSTRACT

Stock investment is a financial instrument with high potential returns, but it also comes with a significant level of risk and uncertainty. In recent years, stocks in the energy sector have shown a strengthening trend. This dynamic is inextricably linked to the influence of both internal and external factors within the company. Therefore, a model is needed that can capture changes in the structure and dynamics of stock returns more adaptively. This study aims to analyze the dynamics of stock returns in the energy sector in Indonesia, specifically PT Perusahaan Gas Negara Tbk (PGAS), PT Alamtri Resources Indonesia Tbk (ADRO), and PT Medco Energi Internasional Tbk (MEDC), using the Non-Homogeneous Markov Switching AutoRegressive (NHMS-AR) approach. The NHMS-AR model is an extension of the MS-AR model. This model allows the probability of regime transitions and/or emission equations to be influenced by exogenous variables. In this study, several model specifications were considered, namely NHTMS-AR (Non-Homogeneous Transition MS-AR), NHEMS-AR (Non-Homogeneous Emission MS-AR), and NHTEMS-AR (Non-Homogeneous Transition and Emission MS-AR). The exogenous variables used include the Climate Risk Index (CRI), the Geopolitical Risk Index (GPR), and the Global Economic Policy Uncertainty Index (GEPU), which represent global and macroeconomic uncertainty factors relevant to the energy sector. The analysis results indicate that the NHMS-AR model is more effective in capturing changes in the energy sector's stock return regime compared to the HMS-AR model. Performance evaluation was conducted using the Symmetric Mean Absolute Percentage Error (SMAPE), and the results indicated that the NHTEMS-AR model yielded the smallest SMAPE value compared to the HMS-AR, NHTMS-AR, and NHEMS-AR models. Thus, the simultaneous use of exogenous variables in the transition and emission mechanisms provides better model performance in describing the dynamics of energy sector stock returns.

Keywords: AutoRegressive, Energy, *Markov Switching*, Non-homogeneous, Time series.

(Halaman ini sengaja dikosongkan)

KATA PENGANTAR

Puji syukur penulis panjatkan kehadirat Allah SWT yang telah melimpahkan segala rahmat dan hidayah-Nya, sehingga penulis dapat menyelesaikan Tesis yang berjudul : “Pemodelan Saham Sektor Energi Menggunakan *Non-Homogeneous Markov Switching Autoregressive Models (NHMS-AR)*”. Selama proses penyusunan Tesis ini, penulis dapat menyelesaikan dengan baik dan lancar tidak lepas dari adanya bantuan berbagai pihak. Oleh karena itu, dengan penuh hormat, ketulusan, dan rendah hati, penulis ingin mengucapkan terima kasih kepada :

1. Bapak Prof. Dr.rer.pol. Dedy Dwi Prastyo, S.Si., M.Si. selaku Kepala Departemen Statistika FSAD dan Ibu Dr. Wibawati, S.Si., M.Si. selaku Sekretaris Departemen yang telah menyediakan fasilitas serta lingkungan akademik yang mendukung penyelesaian tesis ini.
2. Ibu Dr. Irhamah, S.Si., M.Si. selaku Kepala Program Studi Pascasarjana Statistika yang telah memberikan dukungan, arahan, dan kesempatan kepada penulis dalam menyelesaikan studi.
3. Bapak Prof. Drs. NUR Iriawan, M.IKomp., Ph.D. dan Ibu Dr. Dra. Kartika Fithriasari, M.Si. selaku dosen pembimbing yang telah meluangkan waktu, memberikan arahan, bimbingan, serta dukungan yang sangat berarti bagi penulis sepanjang proses penyusunan tesis.
4. Bapak Prof. Dr.rer.pol. Dedy Dwi Prastyo, S.Si., M.Si. dan Bapak Dr. Muhammad Sjahid Akbar, S.Si., M.Si. selaku dosen penguji yang telah memberikan masukan dan saran yang sangat berharga demi penyempurnaan tesis ini.
5. Ibu Dr. Dra. Kartika Fithriasari, M.Si. selaku dosen wali yang senantiasa memberikan nasihat, motivasi, dan bimbingan selama penulis menempuh studi.
6. Seluruh dosen Departemen Statistika ITS atas ilmu dan wawasan yang telah diberikan, serta segenap karyawan Departemen Statistika ITS atas bantuan dan pelayanan selama masa studi.

7. Kedua orang tua tercinta, Bapak Nurhadi Hasyim dan Ibu Farida Masviyah, atas doa, kasih sayang, dukungan, dan motivasi yang tiada henti sehingga menjadi kekuatan bagi penulis dalam menyelesaikan tesis ini.
8. Istri tercinta, Marita Qori'atunnadyah, atas doa, dukungan, semangat, dan pengertian yang senantiasa menyertai penulis dalam setiap tahap proses penyusunan tesis.
9. Semua pihak yang telah memberikan bantuan dan dukungan, baik secara langsung maupun tidak langsung, yang tidak dapat penulis sebutkan satu per satu.

Semoga tesis yang penulis susun dapat bermanfaat dan mampu digunakan sebagaimana mestinya. Penulis menyadari apabila pembuatan tesis ini masih jauh dari kesempurnaan, besar harapan dari penulis untuk menerima kritik dan saran yang berguna untuk perbaikan di masa mendatang. Serta tidak lupa penulis memohon maaf apabila terdapat banyak kekurangan dalam tesis yang telah penulis susun. Atas perhatian dan dukungannya penulis sampaikan ucapan terima kasih.

Surabaya, Januari 2026

Penulis

DAFTAR ISI

LEMBAR PENGESAHAN TESIS	i
ABSTRAK	iii
ABSTRACT	v
KATA PENGANTAR	vii
DAFTAR ISI	ix
DAFTAR TABEL	xi
DAFTAR GAMBAR	xiii
DAFTAR LAMPIRAN	xv
DAFTAR SIMBOL	xvii
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	9
1.3 Tujuan	9
1.4 Manfaat	10
1.5 Batasan Masalah	11
BAB II TINJAUAN PUSTAKA	13
2.1 <i>Markov Chain</i>	13
2.2 <i>Model AutoRegressive</i>	14
2.3 <i>Model Markov Switching AutoRegressive (MS-AR)</i>	15
2.4 <i>Model Non-Homogeneous Markov Switching AutoRegressive (NHMS-AR)</i>	18
2.5 <i>Expectation Maximization (EM)</i>	27
2.6 <i>Symmetric Mean Absolute Percentage Error (SMAPE)</i>	32
2.7 Paket NHMSAR	33
BAB III METODOLOGI PENELITIAN	37
3.1 Sumber Data	37
3.2 Variabel Penelitian	37
3.3 Langkah Analisis	38
3.4 Diagram Alir	40

BAB IV ANALISIS DAN PEMBAHASAN	43
4.1 Karakteristik Data Saham Sektor Energi	43
4.2 Penerapan <i>Homogeneous Markov Switching Autoregressive (HMS-AR)</i> dalam memodelkan <i>return</i> saham sektor energi di Indonesia	48
4.3 Penerapan <i>Non-Homogeneous Markov Switching Autoregressive (NHMS-AR)</i> dalam memodelkan <i>return</i> saham sektor energi di Indonesia	52
4.3.1 <i>NHTMS-AR</i>	55
4.4.2 <i>NHEMS-AR</i>	60
4.4.3 <i>NHTEMS-AR</i>	65
4.4 Evaluasi Model	71
BAB V KESIMPULAN DAN SARAN	75
5.1 Kesimpulan	75
5.2 Saran	77
DAFTAR PUSTAKA	79
LAMPIRAN	83
BIODATA PENULIS	117

DAFTAR TABEL

Tabel 3. 1 Struktur Data	38
Tabel 4. 1 Statistik Deskriptif <i>Return</i> Saham Sektor Energi.....	43
Tabel 4. 2 Statistik Deskriptif Variabel Eksogen	46
Tabel 4. 3 Perbandingan <i>SMAPE</i> Antar Model.....	71

(Halaman ini sengaja dikosongkan)

DAFTAR GAMBAR

Gambar 3. 1 Diagram Alir.....	40
Gambar 4. 1 Plot Deret Waktu Return Saham Sektor Energi	44
Gambar 4. 2 Plot Indeks Resiko Iklim (CRI)	47
Gambar 4. 3 Plot Indeks Ketidakpastian Kebijakan Ekonomi Global (GEPU)	47
Gambar 4. 4 Plot Indeks Resiko Geopolitik (GPR)	48
Gambar 4. 5 Plot <i>Smoothed Regime Probabilities HMS-AR</i>	52
Gambar 4. 6 Plot <i>Smoothed Regime Probabilities NHTMS-AR</i>	60
Gambar 4. 7 Plot <i>Smoothed Regime Probabilities NHEMS-AR</i>	64
Gambar 4. 8 Plot <i>Smoothed Regime Probabilities NHTEMS-AR</i>	70
Gambar 4. 9 Plot Data Aktual dan Prediksi Model <i>HMS-AR</i> (a) <i>NHTMS-AR</i> (b) <i>NHEMS-AR</i> (c) <i>NHTEMS-AR</i> (d) pada Data <i>Training</i>	72
Gambar 4. 10 Plot Data Aktual dan Prediksi Model <i>HMS-AR</i> (a) <i>NHTMS-AR</i> (b) <i>NHEMS-AR</i> (c) <i>NHTEMS-AR</i> (d) pada Data <i>Testing</i>	73

(Halaman ini sengaja dikosongkan)

DAFTAR LAMPIRAN

Lampiran 1 Data <i>Return</i> Saham Sektor Energi	83
Lampiran 2 Data Variabel Eksogen.....	88
Lampiran 3 <i>Syntax</i> R Statistika Deskriptif	93
Lampiran 4 <i>Syntax</i> R untuk Model <i>HMS-AR</i> dan <i>NHMS-AR</i>	93
Lampiran 5 <i>Output</i> R untuk <i>HMS-AR</i> dan <i>NHMS-AR</i>	104

(Halaman ini sengaja dikosongkan)

DAFTAR SIMBOL

t	: Indeks waktu, $t = 1, 2, \dots, M$
T	: Jumlah total pengamatan
i, j	: Indeks rezim, $i, j = 1, 2, \dots, M$
M	: Jumlah rezim
p	: Orde autoregresif
k	: Indeks iterasi algoritma EM
Y_t	: Nilai variabel pada waktu ke- t
$\hat{Y}_t$	: Nilai prediksi (<i>fitted value</i>) pada waktu ke- t
Y_{it}	: Nilai variabel ke- i pada waktu ke- t
Z_t	: Vektor kovariat (variabel eksogen) pada waktu ke- t
Z_{jt}	: Nilai variabel eksogen ke- j pada periode ke- t
$Y_{1:T}$	: Seluruh pengamatan <i>return</i> dari waktu 1 hingga T
c	: Intersep (konstanta)
$\phi_1, \phi_2, \dots, \phi_p$	: Parameter orde 1, 2, ..., p ,
$Y_{t-1}, \dots, Y_{t-p}$	: Nilai variabel pada periode waktu sebelumnya (<i>lagged values</i>)
S_t	: Variabel laten yang menyatakan rezim pada waktu ke- t
$\mathbf{c}_{S_t}$	: Vektor intersep untuk rezim ke- S_t
$\Phi_{S_t, p}$	: Matriks koefisien autoregresif orde ke- p pada rezim ke- S_t
$\mathbf{Y}_{t-p}$	: Vektor nilai observasi pada lag ke- p
Γ_{S_t}	: Matriks koefisien kovariat pada rezim S_t
$\mathbf{Z}_t$	: Vektor kovariat eksternal pada waktu t
$\boldsymbol{\varepsilon}_{S_t, t} \sim N(\mathbf{0}, \boldsymbol{\Sigma}_{S_t})$	: Vektor error Gaussian pada rezim S_t
Π	: Matriks parameter probabilitas transisi
$\boldsymbol{\Sigma}$	: Matriks kovarian error pada masing-masing rezim
$\boldsymbol{\pi}$	: Vektor probabilitas awal rezim.
$\mathbf{B}_i$	: Vektor parameter regresi emisi pada rezim ke- i

$\mathbf{x}_t$	: Vektor regresor pada waktu ke- t
$\boldsymbol{\theta}$	: Vektor seluruh parameter model
$\hat{\boldsymbol{\theta}}$	: Estimator parameter hasil konvergensi
α_i	: Intersep fungsi logit transisi dari rezim ke- i
β_i	: Koefisien kovariat pada probabilitas transisi dari rezim ke-
p_{ij}	: Probabilitas transisi dari rezim i ke rezim j
q_{ij}	: Probabilitas transisi bersyarat kovariat
$a_t(j)$	: Probabilitas <i>forward</i> , yaitu peluang bersama antara pengamatan hingga waktu ke- t dan sistem berada pada rezim ke- j
$\ell(\boldsymbol{\theta})$	: Fungsi <i>log-likelihood</i>
$Q(\boldsymbol{\theta} \boldsymbol{\theta}^{(k)})$	: Fungsi ekspektasi <i>log-likelihood</i>
$\gamma_t(i)$	: Probabilitas posterior rezim i pada waktu ke- t
$\xi_t(i, j)$	: Probabilitas posterior transisi dari rezim i ke j
$\boldsymbol{\theta}^{(k)}$	: Parameter model pada iterasi ke- k
$\boldsymbol{\theta}^{(k+1)}$	: Parameter hasil pembaruan iterasi ke- $k+1$
δ	: Toleransi konvergensi
ε_t	: Galat (<i>error</i>) model pada waktu ke- t
$SMAPE$	: <i>Symmetric Mean Absolute Percentage Error</i>

BAB I

PENDAHULUAN

1.1 Latar Belakang

Investasi adalah kegiatan menempatkan sejumlah dana, waktu, atau sumber daya lainnya pada suatu aset, proyek, atau aktivitas dengan harapan memperoleh keuntungan atau manfaat di masa mendatang. Dalam konteks ekonomi dan keuangan, investasi lebih spesifik merujuk pada penanaman dana pada instrumen seperti saham, obligasi, atau aset lainnya guna memperoleh imbal hasil finansial (Gitman et al., 2011). Salah satu instrumen keuangan yang paling dikenal adalah saham, yaitu surat berharga yang mencerminkan kepemilikan seseorang terhadap suatu perusahaan (Hafer & Hein, 2007).

Investasi saham dapat menjadi pilihan yang menarik dibandingkan instrumen investasi lainnya karena beberapa alasan. Menurut Teng (2023), saham menawarkan potensi keuntungan yang relatif tinggi, terutama dari perusahaan yang sedang berkembang pesat, serta berpotensi memberikan pendapatan pasif dalam bentuk dividen yang dibagikan secara berkala oleh perusahaan. Selain itu, saham memiliki tingkat likuiditas yang tinggi karena dapat diperjualbelikan dengan cepat dan mudah di pasar modal, terutama berkat kemajuan teknologi dan kemudahan akses melalui platform digital yang semakin berkembang (Febiyola et al., 2024).

Namun, penting untuk diingat bahwa investasi dalam saham juga membawa risiko, karena nilai saham dapat turun jika perusahaan mengalami kesulitan atau jika kondisi pasar memburuk. Saham merupakan salah satu instrumen di pasar modal yang memiliki hubungan linier semakin tinggi potensi *return*, semakin besar risiko yang harus ditanggung oleh investor (Kungwani, 2014). Oleh karena itu, investor perlu mempertimbangkan toleransi risiko serta tujuan investasi mereka sebelum memutuskan untuk berinvestasi.

Berdasarkan hal tersebut, perlu mengidentifikasi potensi keuntungan serta pengelolaan risiko yang melekat dalam investasi saham. Analisis menyeluruh terhadap saham dilakukan untuk mengembangkan pendekatan yang dapat meminimalkan potensi kerugian dan mengoptimalkan hasil investasi, dengan mempertimbangkan berbagai faktor yang memengaruhi fluktuasi harga saham serta

kondisi pasar yang dinamis. Dengan menetapkan tujuan investasi yang jelas dan menerapkan strategi manajemen risiko yang tepat, diharapkan investor dapat membuat keputusan investasi yang lebih terukur, sehingga dapat mencapai sasaran finansial yang diinginkan dalam menghadapi tantangan pasar saham.

Saham merupakan instrumen dalam kegiatan ekonomi yang sangat dipengaruhi oleh siklus bisnis, di mana harga saham mengalami fluktuasi seiring dinamika pasar yang terbentuk oleh mekanisme *supply* dan *demand*. Pembentukan harga saham dipengaruhi oleh berbagai faktor, baik yang spesifik terhadap perusahaan, seperti kinerja keuangan dan keputusan strategis, maupun faktor makroekonomi, seperti tingkat suku bunga, inflasi, nilai tukar, serta kondisi sosial dan politik. Faktor-faktor ini dapat dikategorikan menjadi faktor internal, seperti laporan keuangan dan rasio keuangan perusahaan, serta faktor eksternal, seperti kebijakan pemerintah dan perubahan nilai tukar (Oktavia & Nugraha, 2018).

Sebagai contoh, kebijakan *Tax Amnesty* yang diterapkan pemerintah pada 2016-2017 menunjukkan dampak signifikan terhadap likuiditas saham sektor perbankan di Bursa Efek Indonesia (BEI), terutama saham Bank Mandiri (BMRI) dan Bank Negara Indonesia (BBNI), yang mengalami peningkatan volume transaksi. Sebaliknya, saham Bank Central Asia (BBCA) dan Bank Rakyat Indonesia (BBRI) tidak mengalami perubahan signifikan dalam likuiditas. Studi tersebut, yang menggunakan pendekatan *AutoRegressive Conditional Duration* (ACD), mengungkapkan bahwa kebijakan pemerintah, seperti *Tax Amnesty*, dapat memengaruhi likuiditas dan, pada gilirannya, memengaruhi harga saham (Handayani & Prastyo, 2020). Hal ini juga didukung oleh hasil penelitian yang menunjukkan bahwa pengumuman *Tax Amnesty* memberikan sinyal positif bagi pasar saham Indonesia, ditandai dengan peningkatan yang signifikan pada volume perdagangan dan *return* saham (Agustina et al., 2018). Dengan kata lain, peningkatan likuiditas akibat kebijakan tersebut membuka lebih banyak ruang bagi pergerakan modal, yang berdampak pada peningkatan kinerja pasar dan harga saham.

Salah satu pendekatan yang dapat digunakan untuk memahami pergerakan saham dan mengelola risiko investasi adalah melalui pemodelan saham. Pemodelan saham memiliki sejumlah manfaat penting bagi investor, analis, dan manajer

portofolio. Pemodelan saham memungkinkan prediksi harga berdasarkan data historis serta faktor-faktor yang memengaruhinya, sehingga berguna dalam memahami dinamika pasar dan mengelola risiko investasi. Dengan demikian, pemodelan saham menjadi alat penting untuk menganalisis, mengelola risiko, dan membuat keputusan investasi yang lebih baik dalam menghadapi fluktuasi pasar yang kompleks dan dinamis.

Metode yang umum digunakan dalam pemodelan saham adalah analisis deret waktu (*time series analysis*). Deret waktu merupakan rangkaian data berupa nilai pengamatan yang diukur secara berurutan dalam periode waktu tertentu dengan interval yang sama (Wei, 2006). Analisis deret waktu bertujuan untuk mengembangkan model berdasarkan data historis, yang kemudian digunakan untuk meramalkan nilai-nilai di masa depan. Pendekatan ini memiliki relevansi yang signifikan dalam berbagai bidang, seperti bisnis, ekonomi, dan keuangan, di mana pemahaman terhadap pola masa lalu suatu variabel sangat penting dalam memprediksi perilaku di masa yang akan datang.

Namun, data ekonomi sering kali menunjukkan pola yang tidak stabil dan berubah secara tiba-tiba akibat pergeseran kondisi atau rezim (*regime Switching*) yang tidak selalu dapat diamati secara langsung. Untuk menangani dinamika ini, diperlukan pendekatan yang mampu memodelkan transisi antar kondisi secara stokastik, salah satunya adalah dengan menggunakan konsep rantai *Markov*. Rantai *Markov* diperkenalkan oleh Andrei *Markov* pada tahun 1906 sebagai model probabilistik yang menjelaskan transisi antar keadaan berdasarkan sifat *memoryless*, di mana probabilitas transisi hanya bergantung pada keadaan saat ini, bukan pada riwayat sebelumnya (Seneta, 2006). Pendekatan rantai *Markov* sangat sesuai untuk menganalisis data ekonomi yang bersifat acak dan dinamis, seperti pergerakan harga saham, karena model ini memungkinkan prediksi arah pergerakan harga berdasarkan transisi antar keadaan yang diamati dari data historis (Choji et al., 2013).

Hamilton (1989) mengembangkan pendekatan yang menggabungkan rantai *Markov* dengan model *AutoRegressive (AR)*, yang dikenal sebagai model *Markov Switching AutoRegressive (MS-AR)*. Model ini memanfaatkan kemampuan *AR* dalam menangkap pola hubungan antara nilai saat ini dan nilai sebelumnya, yang

umum ditemukan dalam data ekonomi. Dengan menggabungkan sifat stokastik dari rantai *Markov* dan kekuatan *AR* dalam mengidentifikasi pola waktu, *MS-AR* memungkinkan analisis yang lebih akurat terhadap perubahan struktur data yang tidak terlihat secara langsung. Model ini dirancang untuk menangkap pola *non-linear* yang muncul akibat perubahan struktur deret waktu dalam periode tertentu, sebagaimana sering terjadi dalam siklus bisnis dan dinamika ekonomi makro. Dalam penelitian awalnya, Hamilton menerapkan model ini pada data *Gross National Product* (GNP) riil *Amerika Serikat* pascaperang dan menemukan bahwa transisi dari pertumbuhan positif ke negatif merupakan karakteristik siklus bisnis yang berulang. Estimasi parameter menunjukkan bahwa resesi ekonomi umumnya dikaitkan dengan penurunan permanen sekitar 3% dalam tingkat GNP, sehingga model ini dapat digunakan sebagai kriteria objektif untuk mendefinisikan dan mengukur resesi ekonomi.

Beberapa studi telah membuktikan bahwa model *Markov Switching AutoRegressive* (*MS-AR*) efektif untuk menganalisis dinamika ekonomi dan keuangan. Salah satunya dilakukan oleh Ahmad dan Kamaiah (2010) yang menerapkan model *MS(2)-AR(4)* untuk memodelkan siklus bisnis di India menggunakan data triwulanan indeks produksi industri selama periode 1982–2009. Hasil penelitian menunjukkan bahwa model ini secara efektif mengidentifikasi dua rezim, yaitu ekspansi dan kontraksi, dengan probabilitas berlanjutnya ekspansi sebesar 92% dan kontraksi sebesar 66%. Rata-rata durasi ekspansi tercatat 13 kuartal, sedangkan kontraksi berlangsung sekitar 4 kuartal. Temuan ini menunjukkan bahwa fase ekspansi cenderung lebih tahan lama dibandingkan kontraksi. Selain itu, model ini juga berhasil mendeteksi titik balik siklus ekonomi, termasuk pulihnya aktivitas ekonomi India setelah krisis keuangan global pada 2008, sehingga memperkuat relevansi *MS-AR* dalam menangkap dinamika pertumbuhan yang bersifat tidak linier.

Selanjutnya, penelitian oleh Ashariansyah, Iriawan, dan Mukarromah (2020) menggunakan pendekatan *MS-AR* untuk memodelkan volatilitas harga *cryptocurrency* seperti *Bitcoin*, *Ethereum*, dan *Ripple*, dengan tujuan meminimalkan risiko kerugian akibat fluktuasi harga yang tinggi. Menggunakan data harian dari September 2015 hingga Januari 2020 dan algoritma *Expectation*

Maximization (EM), penelitian ini menunjukkan bahwa model $MS(8)AR(1)$ paling cocok untuk *Bitcoin* dan *Ripple*, sementara *Ethereum* lebih sesuai dengan model $MS(9)AR(1)$. Hasilnya menunjukkan bahwa *MS-AR* mampu membantu investor memahami pola harga dan mengurangi risiko di pasar *cryptocurrency* yang sangat volatil.

Selain itu, penelitian yang dilakukan oleh Prihartanti, Rasyid, dan Iriawan (2020) menganalisis saham kategori *Blue Chip* dari sektor transportasi, rumah tangga, dan telekomunikasi, seperti PT Astra Internasional, PT Unilever, dan PT Telekomunikasi Indonesia. Dengan memanfaatkan model *MS-AR*, penelitian ini menunjukkan bahwa metode tersebut mempermudah investor dalam menentukan pilihan investasi dengan lebih baik berdasarkan fluktuasi harga saham individu di sektor-sektor tersebut.

Terdapat beberapa sektor dalam saham, di antaranya sektor energi, industri, transportasi, infrastruktur, keuangan, dan lainnya. Salah satu sektor yang menarik untuk dianalisis adalah sektor energi. Indonesia menjadi negara dengan sumber daya alam (SDA) yang cukup melimpah, baik yang dapat diperbarui maupun yang tidak dapat diperbarui, seperti minyak, gas bumi, batu bara, panas bumi, serta energi terbarukan seperti tenaga surya dan angin. Kondisi ini memberikan landasan yang kuat bagi sektor energi di Indonesia untuk berkembang, sekaligus berpotensi memberikan keuntungan yang signifikan. Selain itu, kondisi geopolitik global yang dinamis turut mempengaruhi harga energi, menciptakan peluang bagi perusahaan energi Indonesia untuk meningkatkan kinerja di pasar global.

Saham sektor energi menawarkan peluang, tetapi juga menyimpan risiko yang tidak dapat diabaikan. Fluktuasi harga komoditas energi akibat dinamika pasokan dan permintaan global sering kali memicu volatilitas tinggi dalam kinerja perusahaan energi. Risiko geopolitik, seperti ketegangan internasional dan kebijakan perdagangan, dapat mengganggu stabilitas pasokan energi dan harga komoditas, yang berdampak langsung pada keuangan perusahaan. Selain itu, perubahan regulasi lingkungan dan pergeseran menuju energi terbarukan turut memengaruhi prospek jangka panjang perusahaan energi konvensional. Studi oleh Hu dan Borjigin (2024) menunjukkan bahwa risiko geopolitik, ketidakpastian kebijakan ekonomi, dan risiko iklim secara signifikan dapat memicu gejolak di

pasar energi yang turut memengaruhi pasar saham, terutama saat terjadi krisis atau pemulihan ekonomi. Dengan mempertimbangkan tantangan tersebut, analisis terhadap saham sektor energi di Indonesia menjadi penting. Penelitian ini bertujuan untuk memodelkan saham-saham energi yang tercatat di Bursa Efek Indonesia (BEI), guna memahami faktor-faktor yang memengaruhi kinerjanya, mengidentifikasi risiko dan peluang, serta memberikan wawasan strategis bagi investor.

Dalam penelitian Schwert (1989), meskipun memberikan wawasan penting terkait hubungan antara volatilitas saham, siklus bisnis, dan krisis keuangan, terdapat keterbatasan pada pendekatan model yang digunakan, yang dinilai belum sepenuhnya mampu menangkap dinamika kompleks volatilitas saham serta pengaruh perubahan kondisi ekonomi terhadap pergerakan pasar. Schwert menekankan perlunya model yang mempertimbangkan faktor struktural dan eksogen, seperti perubahan kebijakan pemerintah atau peristiwa global, guna meningkatkan akurasi prediksi. Sejalan dengan hal tersebut, Ahmad dan Kamaiah (2010) merekomendasikan pengembangan lebih lanjut terhadap pendekatan *MS-AR* dengan memasukkan variabel-variabel ekonomi tambahan, seperti nilai tukar, utang pemerintah, dan tingkat suku bunga, agar model lebih mampu merepresentasikan perubahan siklus ekonomi secara akurat. Rekomendasi ini memperkuat urgensi penggunaan pendekatan yang lebih fleksibel dan adaptif terhadap dinamika eksternal.

Untuk menganalisis sektor saham yang melibatkan beberapa saham secara bersamaan ataupun untuk mengeksplorasi hubungan antara volatilitas saham dan variabel makroekonomi lainnya secara lebih mendalam, diperlukan metode seperti *Vector Autoregression (VAR)*, *Markov Switching Vector Autoregression (MS-VAR)*, atau metode serupa lainnya. *VAR* menggeneralisasi model *AutoRegressive (AR)* untuk lebih dari satu variabel, di mana setiap variabel diprediksi berdasarkan nilai masa lalunya sendiri dan nilai variabel lain, sehingga sangat berguna dalam menganalisis hubungan dinamis antar variabel secara simultan, yang umum dijumpai dalam analisis ekonomi dan keuangan. *MS-VAR* memperluas metode ini dengan memungkinkan perubahan hubungan antar variabel tergantung pada rezim yang berlaku, sehingga mampu menangkap pola dinamis yang lebih kompleks

dalam situasi pasar yang dipengaruhi oleh perubahan kondisi ekonomi. Penelitian oleh Dua dan Tuteja (2021) menerapkan *MS-VAR* untuk menganalisis hubungan dinamis antara pasar saham dan mata uang di beberapa negara, seperti Eurozone, India, Jepang, dan Amerika Serikat, selama periode 1999–2020. Penelitian ini mengidentifikasi dua rezim utama, yaitu rezim tenang dengan volatilitas rendah dan *return* tinggi, serta rezim kacau dengan volatilitas tinggi dan *return* rendah. Mereka menemukan bahwa hubungan antara pasar saham dan mata uang menguat selama periode ketidakstabilan ekonomi, yang menunjukkan bahwa perubahan di satu pasar dapat memengaruhi pasar lainnya secara signifikan.

Sebagai pengembangan dari pendekatan *Markov Switching AutoRegressive (MS-AR)*, model *Non-Homogeneous Markov Switching AutoRegressive (NHMS-AR)* dirancang untuk menangkap dinamika sistem yang lebih kompleks dengan memungkinkan ketergantungan baik pada fungsi transisi antar rezim maupun pada struktur emisi yang bergantung pada kovariat. Berbeda dengan model *MS-AR* homogen yang menggunakan parameter tetap untuk setiap rezim, *NHMS-AR* memperbolehkan baik probabilitas transisi maupun parameter *Output* model (intersep atau *mean*) dipengaruhi oleh nilai kovariat. Kovariat dalam model ini merujuk pada variabel tambahan yang digunakan untuk memengaruhi probabilitas transisi antar rezim (*covariate for transitions*), maupun berperan dalam fungsi yang menghubungkan kovariat dengan parameter *Output* model (intersep atau *mean*) dalam setiap rezim (*covariate for emissions*). Dengan demikian, setiap rezim dapat memiliki karakteristik yang dipengaruhi oleh faktor eksternal atau nilai lainnya.

Model ini pertama kali diperkenalkan oleh Ailliot, Bessac, Monbet, dan Pène (2015) dalam studi meteorologi berjudul *Non-Homogeneous Hidden Markov-Switching Models for Wind Time Series*, yang mengembangkan model *MS-AR* untuk deret waktu bivariat dari kondisi angin dalam beberapa bentuk pengamatan, yaitu dalam koordinat kartesian (u_t, v_t) dan polar (U_t, Φ_t) . Koordinat kartesian menggambarkan komponen angin arah timur-barat dan utara-selatan, sedangkan koordinat polar menyatakan kecepatan dan arah angin sebagai besaran dan sudut. Data tersebut diambil dari satu titik observasi di lepas pantai Atlantik Prancis. Dalam kerangka model ini, kondisi angin berperan sebagai variabel observasi (Y_t) ,

sementara tipe cuaca atau rezim meteorologis diwakili oleh variabel tersembunyi (X_t). Berbeda dengan model *MS-AR* homogen yang mengasumsikan transisi antar rezim konstan, *NHMS-AR* memungkinkan transisi tersebut bergantung pada observasi masa lalu (Y_{t-1}) sebagai kovariat, menjadikannya *non-homogen* dan lebih adaptif terhadap dinamika sistem. Jurnal ini secara khusus menunjukkan bahwa transisi antar rezim, seperti dari siklonik ke antisiklonik, sangat dipengaruhi oleh kondisi angin sebelumnya. Dengan struktur tersebut, *NHMS-AR* mampu menangkap pola *non-linear*, distribusi marginal yang *multimodal*, serta dinamika sistem yang kompleks. Estimasi parameter dilakukan menggunakan algoritma *Expectation-Maximization (EM)*, dan model ini diimplementasikan menggunakan paket R *NHMS-AR* (Monbet, 2022).

Pendekatan serupa kemudian diadopsi oleh Spezia et al. (2023) dalam konteks yang berbeda, yakni hidrologi, untuk menganalisis dinamika suhu air sungai di Skotlandia. Penelitian ini menerapkan metode *Non-Homogeneous Markov Switching Autoregressive Models (NHMS-AR)* pada tiga subset data dengan rentang waktu berbeda, menggunakan kombinasi variabel eksogen seperti debit aliran sungai, suhu udara, curah hujan, kecepatan dan arah angin, radiasi matahari, serta suhu tanah. Model ini dirancang untuk menangani kompleksitas deret waktu suhu air, termasuk non-linearitas, non-Normalitas, non-stasioneritas, dan memori panjang. Probabilitas transisi antar rezim tersembunyi dimodelkan sebagai fungsi logit dari kovariat eksogen, sehingga memungkinkan model menyesuaikan diri secara dinamis terhadap perubahan kondisi lingkungan. Implementasi model dilakukan dalam kerangka Bayesian menggunakan algoritma *Markov Chain Monte Carlo (MCMC)* untuk estimasi parameter, seleksi variabel, dan pemilihan model. *NHMS-AR* juga dimanfaatkan untuk merekonstruksi data suhu air, memperbaiki nilai yang hilang, serta mengklasifikasikan pengamatan ke dalam beberapa rezim tersembunyi dengan akurasi tinggi.

Berdasarkan uraian sebelumnya, penelitian ini akan mengkaji dan menerapkan metode *Non-Homogeneous Markov Switching Autoregressive (NHMS-AR)* dalam konteks ekonomi dan finansial, khususnya pada saham sektor energi di Indonesia. Data yang digunakan mencakup beberapa saham dalam sektor

energi yang tercatat di Bursa Efek Indonesia. Pemodelan dilakukan secara multivariat untuk menangkap dinamika bersama antar saham dalam sektor tersebut, sehingga memungkinkan identifikasi karakteristik dan pola pergerakan saham secara simultan. Selain mempertimbangkan variabel internal saham, penelitian ini juga akan memasukkan faktor eksternal yang bersifat makroekonomi sebagai kovariat tambahan, yaitu risiko geopolitik (*Geopolitical Risk/GPR*), ketidakpastian kebijakan ekonomi (*Economic Policy Uncertainty/EPU*), dan risiko iklim (*Climate Risk Index/CRI*). Ketiga faktor tersebut telah terbukti secara signifikan memengaruhi volatilitas pasar energi dan saham di berbagai negara (Hu & Borjigin, 2024), namun belum banyak diintegrasikan dalam model stokastik multivariat pada konteks saham energi di Indonesia. Oleh karena itu, penelitian ini diharapkan dapat memberikan kontribusi dalam memahami pengaruh gabungan faktor internal dan eksternal terhadap pergerakan saham sektor energi, serta menghasilkan model prediktif yang lebih adaptif terhadap dinamika pasar yang kompleks dan fluktuatif, termasuk perubahan antar rezim yang tidak teramati secara langsung (*hidden regime Switching*).

1.2 Rumusan Masalah

Berdasarkan hal yang telah diuraikan sebelumnya, maka permasalahan yang diselesaikan dalam penelitian ini adalah sebagai berikut.

1. Bagaimana karakteristik data saham sektor energi di Indonesia?
2. Bagaimana pemodelan saham sektor energi menggunakan *Homogeneous Markov Switching Autoregressive (HMS-AR)*?
3. Bagaimana pemodelan saham sektor energi menggunakan *Non-Homogeneous Markov Switching Autoregressive (NHMS-AR)*?
4. Bagaimana hasil evaluasi model *NHMS-AR* dalam memodelkan saham sektor energi?

1.3 Tujuan

Berdasarkan rumusan masalah di atas, tujuan yang ingin dicapai dalam penelitian ini adalah sebagai berikut.

1. Menganalisis karakteristik data dari saham sektor energi di Indonesia.

2. Memodelkan saham sektor energi menggunakan *Homogeneous Markov Switching Autoregressive (HMS-AR)*.
3. Memodelkan saham sektor energi menggunakan *Non-Homogeneous Markov Switching Autoregressive (NHMS-AR)*.
4. Mengevaluasi kinerja model *NHMS-AR* dalam memodelkan saham sektor energi.

1.4 Manfaat

Penelitian ini diharapkan memberikan manfaat baik secara teoritis maupun praktis, khususnya dalam analisis investasi di sektor energi menggunakan pendekatan *Non-Homogeneous Markov Switching Autoregressive (NHMS-AR)*.

1. Manfaat Teoritis

- a. Menambah wawasan akademik mengenai penerapan model *NHMS-AR* dalam pemodelan saham, terutama dalam mengidentifikasi perubahan rezim dan dinamika volatilitas pada sektor energi.
- b. Memberikan pemahaman yang lebih komprehensif mengenai analisis *time series* yang melibatkan pengaruh faktor eksternal terhadap probabilitas transisi rezim saham sektor energi di Indonesia.
- c. Memberikan kontribusi pada literatur keuangan terkait penggunaan model *NHMS-AR* sebagai alternatif metode untuk memahami pola pergerakan harga saham dan responnya terhadap variabel makroekonomi dan geopolitik.
- d. Menjadi referensi bagi penelitian selanjutnya, khususnya yang berkaitan dengan penerapan model *Markov Switching* dan model *time series* nonlinier dalam analisis pasar modal.

2. Manfaat Praktis

- a. Bagi Investor: Memberikan informasi mengenai perilaku volatilitas saham sektor energi serta membantu pengambilan keputusan investasi berbasis analisis risiko dan pengaruh faktor eksternal seperti harga komoditas dan indikator sentimen global.
- b. Bagi Analis Keuangan dan Manajer Portofolio: Penelitian ini menyediakan metode analisis yang lebih akurat untuk memprediksi pergerakan saham,

mempertimbangkan faktor eksternal, dan mengoptimalkan portofolio investasi.

- c. Bagi Pemerintah dan Regulator Pasar Modal: Memberikan wawasan mengenai sensitivitas harga saham sektor energi terhadap kebijakan ekonomi, kondisi global, dan dinamika komoditas, sehingga dapat mendukung penyusunan kebijakan yang lebih efektif.
- d. Bagi Dunia Akademik dan Pendidikan: Menjadi sumber referensi dalam pengajaran dan penelitian studi ekonomi, statistika, dan keuangan, terutama terkait model *time series* adaptif dan analisis pasar modal berbasis pendekatan *Markov Switching*.

1.5 Batasan Masalah

Dalam penelitian ini, batasan-batasan masalah yang digunakan adalah sebagai berikut.

1. Penelitian ini menggunakan metode *Non-Homogeneous Markov Switching AutoRegressive (NHMS-AR)* untuk mengidentifikasi perubahan rezim dan menganalisis pengaruh faktor eksternal terhadap pergerakan harga saham sektor energi melalui sifat non-homogen matriks transisi *Markov Switching*nya.
2. Penelitian ini berfokus pada saham sektor energi yang terdaftar di Bursa Efek Indonesia (BEI).
3. Data saham yang digunakan adalah data bulanan.
4. Penelitian ini menggunakan data dalam rentang waktu tahun 2008 hingga 2024, untuk menangkap dinamika pergerakan saham dalam berbagai kondisi ekonomi.

(Halaman ini sengaja dikosongkan)

BAB II

TINJAUAN PUSTAKA

2.1 *Markov Chain*

Markov (1906) memperkenalkan konsep dasar *Markov chain* dalam makalah berbahasa Rusia yang dalam bahasa Inggris dikenal dengan judul *Extension of the Law of Large Numbers to Dependent Quantities*. Dengan latar belakang bahwa hukum bilangan besar umumnya hanya berlaku untuk variabel acak yang saling independen dan identik distribusinya (*i.i.d.*), *Markov* menunjukkan bahwa hukum tersebut tetap berlaku meskipun observasinya saling bergantung, asalkan ketergantungannya hanya terbatas pada satu nilai sebelumnya. Konsep ini melahirkan model probabilistik baru, dimana transisi antar keadaan hanya bergantung pada kondisi saat ini, bukan pada keseluruhan riwayat masa lalu. Sifat ini kemudian dikenal sebagai *Markov property*, dan secara matematis dinyatakan sebagai berikut:

$$P(X_t = x_t | X_{t-1}, X_{t-2}, \dots, X_0) = P(X_t = x_t | X_{t-1} = x_{t-1}) \quad (2.1)$$

Model *Markov chain* digambarkan melalui matriks probabilitas transisi, yang secara sistematis diperkenalkan oleh Kemeny dan Snell (1960) dalam buku *Finite Markov Chains*. Matriks transisi untuk suatu proses dengan M state dituliskan sebagai berikut:

$$\mathbf{P} = \begin{bmatrix} p_{11} & \cdots & p_{1j} & \cdots & p_{1M} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ p_{i1} & \cdots & p_{ij} & \cdots & p_{iM} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ p_{M1} & \cdots & p_{Mj} & \cdots & p_{MM} \end{bmatrix} \quad (2.2)$$

di mana setiap elemen $p_{ij} = P(X_t = j | X_{t-1} = i)$ menunjukkan probabilitas berpindah dari state i ke state j . Setiap baris matriks harus memenuhi dua sifat dasar, yaitu $p_{ij} \geq 0$, $\sum_{j=1}^M p_{ij} = 1$.

Sebagai ilustrasi, baris ke-1 dari matriks transisi $\mathbf{P}$ menunjukkan bahwa jika sistem saat ini berada pada *state* 1, maka p_{11} menyatakan probabilitas untuk tetap

berada di *state* 1, p_{12} menyatakan probabilitas untuk berpindah ke *state* 2, dan seterusnya. Demikian pula, baris ke-2 menunjukkan transisi dari *state* 2 ke *state* lain, di mana p_{21} menyatakan probabilitas berpindah dari *state* 2 ke *state* 1, p_{22} untuk tetap di *state* 2, dan seterusnya. Prinsip ini berlaku hingga baris ke- M , yang merepresentasikan transisi dari *state* M ke semua *state* 1, 2, ..., M pada waktu berikutnya.

Model yang telah dijelaskan sebelumnya merupakan bentuk dari *time-homogeneous Markov chain*, yaitu model dimana matriks probabilitas transisi bersifat tetap sepanjang waktu. Sebaliknya, *time-inhomogeneous Markov chain* adalah model dimana matriks probabilitas transisi berubah di setiap langkah waktu (Shen, 2013). Dalam model ini, transisi dari satu keadaan ke keadaan lain ditentukan oleh matriks $\mathbf{P}(t)$, sehingga probabilitas berpindah dari *state* i ke *state* j pada waktu t tidak selalu sama dari waktu ke waktu. Secara matematis, probabilitas transisi dalam *inhomogeneous Markov chain* dinyatakan sebagai:

$$P(X_t = j | X_{t-1} = i) = p_{ij}(t) \quad (2.3)$$

sedangkan matriks probabilitas transisi untuk waktu t , yaitu $\mathbf{P}^{(t)}$, dapat dinyatakan dalam bentuk:

$$\mathbf{P}(t) = [p_{ij}(t)] = \begin{bmatrix} p_{11}^{(t)} & \cdots & p_{1j}^{(t)} & \cdots & p_{1M}^{(t)} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ p_{i1}^{(t)} & \cdots & p_{ij}^{(t)} & \cdots & p_{iM}^{(t)} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ p_{M1}^{(t)} & \cdots & p_{Mj}^{(t)} & \cdots & p_{MM}^{(t)} \end{bmatrix} \quad (2.4)$$

dimana $p_{ij}(t)$ menyatakan probabilitas perpindahan dari *state* i ke *state* j bergantung pada waktu t . Model ini relevan ketika sistem berada dalam kondisi yang dinamis, dimana probabilitas transisi antar *state* berubah seiring waktu.

2.2 Model *AutoRegressive*

Model *AutoRegressive* (*AR*) pertama kali dikembangkan oleh Udny Yule pada tahun 1927 melalui makalahnya yang berjudul *On a Method of Investigating Periodicities in Disturbed Series, with Special Reference to Wolfer's Sunspot Numbers*. Dalam kajiannya, Yule menerapkan metode regresi untuk menganalisis

data jumlah bintik matahari Wolfer, dan menunjukkan bahwa nilai suatu variabel deret waktu pada saat ini dapat dijelaskan oleh nilai-nilainya pada waktu sebelumnya (Yule, 1927). Konsep ini menjadi dasar dari model *AR* yang digunakan secara luas dalam analisis deret waktu.

Wei (2006) menyatakan bahwa model *AR* merupakan model linier yang memprediksi nilai suatu variabel deret waktu saat ini berdasarkan nilai-nilai masa lalunya. Secara umum, model *AR* orde p , yang sering dilambangkan sebagai $AR(p)$, dirumuskan sebagai:

$$Y_t = c + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t \quad (2.5)$$

dimana,

Y_t : nilai variabel pada waktu t ,

c : intersep (konstanta),

$\phi_1, \phi_2, \dots, \phi_p$: parameter orde 1, 2, ..., p ,

$Y_{t-1}, \dots, Y_{t-p}$: nilai variabel pada periode waktu sebelumnya (*lagged values*),

$\varepsilon_t \sim N(0, \sigma^2)$: komponen kesalahan (*error term*) yang berdistribusi normal

dengan rata-rata nol dan varians σ^2 .

Jika proses stasioner ($(|\phi| < 1)$), mean tak bersyaratnya adalah sebagai berikut.

$$\begin{aligned} \mathbb{E}(Y_t) &= c + \phi_1 \mathbb{E}(Y_{t-1}) + \phi_2 \mathbb{E}(Y_{t-2}) + \dots + \phi_p \mathbb{E}(Y_{t-p}) + \mathbb{E}(\varepsilon_t) \\ \mu &= c + \phi_1 \mu + \phi_2 \mu + \dots + \phi_p \mu \\ \mu &= c + (\phi_1 + \phi_2 + \dots + \phi_p) \mu \\ \mu &= c + \left(\sum_{p=1}^P \phi_p \right) \mu \\ \mu \left(1 - \sum_{p=1}^P \phi_p \right) &= c \\ \mu &= \frac{c}{\left(1 - \sum_{p=1}^P \phi_p \right)} \end{aligned}$$

2.3 Model Markov Switching AutoRegressive (MS-AR)

Model *Markov Switching AutoRegressive* (MS-AR) pertama kali diperkenalkan oleh James D. Hamilton pada tahun 1989 melalui makalah berjudul *A New Approach to the Economic Analysis of Nonstationary Time Series and the*

Business Cycle. Model ini dikembangkan untuk menangkap perubahan struktur atau pergeseran rezim yang tidak dapat diamati secara langsung dalam data deret waktu, misalnya peralihan antara periode ekspansi dan resesi dalam perekonomian. Berbeda dengan model autoregresif yang mengasumsikan parameter tetap sepanjang waktu, *MS-AR* mengizinkan parameter berubah mengikuti suatu variabel rezim tersembunyi yang berdistribusi *Markov* (Hamilton, 1989).

Konsep dasar *MS-AR* menggabungkan dua elemen utama, yaitu model *AutoRegressive (AR)* dan proses *Markov*. Model *AR* menyatakan bahwa nilai suatu variabel pada waktu t dipengaruhi oleh nilai-nilai masa lalunya, sedangkan proses *Markov* digunakan untuk menggambarkan transisi stokastik antar rezim yang tidak dapat diamati secara langsung. Dengan menggabungkan keduanya, *MS-AR* mampu merepresentasikan dinamika deret waktu yang mengalami perubahan struktur dari satu fase ke fase lainnya.

Sebagai ilustrasi, Hamilton (1994a) menunjukkan bahwa ketika suatu proses mengalami perubahan struktur misalnya perubahan nilai rata-rata akibat kebijakan ekonomi maka data dapat digambarkan melalui dua model yang berbeda. Mengacu pada bentuk umum model $AR(p)$ pada Persamaan (2.5), dan dengan asumsi bahwa proses bersifat stasioner, konstanta pada model dapat dinyatakan sebagai fungsi dari mean proses dan koefisien autoregresif. Untuk mempermudah ilustrasi perubahan rata-rata antar periode, berikut ditunjukkan pada kasus sederhana $AR(1)$. Untuk periode sebelum perubahan, dengan μ_1 , model dapat diformulasikan sebagai:

$$\begin{aligned} Y_t &= c + \phi Y_{t-1} + \varepsilon_t \\ Y_t &= \mu_1 (1 - \phi) + \phi Y_{t-1} + \varepsilon_t \\ Y_t &= \mu_1 - \mu_1 \phi + \phi Y_{t-1} + \varepsilon_t \\ Y_t - \mu_1 &= \phi (Y_{t-1} - \mu_1) + \varepsilon_t \end{aligned} \tag{2.6}$$

sedangkan untuk periode setelah perubahan, dengan μ_2 , modelnya sebagai:

$$Y_t - \mu_2 = \phi (Y_{t-1} - \mu_2) + \varepsilon_t \tag{2.7}$$

dengan asumsi bahwa $\mu_2 < \mu_1$, yang menunjukkan bahwa *mean* setelah perubahan lebih rendah dibanding sebelumnya. Kedua model tersebut dapat menjelaskan dinamika masing-masing periode, namun tidak memadai untuk digunakan sebagai

model deret waktu jangka panjang karena tidak mengakomodasi kemungkinan bahwa rezim tersebut dapat kembali muncul.

MS-AR menyatukan kedua model tersebut melalui suatu variabel rezim tersembunyi S_t yang mengikuti proses *Markov*. Jika $S_t = 1$, maka sistem berada pada rezim 1; sedangkan jika $S_t = 2$, maka sistem berada pada rezim 2. Dengan demikian, kedua persamaan dapat dinyatakan secara umum sebagai:

$$Y_t - \mu_{S_t} = \phi(Y_{t-1} - \mu_{S_{t-1}}) + \varepsilon_t \quad (2.8)$$

di mana ini adalah model *MS-AR* orde 1, μ_{S_t} menunjukkan nilai *mean* yang sesuai dengan *regime* ke- S_t dan $\varepsilon_t \sim N(0, \sigma^2)$ adalah komponen *error* acak yang terdistribusi normal dengan rata-rata nol dan varians konstan σ^2 . Pada bentuk model ini, μ_{S_t} merepresentasikan nilai *mean* proses pada rezim ke- S_t . Sehingga, secara umum model *MS-AR* dengan orde p dan M rezim yaitu sebagai berikut.

$$Y_t = c_{S_t} + \sum_{p=1}^P \phi_{S_t, p} Y_{t-p} + \varepsilon_t \quad (2.9)$$

dengan $\varepsilon_t \sim N(0, \sigma^2)$. Pada Persamaan (2.9), S_t digunakan karena model didefinisikan secara umum dengan rezim laten. Indeks i digunakan setelah dilakukan pengkondisian pada rezim tertentu.

Selanjutnya, perubahan antar rezim dimodelkan melalui variabel laten S_t yang mengikuti proses *Markov* orde satu dengan probabilitas transisi sebagai berikut.

$$P(S_t = j | S_{t-1} = i) = p_{ij} \quad (2.11)$$

Dengan matriks transisi:

$$\mathbf{P} = [p_{ij}]_{M \times M} = \begin{pmatrix} p_{11} & p_{12} & \cdots & p_{1M} \\ p_{21} & p_{22} & \cdots & p_{2M} \\ \vdots & \vdots & \ddots & \vdots \\ p_{M1} & p_{M2} & \cdots & p_{MM} \end{pmatrix} \quad (2.12)$$

di mana M adalah jumlah rezim, setiap elemen p_{ij} menyatakan probabilitas berpindah dari rezim i ke rezim j , dan untuk setiap baris berlaku $\sum_{j=1}^M p_{ij} = 1$.

Inti dari model *MS-AR* adalah adanya perubahan parameter struktural seperti *mean*, koefisien autoregresif, dan varians error yang bergantung pada rezim tempat proses berada. Komponen autoregresif tetap menjelaskan ketergantungan linier pada nilai masa lalu dalam satu rezim, namun komponen *Markov Switching* memungkinkan terjadinya transisi antar rezim yang mencerminkan perubahan kondisi atau struktur data. Dengan demikian, *MS-AR* mampu menangkap pola dinamis dan nonlinear yang tidak dapat dijelaskan oleh model *AR* konvensional. Hamilton (1994b) kemudian memberikan formulasi yang lebih lengkap dan lebih banyak digunakan dalam penelitian modern. Meskipun terdapat dua bentuk penyajian model dalam bukunya, model tersebut bukan merupakan hasil transformasi dari model pertama, melainkan representasi yang berbeda untuk menjelaskan proses *Switching* secara lebih intuitif dan aplikatif.

2.4 Model *Non-Homogeneous Markov Switching AutoRegressive (NHMS-AR)*

Model *Markov Switching AutoRegressive (MS-AR)* merupakan pengembangan dari model *AutoRegressive (AR)* yang memperbolehkan parameter model berubah mengikuti suatu *state* atau *regime* yang tidak teramati secara langsung. Pendekatan ini diperkenalkan oleh Hamilton (1989) dalam analisis siklus bisnis, dan kemudian diformulasikan secara lebih sistematis dalam Hamilton (1994). Dalam model *MS-AR*, perubahan antar rezim mengikuti proses *Markov*, di mana probabilitas perpindahan antar rezim dianggap homogen, yaitu konstan sepanjang waktu dan tidak dipengaruhi oleh faktor eksternal. Asumsi ini sering tidak realistis terutama ketika fenomena yang diamati dipengaruhi oleh dinamika variabel eksogen.

Salah satu pengembangan dari model *MS-AR* adalah *Non-Homogeneous Markov Switching AutoRegressive (NHMS-AR)*, yang memungkinkan probabilitas transisi antar rezim bergantung pada kovariat eksternal melalui fungsi logistik atau fungsi lainnya (Ailliot et al., 2015; Monbet, 2022). Pendekatan ini mengatasi keterbatasan model *MS-AR* homogen, khususnya ketika data deret waktu menunjukkan pengaruh kuat dari variabel eksogen seperti risiko iklim, ketidakpastian ekonomi global, atau kondisi geopolitik. *NHMS-AR* dapat

menangani data deret waktu yang bersifat non-linear, non-normal, non-stasioner, serta memiliki *long memory*, sehingga sesuai untuk data keuangan dan energi yang sering menunjukkan ketidakstabilan struktural (Spezia et al., 2023).

Secara umum, model *NHMS-AR* merupakan perluasan dari *MS-AR* yang memungkinkan parameter model khususnya probabilitas transisi dan/atau struktur emisi dipengaruhi oleh kovariat eksternal Z_t . Pada model ini, proses observasi tetap mengikuti struktur autoregresif yang bergantung pada rezim tersembunyi S_t . Formulasi umum *NHMS-AR* dapat dinyatakan sebagai:

$$Y_t = c_{S_t} + \sum_{p=1}^P \phi_{S_t,p} Y_{t-p} + \varepsilon_t \quad (2.13)$$

dengan $\varepsilon_t \sim N(0, \sigma_{S_t}^2)$ dan S_t merupakan variabel rezim tersembunyi yang mengikuti proses *Markov* tidak homogen.

Keunggulan utama dari model *NHMS-AR* terletak pada fleksibilitasnya dalam menangkap dinamika data deret waktu yang kompleks serta kemampuannya mengakomodasi perubahan rezim yang dipengaruhi oleh variabel eksogen. Berbeda dengan model *MS-AR* homogen yang menggunakan probabilitas transisi konstan, *NHMS-AR* memungkinkan probabilitas tersebut berubah seiring waktu mengikuti nilai kovariat eksternal, sehingga memberikan representasi yang lebih realistis terhadap fenomena ekonomi dan keuangan yang sangat dipengaruhi oleh kondisi global. Selain itu, *NHMS-AR* mampu menangani data dengan karakteristik non-linearitas, non-normalitas, non-stasioneritas, serta pola *long memory*. Non-linearitas muncul ketika hubungan antar variabel tidak bersifat linier dan berbeda pada masing-masing rezim, sedangkan non-normalitas ditandai oleh distribusi data yang tidak simetris atau memiliki ekor panjang. Non-stasioneritas mengacu pada perubahan rata-rata dan varians sepanjang waktu, dan *long memory* mencerminkan adanya ketergantungan jangka panjang dari nilai-nilai masa lalu. Sifat-sifat ini umum ditemukan pada data keuangan dan energi, sehingga model *NHMS-AR* menjadi pilihan yang tepat untuk menganalisis perubahan rezim yang tidak dapat dijelaskan oleh model linear konvensional (Spezia et al., 2023).

Studi-studi sebelumnya, seperti penelitian hidrologi oleh Spezia et al. (2023) dan analisis siklus bisnis oleh Hamilton (1989), memberikan dasar teoretis yang

kuat bagi pengembangan dan penggunaan model berbasis *Markov Switching* dengan komponen non-homogen. Dengan memasukkan kovariat eksternal dalam struktur probabilitas transisi, *NHMS-AR* mampu memberikan pemahaman yang lebih mendalam terhadap dinamika rezim dan respons sistem terhadap perubahan lingkungan eksternal. Hal ini menjadikan *NHMS-AR* sebagai alat analisis yang kuat, terutama untuk sektor-sektor yang rentan terhadap guncangan eksternal, seperti pasar energi.

2.4.1 Model *HMS-AR*

Model *Homogeneous Markov Switching AutoRegressive (HMS-AR)* merupakan bentuk dasar dari keluarga model *Markov Switching AutoRegressive* yang pertama kali dikembangkan oleh Hamilton (1989). Pada model ini, parameter autoregresif dan karakteristik distribusi error diperbolehkan berubah sesuai rezim tersembunyi S_t , namun probabilitas transisi antar rezim diasumsikan konstan sepanjang waktu (*homogeneous*). Dengan demikian, perubahan rezim berlangsung secara stokastik mengikuti proses *Markov* orde pertama tanpa pengaruh variabel eksternal.

Secara umum, model *HMS-AR* mengikuti persamaan (2.9) dan perpindahan antar rezim dikendalikan oleh matriks transisi homogen seperti pada persamaan (2.11) dan persamaan (2.12). Dalam *HMS-AR*, semua bentuk ketidakseragaman (*non-homogeneity*) hanya berasal dari perbedaan parameter pada masing-masing rezim, bukan dari perubahan probabilitas transisi. Keterbatasan ini menjadi salah satu alasan munculnya model *Non-Homogeneous MS-AR (NHMS-AR)* yang memperbolehkan probabilitas transisi bergantung pada kovariat eksternal, sehingga mampu menangkap dinamika data yang lebih kompleks.

2.4.2 Model *NHTMS-AR*

Model *Non-Homogeneous Transition Markov Switching AutoRegressive (NHTMS-AR)* merupakan perluasan dari model *HMS-AR*. Perbedaan utama antara model *HMS-AR* dan *NHTMS-AR* terletak pada cara memodelkan probabilitas transisi antar rezim. Pada *HMS-AR*, probabilitas transisi p_{ij} bersifat *konstan* sepanjang waktu dan tidak dipengaruhi variabel eksternal. Sebaliknya, pada *NHTMS-AR*, probabilitas transisi bergantung pada kovariat eksternal Z_t , sehingga

menjadi dinamis dan dapat berubah setiap waktu mengikuti kondisi lingkungan. Probabilitas transisi untuk berpindah dari rezim i ke rezim j pada waktu t diberikan oleh:

$$P(S_t = j | S_{t-1} = i, Z_t) = q_{ij}(t) \quad (2.14)$$

di mana $q_{ij}(t)$ merupakan fungsi dari kovariat eksternal. Dengan demikian, matriks transisi menjadi bersifat *time-varying*:

$$Q(t) = [q_{ij}(t)] \quad (2.15)$$

dan berubah mengikuti dinamika kovariat eksternal.

Untuk menghubungkan kovariat dengan probabilitas transisi, digunakan fungsi *link* logit, yang mengubah kombinasi linear kovariat menjadi nilai probabilitas dalam rentang (0,1). Bentuk umum fungsi logit untuk probabilitas transisi didefinisikan sebagai:

$$\text{logit}(q_{ij}(t)) = \log\left(\frac{q_{ij}(t)}{1 - q_{ij}(t)}\right) = \alpha_{ij} + \beta_{ij}Z_t \quad (2.16)$$

dengan α_{ij} adalah *intercept* logit, menunjukkan kecenderungan dasar perpindahan dari rezim i ke rezim j tanpa pengaruh kovariat; β_{ij} adalah parameter sensitivitas kovariat, menentukan bagaimana perubahan variabel eksternal meningkatkan atau mengurangi peluang perpindahan rezim. Jika $\beta_{ij} > 0$ maka kenaikan kovariat meningkatkan probabilitas transisi. Sebaliknya $\beta_{ij} < 0$ maka variabel eksternal menekan atau menurunkan probabilitas transisi. Selanjutnya, Z_t adalah kovariat eksternal pada waktu t .

Hasil transformasi logit diubah kembali menjadi probabilitas dengan fungsi logistik (model dua rezim) sebagai berikut.

$$q_{ij}(t) = \frac{\exp(\alpha_{ij} + \beta_{ij}Z_t)}{1 + \exp(\alpha_{ij} + \beta_{ij}Z_t)} \quad (2.17)$$

dimana probabilitas berada dalam rezim selain j diperoleh sebagai $q_{il}(t) = 1 - q_{ij}(t)$, $l \neq j$. Untuk jumlah rezim lebih dari dua ($M > 2$), fungsi logit tidak lagi berbentuk logit biner, melainkan multinomial logit, sehingga probabilitas transisi dari rezim i ke rezim j dirumuskan sebagai berikut.

$$q_{ij}(t) = \frac{\exp(\alpha_{ij} + \beta_{ij}Z_t)}{\sum_{k=1}^M \exp(\alpha_{ik} + \beta_{ik}Z_t)} \quad (2.18)$$

dimana semua probabilitas transisi dalam baris ke- i tetap memenuhi sifat

$$\sum_{j=1}^M q_{ij}(t) = 1.$$

Dengan demikian, perubahan kovariat Z_t pada waktu t secara langsung memengaruhi besarnya probabilitas transisi. Ketika nilai suatu kovariat meningkat dan koefisien β_{ij} bernilai positif, peluang perpindahan dari rezim i ke rezim j juga meningkat. Sebaliknya, jika β_{ij} bernilai negatif, peningkatan kovariat akan menurunkan peluang perpindahan menuju rezim tersebut.

Probabilitas transisi $q_{ij}(t)$ yang telah dimodelkan dengan fungsi logit kemudian disusun ke dalam matriks transisi non-homogen. Berbeda dengan model *HMS-AR* yang menggunakan matriks transisi konstan $\mathbf{P} = (p_{ij})$, pada model *NHTMS-AR* matriks transisi bergantung pada waktu karena setiap elemennya dipengaruhi oleh kovariat eksternal Z_t . Untuk kasus dua rezim ($M = 2$), matriks transisi pada waktu t dituliskan sebagai berikut.

$$Q(t) = \begin{pmatrix} q_{11}(t) & q_{12}(t) \\ q_{21}(t) & q_{22}(t) \end{pmatrix} \quad (2.19)$$

dengan $q_{ij}(t) = P(S_t = j | S_{t-1} = i, Z_t)$, $i, j = 1, 2$. Setiap baris matriks $Q(t)$ merupakan vektor probabilitas, sehingga harus memenuhi sifat stokastik $q_{ij}(t) \geq 0$, $\sum_{j=1}^2 q_{ij}(t) = 1$, $i = 1, 2$. Secara umum, untuk jumlah rezim $M > 2$, matriks

transisi non-homogen memiliki bentuk sebagai berikut.

$$Q(t) = \begin{pmatrix} q_{11}(t) & q_{12}(t) & \cdots & q_{1M}(t) \\ q_{21}(t) & q_{22}(t) & \cdots & q_{2M}(t) \\ \vdots & \vdots & \ddots & \vdots \\ q_{M1}(t) & q_{M2}(t) & \cdots & q_{MM}(t) \end{pmatrix} \quad (2.20)$$

dengan $\sum_{j=1}^M q_{ij}(t) = 1$ untuk setiap i .

Kebergantungan setiap elemen $q_{ij}(t)$ terhadap kovariat Z_t membuat matriks $Q(t)$ mampu mencerminkan perubahan kondisi eksternal dari waktu ke waktu. Ketika nilai kovariat berubah, elemen-elemen dalam matriks transisi akan menyesuaikan, sehingga peluang bertahan dalam suatu rezim maupun berpindah ke rezim lain ikut berubah secara dinamis. Hal ini menjadi perbedaan mendasar antara model *NHTMS-AR* dan *HMS-AR* yang hanya menggunakan satu matriks transisi tetap sepanjang periode pengamatan.

Setelah probabilitas transisi non-homogen dirumuskan melalui fungsi logit dan disusun ke dalam matriks transisi $Q(t)$, langkah berikutnya adalah mendefinisikan model, yaitu bagaimana proses data Y_t didapatkan pada masing-masing rezim. Pada model *NHTMS-AR*, komponen autoregresif (*emission process*) bersifat homogen, yaitu tidak dipengaruhi oleh kovariat eksternal. Artinya, variabel eksogen hanya berpengaruh terhadap perpindahan rezim (*transition*), tetapi tidak memengaruhi struktur pembentukan nilai observasi dalam rezim tersebut. Model observasi *NHTMS-AR* dapat dituliskan sebagai berikut.

$$\mathbf{Y}_t = \mathbf{c}_{S_t} + \sum_{p=1}^P \Phi_{S_t,p} \mathbf{Y}_{t-p} + \boldsymbol{\varepsilon}_{S_t,t}, \quad t = 1, 2, \dots, T \quad (2.21)$$

Dengan :

- S_t : rezim tersembunyi pada waktu t , ditentukan oleh probabilitas transisi non-homogen $q_{ij}(t)$,
- $\mathbf{c}_{S_t}$: vektor intersep untuk rezim ke- S_t ,
- $\Phi_{S_t,p}$: matriks koefisien autoregresif orde ke- p pada rezim ke- S_t ,
- $\mathbf{Y}_{t-p}$: vektor nilai observasi pada lag ke- p ,
- $\boldsymbol{\varepsilon}_{S_t,t} \sim N(\mathbf{0}, \boldsymbol{\Sigma}_{S_t})$: vektor error Gaussian dengan kovarian yang berbeda antar rezim.

Dengan demikian, struktur nilai Y_t tetap mengikuti pola autoregresif biasa, tetapi parameter yang dipakai pada waktu t bergantung pada rezim S_t yang aktif.

Pemilihan rezim tersebut dipengaruhi oleh model transisi non-homogen melalui kovariat eksternal Z_t .

2.4.3 Model *NHEMS-AR*

Berbeda dengan *NHTMS-AR* yang memodifikasi probabilitas transisi antar rezim, pada model *Non-Homogeneous Emission Markov Switching AutoRegressive (NHEMS-AR)* perubahan terjadi pada struktur model, bukan pada perpindahan rezim. Dengan demikian, kovariat eksternal berperan langsung dalam membentuk dinamika Y_t melalui parameter emisi, sehingga perubahan faktor eksternal dapat menggeser atau memodifikasi respons sistem di dalam setiap rezim, tanpa memengaruhi mekanisme perpindahan rezim itu sendiri.

Tidak seperti model *NHTMS-AR*, pada *NHEMS-AR* probabilitas perpindahan antar rezim dianggap konstan dan tidak dipengaruhi oleh kovariat. Oleh karena itu, matriks transisi bersifat homogen dan dituliskan seperti pada persamaan (2.12). Artinya, kovariat eksternal tidak memiliki peran apa pun dalam menentukan peluang perpindahan rezim, sehingga rezim berganti hanya mengikuti probabilitas transisi konstan pada matriks P .

Selanjutnya, pada *NHEMS-AR*, dinamika observasi Y_t dipengaruhi oleh rezim tersembunyi S_t sekaligus oleh variabel kovariat Z_t . Kovariat eksternal masuk ke dalam proses emisi melalui suatu matriks koefisien yang secara langsung memodifikasi *average response* sistem di masing-masing rezim. Bentuk umum modelnya adalah sebagai berikut.

$$\mathbf{Y}_t = \mathbf{c}_{S_t} + \sum_{p=1}^P \Phi_{S_t,p} \mathbf{Y}_{t-p} + \Gamma_{S_t} \mathbf{Z}_t + \boldsymbol{\varepsilon}_{S_t,t}, \quad t = 1, 2, \dots, T \quad (2.22)$$

dengan:

- $\mathbf{c}_{S_t}$: vektor intersep pada rezim S_t .
- $\Phi_{S_t,p}$: matriks koefisien autoregresif lag ke- p pada rezim S_t ,
- Γ_{S_t} : matriks koefisien kovariat pada rezim S_t ,
- $\mathbf{Z}_t$: vektor kovariat eksternal pada waktu t ,
- $\boldsymbol{\varepsilon}_{S_t,t} \sim N(\mathbf{0}, \Sigma_{S_t})$: vektor error Gaussian pada rezim S_t .

Struktur ini menunjukkan bahwa perubahan pada variabel eksternal Z_t dapat menggeser nilai dari proses observasi, meskipun rezim tidak berubah. Dengan kata lain, model ini memungkinkan respons sistem beradaptasi secara langsung terhadap faktor eksternal, sementara mekanisme perpindahan rezim tetap stabil dan tidak dipengaruhi oleh kovariat.

2.4.4 Model *NHTEMS-AR*

Model *Non-Homogeneous Transition and Emission Markov Switching AutoRegressive (NHTEMS-AR)* merupakan bentuk paling lengkap dan fleksibel dari *Non-Homogeneous Markov Switching AutoRegressive (NHMS-AR)*. Pada model ini, kovariat eksternal Z_t tidak hanya berperan dalam menentukan peluang perpindahan rezim seperti pada *NHTMS-AR*, tetapi juga memengaruhi struktur proses observasi seperti pada *NHEMS-AR*. Dengan demikian, variabel eksogen memiliki dua fungsi sekaligus yaitu mengatur dinamika perpindahan rezim melalui probabilitas transisi yang bersifat *time-varying*, serta memengaruhi bentuk respons Y_t dalam masing-masing rezim. Pendekatan gabungan ini memungkinkan model menangkap pengaruh faktor eksternal secara lebih komprehensif, baik terhadap mekanisme perubahan rezim maupun terhadap respons sistem pada setiap rezim.

Pada komponen transisi, probabilitas berpindah dari rezim i ke rezim j dipengaruhi oleh kovariat eksternal melalui fungsi link (umumnya fungsi logit) seperti pada persamaan (2.16) yang setelah ditransformasikan kembali menjadi seperti persamaan (2.17) dan persamaan (2.18). Probabilitas transisi ini membentuk matriks transisi tak homogen seperti pada persamaan (2.19) dan persamaan (2.20) yang berubah-ubah mengikuti dinamika kovariat Z_t . Selain memengaruhi transisi, kovariat eksternal juga masuk secara langsung ke dalam fungsi emisi melalui struktur regresi yang bergantung pada rezim seperti pada persamaan (2.22).

Dengan demikian, perubahan nilai kovariat Z_t memberikan dua jenis pengaruh yang berbeda dalam model. Pertama, pada struktur rezim, kovariat menentukan besarnya probabilitas sistem untuk bertahan pada rezim yang sedang berlangsung atau berpindah ke rezim lainnya. Artinya, dinamika eksternal dapat menggeser peluang perubahan rezim, sehingga mekanisme transisi menjadi responsif terhadap kondisi yang berkembang. Kedua, kovariat juga memengaruhi

proses observasi Y_t di dalam masing-masing rezim. Meskipun rezim tidak berubah, variasi pada kovariat dapat mengubah nilai atau pola Y_t , karena parameter emisi menyesuaikan diri terhadap perubahan eksternal tersebut. Dengan cara ini, model menjadi lebih fleksibel dalam menggambarkan dinamika *return* yang dipengaruhi oleh faktor global.

Pada model *NHTEMS-AR*, keseluruhan proses dibangun dari dua komponen utama yang bekerja secara simultan, yaitu mekanisme perpindahan rezim yang dipengaruhi oleh kovariat eksternal melalui fungsi link pada probabilitas transisi, dan proses observasi Y_t yang juga bergantung pada kovariat melalui struktur emisi. Karena kedua komponen tersebut berinteraksi secara bersamaan dalam membentuk dinamika sistem, maka fungsi *complete-data likelihood* harus mempertimbangkan kontribusi keduanya secara terpadu. Bentuk umum fungsi *complete-data likelihood* model *NHMS-AR* dinyatakan sebagai:

$$L(\theta; Y, Z) = \prod_{t=1}^T P(Y_t | S_t, Z_t, \theta) \prod_{t=2}^T P(S_t | S_{t-1}, Z_t, \theta) \quad (2.23)$$

dengan:

$L(\theta; Y, Z)$: fungsi *complete-data likelihood* model *NHMS-AR*,

$Y = (Y_1, Y_2, \dots, Y_T)$: deret observasi,

$S = (S_1, S_2, \dots, S_T)$: urutan rezim tersembunyi,

Z_t : kovariat eksternal pada waktu t ,

θ : mencakup seluruh parameter model, termasuk parameter autoregresif, parameter emisi yang bergantung kovariat, matriks kovarian error, serta parameter fungsi link yang menentukan probabilitas transisi antar rezim.

Komponen $P(Y_t | S_t, \theta)$ mencerminkan peluang menghasilkan observasi Y_t pada rezim tertentu, sesuai dengan struktur emisi yang diizinkan berbeda antar rezim dan dapat dipengaruhi oleh kovariat pada model *Emission*. Sementara itu, komponen $P(S_t | S_{t-1}, Z_t, \theta)$ menggambarkan probabilitas perpindahan rezim dari waktu $t - 1$ ke waktu t . Pada model *NHTMS-AR* dan *NHTEMS-AR*, besar kecilnya

probabilitas ini ditentukan oleh kovariat melalui fungsi link (misalnya logit), sehingga perpindahan rezim bersifat non-homogen. Dengan mengalikan kedua komponen tersebut pada seluruh waktu pengamatan, fungsi *complete-data likelihood* memberikan landasan bagi proses estimasi parameter melalui metode maksimum *likelihood*. Struktur ini memungkinkan *NHMS-AR* menangkap dinamika kompleks yang muncul baik pada mekanisme perpindahan rezim maupun pada pola observasi di dalam rezim, sekaligus memperhitungkan pengaruh faktor eksternal secara penuh.

2.5 Expectation Maximization (EM)

Algoritma *Expectation–Maximization (EM)* merupakan metode estimasi parameter yang bekerja secara iteratif melalui dua tahap utama, yaitu *Expectation step (E-step)* dan *Maximization step (M-step)*, dengan tujuan memperoleh *Maximum Likelihood Estimator (MLE)*. Metode ini digunakan ketika model melibatkan variabel yang tidak dapat diamati secara langsung (*latent variables*). Dalam konteks model *Non-Homogeneous Markov Switching Autoregressive (NHMS-AR)*, variabel laten tersebut adalah rezim atau state tersembunyi yang dinotasikan sebagai S_t .

Algoritma EM pertama kali diperkenalkan oleh Baum, Petrie, Soules, dan Weiss (1970) dalam pengembangan *Hidden Markov Models (HMM)*, kemudian digeneralisasi oleh Dempster, Laird, dan Rubin (1977) sebagai kerangka estimasi umum untuk model dengan data tidak lengkap (*incomplete data*). Pada model *NHMS-AR*, data observasi deret waktu Y_t bergantung pada rezim tersembunyi S_t , sehingga fungsi *likelihood* tidak dapat dimaksimalkan secara langsung menggunakan pendekatan analitik konvensional. Oleh karena itu, algoritma *EM* digunakan sebagai pendekatan numerik untuk mengestimasi parameter model.

Berikut ini merupakan langkah-langkah Algoritma EM.

1. Inisialisasi parameter

Tentukan nilai awal untuk seluruh parameter model sebagai berikut.

$$\theta^{(0)} = \{\mathbf{c}, \Phi, \Gamma, \Sigma, \Pi, \pi\}, \quad (2.24)$$

yang meliputi,

- $\mathbf{c}$: vektor intersep pada masing-masing rezim,
- Φ : matriks parameter autoregresif untuk seluruh rezim dan lag,
- Γ : matriks parameter kovariat pada komponen emisi (jika *NHEMS-AR*),
- Π : matriks parameter probabilitas transisi,
- Σ : matriks kovarian error pada masing-masing rezim,
- π : vektor probabilitas awal rezim.

2. *Expectation Step (E-step)*

Pada tahap *Expectation Step (E-step)*, tujuan utama adalah menghitung ekspektasi dari *log-likelihood complete-data* dengan mempertimbangkan ketidakpastian pada variabel laten rezim S_t . Karena rezim tidak dapat diamati secara langsung, maka perhitungan ekspektasi dilakukan berdasarkan distribusi posterior rezim yang diperoleh dari data pengamatan dan parameter model pada iterasi sebelumnya.

Sebagai langkah awal, dibentuk *likelihood* emisi yang menyatakan peluang observasi pada waktu t apabila sistem berada pada rezim tertentu. *Likelihood* ini digunakan untuk mengukur tingkat kecocokan data terhadap masing-masing rezim.

$$f(Y_t | S_t = j, Z_t, \theta) \quad (2.25)$$

Dengan mempertimbangkan probabilitas transisi antar rezim, *complete-data likelihood* pada model *Markov Switching* dapat dinyatakan sebagai berikut.

$$L_c(\theta) = \prod_{t=1}^T f(Y_t | S_t, Z_t, \theta) \prod_{t=2}^T P(S_t | S_{t-1}, Z_t, \theta) \quad (2.26)$$

Karena rezim S_t tidak diketahui, maka digunakan pendekatan probabilistik dengan menghitung probabilitas posterior rezim, yaitu peluang sistem berada pada rezim tertentu dengan mempertimbangkan seluruh data pengamatan.

$$\gamma_t(i) = P(S_t = i | Y_{1:T}, Z_{1:T}, \theta^{(k)}) \quad (2.27)$$

Selain itu, untuk keperluan estimasi parameter transisi, dihitung pula probabilitas posterior bersama dua rezim berurutan:

$$\xi_t(i, j) = P(S_{t-1} = i, S_t = j | Y_{1:T}, Z_{1:T}, \theta^{(k)}) \quad (2.28)$$

Kedua probabilitas tersebut diperoleh melalui rekursi *forward-backward*, yang merupakan perluasan dari algoritma *Baum-Welch* untuk *HMM* (Baum et al., 1970). Implementasi khusus untuk *MS-AR* homogen dibahas oleh Hamilton (1990), sementara pengembangannya untuk model non-homogen dijelaskan oleh Hughes et al. (1999) dan Cappe et al. (2005). Berdasarkan probabilitas posterior rezim yang diperoleh, langkah *E-step* dilanjutkan dengan menghitung ekspektasi dari *complete-data likelihood* terhadap distribusi posterior variabel laten rezim. Ekspektasi ini dirumuskan sebagai:

$$Q(\theta | \theta^{(k)}) = \mathbb{E}_{S|Y,Z,\theta^{(k)}} [\log L_c(\theta)] \quad (2.29)$$

$$Q(\theta | \theta^{(k)}) = \sum_{i=1}^M \sum_{t=1}^T \gamma_t(i) \log f(Y_t | S_t = i, Z_t, \theta) + \sum_{i=1}^M \sum_{j=1}^M \sum_{t=2}^T \xi_t(i, j) \log P(S_t = j | S_{t-1} = i, Z_t, \theta) \quad (2.30)$$

Ekspektasi *log-likelihood* ini merepresentasikan kontribusi data terhadap masing-masing rezim secara probabilistik dan menjadi dasar bagi pembaruan parameter pada tahap *Maximization Step (M-step)*.

3. *Maximization Step (M-step)*

Pada tahap *Maximization Step (M-step)*, parameter model diperbarui dengan cara memaksimalkan fungsi ekspektasi *log-likelihood*:

$$\theta^{(k+1)} = \arg \max_{\theta} Q(\theta | \theta^{(k)}) \quad (2.31)$$

Karena $Q(\theta | \theta^{(k)})$ tersusun atas komponen emisi dan transisi, maka pembaruan parameter dilakukan dengan memaksimalkan masing-masing komponen tersebut. Parameter yang diperbarui pada tahap *Maximization Step (M-step)* menyesuaikan dengan spesifikasi model yang digunakan, yaitu *HMS-AR*, *NHTMS-AR*, *NHEMS-AR*, dan *NHTEMS-AR*.

Pembaruan parameter emisi, karena rezim tidak diketahui, setiap pengamatan pada waktu t berkontribusi ke rezim i dengan bobot probabilitas posterior rezim pada persamaan (2.27). Dengan demikian, estimasi $\mu_i, \Phi_{i,p}, \Gamma_i$ dapat

dipandang sebagai regresi berbobot (*weighted least squares*) untuk masing-masing rezim. Definisikan vektor regresor sebagai berikut.

$$\mathbf{x}_t = \begin{bmatrix} 1 \\ \mathbf{Y}_{t-1} \\ \vdots \\ \mathbf{Y}_{t-p} \\ \mathbf{Z}_t \end{bmatrix}, \quad \mathbf{B}_i = \begin{bmatrix} \mathbf{c}_i \\ \boldsymbol{\Phi}_{i,1} \\ \vdots \\ \boldsymbol{\Phi}_{i,p} \\ \boldsymbol{\Gamma}_i \end{bmatrix} \quad (2.32)$$

sehingga $Y_t \approx \mathbf{B}_i^T \mathbf{x}_t$ pada rezim i .

Maka pembaruan parameter emisi pada iterasi ke- $k+1$ adalah

$$\mathbf{B}_i^{(k+1)} = \left(\sum_{t=1}^T \gamma_t(i) \mathbf{x}_t \mathbf{x}_t^T \right)^{-1} \left(\sum_{t=1}^T \gamma_t(i) \mathbf{x}_t Y_t \right) \quad (2.33)$$

Dari $\mathbf{B}_i^{(k+1)}$ ini, didapatkan $\boldsymbol{\mu}_i^{(k+1)}, \boldsymbol{\Phi}_{i,p}^{(k+1)}, \boldsymbol{\Gamma}_i^{(k+1)}$.

Definisikan residual berbobot,

$$\boldsymbol{\varepsilon}_{i,t}^{(k+1)} = \mathbf{Y}_t - \mathbf{c}_i^{(k+1)} - \sum_{p=1}^P \boldsymbol{\Phi}_{i,p}^{(k+1)} \mathbf{Y}_{t-p} - \boldsymbol{\Gamma}_i^{(k+1)} \mathbf{Z}_t \quad (2.34)$$

Maka kovarian error diperbarui sebagai

$$\boldsymbol{\Sigma}_i^{(k+1)} = \frac{\sum_{t=1}^T \gamma_t(i) \boldsymbol{\varepsilon}_{i,t}^{(k+1)} \boldsymbol{\varepsilon}_{i,t}^{(k+1)T}}{\sum_{t=1}^T \gamma_t(i)}. \quad (2.35)$$

Pembaruan probabilitas awal rezim adalah sebagai berikut.

$$\pi_i^{(k+1)} = \gamma_1(i) \quad (2.36)$$

Jika transisi homogen (konstan terhadap waktu), maka peluang transisi diperbarui dari ekspektasi jumlah transisi sebagai berikut.

$$p_{ij}^{(k+1)} = \frac{\sum_{t=2}^T \xi_t(i, j)}{\sum_{t=2}^T \sum_{l=1}^M \xi_t(i, l)} = \frac{\sum_{t=2}^T \xi_t(i, j)}{\sum_{t=2}^T \gamma_{t-1}(i, j)} \quad (2.37)$$

Jika transisi bergantung kovariat Z_t , maka $P(S_t = j | S_{t-1} = i, Z_t)$ tidak lagi berupa p_{ij} , melainkan fungsi parameter. Pada kondisi ini, pembaruan parameter transisi diperoleh dengan memaksimalkan komponen transisi dari Q sebagai berikut.

$$\max \sum_{i=1}^M \sum_{j=1}^M \sum_{t=2}^T \xi_t(i, j) \log P(S_t = j | S_{t-1} = i, Z_t, \theta) \quad (2.38)$$

4. Perhitungan *Log-Likelihood*

Setelah parameter diperbarui menjadi $\theta^{(k+1)}$ pada tahap *M-step*, nilai *log-likelihood* data observasi dihitung untuk memantau peningkatan kecocokan model pada setiap iterasi EM. *Log-likelihood* data observasi didefinisikan sebagai:

$$\ell(\theta) = \log L(\theta; Y, Z) = \log P(Y_{1:T} | Z_{1:T}, \theta) \quad (2.39)$$

Karena variabel rezim S_t tidak teramati, perhitungan $P(Y_{1:T} | Z_{1:T}, \theta)$ dilakukan menggunakan prosedur *forward*. Definisikan peluang *forward*:

$$a_t(j) = P(Y_{1:t}, S_t = j | Z_{1:t}, \theta), \quad j = 1, \dots, M. \quad (2.40)$$

Dengan mendefinisikan *likelihood* emisi $f(Y_t | S_t = j, Z_t, \theta)$, rekursi *forward* dapat dituliskan sebagai:

Inisialisasi ($t = 1$)

$$a_1(j) = \pi_j f(Y_1 | S_1 = j, Z_1, \theta) \quad (2.41)$$

Rekursi ($t = 2, \dots, T$)

$$a_t(j) = f(Y_t | S_t = j, Z_t, \theta) \sum_{i=1}^M a_{t-1}(i) P(S_t = j | S_{t-1} = i, Z_t, \theta) \quad (2.42)$$

Sehingga *likelihood* data observasi adalah:

$$L(\theta, Y, Z) = \sum_{j=1}^M a_T(j) \quad (2.43)$$

$$\ell(\theta) = \log \left(\sum_{j=1}^M a_T(j) \right) \quad (2.44)$$

5. Pemeriksaan konvergensi

Algoritma EM dijalankan secara iteratif sampai memenuhi kriteria konvergensi. Kriteria yang umum digunakan adalah berdasarkan perubahan *log-likelihood* antar iterasi, yaitu:

$$\left| \ell(\theta^{(k+1)}) - \ell(\theta^{(k)}) \right| < \delta \quad (2.45)$$

Dengan $\delta > 0$ merupakan toleransi konvergensi.

Jika kriteria konvergensi belum terpenuhi dan iterasi belum mencapai batas maksimum $K_{\max}$, maka proses kembali ke tahap *E-step* dengan menggunakan parameter terbaru $\theta^{(k+1)}$.

2.6 *Symmetric Mean Absolute Percentage Error (SMAPE)*

Symmetric Mean Absolute Percentage Error (SMAPE) merupakan salah satu ukuran akurasi yang banyak digunakan untuk mengevaluasi kinerja model peramalan, khususnya pada data deret waktu. *SMAPE* mengukur tingkat kesalahan prediksi dalam bentuk persentase dengan membandingkan selisih absolut antara nilai aktual dan nilai prediksi terhadap rata-rata absolut keduanya, sehingga bersifat simetris dan tidak bergantung pada skala data (S. G. Makridakis et al., 1998).

Berbeda dengan *Mean Absolute Percentage Error (MAPE)*, *SMAPE* dirancang untuk mengatasi permasalahan ketidakstabilan error ketika nilai aktual mendekati nol. Dengan menggunakan rata-rata antara nilai aktual dan nilai prediksi sebagai penyebut, *SMAPE* memberikan penalti kesalahan yang lebih seimbang dan mengurangi bias yang sering muncul pada *MAPE* (Hyndman & Athanasopoulos, 2021).

SMAPE dirumuskan sebagai berikut:

$$SMAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Y_t - \hat{Y}_t|}{\left(\frac{|Y_t| + |\hat{Y}_t|}{2} \right)} \times 100\% \quad (2.46)$$

dengan:

Y_t menyatakan nilai aktual pada periode ke- t ,

$\hat{Y}_t$ menyatakan nilai hasil prediksi,

n merupakan jumlah observasi.

Nilai *SMAPE* yang semakin kecil menunjukkan tingkat akurasi model yang semakin baik. Oleh karena itu, *SMAPE* sering digunakan sebagai kriteria pembandingan antar model peramalan, terutama pada data keuangan dan ekonomi yang bersifat fluktuatif dan memiliki kemungkinan nilai mendekati nol (S. Makridakis et al., 2018)

2.7 Paket NHMSAR

Model *Non-Homogeneous Markov Switching AutoRegressive (NHMS-AR)* merupakan pengembangan dari model *Markov Switching AutoRegressive (MS-AR)* yang memungkinkan probabilitas transisi dan/atau struktur emisi dipengaruhi oleh kovariat eksternal (*time-varying*). Estimasi model dalam penelitian ini dilakukan menggunakan paket NHMSAR pada perangkat lunak R, yang dikembangkan oleh Ailliot dan Monbet (2015). Paket ini dirancang untuk mengestimasi model *MS-AR* dalam bentuk homogen maupun non-homogen, baik untuk data univariat maupun multivariat.

Paket NHMSAR menyediakan fungsi-fungsi utama seperti `init.theta.MSAR()` untuk inisialisasi parameter awal model berdasarkan jumlah rezim, orde *AR*, dan spesifikasi *non-homogeneous*; `fit.MSAR()` untuk melakukan estimasi parameter menggunakan metode *Maximum Likelihood Estimation (MLE)* melalui algoritma *Expectation–Maximization (EM)*; `prediction.MSAR()` untuk menghasilkan nilai prediksi dan menghitung ukuran akurasi seperti *SMAPE*. Selain itu, paket ini juga menghasilkan keluaran tambahan berupa matriks transisi, intersep, matriks koefisien autoregresif, parameter transisi, parameter emisi, serta probabilitas *smoothed* untuk masing-masing rezim.

Model yang digunakan dalam penelitian ini merupakan model dua rezim ($M = 2$), dengan asumsi bahwa pasar saham sektor energi dapat berada pada salah satu dari dua kondisi utama, yaitu:

1. Rezim 1 (*Low Volatility Regime*), yang merepresentasikan periode stabil dengan fluktuasi *return* relatif rendah, dan
2. Rezim 2 (*High Volatility Regime*), yang menggambarkan periode dengan ketidakpastian lebih tinggi dan pergerakan harga yang lebih tajam.

Estimasi dilakukan terhadap *return* logaritmik bulanan dari tiga emiten saham sektor energi (PGAS, ADRO, dan MEDC) yang disusun dalam bentuk matriks *Y*. Variabel eksogen berupa *Climate Risk Index (CRI)*, *Geopolitical Risk (GPR)*, dan *Global Economic Policy Uncertainty (GEPU)* dihimpun dalam matriks *Z* dan digunakan sebagai kovariat yang memengaruhi struktur *non-homogeneous* pada

model, baik pada komponen transisi, emisi, maupun keduanya, sesuai dengan spesifikasi model yang diestimasi.

Secara umum, paket NHMSAR digunakan untuk mengestimasi parameter $\theta = \{\mathbf{c}, \Phi, \Gamma, \Sigma, \Pi, \pi\}$, yang mencakup parameter emisi dan parameter transisi rezim pada model *HMS-AR*, *NHTMS-AR*, *NHEMS-AR*, dan *NHTEMS-AR*. Langkah-langkah estimasi model dengan paket NHMSAR dilakukan sebagai berikut.

1. Inisialisasi Parameter Awal

Tahap awal dalam estimasi model adalah pembentukan nilai awal parameter $\theta^{(0)}$, sebagaimana didefinisikan pada persamaan *complete-data likelihood* dan algoritma EM. Parameter awal ini mencakup intersep rezim $\mathbf{c}_{s_t}$, koefisien autoregresif $\Phi_{s_t, p}$, matriks koefisien kovariat Γ_{s_t} (jika digunakan), matriks kovarian error Σ_{s_t} , serta probabilitas transisi rezim Π .

Inisialisasi parameter dilakukan menggunakan fungsi `init.theta.MSAR()`. Fungsi ini menghasilkan nilai awal parameter emisi yang sesuai dengan formulasi model emisi pada persamaan (2.22), serta nilai awal parameter transisi yang sesuai dengan struktur probabilitas transisi pada persamaan (2.16)–(2.20). Penentuan tipe model (*HMS-AR*, *NHTMS-AR*, *NHEMS-AR*, atau *NHTEMS-AR*) pada tahap ini menentukan parameter mana saja yang akan diestimasi pada tahap selanjutnya.

2. Estimasi parameter model

Setelah nilai awal parameter diperoleh, estimasi parameter dilakukan menggunakan fungsi `fit.MSAR()`. Fungsi ini menggunakan pendekatan *Maximum Likelihood Estimation (MLE)* yang dioptimalkan dengan algoritma *Expectation–Maximization (EM)*. Pada setiap iterasi ke- k , fungsi melakukan *E-step* dan *M-step*. Fungsi *E-step* yaitu menghitung probabilitas posterior rezim $\gamma_i(i)$ dan probabilitas posterior transisi $\xi_i(i, j)$ sebagaimana dirumuskan pada persamaan (2.27)–(2.30). Fungsi *M-step* yaitu memperbarui parameter model dengan memaksimalkan fungsi ekspektasi *log-likelihood* $Q(\theta | \theta^{(k)})$ sesuai dengan pembaruan parameter emisi dan transisi yang telah dijelaskan pada persamaan (2.31)–(2.38). Dengan demikian, fungsi `fit.MSAR()` secara langsung merealisasikan prosedur estimasi parameter

pada model *NHMS-AR* yang berbasis EM. Hasil estimasi model yang diperoleh dari `fit.MSAR()` mencakup parameter emisi dan transisi yang telah diperbarui hingga konvergen. Selain itu, *package* NHMSAR juga menghasilkan probabilitas smoothed rezim yang tersimpan dalam objek `theta$smoothedprob`.

3. Evaluasi hasil estimasi dan akurasi model

Setelah parameter model *NHMS-AR* diestimasi hingga konvergen, tahap selanjutnya adalah mengevaluasi kemampuan model dalam memprediksi. Dalam *package* NHMSAR, proses prediksi ini diimplementasikan melalui fungsi `prediction.MSAR()`. Fungsi ini menggunakan parameter hasil estimasi θ , probabilitas transisi rezim, serta probabilitas posterior rezim untuk menghasilkan nilai prediksi *return* sesuai dengan formulasi ekspektasi bersyarat di atas. Dengan demikian, fungsi `prediction.MSAR()` secara langsung merepresentasikan proses prediksi teoritis pada model *NHMS-AR*. Kinerja prediksi model dievaluasi menggunakan ukuran kesalahan prediksi, yaitu *Symmetric Mean Absolute Percentage Error (SMAPE)* menggunakan persamaan (2.46). Nilai *SMAPE* digunakan untuk membandingkan kinerja prediksi antara model *HMS-AR*, *NHTMS-AR*, *NHEMS-AR*, dan *NHTEMS-AR*. Model dengan nilai *SMAPE* paling kecil dipilih sebagai model terbaik dalam merepresentasikan dinamika *return* saham sektor energi.

(Halaman ini sengaja dikosongkan)

BAB III

METODOLOGI PENELITIAN

Penelitian ini berfokus pada kajian teori mengenai *Non-Homogeneous Markov Switching AutoRegressive (NHMS-AR)* dan penerapannya pada data *real*.

3.1 Sumber Data

Data yang digunakan merupakan data sekunder berupa *return* bulanan dari saham-saham sektor energi di Indonesia, yaitu PT Perusahaan Gas Negara Tbk (PGAS), PT Alamtri Resources Indonesia Tbk (ADRO), dan PT Medco Energi Internasional Tbk (MEDC). Data diperoleh dari situs resmi penyedia informasi keuangan <https://finance.yahoo.com> dalam bentuk harga penutupan yang disesuaikan (*adjusted close*), yang kemudian diolah menjadi *return* logaritmik bulanan. Periode pengamatan yang digunakan adalah September 2008 hingga Desember 2024.

Selain data *return* saham, penelitian ini juga memasukkan variabel eksogen yang diduga memengaruhi dinamika pasar energi, yaitu *Geopolitical Risk Index* (GPR) dan *Global Economic Policy Uncertainty Index* (GEPU) yang diperoleh dari sumber resmi policyuncertainty.com, serta *Climate Risk Index* (CRI) yang diperoleh dari <https://www.emdat.be/>.

3.2 Variabel Penelitian

Penelitian ini menggunakan tiga variabel utama berupa *return* saham bulanan dari perusahaan sektor energi yang terdaftar di Bursa Efek Indonesia, yaitu PT Perusahaan Gas Negara Tbk (PGAS), PT Alamtri Resources Indonesia Tbk (ADRO), dan PT Medco Energi Internasional Tbk (MEDC). Ketiga variabel tersebut direpresentasikan dalam bentuk data deret waktu (*time series*) dan diolah menjadi *return* logaritmik bulanan berdasarkan harga penutupan yang disesuaikan (*adjusted close*).

Selain itu, penelitian ini juga menyertakan tiga variabel eksogen yang berperan sebagai faktor eksternal yang memengaruhi dinamika *return* saham, yaitu *Geopolitical Risk Index* (GPR), *Global Economic Policy Uncertainty Index*

(GEPU), dan *Climate Risk Index* (CRI). Berikut ini merupakan struktur data yang digunakan pada penelitian.

Tabel 3. 1 Struktur Data

t	Y_1	Y_2	Y_3	Z_1	Z_2	Z_3
1	Y_{11}	Y_{21}	Y_{31}	Z_{11}	Z_{21}	Z_{31}
2	Y_{12}	Y_{22}	Y_{32}	Z_{12}	Z_{22}	Z_{32}
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
t	Y_{1t}	Y_{2t}	Y_{3t}	Z_{1t}	Z_{2t}	Z_{3t}

Keterangan :

t : Indeks waktu dalam satuan bulanan

Y_1 : *Return* saham PGAS (PT Perusahaan Gas Negara Tbk)

Y_2 : *Return* saham ADRO (PT Alamtri Resources Indonesia Tbk)

Y_3 : *Return* saham MEDC (PT Medco Energi Internasional Tbk)

Z_1 : Variabel eksogen CRI (*Climate Risk Index*)

Z_2 : Variabel eksogen GPR (*Geopolitical Risk Index*)

Z_3 : Variabel eksogen GEPU (*Global Economic Policy Uncertainty Index*)

Y_{it} : Nilai *return* saham ke- i pada periode ke- t

Z_{jt} : Nilai variabel eksogen ke- j pada periode ke- t

3.3 Langkah Analisis

Langkah analisis disusun untuk menggambarkan tahapan penelitian yang dilakukan secara sistematis dan berurutan, mulai dari perumusan masalah hingga penarikan kesimpulan. Adapun tahapan analisis dalam penelitian ini adalah sebagai berikut.

1. Merumuskan masalah dan melakukan studi literatur.
2. Melakukan kajian teori.
3. Melakukan pengumpulan dan *preprocessing data*, termasuk menghitung *return* logaritmik bulanan dari data harga saham.

Return logaritmik bulanan dihitung berdasarkan harga penutupan saham yang disesuaikan dengan rumus:

$$Y_{it} = \ln \left(\frac{P_{it}}{P_{i,t-1}} \right) \quad (3.1)$$

Keterangan :

Y_{it} : Nilai *return* saham ke- i pada periode ke- t

P_{it} : Harga penutupan saham ke- i pada periode ke- t .

$P_{i,t-1}$: Harga penutupan saham ke- i pada periode ke- $t-1$.

4. Melakukan analisis deskriptif untuk mengidentifikasi karakteristik data *return* saham sektor energi dan variabel eksogen.
5. Memodelkan saham sektor energi

Tahap pemodelan dilakukan dengan menetapkan jumlah rezim sebanyak dua rezim, yang merepresentasikan kondisi pasar dengan volatilitas rendah dan volatilitas tinggi. Setiap model diestimasi melalui algoritma *Expectation–Maximization (EM)*. Secara umum, tahapan estimasi model pada setiap spesifikasi adalah sebagai berikut:

- a. Menentukan nilai awal parameter model $\theta^{(0)} = \{\mathbf{c}, \Phi, \Gamma, \Sigma, \Pi, \pi\}$.
- b. Melakukan langkah *Expectation (E-step)*, yaitu menghitung ekspektasi *log-likelihood* $Q(\theta | \theta^{(k)})$ sesuai persamaan (2.29) dan persamaan (2.30).
- c. Melakukan langkah *Maximization (M-step)*, yaitu memperbarui parameter model dengan memaksimalkan fungsi ekspektasi *log-likelihood* sesuai pada persamaan (2.31).
- d. Melakukan perhitungan *log-likelihood* sesuai persamaan (2.39).
- e. Melakukan pemeriksaan konvergensi dimana iterasi *E-step* dan *M-step* dilakukan secara berulang hingga nilai *log-likelihood* memenuhi kriteria konvergensi sebagaimana ditetapkan pada persamaan (2.45), setelah itu diperoleh parameter model.


Berdasarkan tahapan tersebut, pemodelan dilakukan untuk masing-masing spesifikasi model. *HMS-AR*, sebagai model dasar dengan probabilitas transisi rezim yang bersifat homogen. *NHTMS-AR*, dengan probabilitas transisi rezim yang bergantung pada variabel eksogen. *NHEMS-AR*, dengan variabel eksogen dimasukkan pada struktur emisi tanpa memengaruhi probabilitas

transisi. *NHTEMS-AR*, dengan variabel eksogen memengaruhi baik probabilitas transisi maupun struktur emisi.


6. Melakukan evaluasi kinerja model dengan menghitung nilai kesalahan prediksi menggunakan ukuran *Symmetric Mean Absolute Percentage Error (SMAPE)* sebagaimana dirumuskan pada persamaan (2.46).
7. Melakukan analisis dan interpretasi hasil.
8. Menarik kesimpulan dan saran.

3.4 Diagram Alir

Diagram alir menggambarkan alur perjalanan pembuatan laporan ini, mulai dari proses perumusan masalah dan *studi literature* hingga penarikan kesimpulan dan saran. Diagram alir dari langkah analisis pada penelitian ini adalah sebagai berikut.



Gambar 3. 1 Diagram Alir Penelitian



Gambar 3. 1 Diagram Alir Penelitian (Lanjutan)

(Halaman ini sengaja dikosongkan)

BAB IV

ANALISIS DAN PEMBAHASAN

4.1 Karakteristik Data Saham Sektor Energi

Sebelum melakukan pemodelan, tahap awal dalam analisis data adalah memahami karakteristik dan pola dari data yang digunakan. Pada penelitian ini, data yang dianalisis berupa *return* logaritmik bulanan dari tiga emiten saham sektor energi, yaitu PT Perusahaan Gas Negara Tbk (PGAS), PT Alamtri Resources Indonesia Tbk (ADRO), dan PT Medco Energi Internasional Tbk (MEDC), yang diperoleh selama periode September 2008 hingga Desember 2024. Data diperoleh dari situs <https://finance.yahoo.com> dan dihitung berdasarkan harga penutupan yang disesuaikan (*adjusted close*).

Analisis awal dilakukan melalui statistik deskriptif, yang mencakup ukuran pemusatan data dan ukuran penyebaran data dari masing-masing *return* saham. Selain itu, dilakukan juga visualisasi data dalam bentuk plot deret waktu (*time series plot*) untuk masing-masing saham guna mengamati dinamika dan fluktuasi *return* secara temporal. Tahap ini digunakan untuk memperoleh pemahaman awal terhadap pola volatilitas, serta untuk mengidentifikasi kemungkinan adanya perubahan struktur atau dinamika pasar yang berpotensi merepresentasikan peralihan rezim, yang menjadi fokus utama dalam pemodelan menggunakan metode *Non-Homogeneous Markov Switching AutoRegressive (NHMS-AR)*.

Tabel 4. 1 Statistik Deskriptif *Return* Saham Sektor Energi


Variabel	N	Mean	Standar Deviasi	Median	Min	Maks	Range
<i>return.PGAS</i>	196	0	0.12	0	-0.5	0.4	0.9
<i>return.ADRO</i>	196	0.01	0.14	0.01	-0.72	0.62	1.34
<i>return.MEDC</i>	196	0	0.17	-0.01	-0.71	0.59	1.3

Berdasarkan Tabel 4.1, analisis statistik deskriptif terhadap data *return* logaritmik bulanan dari saham sektor energi menunjukkan bahwa secara umum ketiga saham memiliki rata-rata *return* yang relatif rendah. Saham PGAS dan

MEDC memiliki rata-rata *return* sebesar 0, sedangkan saham ADRO memiliki rata-rata *return* sebesar 0,01. Hal ini mengindikasikan bahwa selama periode pengamatan, pergerakan *return* saham cenderung stabil di sekitar nilai nol, dengan kecenderungan sedikit positif pada saham ADRO.

Dari sisi penyebaran, saham MEDC memiliki tingkat volatilitas tertinggi dengan standar deviasi sebesar 0,17, diikuti oleh ADRO sebesar 0,14, dan PGAS sebesar 0,12. Ini menunjukkan bahwa *return* saham MEDC lebih fluktuatif dibanding dua saham lainnya. *Return* minimum yang cukup ekstrem juga terlihat pada saham ADRO dan MEDC, masing-masing sebesar -0,72 dan -0,71, sementara maksimum *return* masing-masing sebesar 0,62 dan 0,59. PGAS memiliki nilai minimum -0,5 dan maksimum 0,4, dengan range yang lebih sempit dibandingkan dua saham lainnya.

Secara keseluruhan, ketiga saham menunjukkan adanya fluktuasi yang signifikan dari waktu ke waktu, yang menjadi indikasi awal kemungkinan adanya perubahan rezim dalam dinamika *return*. Fluktuasi ini menjadi dasar penting untuk menerapkan model *NHMS-AR* dalam mengidentifikasi struktur rezim yang tersembunyi pada data saham sektor energi.



Gambar 4. 1 Plot Deret Waktu *Return* Saham Sektor Energi

Berdasarkan Gambar 4.1 menunjukkan plot deret waktu *return* logaritmik bulanan dari tiga saham sektor energi, yaitu PGAS, ADRO, dan MEDC, selama periode September 2008 hingga Desember 2024. Secara umum, ketiga saham

menunjukkan pola fluktuasi *return* yang tinggi dari waktu ke waktu. Meskipun sebagian besar pergerakan *return* berada dalam rentang antara -0,2 hingga 0,2, terdapat beberapa periode dengan pergerakan ekstrim, baik penurunan maupun kenaikan tajam.

Return saham MEDC (warna hijau) tampak lebih volatil dibanding dua saham lainnya, dengan beberapa lonjakan positif maupun negatif yang lebih mencolok. *Return* ADRO (merah) dan PGAS (biru) juga menunjukkan pola fluktuatif, namun secara visual terlihat sedikit lebih stabil daripada MEDC. Pada periode krisis global, seperti sekitar tahun 2020 (masa pandemi COVID-19), terlihat penurunan tajam pada semua saham yang ditandai dengan spike negatif.

Fluktuasi yang tidak seragam ini mengindikasikan adanya perubahan struktur data dari waktu ke waktu. Fenomena ini memperkuat indikasi bahwa dinamika *return* saham sektor energi kemungkinan dipengaruhi oleh faktor eksternal maupun kondisi pasar yang berubah secara signifikan dalam periode tertentu. Pola ini mendukung penggunaan model *Non-Homogeneous Markov Switching AutoRegressive* (NHMS-AR), yang mampu menangkap perubahan rezim atau fase pergerakan saham secara tersembunyi dan tidak linier.

Selain menganalisis karakteristik *return* saham, penelitian ini juga mempertimbangkan pengaruh variabel-variabel eksogen yang diduga turut memengaruhi dinamika pergerakan harga saham sektor energi. Ketiga variabel eksogen yang digunakan adalah *Climate Risk Index* (CRI), *Geopolitical Risk Index* (GPR), dan *Global Economic Policy Uncertainty Index* (GEPU). Ketiganya merepresentasikan risiko eksternal yang relevan dalam konteks pasar energi global, seperti risiko lingkungan, ketegangan geopolitik, dan ketidakpastian kebijakan ekonomi.

Meskipun fokus utama analisis dalam subbab ini adalah pada karakteristik *return* saham, keberadaan variabel eksogen perlu disebutkan karena model yang digunakan dalam penelitian ini, yaitu *Non-Homogeneous Markov Switching AutoRegressive* (NHMS-AR), memungkinkan probabilitas transisi antar rezim bergantung pada dinamika variabel-variabel eksternal tersebut. Oleh karena itu, pemahaman awal terhadap pola dan distribusi masing-masing variabel eksogen menjadi penting untuk mendukung interpretasi model pada tahap selanjutnya.

Tabel 4. 2 Statistik Deskriptif Variabel Eksogen

Variabel	N	Mean	Standar Deviasi	Median	Min	Maks	Range
CRI	196	0.13	0.08	0.12	0.01	0.47	0.46
GPR	196	99.41	30.1	91.52	58.42	318.96	260.53
GEPU	196	179.96	65.16	168.58	91.76	418.62	326.85


Berdasarkan Tabel 4.2, analisis statistik deskriptif terhadap ketiga variabel eksogen yang digunakan dalam penelitian ini, yaitu *Climate Risk Index* (CRI), *Geopolitical Risk Index* (GPR), dan *Global Economic Policy Uncertainty Index* (GEPU), menunjukkan adanya variasi karakteristik antar indeks. CRI memiliki rata-rata sebesar 0,13 dengan standar deviasi 0,08, serta nilai minimum 0,01 dan maksimum 0,47. Nilai median sebesar 0,12 menunjukkan bahwa distribusi CRI cenderung seimbang, dan secara umum indeks ini menunjukkan fluktuasi yang relatif rendah. Hal ini mengindikasikan bahwa risiko iklim selama periode pengamatan berada dalam kondisi yang cukup stabil, meskipun sesekali terjadi peningkatan tajam.

Berbeda halnya dengan GPR dan GEPU yang menunjukkan nilai yang jauh lebih tinggi dan fluktuatif. GPR memiliki rata-rata sebesar 99,41 dan standar deviasi 30,1, dengan nilai minimum 58,42 dan maksimum 318,96. Rentang yang sangat lebar ini (260,53) mencerminkan ketidakpastian geopolitik global yang cukup dinamis, dengan beberapa periode menunjukkan lonjakan signifikan yang kemungkinan disebabkan oleh peristiwa politik internasional seperti konflik atau ketegangan antar negara.

Sementara itu, GEPU memiliki rata-rata sebesar 179,96 dan standar deviasi tertinggi di antara ketiga indeks, yaitu 65,16. Nilai minimumnya adalah 91,76 dan maksimum 418,62, dengan rentang 326,85. Ini menunjukkan bahwa ketidakpastian kebijakan ekonomi global mengalami fluktuasi yang besar selama periode pengamatan, dan dapat menjadi faktor penting yang memengaruhi pasar saham sektor energi.


Secara keseluruhan, baik GPR maupun GEPU menunjukkan tingkat volatilitas yang tinggi, yang menunjukkan pentingnya mempertimbangkan kedua

indeks tersebut dalam memodelkan dinamika transisi rezim pada saham sektor energi. Meskipun CRI lebih stabil, kontribusinya tetap relevan terutama dalam konteks jangka panjang dan ketika terjadi kejadian iklim ekstrem.




Gambar 4. 2 Plot Indeks Resiko Iklim (CRI)

Berdasarkan Gambar 4.2, terlihat bahwa nilai indeks ini umumnya berada pada rentang 0 hingga 0,3 dengan beberapa lonjakan ekstrem hingga mendekati 0,5. Lonjakan ini dapat diartikan sebagai periode terjadinya peristiwa iklim ekstrem, seperti bencana alam atau perubahan iklim signifikan yang berdampak pada sektor energi.



Gambar 4. 3 Plot Indeks Ketidakpastian Kebijakan Ekonomi Global (GEPU)

Sementara itu, Gambar 4.3 menunjukkan pola yang lebih bervariasi dengan tren peningkatan yang cukup tajam terutama sejak tahun 2016, dan mencapai puncaknya pada periode sekitar pandemi COVID-19 (2020), dengan nilai di atas 400. Hal ini mencerminkan ketidakpastian kebijakan ekonomi yang tinggi secara global, yang tentunya berdampak pada keputusan investasi di pasar modal.



Gambar 4. 4 Plot Indeks Resiko Geopolitik (GPR)

Adapun Gambar 4.4 relatif stabil hingga sekitar tahun 2021, kemudian mengalami lonjakan drastis yang kemungkinan besar berkaitan dengan peristiwa geopolitik global seperti konflik Rusia–Ukraina atau ketegangan di kawasan Timur Tengah. Nilai GPR yang tinggi menandakan risiko politik internasional yang meningkat, yang dapat memicu volatilitas di pasar saham.

Dengan demikian, ketiga variabel eksogen ini memainkan peran penting dalam model *NHMS-AR* yang digunakan, karena mampu merepresentasikan dinamika risiko global yang dapat memengaruhi probabilitas transisi antar rezim dalam pasar saham sektor energi.

4.2 Penerapan *Homogeneous Markov Switching Autoregressive (HMS-AR)* dalam memodelkan *return* saham sektor energi di Indonesia

Dalam model *Markov Switching Autoregressive* yang bersifat *homogeneous* (*HMS-AR*), dinamika *return* saham diasumsikan mengikuti proses *autoregressive* yang parameternya bergantung pada *state* (*regime*) tertentu, sementara probabilitas perpindahan antar-*regime* dianggap konstan sepanjang waktu dan tidak dipengaruhi

oleh variabel eksternal. Dengan demikian, struktur perubahan *regime* sepenuhnya ditentukan oleh karakteristik internal data dan pola volatilitas historisnya. Pendekatan ini memungkinkan identifikasi fase pasar yang berbeda misalnya kondisi volatilitas rendah dan tinggi tanpa mempertimbangkan pengaruh faktor makroekonomi atau indikator global.

Sebelum melihat bagaimana parameter *autoregressive* bekerja dalam masing-masing *regime*, langkah penting pertama adalah meninjau matriks transisi, yang menggambarkan probabilitas perpindahan dari satu *state* ke *state* lainnya. Matriks ini menjadi dasar untuk memahami pola *regime Switching* yang terjadi dalam model *HMS-AR* yang ditunjukkan berikut ini.

$$P = \begin{bmatrix} 0,9063 & 0,0937 \\ 0,5844 & 0,4156 \end{bmatrix}$$

Matriks transisi di atas menunjukkan bahwa probabilitas untuk bertahan pada Regime 1 sebesar 0,9063, sedangkan peluang berpindah dari Regime 1 ke Regime 2 hanya 0,0937. Nilai ini mengindikasikan bahwa Regime 1 sangat persisten, di mana proses *return* saham cenderung tetap berada pada Regime 1 dalam periode yang relatif panjang dan jarang mengalami perpindahan rezim.

Sementara itu, probabilitas bertahan pada Regime 2 sebesar 0,4156, dengan peluang berpindah dari Regime 2 ke Regime 1 sebesar 0,5844. Hal ini menunjukkan bahwa Regime 2 bersifat kurang stabil dan memiliki kecenderungan yang lebih besar untuk segera berpindah kembali ke Regime 1 dibandingkan bertahan di dalam rezim tersebut. Secara keseluruhan, pola matriks transisi ini mengimplikasikan bahwa dinamika *return* saham sektor energi di Indonesia dalam model *HMS-AR* didominasi oleh Regime 1 sebagai rezim yang stabil (persisten), sedangkan Regime 2 berperan sebagai rezim sementara (*transitory*). Kondisi ini menunjukkan bahwa meskipun terjadi periode tertentu dengan karakteristik Regime 2, pasar cenderung kembali ke Regime 1, yang mencerminkan adanya rezim dominan dalam pergerakan *return* saham sektor energi.

Setelah mengetahui struktur perpindahan *regime* melalui matriks transisi, tahap berikutnya adalah meninjau parameter yang membentuk dinamika *return* pada masing-masing *regime*. Berdasarkan hasil estimasi model *HMS-AR*(1) dua

rezim, diperoleh parameter intersep ($\mathbf{c}_{S_t}$), matriks koefisien autoregresif ($\Phi_{S_t,1}$), serta matriks kovarian error (Σ_{S_t}) untuk masing-masing rezim sebagaimana ditunjukkan sebagai berikut.

$$\mathbf{c}_1 = \begin{bmatrix} -0,0017 \\ 0,0168 \\ -0,0136 \end{bmatrix}, \Phi_{1,1} = \begin{bmatrix} 0,0304 & 0,2141 & -0,0142 \\ 0,1039 & -0,0552 & 0,0081 \\ 0,2699 & 0,1307 & 0,1608 \end{bmatrix},$$

$$\Sigma_1 = \begin{bmatrix} 0,0143 & 0,0042 & 0,0066 \\ 0,0042 & 0,0119 & 0,0062 \\ 0,0066 & 0,0062 & 0,0191 \end{bmatrix}$$

$$\mathbf{c}_2 = \begin{bmatrix} 0,0159 \\ -0,0094 \\ 0,1233 \end{bmatrix}, \Phi_{2,1} = \begin{bmatrix} -0,2997 & -0,0943 & -0,0829 \\ 0,1745 & -0,2321 & 0,1025 \\ -0,0884 & 0,2539 & 0,2384 \end{bmatrix},$$

$$\Sigma_2 = \begin{bmatrix} 0,0051 & 0,0036 & -0,0033 \\ 0,0036 & 0,0511 & 0,0111 \\ -0,0033 & 0,0111 & 0,0382 \end{bmatrix}$$

Dengan memasukkan nilai parameter hasil estimasi ke dalam bentuk umum model *HMS-AR*, diperoleh persamaan model untuk masing-masing rezim sebagai berikut.

$$\begin{bmatrix} \hat{Y}_{1,t} \\ \hat{Y}_{2,t} \\ \hat{Y}_{3,t} \end{bmatrix} = \begin{cases} \begin{bmatrix} -0,0017 \\ 0,0168 \\ -0,0136 \end{bmatrix} + \begin{bmatrix} 0,0304 & 0,2141 & -0,0142 \\ 0,1039 & -0,0552 & 0,0081 \\ 0,2699 & 0,1307 & 0,1608 \end{bmatrix} \begin{bmatrix} Y_{1,t-1} \\ Y_{2,t-1} \\ Y_{3,t-1} \end{bmatrix}, & S_t = 1 \\ \begin{bmatrix} 0,0159 \\ -0,0094 \\ 0,1233 \end{bmatrix} + \begin{bmatrix} -0,2997 & -0,0943 & -0,0829 \\ 0,1745 & -0,2321 & 0,1025 \\ -0,0884 & 0,2539 & 0,2384 \end{bmatrix} \begin{bmatrix} Y_{1,t-1} \\ Y_{2,t-1} \\ Y_{3,t-1} \end{bmatrix}, & S_t = 2 \end{cases}$$

Sebagai contoh, untuk *return* saham PGAS, model pada masing-masing rezim dapat dituliskan secara eksplisit sebagai berikut:

$$\text{Rezim 1 : } \hat{Y}_{1,t} = -0,0017 + 0,0304Y_{1,t-1} + 0,2141Y_{2,t-1} - 0,0142Y_{3,t-1}$$

$$\text{Rezim 2 : } \hat{Y}_{1,t} = 0,0159 - 0,2997Y_{1,t-1} - 0,0943Y_{2,t-1} - 0,0829Y_{3,t-1}$$

Pada Rezim 1, persamaan model menunjukkan bahwa koefisien *self-lag return* PGAS $Y_{1,t-1}$ bernilai positif sebesar 0,0304, meskipun relatif kecil. Hal ini mengindikasikan adanya efek momentum yang lemah, di mana kenaikan *return* PGAS pada periode sebelumnya hanya memberikan pengaruh lanjutan yang


terbatas pada periode berjalan. Kondisi ini mencerminkan dinamika pasar yang cenderung stabil, dengan fluktuasi *return* yang tidak terlalu agresif. Koefisien lag *return* ADRO $Y_{2,t-1}$ bernilai positif sebesar 0,2141, menunjukkan bahwa pergerakan *return* ADRO pada periode sebelumnya berkontribusi secara searah terhadap *return* PGAS pada rezim ini. Sementara itu, koefisien lag *return* MEDC $Y_{3,t-1}$ bernilai negatif sebesar -0,0142, meskipun dengan pengaruhnya yang sangat kecil. Nilai ini mengindikasikan adanya hubungan berlawanan arah yang lemah antara *return* MEDC dan PGAS. Secara keseluruhan, Rezim 1 menggambarkan kondisi pasar yang relatif tenang dan persisten, di mana pengaruh antar saham masih ada namun tidak terlalu kuat, sejalan dengan karakter rezim dominan yang stabil.

Pada Rezim 2, intersep bernilai positif sebesar 0,0159, yang mengindikasikan tingkat *return* rata-rata yang lebih tinggi dibandingkan Rezim 1. Namun demikian, koefisien *self-lag* PGAS $Y_{1,t-1}$ bernilai negatif sebesar -0,2997, menunjukkan adanya mean reversion yang kuat. Artinya, kenaikan *return* PGAS pada periode sebelumnya cenderung diikuti oleh penurunan pada periode berikutnya, dan sebaliknya. Pola ini mencerminkan kondisi pasar yang lebih bergejolak, di mana fluktuasi harga cepat terkoreksi. Koefisien lag *return* ADRO $Y_{2,t-1}$ dan MEDC $Y_{3,t-1}$ masing-masing bernilai negatif sebesar -0,0943 dan -0,0829. Hal ini menunjukkan bahwa pada Rezim 2, pergerakan *return* saham energi lainnya cenderung memberikan pengaruh berlawanan arah terhadap PGAS.

Secara keseluruhan, Rezim 2 merepresentasikan fase pasar yang kurang stabil dan bersifat sementara, ditandai dengan koreksi *return* yang kuat dan hubungan antar saham yang cenderung berlawanan arah. Hasil ini konsisten dengan hasil matriks transisi yang menunjukkan bahwa Rezim 2 memiliki tingkat persistensi yang rendah dan cenderung kembali ke Rezim 1.

Gambar 4.5 menampilkan dinamika probabilitas *smoothed* untuk Rezim 1 (garis biru) dan Rezim 2 (garis merah) sepanjang periode pengamatan. Secara umum, terlihat bahwa probabilitas Rezim 1 mendominasi hampir seluruh periode, dengan nilai yang sering berada mendekati 1. Pola ini menunjukkan bahwa pasar saham sektor energi lebih sering berada pada Rezim 1 sebagai rezim yang stabil dan persisten. Meskipun demikian, terdapat beberapa periode tertentu di mana

probabilitas Rezim 2 meningkat tajam hingga mendekati 1, namun hanya berlangsung dalam interval waktu yang relatif singkat. Lonjakan-lonjakan ini mencerminkan kejadian sementara yang mendorong pasar berpindah ke Rezim 2, sebelum kemudian kembali ke Rezim 1. Pola tersebut mengindikasikan bahwa Rezim 2 bersifat *transitory* dan tidak bertahan lama.



Gambar 4.5 Plot *Smoothed Regime Probabilities HMS-AR*

Secara visual, grafik ini menunjukkan bahwa pergantian rezim memang terjadi, namun tidak bersifat simetris. Transisi umumnya berlangsung dari Rezim 1 ke Rezim 2 dalam durasi pendek, lalu kembali ke Rezim 1, yang sejalan dengan hasil matriks transisi sebelumnya di mana probabilitas bertahan pada Rezim 1 jauh lebih tinggi dibandingkan Rezim 2. Dengan demikian, meskipun pasar sesekali mengalami fase yang lebih bergejolak, kondisi tersebut tidak mendominasi dalam jangka panjang.

4.3 Penerapan *Non-Homogeneous Markov Switching Autoregressive (NHMS-AR)* dalam memodelkan *return* saham sektor energi di Indonesia

Penerapan model *Non-Homogeneous Markov Switching AutoRegressive (NHMS-AR)* dalam penelitian ini bertujuan untuk menangkap dinamika perubahan rezim yang tersembunyi (*hidden regimes*) pada pergerakan *return* saham sektor energi di Indonesia. Berbeda dengan model *Switching* homogen, *NHMS-AR* dikembangkan dengan asumsi bahwa karakteristik pasar saham dapat berubah

mengikuti kondisi eksternal, sehingga perilaku *return* tidak bersifat konstan sepanjang waktu. Model ini memungkinkan perpindahan antar-rezim misalnya antara periode volatilitas rendah dan volatilitas tinggi ditentukan oleh variabel-variabel eksogen melalui pembentukan probabilitas transisi yang bersifat non-homogeneous.

Selain mekanisme transisinya, struktur emisi dalam model ini juga dapat dibuat *non-homogeneous*, di mana parameter *mean* maupun varians *return* dipengaruhi oleh faktor eksogen. Dengan demikian, pengaruh variabel eksternal tidak hanya memengaruhi peluang perpindahan rezim, tetapi juga secara langsung membentuk dinamika *return* di dalam rezim tersebut. Akhirnya, ketika kedua komponen transisi dan emisi dibiarkan bergantung pada variabel eksogen, terbentuklah model *NHTEMS-AR*, yaitu bentuk lengkap dari model *non-homogeneous* yang menangkap perubahan rezim dan perubahan perilaku *return* secara simultan. Fleksibilitas ini menjadikan *NHMS-AR* mampu merepresentasikan kondisi pasar yang kompleks dan responsif terhadap perubahan informasi ekonomi global maupun domestik.

Dalam penelitian ini, *return* saham dari tiga emiten utama sektor energi yaitu PT Perusahaan Gas Negara Tbk (PGAS), PT Alamtri Resources Indonesia Tbk(ADRO), dan PT Medco Energi Internasional Tbk (MEDC) yang dianalisis secara multivariat dengan mempertimbangkan kovariat eksternal berupa *Climate Risk Index* (CRI), *Geopolitical Risk Index* (GPR), dan *Global Economic Policy Uncertainty Index* (GEPU). Ketiga variabel eksogen tersebut diasumsikan mempengaruhi probabilitas perpindahan antar rezim, sehingga model *NHMS-AR* mampu merepresentasikan hubungan dinamis antara perubahan kondisi global dan fluktuasi pasar saham energi di Indonesia secara lebih adaptif dan realistis.

Estimasi model *Non-Homogeneous Markov Switching AutoRegressive (NHMS-AR)* dilakukan menggunakan paket *NHMS-AR* di perangkat lunak R dengan pendekatan *Maximum Likelihood Estimation (MLE)*. Model yang diestimasi terdiri dari dua rezim ($S = 2$) dengan orde autoregresif satu ($p = 1$), di mana probabilitas transisi antar rezim dipengaruhi oleh tiga kovariat eksternal, yaitu *Climate Risk Index* (CRI), *Geopolitical Risk Index* (GPR), dan *Global Economic Policy Uncertainty Index* (GEPU).

Secara umum, model *Non-Homogeneous Markov-Switching Autoregressive (NHMS-AR)* seperti pada persamaan (2.13) yang ditulis sebagai:

$$Y_t = c_{S_t} + \sum_{p=1}^P \phi_{S_t,p} Y_{t-p} + \varepsilon_t$$

di mana c_{S_t} adalah *intercept* rezim ke- S_t , $\phi_{S_t,p}$ adalah koefisien autoregresif lag ke- p , dan ε_t merupakan noise Gaussian. Model *NHMS-AR* multivariat dengan kovariat $Z_t = (CRI_t, GPR_t, GEPU_t)$ dapat diletakkan pada tiga komponen yaitu *NHTMS-AR*, *NHEMS-AR* dan *NHTEMS-AR*.

Pada *NHTMS-AR*, probabilitas perpindahan rezim bergantung pada Z_t seperti pada persamaan (2.14) sebagai berikut.

$$P(S_t = j | S_{t-1} = i, Z_t) = q_{ij}(t)$$

Pada 2 rezim, bentuk umum fungsi logit untuk probabilitas transisi didefinisikan seperti pada persamaan (2.16) sebagai berikut.

$$\text{logit}(P(q_{ij}(t))) = \alpha_{ij} + \beta_{ij} Z_t$$

Kemudian, model *NHTMS-AR* seperti pada persamaan (2.21) sebagai berikut.

$$\mathbf{Y}_t = \mathbf{c}_{S_t} + \Phi_{S_t,1} \mathbf{Y}_{t-1} + \boldsymbol{\varepsilon}_{S_t}, \quad \boldsymbol{\varepsilon}_{S_t} \sim N(\mathbf{0}, \Sigma_{S_t})$$

maka persamaan tersebut dapat dijabarkan secara terpisah untuk masing-masing rezim sebagai berikut:

$$\mathbf{Y}_t = \begin{cases} \mathbf{c}_1 + \Phi_{1,1} \mathbf{Y}_{t-1} + \boldsymbol{\varepsilon}_{1t}, & S_t = 1 \\ \mathbf{c}_2 + \Phi_{2,1} \mathbf{Y}_{t-1} + \boldsymbol{\varepsilon}_{2t}, & S_t = 2 \end{cases} \quad (4.1)$$

dengan $\boldsymbol{\varepsilon}_{it} \sim N(\mathbf{0}, \Sigma_i)$, $i = 1, 2$.

Keterangan :

$\mathbf{Y}_t = (Y_{1t}, Y_{2t}, Y_{3t})'$ adalah vektor *return* saham (PGAS, ADRO, MEDC),

$\mathbf{c}_{S_t}$ adalah vektor intersep pada rezim ke- S_t ,

$\Phi_{S_t,1}$ adalah matriks koefisien autoregresif pada rezim ke- S_t ,

Pada *NHEMS-AR*, transisi rezim homogen (tidak tergantung pada kovariat), sehingga probabilitas transisi didefinisikan seperti pada persamaan (2.11) sebagai berikut.

$$P(S_t = j | S_{t-1} = i) = p_{ij}(t)$$

Sedangkan Z_t dimasukkan ke dalam model seperti persamaan (2.22) sebagai berikut.

$$\mathbf{Y}_t = \mathbf{c}_{S_t} + \sum_{p=1}^P \Phi_{S_t,p} \mathbf{Y}_{t-p} + \gamma_{S_t} \mathbf{Z}_t + \varepsilon_{S_t,t}, \quad t = 1, 2, \dots, T$$

dengan:

- $\mathbf{c}_{S_t}$: vektor intersep pada rezim S_t .
- $\Phi_{S_t,p}$: matriks koefisien autoregresif lag ke- p pada rezim S_t ,
- γ_{S_t} : matriks koefisien kovariat pada rezim S_t ,
- $\mathbf{Z}_t$: vektor kovariat eksternal pada waktu t ,
- $\varepsilon_{S_t,t} \sim N(\mathbf{0}, \Sigma_{S_t})$: vektor error Gaussian pada rezim S_t .

Pada *NHTEMS-AR*, kovariat eksternal dimasukkan secara simultan ke dalam dua komponen model, yaitu probabilitas transisi rezim dan persamaan emisi. Dengan pendekatan ini, kovariat tidak hanya memengaruhi peluang terjadinya perpindahan rezim, tetapi juga memengaruhi langsung perilaku *return* saham pada masing-masing rezim. Oleh karena itu, model *NHTEMS-AR* mampu menangkap pengaruh faktor eksternal terhadap dinamika pasar, baik melalui perubahan rezim maupun melalui karakteristik *return* dalam setiap rezim.

4.3.1 *NHTMS-AR*

Dalam model *NHMS-AR*, mekanisme perpindahan *return* saham dari satu rezim ke rezim lainnya tidak lagi diasumsikan konstan seperti pada model *HMS-AR*, tetapi dipengaruhi oleh faktor-faktor eksternal yang relevan dengan dinamika pasar. Pendekatan ini memungkinkan probabilitas transisi antar-rezim berubah secara adaptif mengikuti kondisi ekonomi atau indikator risiko yang bersifat *time-varying*. Dengan demikian, perubahan kondisi pasar seperti meningkatnya tekanan, ketidakpastian global, atau sentimen positif tertentu dapat langsung tercermin dalam peluang perpindahan antar-rezim.

NHTMS-AR dimodelkan melalui fungsi logit yang menghubungkan variabel eksogen dengan probabilitas perpindahan rezim. Pendekatan ini memberikan gambaran yang lebih realistis mengenai hubungan antara perubahan lingkungan

ekonomi dan dinamika perilaku *return*. Sebagai contoh, peningkatan risiko global atau gejolak harga komoditas dapat meningkatkan peluang perpindahan dari rezim stabil menuju rezim volatil, sementara perbaikan indikator ekonomi dapat menurunkan peluang tersebut.

Untuk menganalisis pengaruh variabel eksogen terhadap probabilitas perpindahan antar-rezim, digunakan fungsi link logit pada model transisi non-homogen. Fungsi logit ini menghubungkan peluang sistem berpindah dari satu rezim ke rezim lainnya dengan kombinasi linear dari kovariat eksternal Z_t yang dalam penelitian ini meliputi *Climate Risk Index* (CRI), *Geopolitical Risk* (GPR), dan *Global Economic Policy Uncertainty* (GEPU). Melalui fungsi logit, perubahan pada variabel eksogen tersebut akan secara langsung memengaruhi besarnya probabilitas transisi antar-rezim. Bentuk fungsi logit ditunjukkan sebagai berikut.

$$\begin{aligned}\text{logit}\left[P(S_t = 2 | S_{t-1} = 1, Z_t)\right] &= -0,6887 + 2,7756Z_{1t} - 0,8661Z_{2t} + 2,2768Z_{3t}, \\ \text{logit}\left[P(S_t = 1 | S_{t-1} = 2, Z_t)\right] &= 0,1020 + 1,3010Z_{1t} - 0,1750Z_{2t} - 0,0615Z_{3t}.\end{aligned}$$

Berdasarkan fungsi logit probabilitas transisi rezim di atas, terlihat bahwa CRI (Z_{1t}) memiliki koefisien positif pada kedua persamaan transisi, masing-masing sebesar 2,7756 untuk transisi dari Rezim 1 ke Rezim 2 dan 1,3010 untuk transisi dari Rezim 2 ke Rezim 1. Hal ini menunjukkan bahwa peningkatan risiko iklim global meningkatkan peluang terjadinya perpindahan rezim, baik dari kondisi stabil menuju kondisi tidak stabil maupun sebaliknya. Dengan demikian, CRI berperan sebagai faktor eksternal yang mendorong dinamika perubahan kondisi pasar saham sektor energi.

Koefisien GPR (Z_{2t}) bernilai negatif pada kedua arah transisi, yaitu sebesar $-0,8661$ pada transisi dari Rezim 1 ke Rezim 2 dan $-0,1750$ pada transisi dari Rezim 2 ke Rezim 1. Temuan ini mengindikasikan bahwa peningkatan ketegangan geopolitik cenderung menurunkan probabilitas terjadinya *switching* antar-rezim, sehingga pasar lebih cenderung bertahan pada rezim yang sedang berlangsung. Dampak ini lebih kuat pada transisi dari Rezim 1 ke Rezim 2, yang mengimplikasikan bahwa ketegangan geopolitik memperkuat persistensi rezim dominan. Sementara itu, GEPU (Z_{3t}) menunjukkan koefisien positif sebesar 2,2768 pada transisi dari Rezim 1 ke Rezim 2, yang berarti bahwa meningkatnya

ketidakpastian kebijakan ekonomi global mendorong pasar berpindah dari kondisi stabil menuju kondisi yang lebih tidak stabil. Namun, pada transisi dari Rezim 2 ke Rezim 1, koefisien GEPU bernilai negatif sebesar $-0,0615$, mengindikasikan bahwa pengaruh GEPU terhadap peluang kembali ke rezim stabil bersifat lemah.

Selanjutnya, untuk melihat dinamika perpindahan antar-rezim, digunakan matriks probabilitas transisi rata-rata Q . Matriks ini menggambarkan peluang proses berada pada rezim tertentu pada waktu t berdasarkan rezim pada waktu $t-1$ yang ditunjukkan sebagai berikut.

$$Q = \begin{bmatrix} 0,7151 & 0,2849 \\ 0,1251 & 0,8749 \end{bmatrix}$$

Matriks transisi di atas menunjukkan bahwa probabilitas bertahan pada Regime 1 sebesar 0,7151, sedangkan peluang berpindah dari Regime 1 ke Regime 2 sebesar 0,2849. Hal ini mengindikasikan bahwa Regime 1 cukup persisten, namun masih terdapat peluang perpindahan yang tidak kecil menuju Regime 2. Sementara itu, probabilitas bertahan pada Regime 2 sebesar 0,8749, dengan peluang berpindah dari Regime 2 ke Regime 1 sebesar 0,1251. Nilai ini menunjukkan bahwa Regime 2 sangat persisten (lebih stabil dibanding Regime 1), sehingga ketika sistem sudah masuk ke Regime 2, kemungkinan besar akan bertahan dalam rezim tersebut untuk beberapa periode.

Berdasarkan hasil estimasi model *NHTMS-AR* dua rezim, diperoleh parameter intersep ($\mathbf{c}_{s_t}$), matriks koefisien autoregresif ($\Phi_{s_t,1}$), serta matriks kovarian error (Σ_{s_t}) untuk masing-masing rezim sebagaimana ditunjukkan sebagai berikut.

$$\mathbf{c}_1 = \begin{bmatrix} -0,0268 \\ -0,0150 \\ -0,0604 \end{bmatrix}, \Phi_{1,1} = \begin{bmatrix} 0,2512 & 0,2287 & -0,0514 \\ 0,0728 & -0,0734 & -0,0585 \\ 0,5225 & 0,0794 & -0,2468 \end{bmatrix},$$

$$\Sigma_1 = \begin{bmatrix} 0,0124 & 0,0007 & 0,0030 \\ 0,0007 & 0,0156 & 0,0058 \\ 0,0030 & 0,0058 & 0,0143 \end{bmatrix}$$

$$\mathbf{c}_2 = \begin{bmatrix} 0,0374 \\ 0,0518 \\ 0,0845 \end{bmatrix}, \mathbf{\Phi}_{2,1} = \begin{bmatrix} -0,1995 & -0,0462 & -0,0163 \\ 0,1423 & -0,0942 & 0,0953 \\ -0,0251 & 0,1759 & 0,1625 \end{bmatrix},$$

$$\mathbf{\Sigma}_2 = \begin{bmatrix} 0,0111 & 0,0069 & 0,0019 \\ 0,0069 & 0,0173 & 0,0017 \\ 0,0019 & 0,0017 & 0,0228 \end{bmatrix}$$

Dengan memasukkan nilai parameter hasil estimasi ke dalam bentuk umum model *NHTMS-AR*, diperoleh persamaan model untuk masing-masing rezim sebagai berikut.

$$\begin{bmatrix} \hat{Y}_{1,t} \\ \hat{Y}_{2,t} \\ \hat{Y}_{3,t} \end{bmatrix} = \begin{cases} \begin{bmatrix} -0,0268 \\ -0,0150 \\ -0,0604 \end{bmatrix} + \begin{bmatrix} 0,2512 & 0,2287 & -0,0514 \\ 0,0728 & -0,0734 & -0,0585 \\ 0,5225 & 0,0794 & -0,2468 \end{bmatrix} \begin{bmatrix} Y_{1,t-1} \\ Y_{2,t-1} \\ Y_{3,t-1} \end{bmatrix}, & S_t = 1 \\ \begin{bmatrix} 0,0374 \\ 0,0518 \\ 0,0845 \end{bmatrix} + \begin{bmatrix} -0,1995 & -0,0462 & -0,0163 \\ 0,1423 & -0,0942 & 0,0953 \\ -0,0251 & 0,1759 & 0,1625 \end{bmatrix} \begin{bmatrix} Y_{1,t-1} \\ Y_{2,t-1} \\ Y_{3,t-1} \end{bmatrix}, & S_t = 2 \end{cases}$$

Sebagai contoh, untuk *return* saham PGAS, model pada masing-masing rezim dapat dituliskan secara eksplisit sebagai berikut:

$$\text{Rezim 1 : } \hat{Y}_{1,t} = -0,0268 + 0,2512Y_{1,t-1} + 0,2287Y_{2,t-1} - 0,0514Y_{3,t-1}$$

$$\text{Rezim 2 : } \hat{Y}_{2,t} = 0,0374 - 0,1995Y_{1,t-1} - 0,0462Y_{2,t-1} - 0,0163Y_{3,t-1}$$

Pada Rezim 1, koefisien *return* PGAS periode sebelumnya $Y_{1,t-1}$ bernilai positif sebesar 0,2512. Hal ini berarti bahwa jika *return* PGAS pada periode sebelumnya naik, maka pada periode berikutnya cenderung masih bergerak searah. Kondisi ini menunjukkan bahwa pada Rezim 1, pergerakan *return* PGAS masih berlanjut dan belum langsung mengalami koreksi. Koefisien *return* ADRO periode sebelumnya $Y_{2,t-1}$ juga bernilai positif sebesar 0,2287, yang menunjukkan bahwa kenaikan *return* ADRO di periode sebelumnya diikuti oleh kenaikan *return* PGAS pada periode berjalan. Sebaliknya, koefisien *return* MEDC periode sebelumnya $Y_{3,t-1}$ bernilai negatif sebesar $-0,0514$, yang mengindikasikan bahwa kenaikan *return* MEDC cenderung diikuti oleh penurunan *return* PGAS, meskipun pengaruhnya relatif kecil. Secara umum, Rezim 1 menggambarkan kondisi pasar yang masih aktif, di mana pergerakan harga cenderung mengikuti arah sebelumnya.


Pada Rezim 2, nilai konstanta bernilai positif sebesar 0,0374, yang menunjukkan bahwa rata-rata *return* pada rezim ini relatif lebih tinggi. Namun, koefisien *return* PGAS periode sebelumnya $Y_{1,t-1}$ bernilai negatif sebesar -0,1995, yang berarti bahwa ketika *return* PGAS pada periode sebelumnya naik, maka pada periode berikutnya cenderung turun, dan sebaliknya. Pola ini menunjukkan adanya koreksi harga pada Rezim 2. Koefisien *return* ADRO dan MEDC periode sebelumnya masing-masing bernilai negatif sebesar -0,0462 dan -0,0163, yang menunjukkan bahwa pergerakan saham energi lain cenderung tidak searah dengan PGAS pada rezim ini. Dengan kata lain, hubungan antar saham energi menjadi lebih lemah dan tidak saling menguatkan.

Secara keseluruhan, Rezim 2 menggambarkan kondisi pasar yang lebih bertahan lama, namun dengan pergerakan *return* yang sering mengalami koreksi. Hal ini sesuai dengan hasil matriks transisi *NHTMS-AR* yang menunjukkan bahwa peluang bertahan pada Rezim 2 lebih besar dibandingkan Rezim 1, sehingga ketika pasar sudah masuk ke Rezim 2, kondisi tersebut cenderung berlangsung lebih lama.

Selanjutnya, untuk memahami pola perpindahan rezim secara temporal, dilakukan pengamatan terhadap dinamika perubahan rezim sepanjang periode pengamatan. Gambar berikut menyajikan *smoothed regime probabilities* yang menunjukkan probabilitas setiap waktu t berada pada masing-masing rezim berdasarkan hasil estimasi model *NHTMS-AR*. Probabilitas ini memberikan gambaran yang lebih halus dan informatif mengenai dominasi serta durasi setiap rezim, karena dihitung dengan mempertimbangkan seluruh informasi dari awal hingga akhir periode pengamatan.

Gambar 4.6 menunjukkan perkembangan probabilitas *smoothed* untuk Rezim 1 dan Rezim 2 pada model *NHTMS-AR* sepanjang periode pengamatan. Grafik ini menggambarkan seberapa besar kemungkinan pasar berada pada masing-masing rezim di setiap waktu, setelah mempertimbangkan informasi data secara keseluruhan. Berdasarkan grafik tersebut, terlihat bahwa Rezim 2 lebih sering mendominasi, ditunjukkan oleh probabilitas yang cenderung tinggi dan bertahan dalam waktu yang relatif panjang. Hal ini mengindikasikan bahwa ketika pasar memasuki Rezim 2, kondisi tersebut cenderung berlangsung lebih lama dan tidak

cepat berpindah ke rezim lain. Temuan ini sejalan dengan hasil matriks transisi *NHTMS-AR* yang menunjukkan probabilitas bertahan pada Rezim 2 lebih besar dibandingkan Rezim 1. Sementara itu, Rezim 1 muncul pada periode-periode tertentu dengan durasi yang relatif lebih singkat. Peralihan dari Rezim 1 ke Rezim 2 tampak lebih sering terjadi dibandingkan arah sebaliknya, yang menunjukkan bahwa Rezim 1 bersifat kurang stabil dan lebih mudah berubah.



Gambar 4. 6 *Plot Smoothed Regime Probabilities NHTMS-AR*

Secara keseluruhan, grafik probabilitas *smoothed* ini memperkuat hasil estimasi model *NHTMS-AR* bahwa Rezim 2 merupakan rezim yang lebih persisten, sedangkan Rezim 1 bersifat sementara. Visualisasi ini membantu memahami dinamika perubahan kondisi pasar saham sektor energi dan menunjukkan bagaimana pengaruh kovariat dalam model *NHTMS-AR* berperan dalam menentukan perpindahan antar-rezim dari waktu ke waktu.

4.4.2 NHEMS-AR

Berbeda dengan model *HMS-AR* dan *NHTMS-AR* yang hanya memodifikasi peluang perpindahan antar-rezim, pada *NHEMS-AR* parameter emisi bergantung pada variabel eksternal. Dengan demikian, perubahan faktor-faktor ekonomi global dapat secara langsung mengubah struktur dinamika *return* pada rezim tertentu. Pendekatan ini memberikan fleksibilitas tambahan karena perilaku *return* pada masing-masing rezim tidak lagi dianggap statis sepanjang waktu, tetapi dapat beradaptasi terhadap perubahan kondisi pasar. Misalnya, peningkatan risiko global

dapat memperbesar volatilitas pada rezim tertentu, atau meningkatkan sensitivitas *return* terhadap lag-nya sendiri. Pada tahap ini, model tidak hanya menjelaskan kapan rezim berganti, tetapi juga bagaimana karakter *return* berubah sebagai respons terhadap lingkungan eksternal.

Matriks probabilitas transisi pada model *NHEMS-AR* ditunjukkan sebagai berikut.

$$P = \begin{bmatrix} 0,5311 & 0,4689 \\ 0,0304 & 0,9695 \end{bmatrix}$$

Berdasarkan matriks tersebut, probabilitas bertahan pada Rezim 1 sebesar 0,5311, sedangkan peluang berpindah dari Rezim 1 ke Rezim 2 sebesar 0,4689. Nilai ini menunjukkan bahwa Rezim 1 relatif tidak stabil, karena peluang untuk berpindah ke rezim lain hampir sebesar peluang untuk bertahan. Sementara itu, probabilitas bertahan pada Rezim 2 sangat tinggi, yaitu sebesar 0,9695, dengan peluang berpindah dari Rezim 2 ke Rezim 1 yang sangat kecil, yakni 0,0304. Hal ini mengindikasikan bahwa Rezim 2 merupakan rezim yang sangat persisten, sehingga ketika pasar sudah berada pada Rezim 2, kondisi tersebut cenderung berlangsung dalam waktu yang lama.

Secara keseluruhan, matriks transisi ini menunjukkan adanya perbedaan tingkat kestabilan yang jelas antar-rezim pada model *NHEMS-AR*. Rezim 2 berperan sebagai rezim dominan dan stabil, sedangkan Rezim 1 bersifat sementara dan lebih mudah mengalami perpindahan. Temuan ini memberikan gambaran bahwa dinamika *return* saham sektor energi dalam model *NHEMS-AR* lebih banyak dipengaruhi oleh satu kondisi pasar yang bertahan lama dibandingkan oleh pergantian rezim yang sering.

Setelah mengetahui peluang perpindahan antar-rezim pada model *NHEMS-AR*, langkah berikutnya adalah meninjau bagaimana dinamika *return* dalam masing-masing rezim dibentuk melalui struktur parameter model. Berbeda dengan model *HMS-AR* maupun model *NHTMS-AR*, pada *NHEMS-AR* variabel eksogen berperan langsung dalam membentuk nilai *return* melalui penambahan komponen *time-varying* pada parameter emisi. Dengan demikian, karakteristik *return* pada setiap rezim tidak hanya ditentukan oleh intersep, koefisien autoregresif, dan kovarian error, tetapi juga dipengaruhi oleh sensitivitas terhadap variabel eksternal.

Untuk menggambarkan hal tersebut, bentuk model *NHEMS-AR* pada masing-masing rezim disajikan sebagai berikut, yang mencakup parameter intersep ($\mathbf{c}_{S_t}$), matriks koefisien autoregresif ($\Phi_{S_t,1}$), matriks kovarian error (Σ_{S_t}), serta parameter *emission* (γ_{S_t}) untuk masing-masing rezim sebagaimana ditunjukkan sebagai berikut.

$$\begin{aligned} \mathbf{c}_1 &= \begin{bmatrix} -0,1291 \\ -0,2782 \\ -0,2421 \end{bmatrix}, \Phi_{1,1} = \begin{bmatrix} 0,5487 & 0,0980 & -0,4226 \\ -0,6662 & 0,1568 & -0,3615 \\ 0,9087 & -1,0662 & -0,1297 \end{bmatrix}, \\ \Sigma_1 &= \begin{bmatrix} 0,0205 & -0,0050 & -0,0029 \\ -0,0050 & 0,0051 & 0,0031 \\ -0,0029 & 0,0031 & 0,0047 \end{bmatrix}, \gamma_1 = \begin{bmatrix} 0,0685 & -0,0378 & -0,0384 \\ -0,0299 & -0,1054 & -0,0302 \\ 0,0136 & -0,0551 & 0,0827 \end{bmatrix} \\ \mathbf{c}_2 &= \begin{bmatrix} 0,0120 \\ 0,0268 \\ 0,0183 \end{bmatrix}, \Phi_{2,1} = \begin{bmatrix} -0,1080 & 0,0728 & -0,0203 \\ 0,1322 & -0,1265 & 0,0473 \\ 0,0910 & 0,1459 & -0,0486 \end{bmatrix}, \\ \Sigma_2 &= \begin{bmatrix} 0,0116 & 0,0031 & 0,0033 \\ 0,0031 & 0,0140 & 0,0043 \\ 0,0033 & 0,0043 & 0,0213 \end{bmatrix}, \gamma_2 = \begin{bmatrix} 0,0029 & 0,0018 & 0,0030 \\ 0,0069 & 0,0049 & -0,0046 \\ 0,0015 & 0,0038 & 0,0094 \end{bmatrix} \end{aligned}$$

Dengan memasukkan nilai parameter hasil estimasi ke dalam bentuk umum model *NHEMS-AR* multivariat, diperoleh persamaan model untuk masing-masing rezim sebagai berikut.

$$\begin{bmatrix} \hat{Y}_{1,t} \\ \hat{Y}_{2,t} \\ \hat{Y}_{3,t} \end{bmatrix} = \begin{cases} \begin{bmatrix} -0,1291 \\ -0,2782 \\ -0,2421 \end{bmatrix} + \begin{bmatrix} 0,5487 & 0,0980 & -0,4226 \\ -0,6662 & 0,1568 & -0,3615 \\ 0,9087 & -1,0662 & -0,1297 \end{bmatrix} \begin{bmatrix} Y_{1,t-1} \\ Y_{2,t-1} \\ Y_{3,t-1} \end{bmatrix} + \\ \begin{bmatrix} 0,0685 & -0,0378 & -0,0384 \\ -0,0299 & -0,1054 & -0,0302 \\ 0,0136 & -0,0551 & 0,0827 \end{bmatrix} \begin{bmatrix} Z_{1,t} \\ Z_{2,t} \\ Z_{3,t} \end{bmatrix}, & S_t = 1 \\ \begin{bmatrix} 0,0120 \\ 0,0268 \\ 0,0183 \end{bmatrix} + \begin{bmatrix} -0,1080 & 0,0728 & -0,0203 \\ 0,1322 & -0,1265 & 0,0473 \\ 0,0910 & 0,1459 & -0,0486 \end{bmatrix} \begin{bmatrix} Y_{1,t-1} \\ Y_{2,t-1} \\ Y_{3,t-1} \end{bmatrix} + \\ \begin{bmatrix} 0,0029 & 0,0018 & 0,0030 \\ 0,0069 & 0,0049 & -0,0046 \\ 0,0015 & 0,0038 & 0,0094 \end{bmatrix} \begin{bmatrix} Z_{1,t} \\ Z_{2,t} \\ Z_{3,t} \end{bmatrix}, & S_t = 2 \end{cases}$$

Sebagai contoh, untuk *return* saham PGAS, model pada masing-masing rezim dapat dituliskan secara eksplisit sebagai berikut:

$$\text{Rezim 1 : } \hat{Y}_{1,t} = -0,1291 + 0,5487Y_{1,t-1} + 0,0980Y_{2,t-1} - 0,4226Y_{3,t-1} + \\ 0,0685Z_{1,t} - 0,0378Z_{2,t} - 0,0384Z_{3,t}$$


$$\text{Rezim 2 : } \hat{Y}_{2,t} = 0,0120 - 0,1080Y_{1,t-1} + 0,0728Y_{2,t-1} - 0,0203Y_{3,t-1} + \\ 0,0029Z_{1,t} + 0,0018Z_{2,t} + 0,0030Z_{3,t}$$

Pada Rezim 1, *return* PGAS dipengaruhi kuat oleh *return* pada periode sebelumnya, yang ditunjukkan oleh koefisien bernilai positif sebesar 0,5487. Hal ini berarti bahwa ketika *return* PGAS pada periode sebelumnya meningkat, maka pada periode berikutnya *return* PGAS cenderung tetap bergerak searah. Selain itu, *return* saham ADRO pada periode sebelumnya juga memberikan pengaruh positif terhadap *return* PGAS, meskipun dengan besaran yang lebih kecil. Sebaliknya, *return* saham MEDC menunjukkan pengaruh yang berlawanan arah dengan nilai koefisien yang cukup besar, sehingga kenaikan *return* MEDC cenderung diikuti oleh penurunan *return* PGAS pada rezim ini.

Pengaruh variabel eksternal pada Rezim 1 juga masih terlihat. Peningkatan risiko iklim global (CRI) cenderung diikuti oleh kenaikan *return* PGAS, sedangkan peningkatan ketegangan geopolitik (GPR) dan ketidakpastian kebijakan ekonomi global (GEPU) justru cenderung menekan *return* PGAS. Hal ini menunjukkan bahwa pada Rezim 1, pergerakan *return* PGAS tidak hanya dipengaruhi oleh dinamika internal pasar saham energi, tetapi juga cukup sensitif terhadap kondisi eksternal global.

Pada Rezim 2, perilaku *return* PGAS menunjukkan pola yang berbeda. Koefisien *return* PGAS periode sebelumnya bernilai negatif, yang mengindikasikan bahwa kenaikan *return* pada periode sebelumnya cenderung diikuti oleh penurunan *return* pada periode berjalan, atau dengan kata lain terjadi koreksi *return*. Pengaruh *return* saham ADRO dan MEDC pada rezim ini relatif kecil, begitu pula dengan pengaruh variabel eksternal CRI, GPR, dan GEPU yang memiliki koefisien sangat kecil. Kondisi ini menunjukkan bahwa pada Rezim 2, *return* PGAS bergerak lebih terbatas dan tidak terlalu responsif terhadap perubahan faktor eksternal.

Secara keseluruhan, Rezim 1 merepresentasikan kondisi pasar yang lebih responsif terhadap pergerakan saham lain dan faktor eksternal, sedangkan Rezim 2 menggambarkan kondisi pasar yang lebih bertahan lama dengan pergerakan *return* yang cenderung mengalami koreksi. Interpretasi ini sejalan dengan hasil matriks probabilitas transisi *NHEMS-AR* yang menunjukkan bahwa Rezim 2 memiliki tingkat persistensi yang sangat tinggi, sehingga ketika pasar memasuki Rezim 2, kondisi tersebut cenderung berlangsung dalam jangka waktu yang lebih panjang.



Gambar 4. 7 *Plot Smoothed Regime Probabilities NHEMS-AR*

Gambar 4.7 menunjukkan bahwa probabilitas Rezim 2 (garis merah) hampir selalu berada sangat dekat dengan nilai 1 pada sebagian besar waktu pengamatan. Hal ini menandakan bahwa Rezim 2 merupakan rezim yang sangat dominan dalam model *NHEMS-AR*. Dominasi ini konsisten dengan hasil matriks transisi sebelumnya, di mana probabilitas bertahan di Rezim 2 mencapai lebih dari 92%, sementara peluang untuk kembali ke Rezim 1 relatif kecil. Dengan demikian, model mengidentifikasi bahwa pasar lebih sering berada dalam kondisi volatilitas tinggi daripada berada dalam kondisi stabil.

Sebaliknya, probabilitas Rezim 1 (garis biru) hanya naik secara sporadis di titik-titik tertentu dan umumnya berada pada kisaran mendekati nol. Hal ini mengindikasikan bahwa Rezim 1 muncul hanya sebagai fase yang sangat singkat dan tidak persisten, yang terjadi sesaat sebelum pasar kembali ke Rezim 2. Pola ini memperkuat temuan bahwa Rezim 1 bukanlah kondisi pasar yang bertahan lama, melainkan sekadar fase transisi menuju kondisi volatil.

Secara keseluruhan, perilaku probabilitas smoothed pada model *NHEMS-AR* memperlihatkan bahwa pasar energi selama periode observasi didominasi oleh fase volatilitas tinggi (Rezim 2). Dominasi ini juga selaras dengan hasil analisis parameter emisi, di mana Rezim 2 memiliki varians error lebih besar, sensitivitas positif terhadap variabel eksogen, dan struktur autoregresif yang menggambarkan dinamika yang lebih intens. Dengan demikian, *NHEMS-AR* berhasil menangkap dinamika pasar yang sangat dipengaruhi faktor eksternal dan cenderung berada dalam kondisi bergejolak sepanjang waktu pengamatan.

4.4.3 *NHTEMS-AR*

Model selanjutnya adalah model *NHTEMS-AR* yang menggabungkan dua bentuk ketidakseragaman (*non-homogeneity*), yaitu pada komponen transisi dan pada komponen emisi secara simultan. Pada model ini, variabel eksogen tidak hanya memengaruhi peluang perpindahan antar-rezim melalui fungsi logit, tetapi juga memengaruhi struktur pembentukan *return* di dalam setiap rezim. Dengan demikian, model *NHTEMS-AR* merupakan pendekatan yang paling fleksibel dan komprehensif dalam menangkap dinamika pasar yang dipengaruhi oleh risiko global, ketidakpastian ekonomi, serta perubahan kondisi eksternal lainnya.

Pendekatan ini memungkinkan probabilitas berpindah antar-rezim berubah mengikuti variasi variabel eksogen, sementara parameter emisi di masing-masing rezim juga dapat menyesuaikan secara dinamis. Sebelum melihat hasil matriks transisi, fungsi logit yang digunakan untuk memodelkan probabilitas transisi *non-homogeneous* disajikan terlebih dahulu sebagai berikut.

$$\begin{aligned}\text{logit}\left[P(S_t = 2 | S_{t-1} = 1, Z_t)\right] &= 0,1367 + 1,0095Z_{1t} - 0,5743Z_{2t} + 1,515Z_{3t}, \\ \text{logit}\left[P(S_t = 1 | S_{t-1} = 2, Z_t)\right] &= 0,4925 + 1,9179Z_{1t} - 2,0260Z_{2t} - 0,9075Z_{3t}.\end{aligned}$$

Berdasarkan hasil estimasi fungsi logit pada model *NHTEMS-AR*, dapat dilihat bahwa variabel eksternal memiliki peran yang berbeda dalam memengaruhi probabilitas perpindahan antar rezim. Pada fungsi logit untuk peluang berpindah dari Rezim 1 ke Rezim 2, koefisien CRI (Z_{1t}) bernilai positif. Hal ini menunjukkan bahwa ketika risiko iklim global meningkat, peluang pasar berpindah dari kondisi Rezim 1 menuju Rezim 2 juga cenderung meningkat. Dengan kata lain, faktor risiko iklim dapat menjadi pemicu perubahan kondisi pasar saham sektor energi.

Sebaliknya, koefisien GPR (Z_{2t}) pada transisi dari Rezim 1 ke Rezim 2 bernilai negatif. Hal ini mengindikasikan bahwa peningkatan ketegangan geopolitik justru cenderung menurunkan peluang pasar untuk berpindah ke Rezim 2. Sementara itu, GEPU (Z_{3t}) memiliki koefisien positif, yang berarti bahwa meningkatnya ketidakpastian kebijakan ekonomi global mendorong peluang terjadinya perpindahan rezim dari Rezim 1 ke Rezim 2.

Pada fungsi logit untuk peluang berpindah dari Rezim 2 ke Rezim 1, koefisien CRI (Z_{1t}) juga bernilai positif dan bahkan lebih besar dibandingkan persamaan sebelumnya. Hal ini menunjukkan bahwa peningkatan risiko iklim tidak hanya mendorong pasar keluar dari Rezim 1, tetapi juga meningkatkan kemungkinan pasar kembali ke Rezim 1 ketika sedang berada di Rezim 2. Dengan demikian, CRI berperan sebagai faktor yang mempercepat dinamika perpindahan antar-rezim. Sementara itu, koefisien GPR (Z_{2t}) dan GEPU (Z_{3t}) pada transisi dari Rezim 2 ke Rezim 1 bernilai negatif. Hal ini menunjukkan bahwa meningkatnya ketegangan geopolitik dan ketidakpastian kebijakan ekonomi global cenderung menahan pasar untuk tetap berada pada Rezim 2 dan mengurangi peluang kembali ke Rezim 1.

Secara keseluruhan, hasil ini menunjukkan bahwa pada model *NHTEMS-AR*, risiko iklim global (CRI) merupakan faktor yang paling konsisten dalam mendorong terjadinya perpindahan antar rezim, baik dari Rezim 1 ke Rezim 2 maupun sebaliknya. Sementara itu, ketegangan geopolitik dan ketidakpastian kebijakan ekonomi global cenderung memperkuat persistensi rezim tertentu, terutama dengan menahan perpindahan kembali ke kondisi yang lebih stabil. Temuan ini menegaskan bahwa dinamika rezim pada pasar saham sektor energi sangat dipengaruhi oleh faktor eksternal global, namun dengan arah dan kekuatan pengaruh yang berbeda pada setiap rezim.

Matriks probabilitas transisi pada model *NHTEMS-AR* ditunjukkan sebagai berikut.

$$Q = \begin{bmatrix} 0,7151 & 0,2849 \\ 0,1251 & 0,8749 \end{bmatrix}$$

Matriks probabilitas transisi pada model *NHTEMS-AR* menunjukkan bahwa probabilitas bertahan pada Rezim 1 sebesar 0,7151, sedangkan peluang berpindah dari Rezim 1 ke Rezim 2 sebesar 0,2849. Nilai ini mengindikasikan bahwa Rezim

1 tergolong cukup stabil, meskipun masih terdapat peluang yang tidak kecil bagi pasar untuk berpindah ke Rezim 2. Sementara itu, probabilitas bertahan pada Rezim 2 bernilai 0,8749, dengan peluang berpindah dari Rezim 2 ke Rezim 1 sebesar 0,1251. Hal ini menunjukkan bahwa Rezim 2 memiliki tingkat persistensi yang lebih tinggi dibandingkan Rezim 1. Dengan kata lain, ketika pasar telah berada pada Rezim 2, kondisi tersebut cenderung bertahan lebih lama sebelum kembali ke Rezim 1.

Secara keseluruhan, matriks transisi ini memperlihatkan adanya perbedaan kestabilan antar-rezim pada model *NHTEMS-AR*. Rezim 2 berperan sebagai rezim yang lebih dominan dan bertahan lama, sedangkan Rezim 1 relatif lebih mudah mengalami perpindahan. Temuan ini sejalan dengan hasil estimasi fungsi logit sebelumnya, yang menunjukkan bahwa pengaruh variabel eksternal dapat memperkuat atau menahan perpindahan rezim.

Bentuk model *NHTEMS-AR* yang mencakup parameter intersep ($\mathbf{c}_{s_t}$), matriks koefisien autoregresif ($\Phi_{s_t,1}$), matriks kovarian error (Σ_{s_t}), serta parameter *emission* (γ_{s_t}) untuk masing-masing rezim ditunjukkan sebagai berikut.

$$\begin{aligned} \mathbf{c}_1 &= \begin{bmatrix} -0,0472 \\ -0,0272 \\ -0,0653 \end{bmatrix}, \Phi_{1,1} = \begin{bmatrix} 0,2923 & -0,0736 & 0,0473 \\ 0,0861 & -0,0070 & -0,0236 \\ 0,5396 & 0,1703 & -0,2180 \end{bmatrix}, \\ \Sigma_1 &= \begin{bmatrix} 0,0091 & 0,0012 & 0,0020 \\ 0,0012 & 0,0155 & 0,0042 \\ 0,0020 & 0,0042 & 0,0123 \end{bmatrix}, \gamma_1 = \begin{bmatrix} 0,0060 & -0,0135 & -0,0368 \\ -0,0002 & -0,0077 & -0,0111 \\ 0,0028 & -0,0092 & -0,0131 \end{bmatrix} \\ \mathbf{c}_2 &= \begin{bmatrix} 0,0422 \\ 0,0653 \\ 0,0903 \end{bmatrix}, \Phi_{2,1} = \begin{bmatrix} -0,1887 & 0,1822 & -0,0606 \\ 0,2884 & -0,2030 & 0,0522 \\ 0,0455 & 0,0655 & 0,1461 \end{bmatrix}, \\ \Sigma_2 &= \begin{bmatrix} 0,0132 & 0,0046 & 0,0003 \\ 0,0045 & 0,0154 & 0,0021 \\ 0,0003 & 0,0021 & 0,0226 \end{bmatrix}, \gamma_2 = \begin{bmatrix} -0,0002 & -0,0040 & 0,0160 \\ -0,0001 & -0,0000 & -0,0146 \\ -0,0099 & -0,0088 & -0,0004 \end{bmatrix} \end{aligned}$$

Dengan memasukkan nilai parameter hasil estimasi ke dalam bentuk umum model *NHTEMS-AR* multivariat, diperoleh persamaan model untuk masing-masing rezim sebagai berikut.

$$\begin{bmatrix} \hat{Y}_{1,t} \\ \hat{Y}_{2,t} \\ \hat{Y}_{3,t} \end{bmatrix} = \begin{cases} \begin{bmatrix} -0,0472 \\ -0,0272 \\ -0,0653 \end{bmatrix} + \begin{bmatrix} 0,2923 & -0,0736 & 0,0473 \\ 0,0861 & -0,0070 & -0,0236 \\ 0,5396 & 0,1703 & -0,2180 \end{bmatrix} \begin{bmatrix} Y_{1,t-1} \\ Y_{2,t-1} \\ Y_{3,t-1} \end{bmatrix} + \\ \begin{bmatrix} 0,0060 & -0,0135 & -0,0368 \\ -0,0002 & -0,0077 & -0,0111 \\ 0,0028 & -0,0092 & -0,0131 \end{bmatrix} \begin{bmatrix} Z_{1,t} \\ Z_{2,t} \\ Z_{3,t} \end{bmatrix}, & S_t = 1 \\ \begin{bmatrix} 0,0422 \\ 0,0653 \\ 0,0903 \end{bmatrix} + \begin{bmatrix} -0,1887 & 0,1822 & -0,0606 \\ 0,2884 & -0,2030 & 0,0522 \\ 0,0455 & 0,0655 & 0,1461 \end{bmatrix} \begin{bmatrix} Y_{1,t-1} \\ Y_{2,t-1} \\ Y_{3,t-1} \end{bmatrix} + \\ \begin{bmatrix} -0,0002 & -0,0040 & 0,0160 \\ -0,0001 & -0,0000 & -0,0146 \\ -0,0099 & -0,0088 & -0,0004 \end{bmatrix} \begin{bmatrix} Z_{1,t} \\ Z_{2,t} \\ Z_{3,t} \end{bmatrix}, & S_t = 2 \end{cases}$$

Sebagai contoh, untuk *return* saham PGAS, model pada masing-masing rezim dapat dituliskan secara eksplisit sebagai berikut:

$$\text{Rezim 1 : } \hat{Y}_{1,t} = -0,0472 + 0,2923Y_{1,t-1} - 0,0736Y_{2,t-1} + 0,0473Y_{3,t-1} + \\ 0,0060Z_{1,t} - 0,0135Z_{2,t} - 0,0368Z_{3,t}$$

$$\text{Rezim 2 : } \hat{Y}_{2,t} = 0,0422 - 0,1887Y_{1,t-1} + 0,1822Y_{2,t-1} - 0,0606Y_{3,t-1} - \\ 0,0002Z_{1,t} - 0,0040Z_{2,t} + 0,0160Z_{3,t}$$

Pada Rezim 1, koefisien *return* PGAS periode sebelumnya $Y_{1,t-1}$ bernilai positif sebesar 0,2923. Ini berarti jika *return* PGAS pada periode sebelumnya naik, maka pada periode berjalan *return* PGAS cenderung masih bergerak searah. Sementara itu, pengaruh *return* ADRO periode sebelumnya $Y_{2,t-1}$ bernilai negatif sebesar $-0,0736$, yang menunjukkan bahwa kenaikan *return* ADRO cenderung diikuti oleh penurunan *return* PGAS pada rezim ini. Sebaliknya, *return* MEDC periode sebelumnya $Y_{3,t-1}$ bernilai positif sebesar 0,0473, sehingga kenaikan *return* MEDC cenderung diikuti oleh kenaikan *return* PGAS, walaupun pengaruhnya relatif kecil.


Untuk variabel eksternal, pengaruh CRI (Z_{1t}) bernilai positif sebesar 0,0060, yang menunjukkan bahwa peningkatan risiko iklim global cenderung diikuti oleh kenaikan *return* PGAS, meskipun pengaruhnya kecil. Sementara itu, GPR (Z_{2t}) dan GEPU (Z_{3t}) masing-masing bernilai negatif sebesar $-0,0135$ dan $-0,0368$, yang

mengindikasikan bahwa peningkatan ketegangan geopolitik maupun ketidakpastian kebijakan ekonomi global cenderung menekan *return* PGAS pada rezim ini. Jadi, pada Rezim 1, *return* PGAS masih dipengaruhi oleh dinamika internal saham energi dan juga cukup merespon kondisi eksternal, terutama GEPU yang terlihat lebih besar dibanding dua variabel lainnya.

Pada Rezim 2, koefisien *return* PGAS periode sebelumnya $Y_{1,t-1}$ bernilai negatif sebesar $-0,1887$. Artinya, ketika *return* PGAS pada periode sebelumnya naik, maka pada periode berikutnya cenderung turun, sehingga pada rezim ini terlihat adanya pola koreksi *return*. Selain itu, koefisien *return* ADRO $Y_{2,t-1}$ bernilai positif sebesar $0,1822$, yang menunjukkan bahwa kenaikan *return* ADRO di periode sebelumnya cenderung mendorong kenaikan *return* PGAS pada periode berjalan. Sebaliknya, *return* MEDC $Y_{3,t-1}$ bernilai negatif sebesar $-0,0606$, sehingga kenaikan MEDC cenderung diikuti oleh penurunan PGAS, meskipun pengaruhnya tidak terlalu besar.

Untuk variabel eksternal pada Rezim 2, pengaruhnya terlihat kecil. Koefisien CRI ($0,0002$) dan GPR ($-0,0040$) mendekati nol, sehingga pengaruhnya terhadap *return* PGAS pada rezim ini relatif lemah. Namun, koefisien GEPU ($0,0160$) bernilai positif, yang menunjukkan bahwa meningkatnya ketidakpastian kebijakan ekonomi global pada rezim ini justru cenderung diikuti oleh kenaikan *return* PGAS. Ini bisa menggambarkan bahwa pada kondisi tertentu, saham energi masih dapat bergerak berbeda dari sentimen global, misalnya karena faktor pasar komoditas atau reaksi investor terhadap ketidakpastian.

Secara keseluruhan, Rezim 1 menggambarkan kondisi ketika *return* PGAS cenderung bergerak searah dengan periode sebelumnya dan lebih terpengaruh oleh GEPU yang bersifat menekan. Sementara itu, pada Rezim 2 *return* PGAS lebih menunjukkan pola koreksi, dengan peran ADRO yang cukup searah dan GEPU yang justru memberi dorongan positif. Perbedaan pola ini menunjukkan bahwa hubungan antar saham energi dan respon terhadap faktor global dapat berubah tergantung rezim yang sedang terjadi.



Gambar 4. 8 *Plot Smoothed Regime Probabilities NHTEMS-AR*

Berdasarkan Gambar 4.8, terlihat bahwa probabilitas masing-masing rezim mengalami fluktuasi sepanjang periode pengamatan. Pada beberapa periode, probabilitas Regime 1 (garis biru) mendekati nilai satu, yang mengindikasikan dominasi rezim tersebut. Namun, pada periode lainnya, probabilitas Regime 2 (garis merah) lebih dominan, menunjukkan terjadinya peralihan kondisi pasar. Perubahan probabilitas yang relatif cepat dan sering terjadi antar rezim mengindikasikan bahwa dinamika pasar saham sektor energi bersifat volatil dan sensitif terhadap berbagai faktor eksternal, seperti kondisi geopolitik, ketidakpastian ekonomi global, serta risiko iklim. Hal ini menyebabkan model mendeteksi adanya pergeseran rezim yang intens dalam jangka pendek.

Selain itu, tidak ditemukannya periode dominasi rezim yang berlangsung dalam waktu yang sangat panjang menunjukkan bahwa karakteristik masing-masing rezim belum sepenuhnya terpisah secara tegas. Dengan kata lain, perbedaan struktur statistik antar rezim relatif moderat, sehingga transisi antar rezim dapat terjadi secara cepat. Secara keseluruhan, hasil plot *smoothed regime probabilities* pada model *NHTEMS-AR* menunjukkan bahwa pasar saham sektor energi selama periode penelitian berada dalam kondisi yang dinamis dan tidak stabil, dengan pola pergantian rezim yang cukup intens. Temuan ini mengindikasikan bahwa pendekatan *Markov Switching* relevan untuk menangkap perubahan struktural

dalam data, meskipun interpretasi hasil perlu dilakukan secara hati-hati mengingat tingginya tingkat volatilitas.

4.4 Evaluasi Model

Evaluasi model dilakukan untuk menilai sejauh mana masing-masing spesifikasi model mampu merepresentasikan dinamika *return* saham sektor energi secara akurat. Pada penelitian ini, ukuran yang digunakan adalah *Symmetric Mean Absolute Percentage Error (SMAPE)* sebagai indikator ketepatan prediksi model. Nilai *SMAPE* yang lebih kecil menunjukkan bahwa model menghasilkan tingkat kesalahan prediksi yang lebih rendah dan memiliki kinerja yang lebih baik. Penggunaan *SMAPE* dinilai lebih sesuai karena mampu memberikan ukuran kesalahan yang bersifat simetris serta tidak terlalu sensitif terhadap nilai ekstrem. Tabel berikut menyajikan nilai *SMAPE* untuk seluruh model yang diestimasi.


Tabel 4. 3 Perbandingan *SMAPE* Antar Model

Model	<i>SMAPE</i>
<i>HMS-AR</i>	156,0721
<i>NHTMS-AR</i>	136,6189
<i>NHEMS-AR</i>	146,5551
<i>NHTEMS-AR</i>	131,7568

Berdasarkan Tabel 4.3, model *NHTEMS-AR* menghasilkan nilai *SMAPE* terendah sebesar 131,7568, yang mengindikasikan bahwa model ini memiliki tingkat kesalahan prediksi paling rendah dibandingkan model lainnya. Dengan demikian, *NHTEMS-AR* dikatakan sebagai model dengan kinerja terbaik dalam memodelkan dinamika *return* saham sektor energi pada penelitian ini. Selanjutnya, model *NHTMS-AR* menempati posisi kedua dengan nilai *SMAPE* sebesar 136,6189, diikuti oleh model *NHEMS-AR* sebesar 146,5551. Sementara itu, model *HMS-AR* memiliki nilai *SMAPE* tertinggi, yaitu sebesar 156,0721, yang menunjukkan bahwa model ini memiliki tingkat kesalahan prediksi paling besar.

Hasil ini menunjukkan bahwa pengembangan model dengan memasukkan komponen non-homogenitas dan pengaruh variabel eksogen, sebagaimana pada model *NHTEMS-AR*, mampu meningkatkan kemampuan prediksi. Integrasi faktor-


faktor tersebut memungkinkan model menangkap dinamika pasar yang lebih kompleks, sehingga menghasilkan prediksi yang lebih akurat.



Gambar 4. 9 Plot Data Aktual dan Prediksi Model *HMS-AR* (a) *NHTMS-AR* (b) *NHEMS-AR* (c) *NHTEMS-AR* (d) pada Data *Training*

Plot perbandingan antara data aktual dan data prediksi pada periode *training* menunjukkan kemampuan masing-masing model dalam menyesuaikan diri terhadap pola historis *return* saham sektor energi, khususnya pada saham PGAS, ADRO, dan MEDC. Garis hitam merepresentasikan data aktual, sedangkan garis merah menunjukkan nilai prediksi yang dihasilkan oleh model. Berdasarkan Gambar 4.9, secara umum terlihat bahwa garis prediksi mengikuti pola pergerakan data aktual dengan cukup baik pada ketiga saham yang dianalisis. Hal ini mengindikasikan bahwa model mampu menangkap dinamika *return* saham selama periode pelatihan, termasuk fluktuasi jangka pendek dan perubahan tren. Pada

saham PGAS, ADRO, dan MEDC, pola prediksi cenderung bergerak di sekitar nilai tengah *return* dan mengikuti arah perubahan data aktual, meskipun terdapat beberapa periode di mana model belum sepenuhnya mampu menangkap lonjakan ekstrem (*shock*) yang terjadi secara tiba-tiba. Kondisi ini menunjukkan bahwa model lebih efektif dalam memodelkan pola umum dibandingkan pergerakan ekstrem yang bersifat sementara.



Gambar 4. 10 Plot Data Aktual dan Prediksi Model *HMS-AR* (a) *NHTMS-AR* (b) *NHEMS-AR* (c) *NHTEMS-AR* (d) pada Data *Testing*

Berdasarkan Gambar 4.10, terlihat bahwa secara umum hasil prediksi mampu mengikuti arah pergerakan data aktual. Hal ini menunjukkan bahwa model memiliki kemampuan generalisasi yang cukup baik terhadap data baru. Namun demikian, pada beberapa periode tertentu, terutama saat terjadi perubahan nilai yang tajam, terlihat adanya perbedaan yang relatif besar antara data aktual dan hasil

prediksi. Model cenderung menghasilkan prediksi yang lebih halus dan belum sepenuhnya mampu mengikuti fluktuasi ekstrem yang terjadi secara tiba-tiba. Kondisi ini mengindikasikan bahwa model lebih efektif dalam memodelkan pola sistematis jangka menengah dibandingkan pergerakan jangka pendek. Selain itu, deviasi antara nilai aktual dan prediksi tidak menunjukkan pola yang sistematis, sehingga mengindikasikan bahwa kesalahan prediksi bersifat acak dan tidak mengarah pada bias tertentu. Hal ini mencerminkan bahwa model tidak mengalami overfitting pada data *training* dan tetap mampu mempertahankan kinerjanya pada data pengujian.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil analisis yang diperoleh, kesimpulan yang didapatkan adalah sebagai berikut.

1. Berdasarkan analisis statistik deskriptif dan plot deret waktu, *return* logaritmik bulanan saham PGAS, ADRO, dan MEDC selama September 2008–Desember 2024 memiliki rata-rata *return* relatif kecil di sekitar nol, namun menunjukkan fluktuasi (volatilitas) yang cukup tinggi dan tidak seragam dari waktu ke waktu. Saham MEDC memiliki volatilitas tertinggi (standar deviasi terbesar), diikuti ADRO, sedangkan PGAS relatif lebih rendah. Adanya spike ekstrem pada periode tertentu (misalnya sekitar pandemi) mengindikasikan perubahan dinamika pasar yang berpotensi merepresentasikan peralihan rezim. Variabel eksogen CRI, GPR, dan GEPU juga memperlihatkan variasi yang berbeda, di mana GPR dan GEPU lebih fluktuatif dibanding CRI, sehingga relevan untuk menjelaskan dinamika eksternal yang dapat berhubungan dengan perubahan kondisi pasar.
2. Berdasarkan hasil pemodelan *HMS-AR* pada *return* saham sektor energi di Indonesia, matriks probabilitas transisi menunjukkan bahwa Rezim 1 memiliki tingkat persistensi yang sangat tinggi, sehingga pasar cenderung bertahan dalam kondisi ini dalam jangka waktu yang panjang, sementara Rezim 2 bersifat sementara dan tidak stabil karena memiliki peluang besar untuk kembali ke Rezim 1. Hasil estimasi parameter autoregresif memperkuat temuan tersebut, di mana Rezim 1 ditandai oleh pengaruh lag *return* yang relatif kecil dan moderat, mencerminkan kondisi pasar yang tenang dan tidak terlalu bergejolak. Sebaliknya, Rezim 2 menunjukkan pola koreksi *return* yang kuat (*mean reversion*) serta hubungan antar saham yang cenderung berlawanan arah, sehingga merepresentasikan fase pasar yang lebih bergejolak. Pola ini juga didukung oleh grafik *smoothed regime probabilities* yang memperlihatkan dominasi Rezim 1 sepanjang periode

pengamatan, dengan kemunculan Rezim 2 yang hanya terjadi pada interval waktu tertentu dan bersifat singkat.

3. Berdasarkan hasil pemodelan *NHMS-AR*, dinamika *return* saham sektor energi di Indonesia dipengaruhi oleh perubahan kondisi eksternal dan menunjukkan perilaku rezim yang tidak konstan sepanjang waktu. Pada model *NHTMS-AR*, variabel eksternal terbukti memengaruhi probabilitas perpindahan antar-rezim, dengan Rezim 2 cenderung lebih persisten dibandingkan Rezim 1. Pada *NHEMS-AR*, pengaruh variabel eksternal tidak hanya terlihat pada mekanisme transisi, tetapi juga langsung membentuk dinamika *return* di dalam rezim, di mana Rezim 2 kembali muncul sebagai rezim yang sangat dominan dan bertahan lama, sementara Rezim 1 bersifat sementara. Selanjutnya, pada model *NHTEMS-AR* yang menggabungkan *non-homogeneity* pada komponen transisi dan emisi secara simultan, dinamika pasar terlihat lebih kompleks dan adaptif, ditandai dengan pengaruh kuat risiko iklim, ketegangan geopolitik, dan ketidakpastian kebijakan ekonomi global terhadap baik perpindahan rezim maupun perilaku *return* di dalam rezim. Pola probabilitas *smoothed* pada model ini menunjukkan pergantian rezim yang relatif intens, mencerminkan kondisi pasar saham sektor energi yang dinamis, volatil, dan sensitif terhadap faktor eksternal.
4. Evaluasi model menggunakan *Symmetric Mean Absolute Percentage Error (SMAPE)*. Berdasarkan hasil evaluasi, terlihat bahwa model *NHTEMS-AR* menghasilkan nilai *SMAPE* paling kecil, yaitu sebesar 131,7568, sehingga dapat dikatakan sebagai model dengan kinerja prediksi terbaik dalam penelitian ini. Model *NHTMS-AR* menempati posisi kedua dengan nilai *SMAPE* sebesar 136,6189, diikuti oleh *NHEMS-AR* sebesar 146,5551. Sementara itu, model *HMS-AR* memiliki nilai *SMAPE* paling besar, yaitu 156,0721, yang menunjukkan bahwa model ini memiliki kesalahan prediksi paling tinggi dibandingkan model lainnya. Hasil ini mengindikasikan bahwa penambahan unsur non-homogenitas serta pengaruh variabel eksternal mampu meningkatkan akurasi prediksi model.

5.2 Saran

Penelitian selanjutnya disarankan untuk menambahkan variabel eksogen lain yang lebih spesifik terhadap sektor energi, seperti harga minyak dunia (Brent/WTI), nilai tukar USD/IDR, tingkat inflasi, atau suku bunga global. Penambahan variabel tersebut diharapkan dapat memperkaya model dan memberikan pemahaman yang lebih komprehensif mengenai faktor-faktor eksternal yang memengaruhi perubahan rezim pasar saham energi di Indonesia.

Selain itu, penelitian berikutnya juga dapat melakukan perluasan cakupan data, baik dari sisi periode waktu maupun frekuensi pengamatan. Penggunaan data harian atau mingguan akan membuat model lebih sensitif terhadap perubahan pasar jangka pendek, sedangkan penambahan jumlah emiten energi dapat memberikan gambaran yang lebih menyeluruh terhadap dinamika sektor energi di pasar modal Indonesia.

(Halaman ini sengaja dikosongkan)

DAFTAR PUSTAKA

- Agustina, L., Gunawan, Y., & Chandra, W. (2018). The Impact of Tax Amnesty Announcement towards Share Performance and Market Reaction in Indonesia. *Accounting and Finance Research*, 7(2), 39. <https://doi.org/10.5430/afr.v7n2p39>
- Ahmad, W., & Kamaiah, B. (2010). Modeling Business Cycles in India: A *Markov Switching* Approach. *The Asian Economic Review*, 52(2), 1–14.
- Ailliot, P., Bessac, J., Monbet, V., & Pène, F. (2015). Non-homogeneous hidden *Markov-Switching* models for wind time series. *Journal of Statistical Planning and Inference*, 160, 75–88. <https://doi.org/10.1016/j.jspi.2014.12.005>
- Ashariansyah, A. R., Iriawan, N., & Mukarromah, A. (2020). Pemodelan Harga Cryptocurrency Menggunakan *Markov Switching* Autoregressive. *Inferensi*, 3(2), 81. <https://doi.org/10.12962/j27213862.v3i2.7726>
- Baum, L. E., Petrie, T., Soules, G., & Weiss, N. (1970). A Maximization Technique Occurring in the Statistical Analysis of Probabilistic Functions of *Markov* Chains. *The Annals of Mathematical Statistics*, 41(1), 164–171. <https://www.jstor.org/stable/2239727>
- Cappé, O., Moulines, E., & Rydén, T. (2005). Inference in Hidden *Markov* Models. In *Springer*.
- Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)? <https://doi.org/10.5194/gmdd-7-1525-2014>
- Choji, D. N., Eduno, S. N., & Kassem, G. T. (2013). *Markov* Chain Model Application on Share Price Movement in Stock Market. *Computer Engineering and Intelligent Systems*, 4(10), 84–95.
- Dempster, A. P., Laird, N. M., & Rubin, D. B. (1977). Maximum *Likelihood* from Incomplete Data Via the EM Algorithm. *Journal of the Royal Statistical Society Series B: Statistical Methodology*, 39(1), 1–22. <https://doi.org/10.1111/j.2517-6161.1977.tb01600.x>
- Dua, P., & Tuteja, D. (2021). Regime Shifts in the Behaviour of International Currency and Equity Markets: A *Markov-Switching* Analysis. *Journal of Quantitative Economics*, 19(s1), 309–336. <https://doi.org/10.1007/s40953->

- Febiyola, T., Utari, R. S., Panggabean, B. T., & Agustina, R. (2024). Analisis Surat Berharga Sebagai Alat Investasi. *Deposisi : Jurnal Publikasi Ilmu Hukum*, 2(3). <https://doi.org/https://doi.org/10.59581/deposisi.v2i3.3688>
- Gitman, L. J., Joehnk, M. D., Smart, S. B., Juchau, R. H., Ross, D. G., & Wright, S. (2011). *Fundamentals of investing (3rd ed.)*. Pearson higher education AU.
- Hafer, R. W., & Hein, S. E. (2007). The “stock” market. In *Flexo* (Vol. 32, Nomor 2). Greenwood Press. <https://doi.org/10.5860/choice.44-5761>
- Hamilton, J. D. (1989). A New Approach to the Economic Analysis of Nonstationary Time Series and the Business Cycle. *Econometrica*, 57(2), 357. <https://doi.org/10.2307/1912559>
- Hamilton, J. D. (1990). Analysis of time series subject to changes in regime. *Journal of Econometrics*, 45(1–2), 39–70. [https://doi.org/10.1016/0304-4076\(90\)90093-9](https://doi.org/10.1016/0304-4076(90)90093-9)
- Hamilton, J. D. (1994a). *State-space models* (hal. 3039–3080). [https://doi.org/10.1016/S1573-4412\(05\)80019-4](https://doi.org/10.1016/S1573-4412(05)80019-4)
- Hamilton, J. D. (1994b). *Time Series Analysis*. Princeton University Press. <https://doi.org/10.1515/9780691218632>
- Handayani, L. P. S., & Prastyo, D. D. (2020). Analisis Likuiditas Saham Sektor Perbankan di BEI Menggunakan Analisis Intervensi dan Autoregressive Conditional Duration. *Inferensi*, 3(1), 47. <https://doi.org/10.12962/j27213862.v3i1.6881>
- Hu, Z., & Borjigin, S. (2024). The amplifying role of geopolitical Risks, economic policy Uncertainty, and climate risks on Energy-Stock market volatility spillover across economic cycles. *The North American Journal of Economics and Finance*, 71, 102114. <https://doi.org/10.1016/j.najef.2024.102114>
- Hughes, J. P., Guttorp, P., & Charles, S. P. (1999). A Non-Homogeneous Hidden Markov Model for Precipitation Occurrence. *Journal of the Royal Statistical Society Series C: Applied Statistics*, 48(1), 15–30. <https://doi.org/10.1111/1467-9876.00136>
- Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting Principles and Practice* (3rd ed.). OTexts.

- Kemeny, J. G., & Snell, J. L. (1960). *Finite Markov Chains*. Springer.
- Kungwani, M. P. (2014). *Risk Management-An Analytical Study*. 16(3), 83–89.
- Makridakis, S. G., Wheelwright, S. C., & Hyndman, R. J. (1998). *Forecasting Methods and Applications*. John Wiley & Sons, Ltd.
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). Statistical and Machine Learning forecasting methods: Concerns and ways forward. *PLOS ONE*, 13(3), e0194889. <https://doi.org/10.1371/journal.pone.0194889>
- Markov, A. A. (1906). *Rasprostranenie zakona bol'shikh chisel na velichiny, zavisyashchie drug ot druga [Extension of the law of large numbers to dependent quantities]*. Izvestiya Akademii Nauk.
- Monbet, V. (2022). NHMSAR: Non-Homogeneous Markov Switching Autoregressive Models (Version 1.19) [R package]. *CRAN*.
- Oktavia, I., & Nugraha, K. G. S. (2018). Faktor-Faktor Yang Mempengaruhi Harga Saham. *UNEJ e-Proceeding*.
- Prihartani, W., Rasyid, D. A., & Iriawan, N. (2020). Stock Daily Price Regime Model Detection using Markov Switching Model. *MATEMATIKA*, 36(2), 127–140. <https://doi.org/10.11113/matematika.v36.n2.1189>
- Romanuke, V. (2021). Maximum-versus-mean absolute error in selecting criteria of time series forecasting quality. *Bionics of Intelligence*, 1(96), 3–9. [https://doi.org/10.30837/bi.2021.1\(96\).01](https://doi.org/10.30837/bi.2021.1(96).01)
- Schwert, G. W. (1989). Business Cycles, Financial Crises, and Stock Volatility. *Carnegie-Rochester Conference Series on Public Policy*, 31.
- Seneta, E. (2006). Markov and the Creation of Markov Chains. *MAM2006: Markov Anniversary Meeting*, 1–20.
- Shen, J. (2013). *Merge Times and Hitting Times of Time-inhomogeneous Markov Chains by*.
- Spezia, L., Gibbs, S., Glendell, M., Helliwell, R., Paroli, R., & Pohle, I. (2023). Bayesian analysis of high-frequency water temperature time series through Markov Switching autoregressive models. *Environmental Modelling & Software*, 167, 105751. <https://doi.org/10.1016/j.envsoft.2023.105751>
- Teng, Z. (2023). Stock Selection and Analysis Based on Valuation, Growth, Profitability and Payout. *BCP Business & Management*, 38, 926–934.

<https://doi.org/10.54691/bcpbm.v38i.3798>

Wei, W. W. S. (2006). *Time Series Analysis Univariate and Multivariate Methods* (2nd ed.). Pearson Addison Wesley.

Yule, G. U. (1927). On a Method of Investigating Periodicities in Disturbed Series, with Special Reference to Wolfer's Sunspot Numbers. *Philosophical Transactions of the Royal Society of London. Series A, Containing Papers of a Mathematical or Physical Character*, 226, 267–298.
<https://www.jstor.org/stable/91170>

LAMPIRAN

Lampiran 1 Data *Return* Saham Sektor Energi

year	month	<i>return</i> PGAS	<i>return</i> ADRO	<i>return</i> MEDC
2008	9	-0.159	-0.095	-0.299
2008	10	-0.441	-0.722	-0.546
2008	11	0.273	-0.268	-0.127
2008	12	0.011	-0.07	0.011
2009	1	0.168	0.422	-0.095
2009	2	-0.147	0.04	0.192
2009	3	0.124	0.134	0.066
2009	4	0.19	0.148	0.177
2009	5	0.101	0.273	0.229
2009	6	0.091	-0.11	-0.079
2009	7	0.105	0.065	0.086
2009	8	0.005	0.061	-0.128
2009	9	0.049	0.059	-0.009
2009	10	-0.007	0.074	-0.062
2009	11	0.007	0.122	0
2009	12	0.066	-0.006	-0.106
2010	1	-0.03	0.095	-0.021
2010	2	-0.041	-0.032	0.031
2010	3	0.159	0.069	0.049
2010	4	-0.036	0.115	0.126
2010	5	-0.05	-0.095	-0.034
2010	6	-0.006	-0.005	0.034
2010	7	0.044	0.014	0.017
2010	8	0.024	-0.051	0.025
2010	9	-0.038	0.064	0.078
2010	10	0.051	0.036	0.203
2010	11	0.06	0.102	-0.196
2010	12	0.029	0.097	0.007
2011	1	-0.044	-0.125	-0.045
2011	2	-0.174	0.085	-0.098
2011	3	0.094	-0.108	-0.017
2011	4	0.025	0	-0.044
2011	5	0.012	0.108	-0.056
2011	6	-0.006	0.009	-0.101
2011	7	-0.013	0.078	0.062
2011	8	-0.261	-0.269	-0.051
2011	9	-0.098	-0.163	-0.1
2011	10	0.098	0.163	0.078
2011	11	0.041	-0.058	0

year	month	<i>return</i> PGAS	<i>return</i> ADRO	<i>return</i> MEDC
2011	12	0.032	-0.065	0.042
2012	1	0.065	0.033	-0.042
2012	2	0.105	0.048	-0.011
2012	3	0.013	0.005	-0.067
2012	4	-0.126	-0.037	-0.024
2012	5	0.099	-0.235	-0.149
2012	6	-0.048	0.028	-0.006
2012	7	0.11	0.007	-0.04
2012	8	-0.027	-0.064	-0.029
2012	9	0.109	0.091	0.306
2012	10	0.12	-0.091	-0.091
2012	11	-0.027	-0.022	-0.022
2012	12	-0.011	0.171	0.171
2013	1	0.044	0.044	0.044
2013	2	0.026	-0.05	-0.05
2013	3	0.215	-0.181	-0.181
2013	4	0.049	-0.063	-0.063
2013	5	-0.128	-0.28	-0.28
2013	6	0.077	-0.066	-0.066
2013	7	0.026	-0.206	-0.206
2013	8	-0.089	0.284	0.284
2013	9	-0.038	-0.033	-0.033
2013	10	-0.019	0.125	0.125
2013	11	-0.05	0.102	0.102
2013	12	-0.08	-0.036	-0.036
2014	1	0.064	-0.124	-0.124
2014	2	0.027	0.046	0.046
2014	3	0.045	-0.015	-0.025
2014	4	0.038	0.19	-0.082
2014	5	0.058	0.033	-0.017
2014	6	0.027	-0.032	0.422
2014	7	0.057	0.008	0.125
2014	8	-0.017	0.104	0.425
2014	9	0.034	-0.113	-0.022
2014	10	-0.008	-0.035	0.076
2014	11	0	-0.05	-0.029
2014	12	0.008	-0.038	0.016
2015	1	-0.172	-0.028	-0.196
2015	2	0.029	-0.041	-0.041
2015	3	-0.08	-0.01	0.033
2015	4	-0.158	-0.082	0.032
2015	5	0.077	-0.017	-0.189

year	month	<i>return</i> PGAS	<i>return</i> ADRO	<i>return</i> MEDC
2015	6	0.005	-0.102	0.03
2015	7	-0.076	-0.253	-0.108
2015	8	-0.364	0.008	0.021
2015	9	-0.094	-0.106	-0.712
2015	10	0.17	0.106	-0.133
2015	11	-0.122	-0.079	-0.019
2015	12	0.033	-0.066	-0.283
2016	1	-0.132	0.05	-0.12
2016	2	0.091	0.142	0.329
2016	3	-0.008	0.064	0.422
2016	4	0.002	0.124	0.114
2016	5	-0.021	-0.005	-0.187
2016	6	-0.058	0.18	0.076
2016	7	0.341	0.202	0.116
2016	8	-0.086	0.101	-0.103
2016	9	-0.051	0.047	0.007
2016	10	-0.114	0.274	-0.155
2016	11	0.035	-0.035	-0.039
2016	12	0.019	0.102	0.047
2017	1	0.065	0.015	0.052
2017	2	-0.018	0	0.587
2017	3	-0.112	0.032	0.336
2017	4	-0.04	0.014	-0.157
2017	5	-0.012	-0.155	0.007
2017	6	-0.033	0.049	-0.273
2017	7	0	0.122	0.15
2017	8	-0.06	0.022	0.216
2017	9	-0.297	0	-0.056
2017	10	0.156	0	0.013
2017	11	-0.079	-0.071	0.216
2017	12	0.029	0.09	0.115
2018	1	0.4	0.298	0.226
2018	2	0.023	-0.042	0.239
2018	3	-0.149	-0.098	-0.264
2018	4	-0.147	-0.149	-0.008
2018	5	0.042	0.027	-0.069
2018	6	-0.02	-0.015	-0.149
2018	7	-0.16	0.062	0.026
2018	8	0.23	-0.021	-0.129
2018	9	0.05	-0.016	0.139
2018	10	-0.013	-0.106	-0.198
2018	11	-0.127	-0.25	-0.158

year	month	<i>return</i> PGAS	<i>return</i> ADRO	<i>return</i> MEDC
2018	12	0.081	-0.056	0.111
2019	1	0.192	0.162	0.255
2019	2	-0.012	-0.059	-0.088
2019	3	-0.074	0.023	-0.044
2019	4	-0.017	-0.026	-0.006
2019	5	-0.119	-0.008	-0.127
2019	6	0.05	0.094	0.044
2019	7	-0.029	-0.068	0.048
2019	8	-0.066	-0.121	-0.139
2019	9	0.09	0.137	0.1
2019	10	0.005	0.015	-0.214
2019	11	-0.094	-0.063	0.073
2019	12	0.122	0.234	0.197
2020	1	-0.241	-0.239	-0.205
2020	2	-0.287	-0.014	-0.112
2020	3	-0.502	-0.154	-0.49
2020	4	0.098	-0.073	0.153
2020	5	0.006	0.179	-0.022
2020	6	0.326	-0.1	0.027
2020	7	0.108	0.125	0.026
2020	8	-0.008	0	0.17
2020	9	-0.305	0.045	-0.32
2020	10	0.15	-0.009	0.122
2020	11	0.257	0.212	0.265
2020	12	0.174	0.028	0.17
2021	1	-0.207	-0.175	0.097
2021	2	0.068	-0.017	0.067
2021	3	-0.091	-0.004	-0.198
2021	4	-0.071	0.058	0.162
2021	5	-0.094	-0.045	0.029
2021	6	-0.104	0.067	-0.075
2021	7	-0.03	0.102	-0.271
2021	8	0.06	-0.058	-0.025
2021	9	0.14	0.334	0.145
2021	10	0.238	-0.047	-0.138
2021	11	-0.007	0.012	-0.002
2021	12	-0.087	0.28	-0.025
2022	1	0.004	0.067	0.175
2022	2	0.043	0.09	0.078
2022	3	-0.025	0.093	-0.078
2022	4	0.032	0.216	-0.009
2022	5	0.216	-0.021	0.062

year	month	<i>return</i> PGAS	<i>return</i> ADRO	<i>return</i> MEDC
2022	6	-0.124	-0.089	0.082
2022	7	0.128	0.128	-0.04
2022	8	0.091	0.085	0.343
2022	9	-0.047	0.112	0.122
2022	10	0.118	0.005	0.233
2022	11	-0.049	-0.028	-0.081
2022	12	-0.066	-0.005	-0.048
2023	1	-0.13	-0.263	0.318
2023	2	0.013	0.078	-0.193
2023	3	-0.126	-0.031	-0.13
2023	4	0.036	0.076	0
2023	5	0	-0.428	-0.11
2023	6	-0.091	0.192	-0.017
2023	7	0.149	0.078	0.266
2023	8	0.007	0.102	-0.055
2023	9	0	0.065	0.409
2023	10	-0.091	-0.107	-0.233
2023	11	-0.118	0.023	-0.099
2023	12	0.013	-0.096	0.013
2024	1	0.031	0.089	0.055
2024	2	-0.067	0.008	0.071
2024	3	0.221	0.109	0.088
2024	4	0.078	0.004	-0.058
2024	5	0.072	0.022	0.033
2024	6	-0.026	0.083	-0.044
2024	7	0.136	0.143	0.011
2024	8	-0.038	0.1	-0.051
2024	9	-0.071	0.068	0.008
2024	10	0.087	-0.051	0.012
2024	11	-0.029	-0.554	-0.149
2024	12	0.045	0.618	0.009
2025	1	0.006	-0.159	-0.058
2025	2	-0.061	-0.118	-0.077
2025	3	0.033	-0.115	0.025
2025	4	0.08	0.029	0.024
2025	5	0.077	0.147	0.158
2025	6	-0.12	-0.184	0.012
2025	7	0.009	0.093	0.05
2025	8	0.048	-0.053	-0.098
2025	9	-0.012	-0.038	0.162
2025	10	0.029	0.109	-0.03

Lampiran 2 Data Variabel Eksogen

year	month	CRI	GPR	GEPU
2008	9	0.265	88.543	162.272
2008	10	0.079	64.16	208.108
2008	11	0.109	79.081	143.707
2008	12	0.069	92.366	144.475
2009	1	0.166	85.369	145.795
2009	2	0.025	67.453	147.462
2009	3	0.022	72.645	132.31
2009	4	0.054	85.688	102.434
2009	5	0.069	89.681	103.602
2009	6	0.07	81.11	117.292
2009	7	0.242	83.44	106.577
2009	8	0.112	73.372	103.174
2009	9	0.172	92.84	106.279
2009	10	0.092	90.576	91.993
2009	11	0.157	82.102	105.555
2009	12	0.097	92.947	102.744
2010	1	0.095	91.581	118.002
2010	2	0.141	80.725	114.785
2010	3	0.11	74.117	114.881
2010	4	0.046	88.762	109.304
2010	5	0.295	88.959	147.568
2010	6	0.136	96.454	138.581
2010	7	0.208	79.381	148.885
2010	8	0.137	80.994	123.582
2010	9	0.162	71.169	133.104
2010	10	0.107	65.992	127.106
2010	11	0.079	94.705	130.984
2010	12	0.147	97.204	135.096
2011	1	0.126	79.422	114.926
2011	2	0.039	90.014	96.74
2011	3	0.044	136.888	130.888
2011	4	0.126	91.018	119.599
2011	5	0.098	105.345	94.539
2011	6	0.156	84.392	124.718
2011	7	0.113	78.925	153.854
2011	8	0.323	86.952	217.145
2011	9	0.12	83.35	194.542
2011	10	0.07	76.34	167.073
2011	11	0.031	83.158	191.778
2011	12	0.095	85.341	178.51

year	month	CRI	GPR	GEPU
2012	1	0.149	79.635	154.835
2012	2	0.136	92.446	141.601
2012	3	0.034	88.76	132.98
2012	4	0.138	96.017	130.475
2012	5	0.074	78.171	160.043
2012	6	0.203	77.822	183.552
2012	7	0.112	82.808	152.918
2012	8	0.193	74.878	117.11
2012	9	0.078	69.281	154.025
2012	10	0.164	81.664	151.532
2012	11	0.02	81.39	166.332
2012	12	0.112	74.832	170.704
2013	1	0.171	90.657	167.795
2013	2	0.034	81.59	123.468
2013	3	0.043	75.897	145.901
2013	4	0.026	95.108	136.667
2013	5	0.118	83.717	108.484
2013	6	0.101	82.973	128.35
2013	7	0.103	73.976	108.736
2013	8	0.167	90.957	120.022
2013	9	0.171	100.459	139.267
2013	10	0.09	72.953	169.366
2013	11	0.072	77.779	104.462
2013	12	0.137	70.372	123.743
2014	1	0.261	77.916	115.767
2014	2	0.064	69.004	101.741
2014	3	0.039	119.839	115.452
2014	4	0.06	93.222	111.153
2014	5	0.049	83.429	107.431
2014	6	0.119	98.767	91.765
2014	7	0.112	138.754	94.953
2014	8	0.158	136.446	97.45
2014	9	0.157	131.557	122.46
2014	10	0.079	83.661	112.977
2014	11	0.045	84.38	120.111
2014	12	0.049	86.526	111.469
2015	1	0.456	111.986	129.7
2015	2	0.065	111.925	115.919
2015	3	0.124	104.235	112.76
2015	4	0.122	102.19	101.827
2015	5	0.132	76.262	104.77
2015	6	0.128	85.906	119.777

year	month	CRI	GPR	GEPU
2015	7	0.201	106.809	123.793
2015	8	0.162	82.479	120.173
2015	9	0.152	98.767	153.958
2015	10	0.111	91.932	116.205
2015	11	0.083	150.716	105.976
2015	12	0.048	148.237	112.974
2016	1	0.159	118.211	144.667
2016	2	0.061	103.75	147.712
2016	3	0.044	109.72	159.913
2016	4	0.139	85.221	142.775
2016	5	0.122	88.332	126.734
2016	6	0.273	90.168	230.855
2016	7	0.109	114.61	204.314
2016	8	0.119	98.738	135.2
2016	9	0.127	104.545	136.228
2016	10	0.085	85.748	126.502
2016	11	0.074	82.919	229.263
2016	12	0.017	102.18	185.541
2017	1	0.105	105.201	248.143
2017	2	0.057	114.206	186.338
2017	3	0.087	96.636	237.662
2017	4	0.074	119.46	177.477
2017	5	0.099	102.58	144.984
2017	6	0.193	126.789	172.736
2017	7	0.136	102.813	166.62
2017	8	0.418	138.532	140.961
2017	9	0.467	115.534	158.799
2017	10	0.057	91.462	145.041
2017	11	0.06	92.596	161.16
2017	12	0.01	82.718	149.395
2018	1	0.169	92.427	179.256
2018	2	0.052	64.491	127.329
2018	3	0.053	111.962	183.244
2018	4	0.059	123.263	166.438
2018	5	0.117	125.667	172.567
2018	6	0.145	103.969	165.488
2018	7	0.16	110.028	230.334
2018	8	0.134	112.742	173.509
2018	9	0.12	75.054	194.737
2018	10	0.149	92.016	215.239
2018	11	0.018	80.408	249.541
2018	12	0.009	90.608	221.622

year	month	CRI	GPR	GEPU
2019	1	0.172	87.424	245.259
2019	2	0.04	96.8	174.355
2019	3	0.13	82.328	242.139
2019	4	0.085	79.253	192.406
2019	5	0.09	106.472	225.195
2019	6	0.18	106.588	324.002
2019	7	0.156	93.521	250.889
2019	8	0.132	103.404	292.556
2019	9	0.112	90.368	238.612
2019	10	0.208	97.837	202.842
2019	11	0.094	73.078	244.916
2019	12	0.118	74.28	233.105
2020	1	0.124	138.421	193.103
2020	2	0.134	75.956	197.662
2020	3	0.099	81.54	319.062
2020	4	0.139	69.339	329.932
2020	5	0.223	68.507	418.616
2020	6	0.223	71.228	312.16
2020	7	0.076	66.473	315.372
2020	8	0.199	65.466	292.005
2020	9	0.083	80.377	312.347
2020	10	0.157	76.083	308.132
2020	11	0.153	70.067	401.617
2020	12	0.059	64.067	305.191
2021	1	0.238	77.419	274.469
2021	2	0.13	73.957	196.158
2021	3	0.108	78.619	214.234
2021	4	0.148	88.166	196.743
2021	5	0.123	93.007	175.166
2021	6	0.214	74.127	172.505
2021	7	0.366	58.421	190.972
2021	8	0.258	89.487	203.903
2021	9	0.081	80.697	214.193
2021	10	0.146	79.029	189.629
2021	11	0.072	86.569	231.739
2021	12	0.066	105.345	262.078
2022	1	0.212	138.675	224.787
2022	2	0.145	216.159	177.665
2022	3	0.081	318.955	300.496
2022	4	0.11	191.143	271.762
2022	5	0.292	142.258	279.324
2022	6	0.134	130.707	251.079

year	month	CRI	GPR	GEPU
2022	7	0.134	117.177	296.6
2022	8	0.091	132.863	238.245
2022	9	0.264	131.986	251.304
2022	10	0.112	143.162	267.785
2022	11	0.075	116.716	314.667
2022	12	0.081	111.196	242.744
2023	1	0.095	104.267	219.46
2023	2	0.06	120.994	244.208
2023	3	0.163	105.38	317.537
2023	4	0.162	106.81	258.07
2023	5	0.11	108.468	213.935
2023	6	0.172	110.529	224.112
2023	7	0.386	107.449	194.257
2023	8	0.125	101.141	177.337
2023	9	0.115	98.635	203.205
2023	10	0.129	197.887	192.256
2023	11	0.17	156.696	210.117
2023	12	0.086	142.279	225.805
2024	1	0.149	160.165	242.808
2024	2	0.105	146.598	169.478
2024	3	0.125	133.213	181.203
2024	4	0.224	163.736	173.199
2024	5	0.226	130.522	186.527
2024	6	0.115	112.881	174.814
2024	7	0.18	92.395	232.161
2024	8	0.108	140.764	193.376
2024	9	0.252	130.142	204.51
2024	10	0.155	130.697	207.556
2024	11	0.168	128.482	284.802
2024	12	0.012	142.135	329.905
2025	1	0.064	112.33	309.68
2025	2	0.055	136.43	319.959
2025	3	0.067	175.44	459.379
2025	4	0.041	139.72	584.652
2025	5	0.068	165.81	484.715
2025	6	0.111	222.20	358.558
2025	7	0.104	135.00	395.344
2025	8	0.121	136.76	332.074
2025	9	0.090	124.11	297.619
2025	10	0.092	154.43	404.563

Lampiran 3 *Syntax* R Statistika Deskriptif

```
# Baca data
data <- read.csv("D:/Adam/Tesis/Data Lengkap Tambah Covariate (2).csv",
  header = TRUE, sep = ";")

# Load package yang diperlukan
library(psych) # Untuk describe()
library(dplyr) # Untuk select()

# Ambil variabel return (endogen) dan variabel eksogen
statdes_data <- data %>%
  select(return.PGAS, return.ADRO, return.MEDC, CRI, GPR, GEPU)

# Hitung statistik deskriptif
statistik_deskriptif <- describe(statdes_data)

# Tampilkan hasil
print(statistik_deskriptif)

# Buat vektor waktu bulanan dari September 2008 hingga Desember 2024
waktu <- seq(as.Date("2008-09-01"), as.Date("2024-12-01"), by = "month")

# Ambil matrix return saham
return_data <- data[, c("return.PGAS", "return.ADRO", "return.MEDC")]

# Plot dengan waktu sebagai sumbu X
matplot(waktu, return_data,
  type = "l", lty = 1, col = c("blue", "red", "darkgreen"),
  main = "Plot Return Saham Sektor Energi",
  ylab = "Return", xlab = "Waktu", xaxt = "n") # nonaktifkan default axis

# Buat axis X dengan label tahun
axis.Date(1, at = seq(min(waktu), max(waktu), by = "year"), format = "%Y")

# Tambahkan legenda
legend("topright", legend = c("PGAS", "ADRO", "MEDC"),
  col = c("blue", "red", "darkgreen"), lty = 1, bty = "n")

plot(waktu, data$CRI, type = "l", col = "orange", lwd = 2,
  main = "Plot Indeks Risiko Iklim (CRI)",
  xlab = "Waktu", ylab = "Nilai CRI", xaxt = "n")
axis.Date(1, at = seq(min(waktu), max(waktu), by = "year"), format = "%Y")

plot(waktu, data$GEPU, type = "l", col = "blue", lwd = 2,
  main = "Plot Indeks Ketidakpastian Kebijakan Ekonomi Global (GEPU)",
  xlab = "Waktu", ylab = "Nilai GEPU", xaxt = "n")
axis.Date(1, at = seq(min(waktu), max(waktu), by = "year"), format = "%Y")

plot(waktu, data$GPR, type = "l", col = "darkgreen", lwd = 2,
  main = "Plot Indeks Risiko Geopolitik (GPR)",
  xlab = "Waktu", ylab = "Nilai GPR", xaxt = "n")
axis.Date(1, at = seq(min(waktu), max(waktu), by = "year"), format = "%Y")
```

Lampiran 4 Syntax R untuk Model HMS-AR dan NHMS-AR

```
# =====
# NHMSAR — CONSISTENT BEST INITIALIZATION + REFIT (HH/NH/HN/NN)
# Objective:
# 1) Multi-run -> pick best theta per model (SMAPE_test_total smallest)
# 2) Refit each model using best theta as initialization (consistent)
# 3) Save & Load so next runs are identical
# =====

rm(list = ls())

library(psych)
library(dplyr)
library(NHMSAR)

# =====
# 1) Read data
# =====
data <- read.csv("D:/Adam/Tesis/Data NHMSAR.csv", header = TRUE, sep = ";")

stopifnot(all(c("year", "month", "day",
               "return.PGAS", "return.ADRO", "return.MEDC",
               "CRI", "GPR", "GEPU") %in% names(data)))

data$date <- as.Date(paste(data$year, data$month, data$day, sep = "-"))
print(range(data$date))

# =====
# 2) Build Y (AR(1) drop first obs)
# =====
cols_y <- c("return.PGAS", "return.ADRO", "return.MEDC")
Y_mat <- as.matrix(data[, cols_y])
Ttot <- nrow(Y_mat)
d <- ncol(Y_mat)

Y_all <- array(Y_mat[2:Ttot, , drop = FALSE], dim = c(Ttot - 1, 1, d))
waktu_Y <- data$date[-1]

# =====
# 3) Train/Test split
# =====
idx_train <- which(waktu_Y <= as.Date("2024-12-01"))
idx_test <- which(waktu_Y >= as.Date("2025-01-01") &
                 waktu_Y <= as.Date("2025-10-01"))

cat("Jumlah train:", length(idx_train), "\n")
cat("Jumlah test :", length(idx_test), "\n")
```

Lampiran 4 Syntax R untuk Model HMS-AR dan NHMS-AR

```
Y_train <- Y_all[idx_train, , drop = FALSE]

# =====
# 4) Covariates scaling using TRAIN only
# =====
X_raw <- as.matrix(data[, c("CRI","GPR","GEPU")]) # T x 3
X_raw_Z <- X_raw[1:(Ttot - 1), , drop = FALSE] # align to Y_all length

mu <- colMeans(X_raw_Z[idx_train, , drop = FALSE])
sdv <- apply(X_raw_Z[idx_train, , drop = FALSE], 2, sd)
sdv[sdv == 0] <- 1

X_scaled_Z <- scale(X_raw_Z, center = mu, scale = sdv)

Z_all <- array(NA_real_, dim = c(Ttot - 1, 1, 3))
Z_all[, 1, ] <- X_scaled_Z

Z_train <- Z_all[idx_train, , drop = FALSE]

# =====
# 5) SMAPE metric
# =====
smape <- function(y, yhat, eps = 1e-6) {
  y <- as.numeric(y)
  yhat <- as.numeric(yhat)
  denom <- pmax(abs(y) + abs(yhat), eps)
  mean(2 * abs(y - yhat) / denom, na.rm = TRUE) * 100
}

eval_smape_split <- function(Y_all, Z_all, theta_hat,
                             idx_train, idx_test,
                             use_trans = FALSE, use_emis = FALSE) {

  pred <- prediction.MSAR(
    Y_all, theta_hat,
    covar.trans = if (use_trans) Z_all else NULL,
    covar.emis = if (use_emis) Z_all else NULL
  )

  yhat <- pred$y.p

  c(
    SMAPE_train_total = smape(Y_all[idx_train, , ], yhat[idx_train, , ]),
    SMAPE_test_total = smape(Y_all[idx_test, , ], yhat[idx_test, , ]),

    SMAPE_train_PGAS = smape(Y_all[idx_train, , 1], yhat[idx_train, , 1]),
    SMAPE_test_PGAS = smape(Y_all[idx_test, , 1], yhat[idx_test, , 1]),
```

Lampiran 4 Syntax R untuk Model HMS-AR dan NHMS-AR

```
SMAPE_train_ADRO = smape(Y_all[idx_train, , 2], yhat[idx_train, , 2]),
SMAPE_test_ADRO = smape(Y_all[idx_test, , 2], yhat[idx_test, , 2]),

SMAPE_train_MEDC = smape(Y_all[idx_train, , 3], yhat[idx_train, , 3]),
SMAPE_test_MEDC = smape(Y_all[idx_test, , 3], yhat[idx_test, , 3])
)
}

# =====
# 6) Helper: init theta (base) per model
# =====
init_theta_by_model <- function(model, Y_train) {
  if (model == "HH") {
    return(init.theta.MSAR(data = Y_train, M = 2, order = 1, label = "HH"))
  }
  if (model == "NH") {
    return(init.theta.MSAR(data = Y_train, M = 2, order = 1, label = "NH",
      nh.transitions = "logistic", ncov.trans = 3))
  }
  if (model == "HN") {
    return(init.theta.MSAR(data = Y_train, M = 2, order = 1, label = "HN",
      ncov.emis = 3))
  }
  if (model == "NN") {
    return(init.theta.MSAR(data = Y_train, M = 2, order = 1, label = "NN",
      nh.transitions = "logistic", ncov.trans = 3, ncov.emis = 3))
  }
  stop("Unknown model.")
}

# =====
# 7) Helper: fit model given theta_init
# =====
fit_model_given_theta <- function(model, Y_train, Z_train, theta_init) {

  if (model == "HH") {
    fit <- fit.MSAR(Y_train, theta_init, verbose = FALSE, MaxIter = 200)
  } else if (model == "NH") {
    fit <- fit.MSAR(Y_train, theta_init, covar.trans = Z_train, verbose = FALSE, MaxIter = 200)
  } else if (model == "HN") {
    fit <- fit.MSAR(Y_train, theta_init, covar.emis = Z_train, verbose = FALSE, MaxIter = 200)
  } else if (model == "NN") {
    fit <- fit.MSAR(Y_train, theta_init, covar.trans = Z_train, covar.emis = Z_train,
      verbose = FALSE, MaxIter = 200)
  } else {
```


Lampiran 4 Syntax R untuk Model *HMS-AR* dan *NHMS-AR*

```
stop("Unknown model.")
}

return(fit)
}

# =====
# 8) A) MULTI-RUN search best theta per model
# =====
models <- c("HH","NH","HN","NN")
n_run <- 50

all_runs <- data.frame()
best_theta <- list()
best_seed <- list()
best_fit <- list()

for (m in models) {

  cat("\n=====\\n")
  cat("SEARCH BEST:", m, "\\n")
  cat("=====\\n")

  best_score <- Inf
  best_obj <- NULL

  for (i in 1:n_run) {

    seed_i <- 1000 + i
    set.seed(seed_i)

    theta0 <- init_theta_by_model(m, Y_train)

    fit_i <- tryCatch({
      fit_model_given_theta(m, Y_train, Z_train, theta0)
    }, error = function(e) {
      cat(" FAILED fit:", m, "run", i, "->", conditionMessage(e), "\\n")
      return(NULL)
    })

    if (is.null(fit_i)) next

    # evaluate with theta from this run
    if (m == "HH") met <- eval_smape_split(Y_all, Z_all, fit_i$theta, idx_train, idx_test,
FALSE, FALSE)
    if (m == "NH") met <- eval_smape_split(Y_all, Z_all, fit_i$theta, idx_train, idx_test, TRUE,
FALSE)
```

Lampiran 4 Syntax R untuk Model *HMS-AR* dan *NHMS-AR*

```
if (m == "HN") met <- eval_smape_split(Y_all, Z_all, fit_i$theta, idx_train, idx_test,
FALSE, TRUE)
if (m == "NN") met <- eval_smape_split(Y_all, Z_all, fit_i$theta, idx_train, idx_test, TRUE,
TRUE)

score <- as.numeric(met["SMAPE_test_total"])

all_runs <- rbind(all_runs, data.frame(
  model = m, run = i, seed = seed_i,
  SMAPE_train_total = met["SMAPE_train_total"],
  SMAPE_test_total = met["SMAPE_test_total"]
))

if (is.finite(score) && score < best_score) {
  best_score <- score
  best_obj <- list(seed = seed_i, theta = fit_i$theta, fit = fit_i, met = met)
}

cat("Run", i, "| seed", seed_i, "| SMAPE_test_total =", round(score, 6), "\n")
}

if (!is.null(best_obj)) {
  cat(" BEST", m, "| seed =", best_obj$seed, "| SMAPE_test_total =", round(best_score, 6),
"\n")
  best_theta[[m]] <- best_obj$theta
  best_seed[[m]] <- best_obj$seed
  best_fit[[m]] <- best_obj$fit
} else {
  cat(" No valid run found for", m, "\n")
}
}

cat("\n=== ALL RUNS SUMMARY ===\n")
#print(all_runs)

best_summary <- all_runs %>%
  group_by(model) %>%
  arrange(SMAPE_test_total) %>%
  slice(1) %>%
  ungroup()

cat("\n=== BEST PER MODEL (from search) ===\n")
print(best_summary)

# Save search result so later runs identical
saveRDS(best_theta, "best_theta_search.rds")
saveRDS(best_seed, "best_seed_search.rds")
```

Lampiran 4 Syntax R untuk Model HMS-AR dan NHMS-AR

```
saveRDS(best_fit, "best_fit_search.rds")
saveRDS(best_summary, "best_summary_search.rds")

cat("\nSaved:\n",
    "- best_theta_search.rds\n",
    "- best_seed_search.rds\n",
    "- best_fit_search.rds\n",
    "- best_summary_search.rds\n")

# =====
# 9) B) REFIT CONSISTENTLY using best_theta as initialization
# =====
# Jika kamu ingin Output FIT (smoothedprob) yang konsisten:
# kita refit lagi dengan theta_init = best_theta[[model]]

refit_fit <- list()
refit_theta <- list()
refit_met <- data.frame()

for (m in models) {

  if (is.null(best_theta[[m]])) next

  cat("\n===== \n")
  cat("REFIT CONSISTENT:", m, "\n")
  cat("===== \n")

  # IMPORTANT: use exact theta best as init (no randomness)
  fit_c <- tryCatch({
    fit_model_given_theta(m, Y_train, Z_train, best_theta[[m]])
  }, error = function(e) {
    cat(" FAILED refit:", m, "->", conditionMessage(e), "\n")
    return(NULL)
  })

  if (is.null(fit_c)) next

  # evaluate
  if (m == "HH") met <- eval_smape_split(Y_all, Z_all, fit_c$theta, idx_train, idx_test, FALSE,
FALSE)
  if (m == "NH") met <- eval_smape_split(Y_all, Z_all, fit_c$theta, idx_train, idx_test, TRUE,
FALSE)
  if (m == "HN") met <- eval_smape_split(Y_all, Z_all, fit_c$theta, idx_train, idx_test, FALSE,
TRUE)
  if (m == "NN") met <- eval_smape_split(Y_all, Z_all, fit_c$theta, idx_train, idx_test, TRUE,
TRUE)
```

Lampiran 4 Syntax R untuk Model *HMS-AR* dan *NHMS-AR*

```
refit_fit[[m]] <- fit_c
refit_theta[[m]] <- fit_c$theta

refit_met <- rbind(refit_met, data.frame(
  model = m,
  SMAPE_train_total = met["SMAPE_train_total"],
  SMAPE_test_total = met["SMAPE_test_total"],
  seed_search_best = best_seed[[m]]
))

cat(" RE-FIT", m, "| SMAPE_test_total =", round(as.numeric(met["SMAPE_test_total"]), 6),
"\n")
}

cat("\n=== CONSISTENT REFIT RESULTS ===\n")
print(refit_met)

# Save refit-consistent objects for future identical runs
saveRDS(refit_theta, "theta_refit_consistent.rds")
saveRDS(refit_fit, "fit_refit_consistent.rds")
saveRDS(refit_met, "smape_refit_consistent.rds")

cat("\nSaved:\n",
  "- theta_refit_consistent.rds\n",
  "- fit_refit_consistent.rds\n",
  "- smape_refit_consistent.rds\n")

# misal kamu sudah punya fit_refit_consistent
fit_refit_consistent <- readRDS("fit_refit_consistent.rds")

summary(fit_refit_consistent$HH)
summary(fit_refit_consistent$NH)
summary(fit_refit_consistent$HN)
summary(fit_refit_consistent$NN)

# theta mentahnya (untuk lihat isi)
fit_refit_consistent$HH$theta
# theta mentahnya (untuk lihat isi)
fit_refit_consistent$HN$theta
# theta mentahnya (untuk lihat isi)
fit_refit_consistent$NH$theta
# theta mentahnya (untuk lihat isi)
fit_refit_consistent$NN$theta

# =====
```

Lampiran 4 Syntax R untuk Model HMS-AR dan NHMS-AR

```
# 10) C) How to rerun consistently next time (NO SEARCH)
# =====
# Uncomment these lines if you want to just load the best consistent model:
# refit_theta <- readRDS("theta_refit_consistent.rds")
# refit_fit <- readRDS("fit_refit_consistent.rds")
# refit_met <- readRDS("smape_refit_consistent.rds")
# print(refit_met)

# =====
# 11) Plot helpers (using theta)
# =====
plot_train_actual_vs_pred <- function(Y_all, Z_all, waktu_Y, idx_train,
                                     theta_hat, model_name,
                                     use_trans = FALSE, use_emis = FALSE) {

  pred <- prediction.MSAR(
    Y_all, theta_hat,
    covar.trans = if (use_trans) Z_all else NULL,
    covar.emis = if (use_emis) Z_all else NULL
  )

  y_train <- Y_all[idx_train, , drop = FALSE]
  yhat_train <- pred$y.p[idx_train, , drop = FALSE]
  t_train <- waktu_Y[idx_train]

  par(mfrow = c(3,1), mar = c(3,4,2,1))
  nm <- c("PGAS", "ADRO", "MEDC")

  for (j in 1:3) {
    matplot(t_train, cbind(y_train[, , j], yhat_train[, , j]),
            type = "l", lty = 1, lwd = 2,
            col = c("black", "red"),
            main = paste0(model_name, " — TRAIN Actual vs Pred (" , nm[j], ")"),
            xlab = "Waktu (Train)", ylab = "Return", xaxt = "n")
    axis.Date(1, at = seq(min(t_train), max(t_train), by = "year"), format = "%Y")
    legend("topright", legend = c("Actual", "Predicted"),
           col = c("black", "red"), lty = 1, bty = "n")
  }

  par(mfrow = c(1,1))
}

plot_test_actual_vs_pred <- function(Y_all, Z_all, waktu_Y, idx_test,
                                     theta_hat, model_name,
                                     use_trans = FALSE, use_emis = FALSE) {

  pred <- prediction.MSAR(
```

Lampiran 4 Syntax R untuk Model *HMS-AR* dan *NHMS-AR*

```

Y_all, theta_hat,
covar.trans = if (use_trans) Z_all else NULL,
covar.emis = if (use_emis) Z_all else NULL
)

y_test <- Y_all[idx_test, , drop = FALSE]
yhat_test <- pred$y.p[idx_test, , drop = FALSE]
t_test <- waktu_Y[idx_test]

par(mfrow = c(3,1), mar = c(3,4,2,1))
nm <- c("PGAS","ADRO","MEDC")

for (j in 1:3) {
  matplot(t_test, cbind(y_test[, , j], yhat_test[, , j]),
    type = "l", lty = 1, lwd = 2,
    col = c("black","red"),
    main = paste0(model_name, " — TEST Actual vs Pred (", nm[j], ")"),
    xlab = "Waktu (Test)", ylab = "Return", xaxt = "n")
  axis.Date(1, at = t_test, format = "%b-%Y")
  legend("topright", legend = c("Actual","Predicted"),
    col = c("black","red"), lty = 1, bty = "n")
}

par(mfrow = c(1,1))
}

plot_smoothed <- function(fit_obj, title = "Smoothed Regime Probabilities (Train)") {
  prob_matrix <- fit_obj$smoothedprob
  matplot(1:nrow(prob_matrix), prob_matrix,
    type = "l", lty = 1, lwd = 2,
    col = c("blue","red"),
    ylab = "Probabilitas Rezim", xlab = "Index Waktu (Train)",
    main = title)
  legend("topright", legend = c("Rezim 1","Rezim 2"),
    col = c("blue","red"), lty = 1, bty = "n")
}

# =====
# 12) Example: plot CONSISTENT REFIT results
# =====
# HH
if (!is.null(refit_theta$HH)) {
  plot_train_actual_vs_pred(Y_all, Z_all, waktu_Y, idx_train, refit_theta$HH, "HH (REFIT
CONSISTENT)", FALSE, FALSE)
  plot_test_actual_vs_pred(Y_all, Z_all, waktu_Y, idx_test, refit_theta$HH, "HH (REFIT
CONSISTENT)", FALSE, FALSE)
  plot_smoothed(refit_fit$HH, "HH (REFIT CONSISTENT) - Smoothed Prob (Train)")
}

```

Lampiran 4 Syntax R untuk Model *HMS-AR* dan *NHMS-AR*

```
}

# NH
if (!is.null(refit_theta$NH)) {
  plot_train_actual_vs_pred(Y_all, Z_all, waktu_Y, idx_train, refit_theta$NH, "NH (REFIT
CONSISTENT)", TRUE, FALSE)
  plot_test_actual_vs_pred(Y_all, Z_all, waktu_Y, idx_test, refit_theta$NH, "NH (REFIT
CONSISTENT)", TRUE, FALSE)
  plot_smoothed(refit_fit$NH, "NH (REFIT CONSISTENT) - Smoothed Prob (Train)")
}

# HN
if (!is.null(refit_theta$HN)) {
  plot_train_actual_vs_pred(Y_all, Z_all, waktu_Y, idx_train, refit_theta$HN, "HN (REFIT
CONSISTENT)", FALSE, TRUE)
  plot_test_actual_vs_pred(Y_all, Z_all, waktu_Y, idx_test, refit_theta$HN, "HN (REFIT
CONSISTENT)", FALSE, TRUE)
  plot_smoothed(refit_fit$HN, "HN (REFIT CONSISTENT) - Smoothed Prob (Train)")
}

# NN
if (!is.null(refit_theta$NN)) {
  plot_train_actual_vs_pred(Y_all, Z_all, waktu_Y, idx_train, refit_theta$NN, "NN (REFIT
CONSISTENT)", TRUE, TRUE)
  plot_test_actual_vs_pred(Y_all, Z_all, waktu_Y, idx_test, refit_theta$NN, "NN (REFIT
CONSISTENT)", TRUE, TRUE)
  plot_smoothed(refit_fit$NN, "NN (REFIT CONSISTENT) - Smoothed Prob (Train)")
}
```

Lampiran 5 Output R untuk HMS-AR dan NHMS-AR

=====

SEARCH BEST: HH

=====

Run 1 | seed 1001 | SMAPE_test_total = 156.0829
Run 2 | seed 1002 | SMAPE_test_total = 167.2285
Run 3 | seed 1003 | SMAPE_test_total = 167.3064
Run 4 | seed 1004 | SMAPE_test_total = 167.3751
Run 5 | seed 1005 | SMAPE_test_total = 167.3713
Run 6 | seed 1006 | SMAPE_test_total = 167.3712
Run 7 | seed 1007 | SMAPE_test_total = 167.382
Run 8 | seed 1008 | SMAPE_test_total = 167.3851
Run 9 | seed 1009 | SMAPE_test_total = 166.9531
Run 10 | seed 1010 | SMAPE_test_total = 167.3829
.
.
.
Run 91 | seed 1091 | SMAPE_test_total = 167.3718
Run 92 | seed 1092 | SMAPE_test_total = 167.3759
Run 93 | seed 1093 | SMAPE_test_total = 167.3773
Run 94 | seed 1094 | SMAPE_test_total = 167.1124
Run 95 | seed 1095 | SMAPE_test_total = 167.3712
Run 96 | seed 1096 | SMAPE_test_total = 167.3794
Run 97 | seed 1097 | SMAPE_test_total = 167.3757
Run 98 | seed 1098 | SMAPE_test_total = 167.3739
Run 99 | seed 1099 | SMAPE_test_total = 167.3746
Run 100 | seed 1100 | SMAPE_test_total = 167.3691
BEST HH | seed = 1001 | SMAPE_test_total = 156.0829

=====

SEARCH BEST: NH

=====

Run 1 | seed 1001 | SMAPE_test_total = 151.7974
Run 2 | seed 1002 | SMAPE_test_total = 151.7974
Run 3 | seed 1003 | SMAPE_test_total = 151.7972
Run 4 | seed 1004 | SMAPE_test_total = 136.0096
Run 5 | seed 1005 | SMAPE_test_total = 136.0099
Run 6 | seed 1006 | SMAPE_test_total = 136.0097
Run 7 | seed 1007 | SMAPE_test_total = 151.7974
Run 8 | seed 1008 | SMAPE_test_total = 136.0096
Run 9 | seed 1009 | SMAPE_test_total = 151.7974
Run 10 | seed 1010 | SMAPE_test_total = 151.7974
.
.
.
Run 91 | seed 1091 | SMAPE_test_total = 151.7974
Run 92 | seed 1092 | SMAPE_test_total = 151.7974
Run 93 | seed 1093 | SMAPE_test_total = 151.7974
Run 94 | seed 1094 | SMAPE_test_total = 151.7974

Lampiran 5 Output R untuk HMS-AR dan NHMS-AR

```
Run 95 | seed 1095 | SMAPE_test_total = 136.0096
Run 96 | seed 1096 | SMAPE_test_total = 136.0096
Run 97 | seed 1097 | SMAPE_test_total = 136.01
Run 98 | seed 1098 | SMAPE_test_total = 151.7974
Run 99 | seed 1099 | SMAPE_test_total = 136.0096
Run 100 | seed 1100 | SMAPE_test_total = 136.0096
BEST NH | seed = 1072 | SMAPE_test_total = 136.0095
```

SEARCH BEST: HN

```
[1] *****likelihood decreased from 403.519772367417 to 403.491304177104
[1] *****likelihood decreased from 403.491304177104 to 403.238322065353
[1] *****likelihood decreased from 403.238322065353 to 403.117329572795
[1] *****likelihood decreased from 403.117329572795 to 403.029704826016
[1] *****likelihood decreased from 403.029704826016 to 402.937391188428
[1] *****likelihood decreased from 402.937391188428 to 402.838974291456
[1] *****likelihood decreased from 402.838974291456 to 402.745629601671
[1] *****likelihood decreased from 402.745629601671 to 402.722971854065
[1] *****likelihood decreased from 406.242742442944 to 405.744618978639
[1] *****likelihood decreased from 405.744618978639 to 404.851668313602
[1] *****likelihood decreased from 404.851668313602 to 404.662109210982
Run 1 | seed 1001 | SMAPE_test_total = 158.9892
```

```
.
.
.
```

```
Run 99 | seed 1099 | SMAPE_test_total = 164.6396
[1] *****likelihood decreased from 388.429781577581 to 388.056408418215
[1] *****likelihood decreased from 388.056408418215 to 386.856426139447
[1] *****likelihood decreased from 387.512247429903 to 386.82491210577
[1] *****likelihood decreased from 386.82491210577 to 386.019720147176
[1] *****likelihood decreased from 386.019720147176 to 385.401392123598
[1] *****likelihood decreased from 385.401392123598 to 384.936352285717
[1] *****likelihood decreased from 384.936352285717 to 384.576676734123
[1] *****likelihood decreased from 384.576676734123 to 384.296441967336
[1] *****likelihood decreased from 384.296441967336 to 384.080300041414
[1] *****likelihood decreased from 384.080300041414 to 383.918187434899
[1] *****likelihood decreased from 383.918187434899 to 383.80283913713
[1] *****likelihood decreased from 383.80283913713 to 383.728152709463
[1] *****likelihood decreased from 383.728152709463 to 383.688305831845
[1] *****likelihood decreased from 383.688305831845 to 383.677492969843
Run 100 | seed 1100 | SMAPE_test_total = 164.6428
BEST HN | seed = 1056 | SMAPE_test_total = 146.5574
```

SEARCH BEST: NN

```
[1] *****likelihood decreased from 397.019031533727 to 396.985947588826
[1] *****likelihood decreased from 396.985947588826 to 396.94295213892
[1] *****likelihood decreased from 396.94295213892 to 396.932101916716
Run 1 | seed 1001 | SMAPE_test_total = 139.7088
[1] *****likelihood decreased from 397.018977560871 to 396.98575456451
[1] *****likelihood decreased from 396.98575456451 to 396.943017982416
[1] *****likelihood decreased from 396.943017982416 to 396.932196329
Run 2 | seed 1002 | SMAPE_test_total = 139.7088
[1] *****likelihood decreased from 397.018975429327 to 396.985709616713
```

Lampiran 5 Output R untuk HMS-AR dan NHMS-AR

```
[1] *****likelihood decreased from 396.985709616713 to 396.943035392655
[1] *****likelihood decreased from 396.943035392655 to 396.932219885489
Run 3 | seed 1003 | SMAPE_test_total = 139.7088
Run 4 | seed 1004 | SMAPE_test_total = 131.4208
Run 5 | seed 1005 | SMAPE_test_total = 131.4216
.
.
.
Run 93 | seed 1093 | SMAPE_test_total = 139.7088
[1] *****likelihood decreased from 397.018980351341 to 396.985721966801
[1] *****likelihood decreased from 396.985721966801 to 396.943032000019
[1] *****likelihood decreased from 396.943032000019 to 396.932214841317
Run 94 | seed 1094 | SMAPE_test_total = 139.7088
Run 95 | seed 1095 | SMAPE_test_total = 131.4208
Run 96 | seed 1096 | SMAPE_test_total = 131.4203
Run 97 | seed 1097 | SMAPE_test_total = 131.4203
[1] *****likelihood decreased from 397.01903236153 to 396.985944674739
[1] *****likelihood decreased from 396.985944674739 to 396.942953643842
[1] *****likelihood decreased from 396.942953643842 to 396.932103848721
Run 98 | seed 1098 | SMAPE_test_total = 139.7088
Run 99 | seed 1099 | SMAPE_test_total = 131.4207
Run 100 | seed 1100 | SMAPE_test_total = 131.4233
BEST NN | seed = 1072 | SMAPE_test_total = 131.4203

=== BEST PER MODEL (from search) ===
# A tibble: 4 × 5
  model run seed SMAPE_train_total SMAPE_test_total
  <chr> <int> <dbl>      <dbl>      <dbl>
1 HH     1 1001      161.      156.
2 HN    56 1056      159.      147.
3 NH    72 1072      152.      136.
4 NN    72 1072      148.      131.

=====
REFIT CONSISTENT: HH
=====
RE-FIT HH | SMAPE_test_total = 156.0721

=====
REFIT CONSISTENT: NH
=====
RE-FIT NH | SMAPE_test_total = 136.6189

=====
REFIT CONSISTENT: HN
=====
RE-FIT HN | SMAPE_test_total = 146.5551

=====
REFIT CONSISTENT: NN
=====
RE-FIT NN | SMAPE_test_total = 131.7568

=== CONSISTENT REFIT RESULTS ===
      model SMAPE_train_total SMAPE_test_total seed search best
```

Lampiran 5 Output R untuk HMS-AR dan NHMS-AR

```

SMAPE_train_total HH      160.7050      156.0721      1001
SMAPE_train_total1 NH      151.9610      136.6189      1072
SMAPE_train_total2 HN      158.9042      146.5551      1056
SMAPE_train_total3 NN      148.1740      131.7568      1072

> fit_refit_consistent$HH$theta
$A
$A$Regime1
$A$Regime1$A1

0.03041027 0.21405099 -0.014244297
0.10393150 -0.05518198 0.008050281
0.26988143 0.13069025 -0.160778892

$A$Regime2
$A$Regime2$A1

-0.29968133 -0.09432591 -0.08291047
0.17445869 -0.23208720 0.10248571
-0.08837549 0.25388750 0.23838128

$A0
      A01      A02      A03
Regime1 -0.001725325 0.016810486 -0.0136644
Regime2 0.015873878 -0.009410833 0.1232540

$sigma
$sigma$Regime1

0.014319352 0.004244362 0.006643195
0.004244362 0.011928218 0.006211124
0.006643195 0.006211124 0.019070560

$sigma$Regime2

0.005060239 0.003598628 -0.003321622
0.003598628 0.051138660 0.011095283
-0.003321622 0.011095283 0.038238100

$prior
Regime1 1.122193e-124
Regime2 1.000000e+00

$transmat
      Regime1 Regime2
Regime1 0.9063233 0.0936767
Regime2 0.5843913 0.4156087

> fit_refit_consistent$HN$theta
$A

```

Lampiran 5 Output R untuk HMS-AR dan NHMS-AR

```

$A$Regime1
$A$Regime1$A1

  0.5487397  0.09798017 -0.4225456
-0.6662207  0.15683634 -0.3614456
  0.9087310 -1.06617859 -0.1296550

$A$Regime2
$A$Regime2$A1

-0.10796337  0.07280402 -0.02029308
  0.13223636 -0.12646360  0.04730778
  0.09095693  0.14587021 -0.04857354

$A0
      A01      A02      A03
Regime1 -0.12906235 -0.27815583 -0.24205781
Regime2  0.01201631  0.02681503  0.01833794

$sigma
$sigma$Regime1

  0.020536811 -0.004961816 -0.002935710
-0.004961816  0.005098016  0.003059411
-0.002935710  0.003059411  0.004689971

$sigma$Regime2

  0.011608253  0.003120847  0.003252351
  0.003120847  0.014017607  0.004285897
  0.003252351  0.004285897  0.021304242

$prior

Regime1 2.250126e-173
Regime2 1.000000e+00

$transmat
      Regime1  Regime2
Regime1 0.53107746 0.4689225
Regime2 0.03044003 0.9695600

$par.emis
$par.emis$Regime1
  coef.emis1 coef.emis2 coef.emis3
  0.06849869 -0.03779032 -0.03842236
-0.02987420 -0.10537219 -0.03019099
  0.01355918 -0.05512482  0.08265248

$par.emis$Regime2
  coef.emis1 coef.emis2 coef.emis3

```

Lampiran 5 Output R untuk HMS-AR dan NHMS-AR

```

0.002848098 0.001825664 0.003027200
0.006920492 0.004911392 -0.004605941
0.001460127 0.003772483 0.009441355

> fit_refit_consistent$NH$theta
$A
$A$Regime1
$A$Regime1$A1

0.25114484 0.22864602 -0.05136409
0.07275967 -0.07341647 -0.05851341
0.52251890 0.07938109 -0.24679945

$A$Regime2
$A$Regime2$A1

-0.19944923 -0.04618431 -0.01633886
0.14231577 -0.09417479 0.09533228
-0.02512249 0.17589235 0.16247606

$A0
      A01      A02      A03
Regime1 -0.02676818 -0.01497074 -0.06037450
Regime2 0.03740592 0.05181328 0.08450584

$sigma
$sigma$Regime1

0.0123828676 0.0007125185 0.003003301
0.0007125185 0.0156360968 0.005750552
0.0030033012 0.0057505520 0.014266195

$sigma$Regime2

0.011092920 0.006892119 0.001855584
0.006892119 0.017301724 0.001672907
0.001855584 0.001672907 0.022837867

$prior
Regime1 6.122176e-204
Regime2 1.000000e+00

$transmat
      Regime1 Regime2
Regime1 0.7150595 0.2849405
Regime2 0.1251057 0.8748943

$par.trans
      coef.trans1 coef.trans2 coef.trans3 coef.trans4
Regime1 -0.6886902 2.775600 -0.8661264 2.27683061

```

Lampiran 5 Output R untuk HMS-AR dan NHMS-AR

```
Regime2 0.1020142 1.300966 -0.1749875 -0.06148896
```

```
> fit_refit_consistent$NN$theta
```

```
$A
```

```
$A$Regime1
```

```
$A$Regime1$A1
```

```
0.29232095 -0.073603938 0.04734142
0.08608683 -0.006981305 -0.02356271
0.53956833 0.170278556 -0.21791555
```

```
$A$Regime2
```

```
$A$Regime2$A1
```

```
-0.18870864 0.18228003 -0.06063344
0.28841908 -0.20299078 0.05220700
0.04551661 0.06546107 0.14607160
```

```
$A0
```

```
A01 A02 A03
```

```
Regime1 -0.04723707 -0.02719297 -0.07762127
```

```
Regime2 0.04227685 0.06532706 0.09027530
```

```
$sigma
```

```
$sigma$Regime1
```

```
0.009138093 0.001157749 0.002018618
0.001157749 0.015576037 0.004191937
0.002018618 0.004191937 0.012246389
```

```
$sigma$Regime2
```

```
0.0131486765 0.004580351 0.0003447375
0.0045803514 0.015426733 0.0020661985
0.0003447375 0.002066199 0.0226382858
```

```
$prior
```

```
Regime1 8.214396e-146
```

```
Regime2 1.000000e+00
```

```
$transmat
```

```
Regime1 Regime2
```

```
Regime1 0.7150595 0.2849405
```

```
Regime2 0.1251057 0.8748943
```

```
$par.trans
```

```
coef.trans1 coef.trans2 coef.trans3 coef.trans4
```

```
Regime1 0.1366766 1.009509 -0.5743172 1.5152152
```

```
Regime2 0.4924570 1.917920 -2.0259970 -0.9074602
```

Lampiran 5 Output R untuk HMS-AR dan NHMS-AR

```
$par.emis
```

```
$par.emis$Regime1
```

```
coef.emis1 coef.emis2 coef.emis3
```

```
0.0059768089 -0.013445459 -0.03684220
```

```
-0.0002190082 -0.007727544 -0.01107868
```

```
0.0027892996 -0.009165951 -0.01307357
```


```
$par.emis$Regime2
```

```
coef.emis1 coef.emis2 coef.emis3
```


```
-2.303380e-04 -3.981457e-03 0.0160185147
```

```
-5.159324e-05 3.071086e-05 -0.0145732056
```


```
-9.936689e-03 -8.776162e-03 -0.0003886859
```




Lampiran 5 Output R untuk HMS-AR dan NHMS-AR




Lampiran 5 Output R untuk *HMS-AR* dan *NHMS-AR*



Lampiran 5 Output R untuk *HMS-AR* dan *NHMS-AR*



Lampiran 5 *Output R* untuk *HMS-AR* dan *NHMS-AR*



(Halaman ini sengaja dikosongkan)

BIODATA PENULIS



Penulis bernama Adam Fahmi Fandisyah, lahir di Tulungagung, 26 Mei 1997. Penulis menyelesaikan pendidikan Strata Satu pada Program Studi Statistika di Institut Teknologi Sepuluh Nopember Surabaya, kemudian melanjutkan studi Strata Dua pada program studi dan institusi yang sama. Setelah menamatkan pendidikan S1, penulis memulai karier sebagai Statistisi di Dinas Kebudayaan dan Pariwisata Provinsi Jawa Timur. Saat ini, penulis bekerja sebagai Pengawas Pendataan Statistik pada Badan Pendapatan Daerah Provinsi Jawa Timur UPT PPD Tulungagung, serta aktif terlibat dalam berbagai kegiatan profesional sesuai bidang keahliannya. Selama masa studi, penulis memiliki ketertarikan pada bidang statistika komputasi. Penulis berdomisili di Tulungagung dan dapat dihubungi melalui *email* adamfahmifandisyah@gmail.com.

(Halaman ini sengaja dikosongkan)