



TUGAS AKHIR SM-141501

**ESTIMASI PARAMETER MODEL ARIMA PADA
PERAMALAN KURVA *YIELD* MENGGUNAKAN
KALMAN FILTER**

**WULAN DWI PUSPITASARI
NRP 0611144000024**

**Dosen Pembimbing:
Prof. Dr. Erna Apriliani, M.Si
Dra. Nuri Wahyuningsih, M.Kes**

**Departemen Matematika
Fakultas Matematika Komputasi dan Sains Data
Institut Teknologi Sepuluh Nopember
Surabaya
2018**



FINAL PROJECT SM-141501

***ESTIMATION OF ARIMA MODEL PARAMETER ON THE
FORECASTING OF YIELD CURVE USING KALMAN
FILTER***

**WULAN DWI PUSPITASARI
NRP 0611144000024**

**Supervisors:
Prof. Dr. Erna Apriliani, M.Si
Dra. Nuri Wahyuningsih, M.Kes**

**Department of Mathematics
Faculty of Computation Mathematics and Data Science
Institut Teknologi Sepuluh Nopember
Surabaya
2018**

LEMBAR PENGESAHAN

**ESTIMASI PARAMETER MODEL ARIMA PADA
PERAMALAN KURVA YIELD MENGGUNAKAN
KALMAN FILTER
*ESTIMATION OF ARIMA MODEL PARAMETER ON THE
FORCASTING OF YIELD CURVE USING KALMAN
FILTER***

Diajukan Untuk memenuhi Salah Satu Syarat Memperoleh Gelar
Sarjana Sains
pada

Bidang Studi Matematika Terapan
Program S-1 Departemen Matematika

Fakultas Matematika Komputasi dan Sains Data

Oleh:

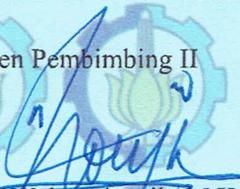
WULAN DWI PUSPITASARI

NRP. 06111440000024

Menyetujui,

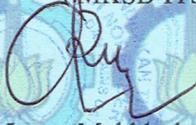
Dosen Pembimbing II

Dosen Pembimbing I


Dra. Nuri Wahyuningsih, M.Kes
NIP. 19650220 198903 2 002


Prof. Dr. Erna Apriliani, M.Si
NIP. 19660414 199102 2 001

Mengetahui,
Kepala Departemen Matematika
FMKSD ITS


Dr. Imam Mukhlash, S.Si M.T
NIP. 19700831 199403 1 003

ESTIMASI PARAMETER MODEL ARIMA PADA PERAMALAN KURVA *YIELD* MENGGUNAKAN KALMAN FILTER

Nama Mahasiswa : WULAN DWI PUSPITASARI
NRP : 0611144000024
Departemen : Matematika FMKSD – ITS
Dosen Pembimbing : 1. Prof. Dr. Erna Apriliani, M.Si
2. Dra. Nuri Wahyuningsih, M.Kes

ABSTRAK

Investasi merupakan penanaman modal oleh investor guna memperoleh keuntungan di masa depan. Salah satu jenis investasi adalah obligasi. Obligasi merupakan surat utang jangka panjang yang dijual belikan kepada investor pemilik dana dengan besar kecilnya keuntungan yang diperoleh, dipengaruhi oleh waktu jatuh tempo. Kurva *yield* merupakan kurva yang menunjukkan hubungan antara *yield* (hasil) dengan waktu jatuh tempo. *Yield* merupakan tingkat return yang akan diterima dari obligasi. *Yield* menggambarkan ekspektasi pasar terhadap pergerakan tingkat suku bunga sesuai dengan kondisi pasar yang terjadi pada waktu tertentu. Nilai *yield* akan selalu berubah seiring dengan pergerakan harga di pasar. Dalam tugas akhir ini akan dibahas tentang penerapan metode ARIMA pada peramalan kurva *yield* dan estimasi parameter model ARIMA menggunakan Kalman Filter. Metode ARIMA digunakan untuk mendapatkan model terbaik peramalan kurva *yield*. Parameter model ARIMA yang didapat selanjutnya akan diestimasi dengan menggunakan metode Kalman Filter. Hasil akhir menunjukkan bahwa menggunakan Kalman Filter sebagai estimasi pada parameter model ARIMA menghasilkan nilai peramalan yang lebih akurat. Hal tersebut didukung dengan membandingkan nilai MAPE sebelum dan sesudah proses estimasi dengan menggunakan Kalman Filter.

Kata Kunci : ARIMA, estimasi parameter, kalman filter

***ESTIMATION OF ARIMA MODEL PARAMETER ON THE
FORCASTING OF YIELD CURVE USING KALMAN
FILTER***

Student's Name : WULAN DWI PUSPITASARI
NRP : 0611144000024
Departement : Matematika FMKSD – ITS
Supervisor : 1. Prof. Dr. Erna Apriliani, M.Si
2. Dra. Nuri Wahyuningsih, M.Kes

ABSTRACT

Investment is an investment by investors in order to gain profit in the future. One type of investment is bonds. Bonds are long-term debt securities traded to investors with the size of the profits gained, influenced by the time maturity. The yield curve is a curve showing the relationship between yield and maturity. Yield is the rate of return to be received from the bond. Yield illustrates market expectations of interest rate movements in accordance with market conditions occurring at any given time. The yield value will always change along with the price movement in the market. In this final project will be discussed about the implementation of ARIMA method in forecasting yield curve and parameter estimation of ARIMA model using Kalman Filter. ARIMA method is used to get the best model forecasting yield curve. The ARIMA model parameters obtained will then be estimated using the Kalman Filter method. The final result shows that using Kalman Filter as an estimate on ARIMA model parameters yields a more accurate forecasting value. This is supported by comparing the MAPE values before and after the estimation process using the Kalman Filter.

Keywords : ARIMA, Parameter Estimation, Kalman Filter

KATA PENGANTAR

Segala puji bagi Allah SWT Tuhan semesta alam yang telah memberikan karunia, rahmat dan hidayah-Nya sehingga penulis dapat menyelesaikan Tugas Akhir yang berjudul:

“Estimasi Parameter Model ARIMA pada Peramalan Kurva *Yield* Menggunakan Kalman Filter”

Sebagai salah satu persyaratan akademis dalam menyelesaikan Program Studi Sarjana pada Departemen Matematika Fakultas FMKSD Institut Teknologi Sepuluh Nopember Surabaya.

Tugas Akhir ini dapat diselesaikan berkat kerjasama, bantuan, dan dukungan dari banyak pihak. Sehubungan dengan hal itu, penulis mengucapkan terima kasih kepada:

1. Dr. Imam Mukhlash, S.Si, MT selaku Ketua Departemen Matematika FMKSD ITS.
2. Prof. Dr. Erna Apriliani, M.Si dan Dra. Nuri Wahyuningsih, M.Kes sebagai dosen pembimbing Tugas Akhir atas segala bimbingan dan motivasi yang telah diberikan kepada penulis.
3. Dra. Laksmi Prita Wardhani, M.Si, Drs. Lukman Hanafi, M.Sc, dan Drs. Sentot Didik Surjanto, M.Si selaku dosen penguji Tugas Akhir.
4. Drs. Iis Herisman, M.Si, Sekretaris Kaprodi Departemen Matematika FMKSD ITS yang telah memberikan banyak bantuan dalam proses pengumpulan Tugas Akhir ini.
5. Drs. Sentot Didik Surjanto, M.Si selaku dosen wali penulis yang telah banyak membantu memberikan arahan akademik selama penulis menempuh pendidikan di Departemen Matematika FMKSD ITS.
6. Bapak dan Ibu Dosen serta seluruh *staff* Tata Usaha dan Laboratorium Departemen Matematika FMKSD ITS.
7. Kedua orang tua saya Bapak Alamin dan Ibu Imro'ah serta kakak dan adik saya Edi Budiono dan Putra Heru Aditria yang

telah memberikan dukungan moral dan finansial sehingga penulis dapat menyelesaikan Tugas Akhir.

8. Seluruh penghuni Lab. Komputasi terutama kepada Briyan, Tri Wahyuni, Eko Andi, dan Faidzin Anshori atas semua fasilitas, canda dan tawa hingga mengajarkan tentang kebersamaan dalam berjuang menyelesaikan Tugas Akhir.
9. Meylita Sari dan Briyan Fadi Nugraha selaku teman satu tim selama proses pengerjaan Tugas Akhir.
10. Irvan Adi Pradana atas segala waktu, perhatian, dan kesabaran untuk menemani penulis dalam menyelesaikan Tugas Akhir.
11. Teman-teman mahasiswa Departemen Matematika FMKSD ITS terutama teman-teman AKSIOMA.

Penulis menyadari bahwa Tugas Akhir ini masih jauh dari kesempurnaan. Oleh karena itu, penulis mengharapkan saran dan kritik dari pembaca. Akhir kata, semoga Tugas Akhir ini bermanfaat bagi semua pihak yang berkepentingan.

Surabaya, 2 Agustus 2018

Penulis

DAFTAR ISI

	Hal
HALAMAN JUDUL.....	i
LEMBAR PENGESAHAN.....	v
ABSTRAK	vii
<i>ABSTRACT</i>	ix
KATA PENGANTAR.....	xi
DAFTAR ISI.....	xiii
DAFTAR GAMBAR	xv
DAFTAR TABEL	xvii
DAFTAR LAMPIRAN	xix
BAB I PENDAHULUAN	1
1.1 Latar Belakang Masalah	1
1.2 Rumusan Masalah.....	3
1.3 Batasan Masalah	3
1.4 Tujuan	4
1.5 Manfaat	4
1.6 Sistematika Penulisan	4
BAB II TINJAUAN PUSTAKA	7
2.1 Penelitian Terdahulu	7
2.2 Model ARIMA.....	8
2.3 Perumusan Model ARIMA	10
2.4.1 Identifikasi Model ARIMA	10
2.4.2 Penaksiran dan Pengujian Parameter.....	12
2.4.3 Diagnostik Cek	13
2.4.4 Pemilihan Model Terbaik	15
2.4 Metode <i>Maximum Likelihood Estimation</i>	15
2.5 Metode Kalman Filter	16
2.6 Penerapan Metode Kalman Filter	18
BAB III METODE PENELITIAN.....	19
3.1 Tahapan Penelitian.....	19
3.2 Diagram Alir Penelitian	20

BAB IV ANALISIS DAN PEMBAHASAN	25
4.1 Variabel dan Data Penelitian.....	25
4.2 Analisis dan Perumusan Model ARIMA	26
4.2.1 <i>Yield</i> Tenor 1 Tahun	26
4.2.2 <i>Yield</i> Tenor 5 Tahun	32
4.2.3 <i>Yield</i> Tenor 10 Tahun	39
4.2.4 <i>Yield</i> Tenor 20 Tahun	46
4.3 Estimasi Parameter dengan Kalman Filter	53
4.3.1 <i>Yield</i> Tenor 1 Tahun	53
4.3.2 <i>Yield</i> Tenor 5 Tahun	56
4.3.3 <i>Yield</i> Tenor 10 Tahun	59
4.3.4 <i>Yield</i> Tenor 20 Tahun	61
BAB V PENUTUP	65
5.1 Kesimpulan	65
5.2 Saran	66
DAFTAR PUSTAKA.....	67
LAMPIRAN	69
BIODATA PENULIS.....	141

DAFTAR GAMBAR

	Hal
Gambar 3. 1	Diagram Alir Penelitian21
Gambar 3. 2	Diagram Alir Metode ARIMA.....22
Gambar 3. 3	Diagram Alir Metode Kalman Filter.....23
Gambar 4. 1	Box – Cox Data Tenor 1 Tahun27
Gambar 4. 2	Plot ACF Data Tenor 1 Tahun27
Gambar 4. 3	Plot Trend Analysis Data Differencing.....28
Gambar 4. 4	Plot ACF Diffrencing.....28
Gambar 4. 5	Plot PACF Differencing.....29
Gambar 4. 6	Box – Cox Data Tenor 5 Tahun33
Gambar 4. 7	Plot ACF Data Tenor 5 Tahun34
Gambar 4. 8	Plot Trend Analysis Data Differencing.....34
Gambar 4. 9	Plot ACF Diffrencing.....35
Gambar 4. 10	Plot PACF Differencing.....35
Gambar 4. 11	Box – Cox Data Tenor 10 Tahun39
Gambar 4. 12	Box – Cox Data Transformasi (1).....39
Gambar 4. 13	Box – Cox Data Transformasi (2).....40
Gambar 4. 14	Plot ACF Transformasi (2)40
Gambar 4. 15	Plot Trend Analysis Data Diffrencing41
Gambar 4. 16	Plot ACF Diffrencing.....41
Gambar 4. 17	Plot PACF Differencing.....42
Gambar 4. 18	Box – Cox Data Tenor 20 Tahun46
Gambar 4. 19	Box – Cox Transformasi (1)47
Gambar 4. 20	Box – Cox Transformasi (2)47
Gambar 4. 21	Box – Cox Transformasi (3)48
Gambar 4. 22	Plot ACF Data Transformasi (3).....48
Gambar 4. 23	Plot Trend Analysis Data Differencing.....49
Gambar 4. 24	Plot ACF Diffrencing.....49
Gambar 4. 25	Plot PACF Differencing.....49
Gambar 4. 26	Hasil Simulasi Perbandingan ARIMA, ARIMA- Filter Kalman, dan Faktual55

Gambar 4. 27	Hasil Simulasi Perbandingan ARIMA, ARIMA- Filter Kalman, dan Faktual	58
Gambar 4. 28	Hasil Simulasi Perbandingan ARIMA, ARIMA- Filter Kalman, dan Faktual	61
Gambar 4. 29	Hasil Simulasi Perbandingan ARIMA, ARIMA- Filter Kalman, dan Faktual	64

DAFTAR TABEL

	Hal
Tabel 2. 1 Transformasi Box - Cox	10
Tabel 2. 2 Pola ACF dan PACF.....	12
Tabel 4. 1 Deskripsi Data Yield Obligasi SBN	25
Tabel 4. 2 Estimasi Parameter Model ARIMA ([23],1,0)	29
Tabel 4. 3 Uji Signifikan Parameter dan Diagnostik Residual pada Model ARIMA Tenor 1 Tahun	32
Tabel 4. 4 MAPE Model ARIMA Tenor 1 Tahun.....	32
Tabel 4. 5 Estimasi Parameter Model ARIMA (1,1,[1,32])	36
Tabel 4. 6 MAPE Model ARIMA Tenor 5 Tahun.....	38
Tabel 4. 7 Estimasi Parameter Model ARIMA ([1,7,17],1,1) .	42
Tabel 4. 8 MAPE Model ARIMA Tenor 10 Tahun.....	45
Tabel 4. 9 Estimasi Parameter Model ARIMA ([1,7],1,1)	50
Tabel 4. 10 MAPE Model ARIMA Tenor 20 Tahun.....	52
Tabel 4. 11 Hasil Estimasi Parameter Model ARIMA Tenor 1 Tahun Sebelum dan Sesudah menggunakan Kalman Filter.....	55
Tabel 4. 12 Hasil Estimasi Parameter Model ARIMA Tenor 5 Tahun Sebelum dan Sesudah menggunakan Kalman Filter.....	58
Tabel 4. 13 Hasil Estimasi Parameter Model ARIMA Tenor 10 Tahun Sebelum dan Sesudah menggunakan Kalman Filter.....	61
Tabel 4. 14 Hasil Estimasi Parameter Model ARIMA Tenor 20 Tahun Sebelum dan Sesudah menggunakan Kalman Filter.....	63

DAFTAR LAMPIRAN

	Hal
LAMPIRAN 1	Data Yield Obligasi67
LAMPIRAN 2	Hasil Uji Parameter Signifikan, Uji White Noise dan Uji Normalitas pada Yield Tenor 5 Tahun71
LAMPIRAN 3	Hasil Uji Parameter Signifikan, Uji White Noise dan Uji Normalitas pada Yield Tenor 10 Tahun73
LAMPIRAN 4	Hasil Uji Parameter Signifikan, Uji White Noise dan Uji Normalitas pada Yield Tenor 20 Tahun75
LAMPIRAN 5	Hasil Estimasi Parameter Model ARIMA Yield Tenor 1 Tahun77
LAMPIRAN 6	Hasil Estimasi Parameter Model ARIMA Yield Tenor 5 Tahun79
LAMPIRAN 7	Hasil Estimasi Parameter Model ARIMA Yield Tenor 10 Tahun83
LAMPIRAN 8	Hasil Estimasi Parameter Model ARIMA Yield Tenor 20 Tahun93
LAMPIRAN 9	Hasil Uji White Noise Model ARIMA Yield Tenor 1 Tahun97
LAMPIRAN 10	Hasil Uji White Noise Model ARIMA Yield Tenor 5 Tahun99
LAMPIRAN 11	Hasil Uji White Noise Model ARIMA Yield Tenor 10 Tahun103
LAMPIRAN 12	Hasil Uji White Noise Model ARIMA Yield Tenor 20 Tahun109
LAMPIRAN 13	Hasil Uji Normalitas Model ARIMA Yield Tenor 1 Tahun113
LAMPIRAN 14	Hasil Uji Normalitas Model ARIMA Yield Tenor 5 Tahun115

LAMPIRAN 15	Hasil Uji Normalitas Model ARIMA Yield Tenor 10 Tahun.....	119
LAMPIRAN 16	Hasil Uji Normalitas Model ARIMA Yield Tenor 20 Tahun.....	127
LAMPIRAN 17	Listing Program Kalman Filter untuk Estimasi Parameter Model ARIMA Yield Tenor 1 Tahun	131
LAMPIRAN 18	Listing Program Kalman Filter untuk Estimasi Parameter Model ARIMA Yield Tenor 5 Tahun	133
LAMPIRAN 19	Listing Program Kalman Filter untuk Estimasi Parameter Model ARIMA Yield Tenor 10 Tahun	135
LAMPIRAN 20	Listing Program Kalman Filter untuk Estimasi Parameter Model ARIMA Yield Tenor 20 Tahun	137

BAB I PENDAHULUAN

Pada bab ini diuraikan hal-hal yang melatarbelakangi munculnya permasalahan pada Tugas Akhir yang selanjutnya dituliskan dalam suatu rumusan masalah. Dalam bab ini juga dijabarkan mengenai batasan masalah, tujuan, dan manfaat yang akan diperoleh. Adapun sistematika penulisan Tugas Akhir diuraikan pada bagian akhir bab.

1.1 Latar Belakang Masalah

Investasi adalah penanaman modal yang dilakukan oleh investor atas sejumlah dana atau sumber daya lainnya yang dilakukan dengan tujuan untuk memperoleh sejumlah keuntungan di masa yang akan datang. Ada berbagai macam jenis investasi, salah satunya adalah obligasi. Obligasi merupakan surat utang jangka menengah-panjang yang dapat dipindahtangankan dan berisi janji dari pihak yang menerbitkan obligasi untuk membayar imbalan berupa bunga pada periode tertentu dan melunasi pokok utang pada waktu yang ditentukan kepada pihak pembeli obligasi tersebut [1].

Karakteristik obligasi berupa nilai nominal (*face value*), kupon (*interest rate*), jatuh tempo (*maturity*), dan penerbit atau emiten (*issuer*) [1]. Nilai nominal adalah nilai pokok dari suatu obligasi yang akan diterima oleh pemegang obligasi pada saat obligasi tersebut jatuh tempo. Kupon adalah nilai bunga yang diterima pemegang obligasi secara berkala yang dinyatakan dalam persentase tahunan. Jatuh tempo adalah tanggal dimana pemegang obligasi akan mendapatkan pembayaran kembali nilai pokok atau nilai nominal obligasi yang dimilikinya. Sedangkan penerbit adalah pihak yang mengeluarkan suatu obligasi yang bertanggung jawab untuk membayar kupon secara berkala dan membayar nilai nominal pada saat jatuh tempo kepada pemegang obligasi.

Sebelum memutuskan untuk berinvestasi obligasi, investor perlu melakukan analisis agar investasi tersebut memberikan hasil yang maksimal dan sesuai dengan rencana. Dalam aplikasi praktis, nilai relatif obligasi tidak dapat dilihat dengan membandingkan harga obligasi secara langsung karena nilai obligasi dipengaruhi

oleh beberapa faktor antara lain faktor jatuh tempo dan nilai kupon obligasi. Faktor lain yang harus diperhatikan oleh investor adalah *yield*. *Yield* adalah tingkat return yang akan diterima dari investasi. Salah satu ukuran *yield* yang sering digunakan adalah *yield to maturity*. *Yield to maturity* adalah tingkat bunga sebenarnya yang akan diterima investor, dengan asumsi obligasi akan terus dipertahankan sampai waktu jatuh tempo [2]. Hubungan yang menggambarkan hubungan antara *yield to maturity* dengan waktu jatuh tempo adalah kurva *yield*.

Kurva *yield* adalah kurva yang menggambarkan hubungan antara periode waktu jatuh tempo obligasi dengan struktur tingkat bunga [2]. Kurva *yield* merupakan salah satu tools yang bisa digunakan dalam metode valuasi obligasi dimana nilai kurva *yield* dapat memberikan gambaran mengenai ekspektasi pasar terhadap pergerakan tingkat suku bunga sesuai dengan kondisi pasar yang terjadi pada waktu tertentu. Bentuk kurva *yield* akan selalu berubah sesuai dengan pergerakan harga di pasar.

Mengingat akan pentingnya kurva *yield* dalam melakukan investasi pada obligasi maka perlu dilakukan peramalan pada kurva *yield* sebagai alat bantu investor maupun pemerintah untuk mengetahui *yield* pada masa yang akan datang sehingga didapat keuntungan yang maksimal. Peramalan merupakan suatu proses untuk membangun sebuah hipotesa di masa yang akan datang [3]. Salah satu metode analisis *time series* yang digunakan dalam peramalan adalah *Autoregressive Moving Average* (ARIMA). Metode ARIMA memiliki asumsi parameter signifikan, residual *white noise*, dan residual berdistribusi normal. Adapun langkah langkah model ARIMA adalah identifikasi model, estimasi parameter, pengujian parameter, pemilihan model terbaik yang selanjutnya digunakan untuk peramalan. Model peramalan yang diperoleh dari model ARIMA memiliki beberapa parameter dan error, sehingga dibutuhkan sebuah metode untuk mengestimasi parameter pada model ARIMA.

Metode Kalman Filter merupakan suatu metode yang digunakan untuk menyatakan suatu model runtun waktu yang ditampilkan dalam bentuk linear *state space*. Keunggulan Kalman Filter dibandingkan dengan metode lain adalah pada proses estimasinya menggunakan bentuk dari kontrol umpan balik

(rekursif) yang dapat memperkecil nilai *Mean Absolute Percentage Error* (MAPE) dan *noise*. Data pengukuran terbaru menjadi bagian penting dalam algoritma Kalman Filter karena akan digunakan untuk mengoreksi hasil prediksi, sehingga hasil estimasinya selalu mendekati data yang sebenarnya [3].

Pada penelitian terdahulu yang dilakukan oleh Tomy Kurniawan pada tahun 2014 dengan judul “Penerapan Metode Kalman Filter dalam Perbaikan Hasil Prediksi Cuaca dengan Metode ARIMA” yang menjelaskan tentang pengamatan dari hasil model peramalan analisis *time series* dari dua parameter meteorologi yaitu suhu udara dan kecepatan angin. Pada penelitian ini digunakan metode ARIMA dalam menentukan peramalan curah hujan dan metode Kalan Filter untuk memperbaiki hasil ramalan yang didapat. Penggunaan Kalman Filter pada penelitian ini menunjukkan bahwa terdapat pengaruh baik dalam perbaikan hasil prediksi curah hujan[4].

Berdasarkan pemaparan diatas penulis termotivasi untuk menerapkan motode ARIMA untuk mendapatkan model terbaik ARIMA pada peramalan kurva *yield* obligasi pemerintah Indonesia dimana parameter model ARIMA yang didapat akan diestimasi menggunakan Kalman Filter. Dengan penggunaan ARIMA-Filter diharapkan hasil peramalan kurva *yield* yang didapat akan lebih akurat.

1.2 Rumusan Masalah

Berdasarkan latar belakang, rumusan masalah yang akan dibahas pada Tugas Akhir ini adalah sebagai berikut:

1. Bagaimana perumusan model peramalan kurva *yield* menggunakan Motode ARIMA?
2. Bagaimana estimasi parameter model ARIMA menggunakan Metode Kalman Filter?

1.3 Batasan Masalah

Adapun batasan masalah yang akan dibahas oleh penulis pada Tugas Akhir ini adalah sebagai berikut:

1. Data yang digunakan adalah data *yield* obligasi yang diperoleh dari Kementrian Keuangan Republik Indonesia pada periode Januari 2010 sampai dengan Maret 2018.

2. Penelitian ini dibatasi pada variabel waktu jatuh tempo (*time to maturity*) dan nilai imbal hasil (*yield*) obligasi pemerintah Indonesia.
3. Tenor (jatuh tempo) yang digunakan dalam penelitian adalah 1, 5, 10, dan 20 tahun.
4. Nilai taraf signifikan (α) yang digunakan adalah 0,05
5. Obligasi yang digunakan adalah obligasi dalam bentuk Surat Berharga Negara (SBN) berkupon tetap dengan asumsi obligasi tersebut tidak dipindahtangankan sebelum waktu jatuh tempo.

1.4 Tujuan

Tujuan pada penulisan Tugas Akhir ini adalah sebagai berikut:

1. Memperoleh model ARIMA yang sesuai untuk peramalan kurva *yield* pada masing masing jatuh tempo.
2. Mengestimasi parameter model ARIMA menggunakan metode Kalman Filter.

1.5 Manfaat

Manfaat yang diharapkan dari penulisan Tugas Akhir ini adalah sebagai berikut:

1. Memberikan pemahaman kepada pembaca mengenai penerapan metode Kalman Filter untuk mengestimasi parameter model ARIMA.
2. Menyediakan informasi hasil prediksi harga *yield* obligasi sebagai bahan pertimbangan pemerintah dalam perencanaan penerbitan obligasi.
3. Sebagai bahan pertimbangan investor untuk mengambil keputusan dalam hal investasi dalam bentuk obligasi pemerintah.

1.6 Sistematika Penulisan

Penulisan Tugas Akhir ini disusun dalam lima bab sebagai berikut:

BAB I PENDAHULUAN

Bab ini berisi tentang gambaran umum dari penulisan Tugas Akhir yang meliputi latar belakang, rumusan masalah, batasan masalah, tujuan, manfaat, dan sistematika penulisan.

BAB II TINJAUAN PUSTAKA

Bab ini membahas tentang teori dasar yang relevan untuk memecahkan persoalan yang dibahas pada Tugas Akhir ini, yaitu meliputi cara merumuskan model ARIMA Box-Jenkins dan metode Filter Kalman.

BAB III METODOLOGI PENELITIAN

Dalam bab ini membahas tentang metode yang akan digunakan dan tahapan-tahapan yang dilakukan dalam pengerjaan Tugas Akhir.

BAB IV ANALISIS DAN PEMBAHASAN

Bab ini membahas secara detail proses pemilihan model yang sesuai untuk prediksi harga minyak mentah. Kemudian mengaplikasikan metode Filter Kalman untuk mengestimasi parameter model ARIMA dan perbaikan *error*-nya.

BAB V PENUTUP

Bab ini berisi kesimpulan tugas akhir yang diperoleh dari bab pembahasan dan saran untuk pengembangan lebih lanjut dari Tugas Akhir.

BAB II TINJAUAN PUSTAKA

Pada bab ini dibahas teori-teori yang berhubungan dengan permasalahan dalam Tugas Akhir. Teori yang akan dibahas meliputi penelitian terdahulu, pengertian dan bentuk umum serta langkah-langkah dalam merumuskan model ARIMA. Selanjutnya dijelaskan mengenai metode Kalman Filter dan implementasinya untuk mengestimasi parameter model ARIMA.

2.1 Penelitian Terdahulu

Tinjauan pustaka yang digunakan dalam Tugas Akhir ini adalah beberapa penelitian yang relevan dengan tema yang diambil. Penelitian pertama adalah penelitian yang dilakukan oleh Yuli Wahyuningsih pada tahun 2015 dengan judul “Peramalan *Yield* dan Harga Obligasi Pemerintah dengan Pendekatan ARIMA dan *Artificial Neural Network*”. Dari penelitian ini dilakukan peramalan pada data *yield* dan harga obligasi pemerintah Indonesia. Hasil yang diperoleh menunjukkan bahwa tanpa adanya *outlier*, model ARIMA lebih akurat dalam meramalkan *yield* dan harga obligasi dibandingkan dengan model ANN. Hal ini berdasarkan nilai MAPE dan RMSE yang dimiliki ARIMA lebih kecil daripada ANN [5].

Penelitian selanjutnya adalah oleh Tomy Kurniawan pada tahun 2014 dengan judul “Penerapan Metode Kalman Filter dalam Perbaikan Hasil Prediksi Cuaca dengan Metode ARIMA”. Penggunaan Kalman-Filter pada penelitian ini menunjukkan bahwa terdapat pengaruh baik dalam perbaikan hasil peramalan analisis *time series* dari dua parameter meteorologi yaitu suhu udara dan kecepatan angin [4].

Penelitian berikutnya adalah penelitian yang dilakukan oleh Hilmi Pamungkas pada tahun 2016 dengan judul “Estimasi Parameter Model ARIMA Menggunakan Kalman Filter Untuk Peramalan Permintaan Darah”. Dari penelitian ini disimpulkan bahwa model ARIMA yang parameternya diestimasi menggunakan Kalman Filter diperoleh hasil prediksi yang lebih akurat dibandingkan hasil prediksi ARIMA yang diestimasi menggunakan metode *Least Square* [6].

2.2 Model ARIMA

Model *Autoregressive Intergrated Moving Average* (ARIMA) telah dipelajari secara mendalam oleh Goerge Box dan Gwilym Jenkins pada tahun 1967 [7]. Model ARIMA sering juga disebut model runtun waktu Box-Jenkins. Model ARIMA adalah model yang menggunakan nilai masa lalu dan sekarang dari variabel dependen untuk menghasilkan peramalan jangka pendek yang akurat. Model ARIMA cocok untuk observasi dari *time series* yang secara statistik berhubungan satu sama lain (*dependent*).

Model Box-Jenkins (ARIMA) dibagi kedalam 3 kelompok, yaitu: model *autoregressive* (AR), *moving average* (MA), dan model campuran ARIMA (*autoregressive moving average*) yang mempunyai karakteristik dari dua model pertama.

Model *autoregressive* (AR) adalah model yang mendeskripsikan bahwa variabel terikat dipengaruhi oleh variabel terikat itu sendiri pada periode sebelumnya. Bentuk umum model *autoregressive* dengan ordo ke- p atau model ARIMA ($p,0,0$) dinyatakan sebagai berikut [8]:

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + e_t ; e_t \underset{\sim}{\overset{iid}{N}}(0, \sigma^2)$$

dengan :

Y_t : data ke t

ϕ_p : parameter *autoregressive* ke p

e_t : nilai kesalahan pada waktu ke t

Model *moving average* (MA) adalah model yang mendeskripsikan secara eksplisit hubungan ketergantungan antara nilai-nilai kesalahan berurutan. Bentuk umum model *moving average* dengan ordo ke- q atau ARIMA ($0,0,q$) dinyatakan sebagai berikut [8]:

$$Y_t = e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} ; e_t \underset{\sim}{\overset{iid}{N}}(0, \sigma^2)$$

dengan :

Y_t : data ke t

θ_q : parameter *moving average* ke- q

e_t : nilai kesalahan pada waktu ke t

Model *autoregressive moving average* (ARMA) adalah gabungan dari model AR dan MA. Bentuk umum model ARMA (p, q) atau ARIMA $(p, 0, q)$ dinyatakan sebagai berikut [8]:

$$\phi_p(B) Y_t = \theta_q(B) e_t ; e_t \stackrel{iid}{\sim} N(0, \sigma^2)$$

dengan :

$$\phi_p(B) : (1 - \phi_1 B - \dots - \phi_p B^p)$$

$$\theta_q(B) : (1 - \phi_1 B - \dots - \phi_q B^q)$$

Y_t : data ke t

B : operator *back shift*

ϕ_p : parameter *autoregressive* ke p

θ_q : parameter *moving average* ke q

e_t : nilai kesalahan pada waktu ke t

Model ARIMA adalah gabungan dari model AR dan MA dengan penambahan nontasioneritas pada model. Dengan orde p menyatakan operator AR, orde d menyatakan orde *differencing*, dan orde q menyatakan operator MA. Bentuk umum model ARIMA (p, d, q) adalah sebagai berikut [8]:

$$\phi_p(B)(1 - B)^d Y_t = \theta_q(B) e_t ; e_t \stackrel{iid}{\sim} N(0, \sigma^2) \quad (2.1)$$

dengan :

$$\phi_p(B) : (1 - \phi_1 B - \dots - \phi_p B^p)$$

$$\theta_q(B) : (1 - \phi_1 B - \dots - \phi_q B^q)$$

Y_t : data ke t

B : operator *back shift*

ϕ_p : parameter *autoregressive* ke p

θ_q : parameter *moving average* ke q

e_t : nilai kesalahan pada waktu ke t

2.3 Perumusan Model ARIMA

Terdapat empat tahapan dalam merumuskan model ARIMA yaitu tahap identifikasi model, penaksiran dan pengujian parameter, diagnostik cek, dan peramalan

2.3.1 Identifikasi Model ARIMA

Data *time series* adalah data yang dikumpulkan dari serangkaian pengamatan terhadap suatu variabel yang diambil dari waktu ke waktu dan dicatat secara berurutan menurut urutan waktu kejadiannya dengan interval waktu yang tetap. Setiap pengamatan dinyatakan sebagai variabel random Z_t yang diperoleh berdasarkan indeks waktu tertentu (t_i) dengan $i = 1, 2, \dots, n$ sehingga data *time series* dapat ditulis sebagai berikut $Z_{t_1}, Z_{t_2}, Z_{t_3}, \dots, Z_{t_n}$.

Beberapa hal yang perlu diperhatikan di dalam *time series* metode ARIMA adalah kestasioneran data, fungsi autokorelasi dan fungsi autokorelasi parsial [4]. Data yang digunakan untuk *time series* adalah data yang stasioner dalam rata-rata dan varian.

Data *time series* dikatakan stasioner dalam varian jika varian dari data bernilai konstan. Kestasioneran data dapat dilihat dari transformasi Box-Cox dengan persamaan sebagai berikut[9]:

$$T(Y_t) = \begin{cases} \frac{Y_t^\lambda - 1}{\lambda}, & \lambda \neq 0 \\ \ln Y_t, & \lambda = 0 \end{cases}$$

Transformasi Box-Cox adalah transformasi pangkat oleh λ pada variabel tak bebas Y sehingga transformasinya menjadi Y^λ , dimana λ adalah parameter yang perlu diduga. Nilai λ beserta aturan pada Transformasi Box-Cox dapat dilihat pada Tabel 2.1.

Tabel 2. 1 Transformasi Box - Cox

Nilai λ	Transformasi Box – Cox
-1	$1/Y_t$
-0.5	$1/\sqrt{Y_t}$
0	$\ln Y_t$
0.5	$\sqrt{Y_t}$
1	Y_t

Fungsi autokorelasi (ACF) merupakan suatu hubungan linear pada data *time series* antara Y_t dengan Y_{t+k} yang dipisahkan oleh waktu *lag* k . ACF dapat digunakan untuk mengidentifikasi model *time series* dan melihat kestasioneran dalam rata-rata. Fungsi autokorelasi dihitung berdasarkan sampel data dapat ditulis sebagai berikut [8]:

$$\hat{\rho}_k = \frac{\sum_{t=1}^{n-k} (Y_t - \bar{Y})(Y_{t+k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2}, \quad k = 0, 1, 2, \dots$$

dengan :

- $\hat{\rho}_k$: autokorelasi pada *lag* ke k
- Y_t : data ke t
- \bar{Y} : nilai rata-rata Y_t
- n : jumlah data

Data *time series* dikatakan stasioner dalam *mean* apabila nilai-nilai autokorelasinya turun secara cepat menuju nol. Sedangkan jika nilai-nilai autokorelasinya turun secara lambat menuju nol maka data tersebut tidak stasioner terhadap *mean*.

Fungsi Autokorelasi Parsial (PACF) digunakan sebagai alat untuk mengukur tingkat kerataan antara Y_t dan Y_{t+k} apabila pengaruh *lag* $t + 1, t + 2, \dots, t + k - 1$ dianggap terpisah. Untuk PACF dapat didekati dengan persamaan sebagai berikut [8]:

$$\bar{\phi}_{k+1,k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \bar{\phi}_{k,j} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \bar{\phi}_{k,j} \hat{\rho}_j}$$

dan

$$\bar{\phi}_{k+1,j} = \bar{\phi}_{k,j} - \bar{\phi}_{k+1,k+1} \bar{\phi}_{k,k+1-j}$$

dengan :

- $\hat{\rho}_k$: autokorelasi pada *lag* ke k
- $\bar{\phi}_{kk}$: autokorelasi parsial pada *lag* ke k

Pada tahap identifikasi model, data diuji kestasionerannya baik dalam varians maupun dalam *mean*. Setelah data stasioner dalam

varian dan *mean* maka akan dilakukan proses pemilihan model yang sesuai dengan cara mengidentifikasi orde AR dan MA pada grafik ACF dan PACF.

Tabel 2. 2 Pola ACF dan PACF

Model	ACF	PACF
AR (p)	Menurun secara eksponensial	Terpotong setelah lag ke- p
MA (q)	Terpotong setelah lag ke- q	Menurun secara eksponensial
ARMA (p, q)	Menurun secara eksponensial setelah lag ke- $(q - p)$	Menurun secara eksponensial setelah lag ke- $(p - q)$

Tabel 2.2 menunjukkan cara menentukan model AR, MA, dan ARMA. Untuk menentukan orde tertinggi q dapat dilihat dari banyaknya lag yang keluar pada plot ACF. Untuk menentukan orde tertinggi p dapat dilihat dari banyaknya lag yang keluar pada plot PACF.

2.3.2 Penaksiran dan Pengujian Parameter

Pada tahap penaksiran dan pengujian parameter, akan ditentukan parameter model AR dan MA. Untuk penaksiran parameter model ARIMA dapat dilakukan dengan beberapa metode Antara lain metode *Least Square*, metode *Maximum Likelihood*, metode *Nonlinear Estimation*. Setelah diperoleh nilai estimasi dari masing-masing parameter kemudian dilakukan pengujian signifikansi parameter untuk mengetahui apakah model sudah layak atau belum untuk digunakan.

Untuk pengujian signifikansi parameter menggunakan uji-t student. Misalnya β adalah suatu parameter pada model ARIMA (mencakup ϕ dan θ) dan $\hat{\beta}$ adalah estimasi dari β maka pengujian signifikansi parameter dapat dinyatakan sebagai berikut [7]:

Hipotesis :

$H_0: \beta = 0$ (Parameter model tidak signifikan)

$H_1: \beta \neq 0$ (Parameter model signifikan)

Statistik Uji :

$$t_{hitung, i} = \frac{\hat{\beta}_i}{SE(\hat{\beta}_i)} \text{ untuk } SE(\hat{\beta}_i) \neq 0 \quad (2.2)$$

dengan :

$\hat{\beta}$: parameter hasil estimasi

$SE(\hat{\beta}_i)$: standart error estimasi parameter

Kriteria Pengujian :

H_0 akan ditolak apabila nilai statistik uji $|t_{hitung, i}| > t_{\frac{\alpha}{2}, (n-1)}$

atau nilai $p - value < \alpha$, yang berarti bahwa parameter model signifikan.

dengan :

n : jumlah data

α : taraf signifikan

2.3.3 Diagnostik Cek

Pengujian diagnostik residual dilakukan setelah pengujian signifikansi parameter model ARIMA, untuk membuktikan kecukupan model. Pemeriksaan diagnostik residual meliputi uji asumsi *white noise* dan uji asumsi distribusi normal.

1. Uji Asumsi Residual *White noise*

Proses *white noise* dapat dideteksi menggunakan uji autokorelasi residual yang bertujuan untuk mendeteksi ada tidaknya korelasi residual antar *lag*. Pengujian asumsi residual *white noise* dapat menggunakan uji Ljung-Box. Pengujian dapat dilakukan sebagai berikut [7]:

Hipotesis :

$H_0: \rho_1 = \rho_2 = \dots = \rho_k = 0$ (residual *white noise*).

H_1 : Minimal ada satu $\rho_k \neq 0$ dengan $k = 1, 2, \dots, K$ (residual tidak *white noise*).

Statistik uji :

$$Q = n(n + 2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{(n-k)} \quad (2.3)$$

dengan :

K : lag maksimum

n : jumlah data

\hat{p}_k : autokorelasi residual lag ke k

Kriteria Pengujian :

Jika $Q > X_{\alpha, K-p-q}^2$ atau P-value $< \alpha$ maka H_0 ditolak yang berarti bahwa residual tidak *white noise*.

dengan :

K : lag maksimum

p : orde AR

q : orde MA

2. Uji Asumsi Distribusi Normal

Untuk pengujian residual berdistribusi normal dapat menggunakan uji Komogorov-Smirnov. Pengujian dapat dilakukan sebagai berikut [7]:

Hopotesis :

H_0 : $F(x) = F_0(x)$ untuk semua x (residual berdistribusi normal)

H_1 : $F(x) \neq F_0(x)$ untuk beberapa x (residual tidak berdistribusi normal)

Statistik uji :

$$D_{hitung} = \sup_x |S(x) - F_0(x)| \quad (2.4)$$

dengan :

D_{hitung} : deviasi maksimum

\sup_x : nilai supremum (maksimum) untuk semua x dari selisih mutlak $S(x)$ dan $F_0(x)$

$S(x)$: fungsi distribusi kumulatif dari data sampel

$F_0(x)$: fungsi peluang kumulatif berdistribusi normal atau fungsi yang dihipotesiskan.

Kriteria Pengujian :

Jika $D_{hitung} > D_{\alpha, n}$ atau $P - value < \alpha$, maka H_0 ditolak yang berarti residual tidak berdistribusi normal.

dengan :

n : jumlah data

3. *Overfitting*

Salah satu prosedur diagnostik cek yang dikemukakan Box Jenkins adalah *overfitting*, yaitu menambah satu atau lebih parameter dalam model yang dihasilkan pada tahap identifikasi. Model yang dihasilkan dari *overfitting* dijadikan sebagai model alternatif yang kemudian dicari model terbaik diantara model-model yang signifikan.

2.3.4 Pemilihan Model Terbaik

Pemilihan model terbaik dapat dilihat melalui pendekatan *out-sample* menggunakan MAPE (*Mean Absolute Percentage Error*) yaitu ukuran kesalahan yang dihitung dengan mencari nilai tengah dari presentase absolut perbandingan nilai *error* dengan nilai aktualnya. Persamaan MAPE didefinisikan sebagai berikut [7].

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \times 100 \quad (2.5)$$

dengan :

n : banyaknya data

Y_t : data aktual pada waktu ke- t

\hat{Y}_t : data ramalan pada waktu ke- t

2.4 Metode Maximum Likelihood Estimation

Metode kemungkinan maksimum (*Maximum Likelihood Estimation*) adalah metode yang digunakan untuk menduga parameter dengan memaksimumkan fungsi kemungkinan yang dibentuk dari fungsi peluang bersama suatu peubah acak[9]. Fungsi kemungkinan (*likelihood*) dilambangkan dengan $L(\theta)$. Jika $X_1, X_2, X_3 \dots X_n$ merupakan peubah acak dari $f(x_i, \theta)$, maka:

$$L(\theta) = f(x_1, \theta), f(x_2, \theta) \dots f(x_n, \theta)$$

$$L(\theta) = \prod_{i=1}^n f(x_i, \theta)$$

dengan :

$L(\theta)$: fungsi *likelihood*

$f(x_i, \theta)$: fungsi kepadatan peluang

Dalam penelitian ini metode MLE digunakan untuk mengestimasi parameter model ARIMA. Contoh pada model ARIMA (1,0,0) dinotasikan sebagai berikut:

$$Y_t = \phi_1 Y_{t-1} + e_t ; \text{dimana } e_t \sim N(0, \sigma_e^2)$$

Sehingga diperoleh fungsi *likelihood* untuk model ARIMA (1,0,0) yaitu :

$$L(\phi_1, \sigma_e^2) = (2\pi\sigma_e^2)^{-\frac{n}{2}} \exp\left(-\frac{1}{2\sigma_e^2} \sum_{t=1}^n (Y_t - \phi_1 Y_{t-1})^2\right)$$

Selanjutnya untuk memperoleh penduga kemungkinan maksimum dilakukan dengan menurunkan fungsi *likelihood* terhadap parameter ϕ_1 dan σ_e^2 dimana $\frac{\partial L}{\partial \phi_1} = 0$ dan $\frac{\partial L}{\partial \sigma_e^2} = 0$

Fungsi *likelihood* $L(\theta)$ dikatakan maksimum jika $\frac{\partial^2 L(\theta)}{\partial \theta^2} < 0$. Umumnya untuk mempermudah perhitungan secara matematis akan digunakan fungsi log-likelihood:

$$\ln L(\theta) = \sum_{i=1}^n \ln f(x_i, \theta)$$

2.5 Metode Kalman Filter

Kalman Filter mengestimasi suatu proses dengan menggunakan *feedback* yang berulang. Persamaan pada Kalman Filter dibagi dalam dua tahap yaitu persamaan pembaruan waktu (*time update*) dan persamaan pembaruan pengukuran (*measurement update*)[10]. Persamaan pembaharuan waktu yang ada akan digunakan untuk memproyeksikan (dalam waktu) keadaan saat ini dan estimasi kovarians errornya untuk mendapatkan estimasi *priori* untuk langkah selanjutnya. Selanjutnya persamaan pengukuran yang diperbarui akan digunakan untuk umpan balik, seperti halnya menggabungkan pengukuran baru ke dalam estimasi *a priori* untuk mendapatkan peningkatan estimasi *priori*. Persamaan pembaruan waktu juga dapat disebut sebagai prediksi, sedangkan persamaan pembaruan

pengukuran sebagai koreksi. Algoritma Kalman Filter waktu diskrit ditulis sebagai berikut [10]:

1. Model Sistem dan Model Pengukuran

- Model sistem :

$$x_{k+1} = Ax_k + Bu_k + Gw_k \quad (2.6)$$

- Model Pengukuran :

$$z_k = Hx_k + v_k \quad (2.7)$$

- Dengan asumsi :

$$x_0 \sim N(x_0, P_{x_0}), w_k \sim N(0, Q_k), v_k \sim N(0, R_k)$$

2. Inisialisasi

$$P_0 = P_{x_0}$$

$$\hat{x}_0 = \bar{x}_0$$

3. Tahap Prediksi :

- Kovarian error :

$$P_{k+1} = A_k P_k A_k^T + G_k Q_k G_k^T$$

- Estimasi :

$$\hat{x}_{k+1} = A_k \hat{x}_k + B_k u_k$$

4. Tahap Koreksi:

- Kalman Gain:

$$K_{k+1} = P_{\bar{k}+1} H_{k+1}^T (H_{k+1} P_{\bar{k}+1} H_{k+1}^T + R_{k+1})^{-1}$$

- Kovariansi error :

$$P_{k+1} = [I - K_{k+1} H_{k+1}] P_{\bar{k}+1}$$

- Estimasi :

$$\hat{x}_{k+1} = \hat{x}_{\bar{k}+1} + K_{k+1} [z_{k+1} - H_{k+1} \hat{x}_{\bar{k}+1}]$$

dengan :

x_k : variabel keadaan sistem pada waktu ke k yang nilai estimasi awalnya adalah \hat{x}_0 dan kovarian awal P_{x_0}

u_k : variabel input deterministik pada waktu ke k

w_k : *noise* pada model sistem

v_k : *noise* pada model pengukuran

- z_k : variabel pengukuran
- H : matriks koefisien model pengukuran dengan ukuran $p \times n$
- A : matriks koefisien model system dengan ukuran $n \times n$
- G : matriks koefisien noise system dengan ukuran $n \times l$

2.6 Penerapan Metode Kalman Filter

Hasil model terbaik peramalan ARIMA dari data *yield* obligasi pemerintah pada masing-masing tenor selanjutnya akan dilakukan estimasi parameter menggunakan Kalman Filter. Seperti pada model ARIMA $(p, 0, 0)$:

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + e_t$$

dengan :

- Y_t : data ke t
- ϕ_p : parameter *autoregressive* ke p
- e_t : nilai kesalahan pada waktu ke t

Dengan koefisien $\phi_1, \phi_2, \dots, \phi_p$ adalah parameter yang akan diestimasi menggunakan Kalman Filter. Diasumsikan sebagai *state* vektor yang dibentuk dari koefisien $\phi_1, \phi_2, \dots, \phi_p$ yaitu $x(t) = [\phi_1, \phi_2, \dots, \phi_p]^T$.

Berikut persamaan model sistem dan pengukuran pada model Kalman Filter :

$$x_{t+1} = Ax_t + w_t$$

$$z_t = Hx_t + v_t$$

dengan :

- x_t : variabel keadaan sistem pada waktu k yang nilai estimasi awalnya adalah \hat{x}_0 dan kovarian awal P_{x0}
- w_t : *noise* pada model sistem
- z_t : variabel pengukuran
- v_t : *noise* pada model pengukuran

BAB III

METODOLOGI PENELITIAN

Pada bab ini diuraikan langkah-langkah sistematis yang akan dilakukan dalam proses pengerjaan Tugas Akhir. Tahapan penelitian Tugas Akhir terdiri dari beberapa tahapan, yaitu studi literature, pengumpulan dan analisis data, perumusan model ARIMA, estimasi dengan Kalman Filter, simulasi, dan penarikan kesimpulan.

3.1 Tahapan Penelitian

Tahapan penelitian Tugas Akhir ini akan dilakukan sebagai berikut :

1. Studi Literatur

Pada tahap ini dilakukan pencarian dan pengumpulan referensi yang menunjang pengerjaan Tugas Akhir dan pemahaman lebih mendalam tentang metode yang akan digunakan. Literatur yang dipakai adalah buku-buku, jurnal ilmiah, tugas akhir atau tesis yang berkaitan dengan permasalahan, serta artikel dari internet.

2. Pengumpulan dan Analisis Data

Data yang digunakan dalam penelitian ini adalah data bulanan *yield* obligasi yang diperoleh dari Kementerian Keuangan Republik Indonesia. Periode data *yield* yang akan digunakan adalah bulan Januari 2010 – Maret 2018.

3. Perumusan Model ARIMA

Pada tahap ini dilakukan analisis deret berkala untuk merumuskan model peramalan. Tahapan ini disajikan dalam bentuk diagram alir (*flowchart*) pada Gambar 3.2. Berikut langkah-langkah merumuskan model ARIMA :

- a. Menguji kestasioneran data *time series* baik stasioner dalam *mean* maupun dalam varian.
- b. Mengidentifikasi dugaan model sementara dengan cara menentukan orde AR dan MA dari grafik ACF dan PACF.
- c. Melakukan pemeriksaan diagnostik yang meliputi uji signifikansi parameter, uji *white noise*, dan uji normalitas.
- d. Menentukan model terbaik ARIMA

4. Estimasi Model ARIMA dengan Kalman Filter

Pada tahap ini, akan dilakukan estimasi pada parameter model ARIMA yang telah didapatkan. Dengan menggunakan Kalman Filter sehingga dapat meminimalkan tingkat kesalahan perkiraan dalam *time series*. Metode Kalman Filter terdiri dari 2 tahapan yaitu tahap prediksi dan tahap koreksi. Kedua tahapan tersebut akan dilakukan untuk estimasi parameter θ dan ϕ pada model ARIMA. Tahapan ini disajikan dalam bentuk diagram alir (*flowchart*) pada Gambar 3.3. Langkah-langkah dalam estimasi model ARIMA menggunakan Kalman Filter adalah sebagai berikut :

- a. Membentuk sebuah fungsi *state space* dari model terbaik ARIMA yang didapat.
- b. Mengestimasi nilai awal parameter dari fungsi yang telah dibentuk.
- c. Melakukan pemfilteran dari data *yield* dengan output parameter dari hasil fungsi yang telah diestimasi.
- d. Menghitung nilai residual, membuat plot hasil filtering dan normalitas residual.
- e. Melakukan prediksi *yield* dari data yang telah difilter kemudian mencari batas atas dan batas bawah hasil prediksi.

5. Simulasi dan Pembahasan

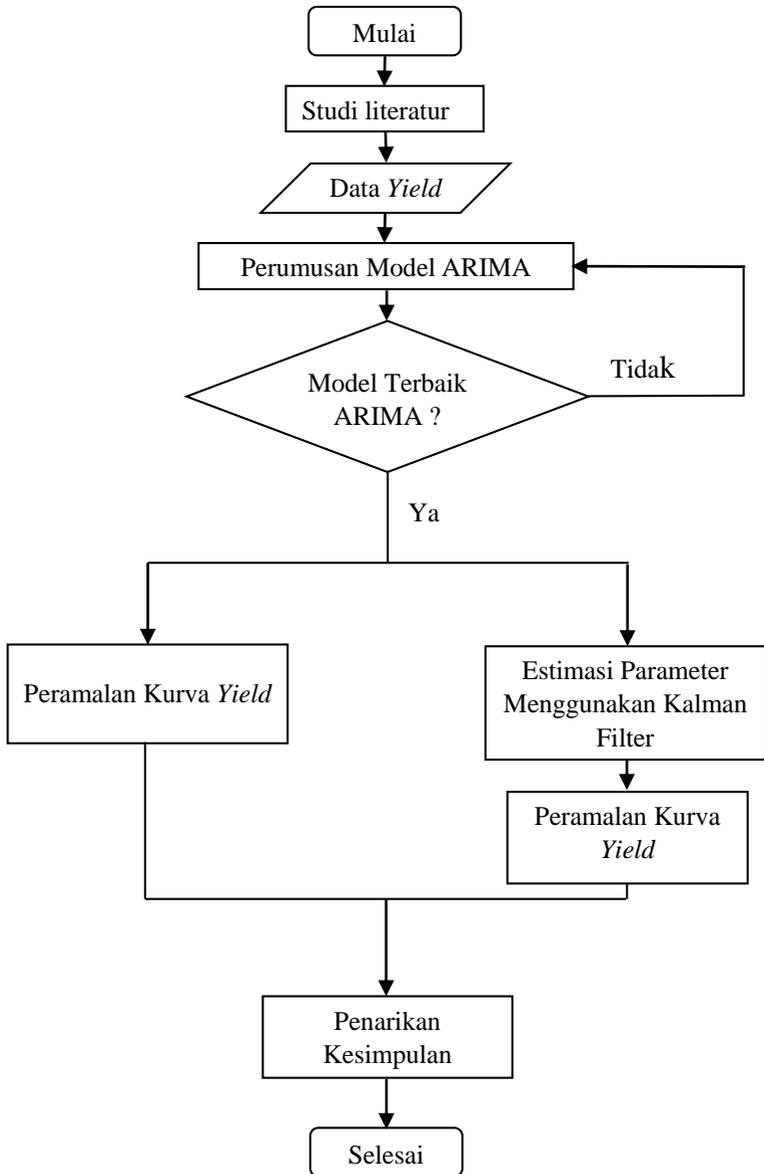
Pada tahap ini, akan dilakukan simulasi dari model ARIMA yang didapat setelah proses estimasi. Model ARIMA yang didapat selanjutnya akan digunakan untuk peramalan kurva *yield*. Simulasi dilakukan dengan software SAS dan MATLAB

6. Penarikan Kesimpulan

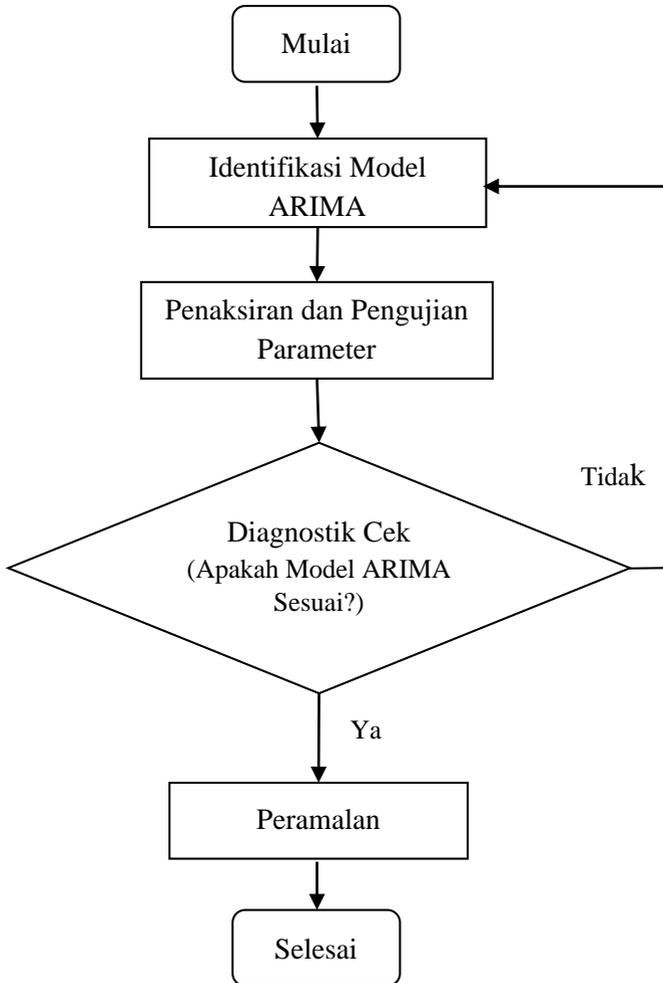
Pada tahap ini dilakukan penarikan kesimpulan dari hasil yang telah didapatkan pada tahapan-tahapan sebelumnya dan juga saran untuk penelitian selanjutnya.

3.2 Diagram Alir Penelitian

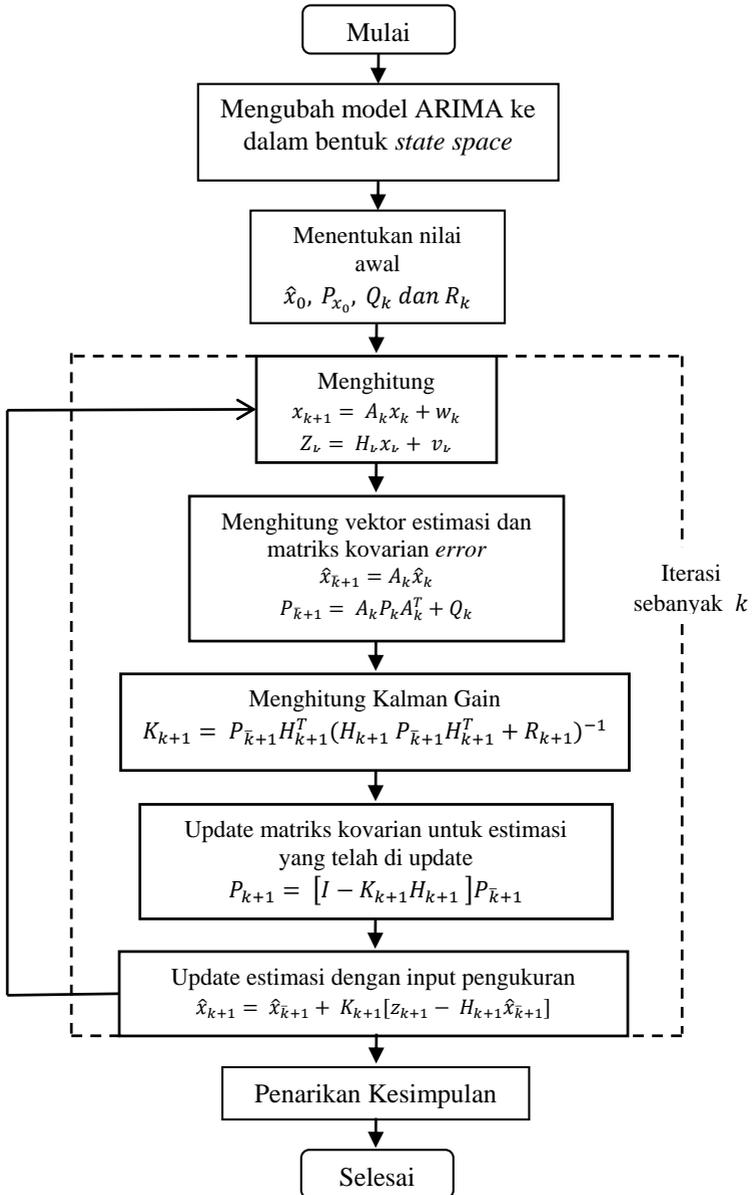
Tahapan penelitian Tugas Akhir ini disajikan dalam bentuk diagram alir (*flowchart*) pada Gambar 3.1. Diagram alir dari metode ARIMA dan metode Kalman Filter juga dapat dilihat pada Gambar 3.2 dan Gambar 3.3.



Gambar 3. 1 Diagram Alir Penelitian



Gambar 3. 2 Diagram Alir Metode ARIMA



Gambar 3. 3 Diagram Alir Metode Kalman Filter

BAB IV ANALISIS DAN PEMBAHASAN

Pada bab ini akan dilakukan analisis dan pembahasan mengenai langkah-langkah perumusan model ARIMA dan estimasi parameter model ARIMA menggunakan Kalman Filter.

4.1 Variabel dan Data Penelitian

Dalam tugas akhir ini, penulis menggunakan data bulanan *yield* obligasi Surat Berharga Negara yang bersumber dari Kementerian Keuangan Republik Indonesia. Data yang digunakan adalah data *yield* pada tenor 1,5,10, dan 20 tahun dimana masing-masing sebanyak 99 data yaitu data pada periode Januari 2010 sampai dengan Maret 2018.

Data yang diperoleh selanjutnya dibagi menjadi dua yaitu data *in-sample* dan *out-sample*. Data *in-sample* digunakan untuk merumuskan model ARIMA dan data *out-sample* digunakan untuk pemilihan model terbaik. Data yang digunakan untuk *in-sample* adalah data periode Januari 2010-Desember 2017, sedangkan data yang digunakan untuk *out-sample* adalah data periode Januari 2018-Maret 2018.

Variabel yang digunakan pada penelitian ini yaitu $Y_{1(t)}$, $Y_{5(t)}$, $Y_{10(t)}$, dan $Y_{20(t)}$ dimana masing-masing adalah peramalan *yield* obligasi pada tenor 1,5,10, dan 20 tahun. Data *yield* pada masing-masing tenor dapat dilihat pada Lampiran 1. Deskripsi dari data *yield* obligasi pada tenor 1,5,10, dan 20 tahun secara umum dapat ditampilkan dalam Tabel 4.1.

Tabel 4. 1 Deskripsi Data Yield Obligasi SBN

Variabel	N	Min	Max	Mean	St. Deviasi
$Y_{1(t)}$	99	3.56	7.61	5.89	1.049
$Y_{5(t)}$	99	4.62	8.95	6.93	1.1304
$Y_{10(t)}$	99	5.17	9.80	7.38	1.0842
$Y_{20(t)}$	99	6.18	10.69	8.09	1.0736

Tabel 4.1 menunjukkan jumlah data, data terkecil, data terbesar, rata-rata, dan standar deviasi pada data *yield* obligasi Surat Berharga Negara pada tenor 1,5,10, dan 20 tahun. Pada Tabel 4.1 diketahui bahwa *yield* terkecil adalah pada data tenor 1 tahun dan *yield* terbesar adalah pada data tenor 20 tahun. Dapat disimpulkan juga bahwa semakin besar tenor maka semakin besar nilai *yield*.

4.2 Analisis dan Perumusan Model ARIMA

Langkah awal dalam merumuskan model ARIMA adalah dengan menguji kestasioneran data. Dalam hal ini, data *yield* yang diuji pada masing-masing tenor harus stasioner baik dalam varian maupun rata-rata. Jika data sudah stasioner dalam maka selanjutnya dilakukan proses pemilihan model yang tepat dengan cara identifikasi orde AR dan MA pada grafik ACF dan PACF. Setelah diperoleh model dilakukan uji signifikansi parameter, uji residual *white noise* dan berdistribusi normal. Selanjutnya dilakukan estimasi parameter model terbaik ARIMA dengan menggunakan Kalman Filter. Berikut akan dilakukan perumusan model ARIMA pada masing-masing tenor.

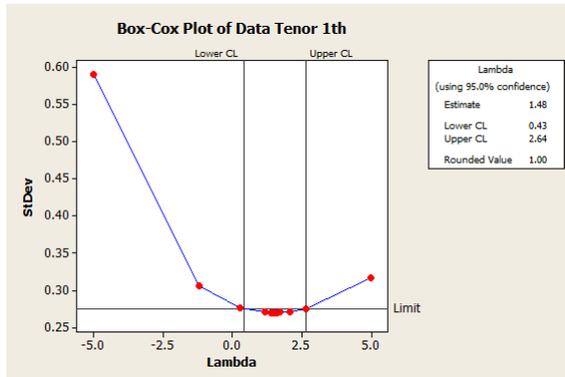
4.2.1 Yield Tenor 1 Tahun

Langkah-langkah perumusan model ARIMA pada *Yield* Tenor 1 Tahun akan dijelaskan sebagai berikut.

1. Identifikasi Model ARIMA

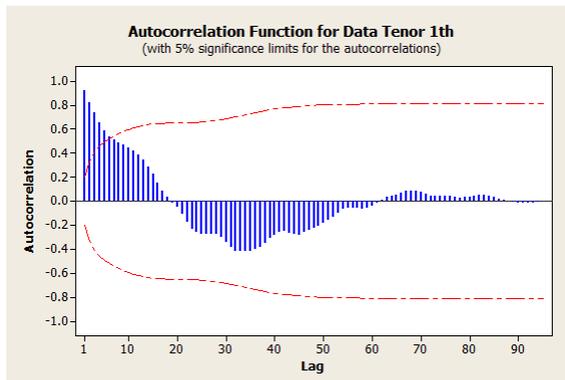
Langkah awal dalam merumuskan model ARIMA adalah dengan identifikasi stasioneritas baik dalam varian maupun rata-rata terhadap data *yield* tenor 1 tahun. Untuk kestasioneran dalam varian dapat dilihat pada transformasi Box-Cox dimana dikatakan stasioner jika *rounded value*-nya adalah 1. Plot Transformasi Box-Cox dari data *yield* tenor 1 tahun dapat dilihat pada Gambar 4.1.

Gambar 4.1 menunjukkan nilai λ dengan nilai kepercayaan 95% berada diantara 0,43 dan 2,64, dengan nilai *estimate* sebesar 1,48 dan *rounded value* sebesar 1,00. Hal ini menunjukkan bahwa data sudah stasioner terhadap varian karena nilai *rounded value*-nya sama dengan 1.



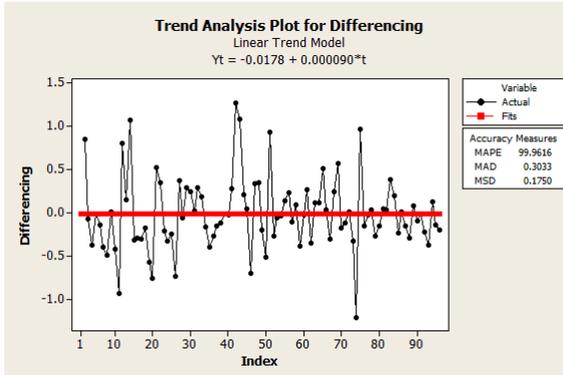
Gambar 4. 1 Box – Cox Data Tenor 1 Tahun

Setelah data stasioner dalam varian maka akan dilihat apakah data sudah stasioner dalam rata-rata dapat dilihat dari plot ACF dari data yang sudah stasioner dalam varian pada Gambar 4.2.



Gambar 4. 2 Plot ACF Data Tenor 1 Tahun

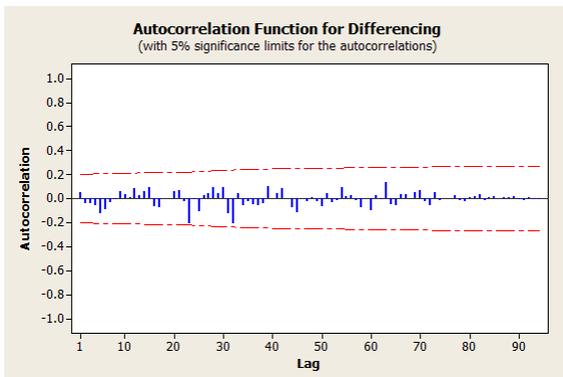
Dari Gambar 4.2 dapat dilihat bahwa plot ACF memiliki pola *dies down* atau bisa dikatakan mengikuti gelombang sinus. Dapat dilihat juga bahwa masih banyak *lag* yang keluar dari garis merah putus-putus (*significance limit*) dan diduga masih belum stasioner terhadap *mean* sehingga perlu dilakukan proses *differencing*. Plot *trend analysis* data *yield* setelah proses *differencing* dapat dilihat pada Gambar 4.3.



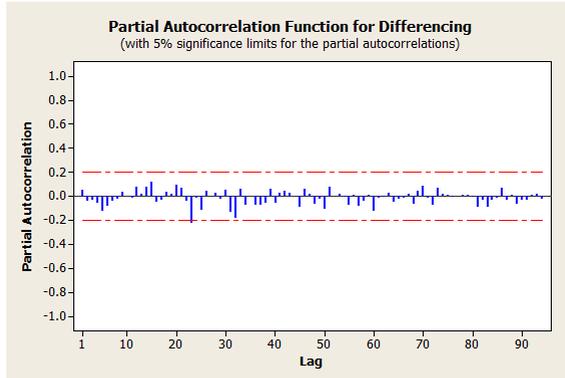
Gambar 4. 3 Plot Trend Analysis Data Differencing

Pada plot *trend* analysis terlihat bahwa plot berfluktuasi di sekitar nilai tengah dan mendekati sumbu horizontal yang berarti bahwa data sudah stasioner dalam varian maupun rata-rata.

Langkah selanjutnya adalah identifikasi model ARIMA dari data yang sudah stasioner dalam varian maupun rata-rata melalui identifikasi plot ACF dan PACF. Plot ACF dapat dilihat pada Gambar 4.4 dan plot PACF dapat dilihat pada Gambar 4.5. Hasil identifikasi terlihat bahwa plot ACF tidak ada *lag* yang keluar sedangkan plot PACF keluar pada *lag* ke-23. Sehingga didapatkan dugaan model sementara untuk data *yield* tenor 1 tahun adalah ARIMA([23],1,0).



Gambar 4. 4 Plot ACF Differencing



Gambar 4. 5 Plot PACF Differencing

2. Penaksiran dan Pengujian Parameter

Dalam langkah ini akan dilakukan estimasi parameter menggunakan metode *Maximum Likelihood* dengan software SAS pada Lampiran 5. Hasil estimasi ditunjukkan pada Tabel 4.2.

Tabel 4. 2 Estimasi Parameter Model ARIMA ([23],1,0)

Parameter	Koefisien	SE	t-stat	P-value
AR(23)	-0,30263	0,10693	-2,83	-0,0047

Langkah selanjutnya adalah uji signifikansi parameter model ARIMA ([23],1,0) dengan menggunakan uji-*t* untuk melihat kesesuaian dengan data yang ada seperti berikut:

Uji Parameter AR (23)

Hipotesis:

$H_0 : \phi_{23} = 0$ (parameter ϕ_{23} tidak signifikan)

$H_1 : \phi_{23} \neq 0$ (parameter ϕ_{23} signifikan)

Statistik uji:

Dengan menggunakan persamaan (2.2) maka didapatkan

$$\begin{aligned}
 t_{hitung} &= \frac{\hat{\phi}_{23}}{SE(\hat{\phi}_{23})} \\
 &= \frac{-0,30263}{0,10693} \\
 &= -2,83
 \end{aligned}$$

Dengan tabel distribusi t diperoleh:

$$t_{tabel} = t_{0,025;96} = 1,960$$

Kriteria pengujian:

Karena $|t_{hitung}| > t_{tabel}$, maka H_0 ditolak yang artinya parameter model signifikan

Berdasarkan hasil uji signifikansi parameter pada model ARIMA ([23],1,0) menunjukkan parameter AR(23) signifikan.

3. Uji Diagnostik

Asumsi yang harus dipenuhi adalah residual bersifat *white noise* dan berdistribusi normal. Pengujian residual bersifat *white noise* dilakukan dengan uji Ljung-Box sebagai berikut:

Hipotesis:

$H_0 : \rho_1 = \rho_2 = \dots = \rho_{12} = 0$ (residual bersifat *white noise*)

$H_1 : \text{minimal ada satu } \rho_i \neq 0 \text{ untuk } i = 1,2,3, \dots, 12$ (residual tidak bersifat *white noise*)

Statistik uji:

Dengan menggunakan persamaan (2.3) maka didapatkan:

$$Q = n(n+2) \sum_{k=1}^{12} \frac{\hat{\rho}_k^2}{n-k}, \quad n > k$$

$$Q = 96(98) \left(\frac{(0,0508)^2}{96-1} + \frac{(-0,0546)^2}{96-2} + \frac{(-0,0160)^2}{96-3} \right. \\ \left. + \frac{(-0,0667)^2}{96-4} + \frac{(-0,1123)^2}{96-5} + \frac{(0,1178)^2}{96-6} \right. \\ \left. + \frac{(0,0405)^2}{96-7} + \frac{(-0,0143)^2}{96-8} + \frac{(0,0144)^2}{96-9} \right. \\ \left. + \frac{(0,0672)^2}{96-10} + \frac{(-0,0185)^2}{96-11} + \frac{(-0,0790)^2}{96-12} \right)$$

$$Q = 5,245587$$

Dengan tabel distribusi Chi-Square diperoleh:

$$X_{(0,05; 12-0-1)}^2 = X_{(0,05;11)}^2 = 19.675$$

Kriteria Pengujian:

Karena $Q < X_{(0,05;9)}^2$, maka H_0 diterima yang berarti bahwa residual bersifat *white noise*.

Pengujian residual bersifat *white noise* dengan menggunakan SAS dapat dilihat pada Lampiran 9.

Selanjutnya pengujian asumsi residual berdistribusi normal dengan menggunakan uji Kolmogorov-Smirnov sebagai berikut:

Hipotesis:

$H_0: F(x) = F_0(x)$ untuk semua x (residual berdistribusi normal)

$H_1: F(x) \neq F_0(x)$ untuk beberapa x (residual tidak berdistribusi normal)

Statistik uji:

Dengan menggunakan persamaan (2.4) maka didapatkan,

$$\begin{aligned} D_{hitung} &= \sup_x |S(x) - F_0(x)| \\ &= 0,079804 \end{aligned}$$

Dengan tabel Kolmogorov-Smirnov diperoleh:

$$D_{0,05;96} = 0,138507$$

Kriteria pengujian:

Karena $D_{hitung} < D_{\alpha,n}$, maka H_0 diterima yang artinya residual berdistribusi normal.

Pengujian residual berdistribusi normal dengan menggunakan SAS dapat dilihat pada Lampiran 13.

Tahap selanjutnya adalah proses *overfitting*. Model yang dihasilkan dari proses *overfitting* akan dijadikan model alternatif yang kemudian dicari model yang terbaik. Untuk memilih satu model terbaik maka dipilih model ARIMA yang memenuhi uji parameter signifikan, residualnya bersifat *white noise* dan berdistribusi normal. Hasil pengujian signifikansi parameter model dan uji asumsi residual dapat dilihat pada Tabel 4.3.

Dari Tabel 4.3 dapat diketahui model ARIMA (0,1,[23]) memiliki parameter signifikan dan residual bersifat *white noise* dan normal.

Tabel 4. 3 Uji Signifikan Parameter dan Diagnostik Residual pada Model ARIMA Tenor 1 Tahun

Model	Uji Parameter Signifikan		Uji <i>White noise</i>	Uji Normalitas
ARIMA (0,1,[23])	MA (23)	Ya	Ya	Ya
ARIMA ([23],1,[23])	AR (23)	Tidak	Ya	Ya
	MA(23)	Tidak		

Selanjutnya akan dilakukan pemeriksaan nilai MAPE pada model yang memenuhi uji signifikan parameter, uji *white noise*, dan uji normalitas.

Tabel 4. 4 MAPE Model ARIMA Tenor 1 Tahun

Model	MAPE
ARIMA ([23],1,0)	7,2536
ARIMA (0,1,[23])	5,7396

Dari Tabel 4.4 terlihat bahwa model ARIMA (0,1,[23]) memenuhi semua asumsi dan mempunyai nilai MAPE terkecil. Sehingga dapat disimpulkan bahwa model terbaik untuk peramalan *yield* tenor 1 tahun adalah ARIMA (0,1,[23]). Dengan menggunakan Persamaan (2.1) diperoleh persamaan model peramalan *yield* tenor 1 tahun adalah sebagai berikut:

$$Y_{1(t)} = Y_{t-1} + \theta_{23}e_{t-23} + e_t \quad (4.1)$$

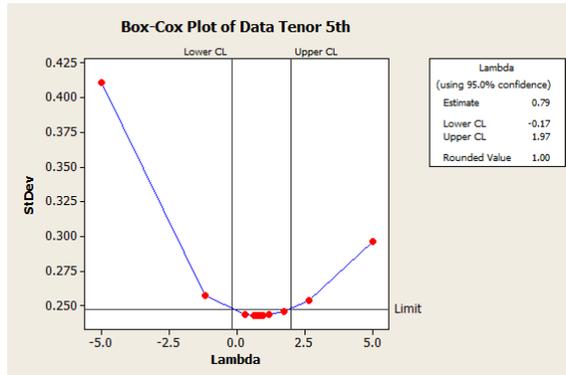
Kemudian akan dicari nilai parameter θ_{23} menggunakan metode Kalman Filter dengan tujuan untuk memperkecil *noise* pada model ARIMA dan selanjutnya akan dilakukan peramalan *yield* tenor 1 tahun selama 3 bulan kedepan.

4.2.2 Yield Tenor 5 Tahun

Langkah-langkah perumusan model ARIMA pada *Yield* Tenor 5 Tahun akan dijelaskan sebagai berikut.

1. Identifikasi Model ARIMA

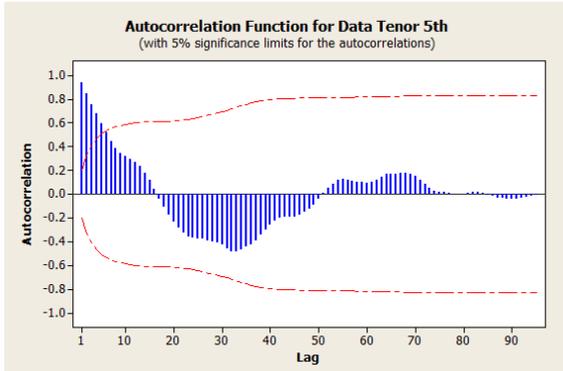
Langkah awal dalam merumuskan model ARIMA adalah dengan identifikasi stasioneritas baik secara varian maupun rata-rata terhadap data *yield* tenor 5 tahun. Untuk kestasioneran dalam varian dapat dilihat pada transformasi Box-Cox dimana dikatakan stasioner jika *rounded value*-nya adalah 1. Plot Transformasi Box-Cox dari data *yield* tenor 5 tahun dapat dilihat pada Gambar 4.6



Gambar 4. 6 Box – Cox Data Tenor 5 Tahun

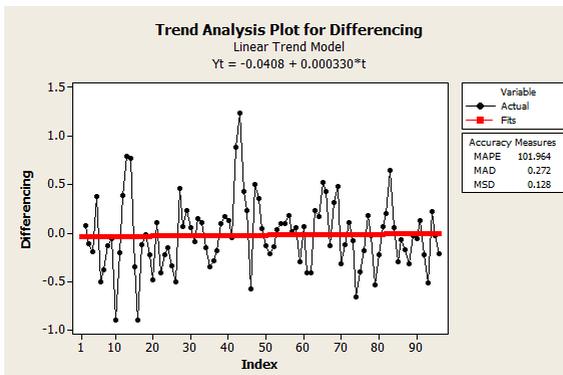
Gambar 4.6 menunjukkan nilai λ dengan nilai kepercayaan 95% berada diantara $-0,17$ dan $1,97$, dengan nilai *estimate* sebesar $0,79$ dan *rounded value* sebesar $1,00$. Hal ini menunjukkan bahwa data sudah stasioner terhadap varian karena nilai *rounded value*-nya sama dengan 1.

Setelah data stasioner dalam varians maka akan dilihat apakah data sudah stasioner dalam rata-rata dapat dilihat dari plot ACF dari data yang sudah stasioner dalam rata-rata pada Gambar 4.7. Dari Gambar 4.7 dapat dilihat bahwa plot ACF memiliki pola *dies down* atau bisa dikatakan mengikuti gelombang sinus. Dapat dilihat juga bahwa masih banyak *lag* yang keluar dari garis merah putus-putus (*significance limit*) dan diduga masih belum stasioner terhadap *mean* sehingga perlu dilakukan proses *differencing*.



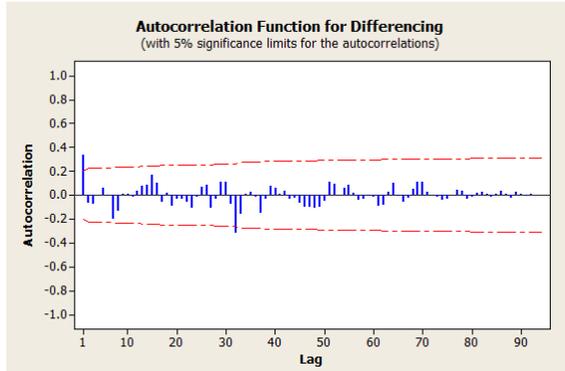
Gambar 4. 7 Plot ACF Data Tenor 5 Tahun

Plot *trend* analysis data *yield* setelah proses differencing dapat dilihat pada Gambar 4.8. Pada plot *trend* analysis terlihat bahwa plot berfluktuasi di sekitar nilai tengah dan mendekati sumbu horizontal yang berarti bahwa data sudah stasioner dalam varian maupun rata-rata.

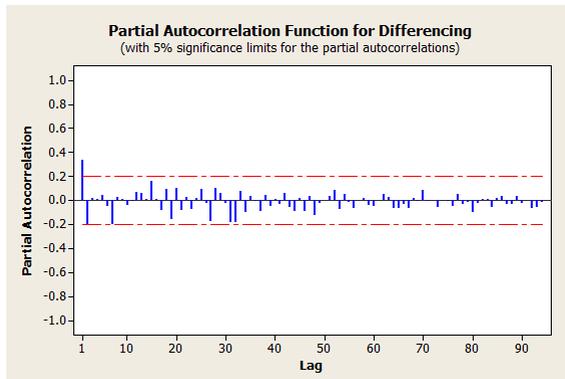


Gambar 4. 8 Plot Trend Analysis Data Differencing

Langkah selanjutnya adalah identifikasi model ARIMA dari data yang sudah stasioner dalam varian maupun rata-rata melalui identifikasi plot ACF dan PACF. Plot ACF dapat dilihat pada Gambar 4.9 dan plot PACF dapat dilihat pada Gambar 4.10.



Gambar 4. 9 Plot ACF Differencing



Gambar 4. 10 Plot PACF Differencing

Hasil identifikasi terlihat bahwa plot ACF keluar pada *lag* ke-1 dan *lag* ke-32 sedangkan plot PACF keluar pada *lag* ke-1. Sehingga didapatkan dugaan model sementara untuk data *yield* tenor 5 tahun adalah ARIMA (1,1,[1,32]).

2. Penaksiran dan Pengujian Parameter

Selanjutnya dilakukan estimasi parameter menggunakan metode *Maximum Likelihood* dengan software SAS seperti pada Lampiran 3. Hasil estimasi ditunjukkan pada Tabel 4.5.

Tabel 4. 5 Estimasi Parameter Model ARIMA (1,1,[1,32])

Parameter	Koefisien	SE	t-stat	P-value
AR(1)	0,27	0,2242	1,20	0,2284
MA(1)	-0,0694	0,2367	-0,29	0,7692
MA(32)	0,4020	0,1474	2,73	0,0064

Langkah selanjutnya adalah uji signifikansi parameter model ARIMA ([1,1,[1,32]) dengan menggunakan uji-t untuk melihat kesesuaian dengan data yang ada seperti berikut:

Uji Parameter AR (1)

Hipotesis:

$H_0 : \phi_1 = 0$ (parameter ϕ_1 tidak signifikan)

$H_1 : \phi_1 \neq 0$ (parameter ϕ_1 signifikan)

Statistik uji:

Dengan menggunakan persamaan (2.2) maka didapatkan,

$$\begin{aligned} t_{hitung} &= \frac{\hat{\phi}_1}{SE(\hat{\phi}_1)} \\ &= \frac{0,27}{0,2242} \\ &= 1,20 \end{aligned}$$

Dengan tabel distribusi t diperoleh:

$$t_{tabel} = t_{0,025;96} = 1,960$$

Kriteria pengujian:

Karena $|t_{hitung}| < t_{tabel}$, maka H_0 diterima yang artinya parameter model tidak signifikan

Uji Parameter MA (1)

Hipotesis:

$H_0 : \theta_1 = 0$ (parameter θ_1 tidak signifikan)

$H_1 : \theta_1 \neq 0$ (parameter θ_1 signifikan)

Statistik uji:

Dengan menggunakan persamaan (2.2) maka didapatkan,

$$\begin{aligned}
 t_{hitung} &= \frac{\hat{\theta}_1}{SE(\theta_1)} \\
 &= \frac{-0,0694}{0,2367} \\
 &= -0,29
 \end{aligned}$$

Dengan tabel distribusi t diperoleh:

$$t_{tabel} = t_{0,025;96} = 1,960$$

Kriteria pengujian:

Karena $|t_{hitung}| < t_{tabel}$, maka H_0 diterima yang artinya parameter model tidak signifikan

Uji Parameter MA (32)

Hipotesis:

$H_0 : \theta_{32} = 0$ (parameter θ_{32} tidak signifikan)

$H_1 : \theta_{32} \neq 0$ (parameter θ_{32} signifikan)

Statistik uji:

Dengan menggunakan persamaan (2.2) maka didapatkan,

$$\begin{aligned}
 t_{hitung} &= \frac{\hat{\theta}_{32}}{SE(\theta_{32})} \\
 &= \frac{0,4020}{0,1474} \\
 &= 2,73
 \end{aligned}$$

Dengan tabel distribusi t diperoleh:

$$t_{tabel} = t_{0,025;96} = 1,960$$

Kriteria pengujian:

Karena $|t_{hitung}| > t_{tabel}$, maka H_0 ditolak yang artinya parameter model signifikan.

Berdasarkan hasil uji signifikansi parameter pada model ARIMA (1,1,[1,32]) menunjukkan parameter MA(32) signifikan namun parameter AR(1) dan MA(1) tidak signifikan. Karena model ARIMA (1,1,[1,32]) tidak memenuhi uji signifikansi parameter maka tahap pengujian residual white noise dan residual berdistribusi normal tidak perlu dilakukan.

Tahap selanjutnya adalah proses *overfitting*. Model yang dihasilkan dari proses *overfitting* akan dijadikan model alternatif yang kemudian dicari model yang terbaik. Untuk memilih satu model terbaik maka dipilih model ARIMA yang memenuhi uji parameter signifikan, residualnya bersifat *white noise* dan berdistribusi normal. Hasil pengujian signifikansi parameter model dan uji asumsi residual dapat dilihat pada Lampiran 2.

Dari Lampiran 2 dapat diketahui model ARIMA(0,1,[1,32]), ARIMA (0,1,1), ARIMA (1,1,[32]), ARIMA (1,1,0), ARIMA ([1,32],1,0), dan ARIMA([32],1,1) memiliki parameter signifikan dan residualnya bersifat *white noise* dan normal. Selanjutnya akan dilakukan pemeriksaan nilai MAPE pada model yang memenuhi uji signifikan parameter, uji *white noise*, dan uji normalitas.

Dari Tabel 4.6 terlihat bahwa model ARIMA (0,1,[1,32]) memenuhi semua asumsi dan mempunyai nilai MAPE terkecil. Sehingga dapat disimpulkan bahwa model terbaik untuk peramalan *yield* tenor 5 tahun adalah ARIMA (0,1,[1,32]).

Tabel 4. 6 MAPE Model ARIMA Tenor 5 Tahun

Model	MAPE
ARIMA (0,1,[1,32])	2,585
ARIMA (0,1,1)	2,9482
ARIMA (1,1,32)	4,0393
ARIMA (1,1,0)	2,8684
ARIMA ([1,32],1,0)	5,7147
ARIMA (32,1,1)	4,4601

Dengan menggunakan Persamaan (2.1) diperoleh persamaan model peramalan *yield* tenor 5 tahun adalah sebagai berikut:

$$Y_{5(t)} = Y_{t-1} + \theta_1 e_{t-1} + \theta_{32} e_{t-32} + e_t \quad (4.2)$$

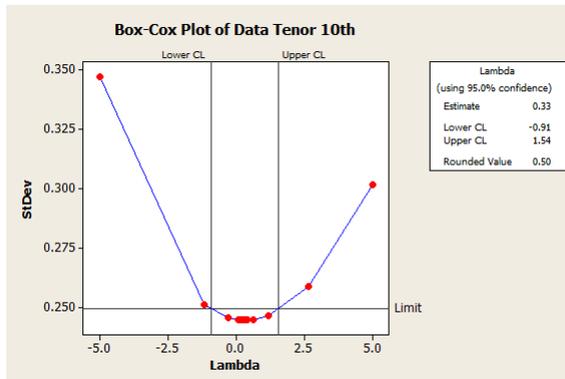
Kemudian akan dicari nilai parameter θ_1 dan θ_{32} menggunakan metode Kalman Filter dengan tujuan untuk memperkecil *noise* pada model ARIMA dan selanjutnya akan dilakukan peramalan *yield* tenor 5 tahun selama 3 bulan kedepan.

4.2.3 Yield Tenor 10 Tahun

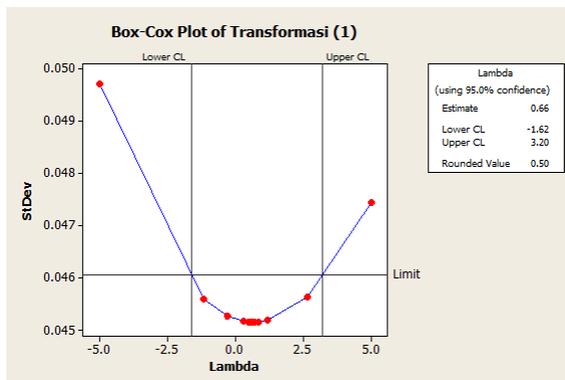
Langkah-langkah perumusan model ARIMA pada *Yield* Tenor 10 Tahun akan dijelaskan sebagai berikut.

1. Identifikasi Model ARIMA

Langkah awal dalam merumuskan model ARIMA adalah dengan identifikasi stasioneritas baik secara varian maupun rata-rata terhadap data *yield* tenor 10 tahun. Untuk kestasioneran dalam varian dapat dilihat pada transformasi Box – Cox dimana dikatakan stasioner jika *rounded value*-nya adalah 1. Plot Transformasi Box-Cox dari data *yield* tenor 10 tahun dapat dilihat pada Gambar 4.11

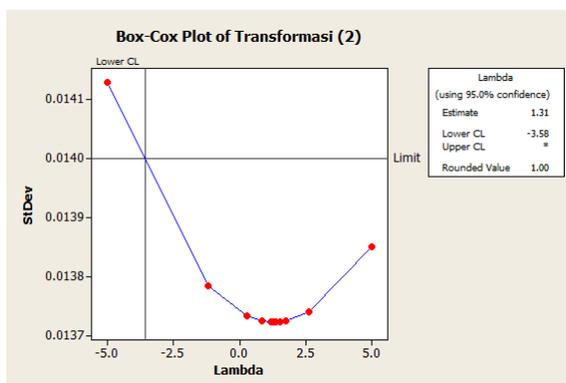


Gambar 4. 11 Box – Cox Data Tenor 10 Tahun

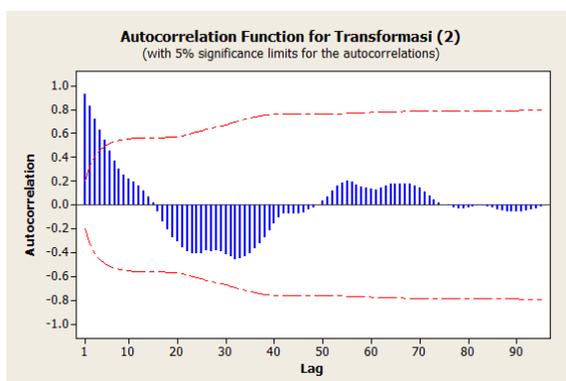


Gambar 4. 12 Box – Cox Data Transformasi (1)

Gambar 4.11 menunjukkan nilai λ dengan nilai kepercayaan 95% berada diantara $-0,91$ dan $1,54$, dengan nilai *estimate* sebesar $0,33$ dan *rounded value* sebesar $0,50$. Hal ini menunjukkan bahwa data belum stasioner terhadap varian karena nilai *rounded value*-nya tidak sama dengan 1. Oleh karena itu perlu dilakukan proses transformasi. Pada Gambar 4.12 terlihat terlihat *rounded value* belum bernilai 1 maka perlu dilakukan transformasi kembali. Pada Gambar 4.13 terlihat bahwa *rounded value* sama dengan 1 sehingga menunjukkan bahwa data sudah stasioner terhadap varian.

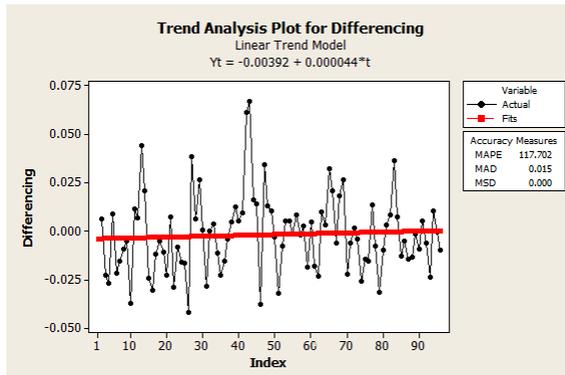


Gambar 4. 13 Box – Cox Data Transformasi (2)

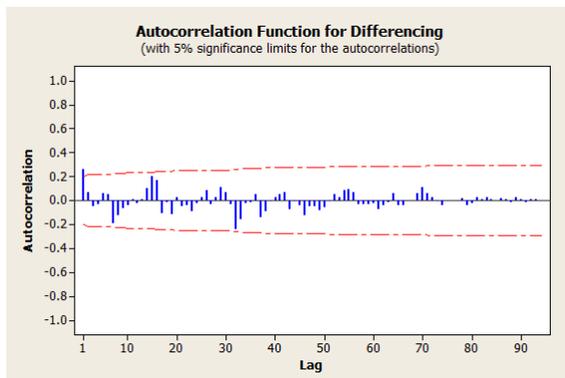


Gambar 4. 14 Plot ACF Transformasi (2)

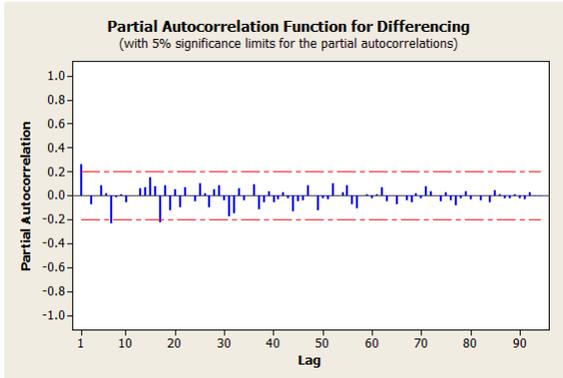
Setelah data stasioner dalam varian maka akan dilihat apakah data sudah stasioner dalam rata-rata dapat dilihat dari plot ACF dari data yang sudah stasioner dalam varians pada Gambar 4.14. Dari plot ACF dapat dilihat bahwa plot ACF memiliki pola *dies down* atau bisa dikatakan mengikuti gelombang sinus. Dapat dilihat juga bahwa masih banyak *lag* yang keluar dari garis merah putus-putus (*significance limit*) dan diduga masih belum stasioner terhadap *mean* sehingga perlu dilakukan proses *differencing*.



Gambar 4. 15 Plot Trend Analysis Data Differencing



Gambar 4. 16 Plot ACF Differencing



Gambar 4. 17 Plot PACF Differencing

Plot *trend* analysis data *yield* setelah proses *differencing* dapat dilihat pada Gambar 4.3. Pada plot *trend* analysis terlihat bahwa plot berfluktuasi di mendekati sumbu horizontal yang berarti bahwa data sudah stasioner dalam varian maupun rata-rata.

Langkah selanjutnya adalah identifikasi model ARIMA dari data yang sudah stasioner dalam varian maupun rata-rata melalui identifikasi plot ACF dan PACF. Plot ACF dapat dilihat pada Gambar 4.16 dan plot PACF dapat dilihat pada Gambar 4.17. Hasil identifikasi terlihat bahwa plot ACF keluar pada *lag* ke-1 sedangkan plot PACF keluar pada *lag* ke-1, *lag* ke-7, dan *lag* ke-17. Sehingga didapatkan dugaan model sementara untuk data *yield* tenor 10 tahun adalah ARIMA ([1,7,17],1,1).

2. Penaksiran dan Pengujian Parameter

Selanjutnya dilakukan estimasi parameter menggunakan metode *Maximum Likelihood* dengan software SAS seperti pada lampiran 7. Hasil estimasi ditunjukkan pada Tabel 4.7

Tabel 4. 7 Estimasi Parameter Model ARIMA ([1,7,17],1,1)

Parameter	Koefisien	SE	t-stat	P-value
AR(1)	0,34470	0,26686	1,29	0,1965
AR(7)	-0,20315	0,09773	-2,08	0,0376
AR(17)	-0,16951	0,09979	-1,70	0,0894
MA(1)	0,05932	0,29561	0,20	0,8409

Langkah selanjutnya adalah uji signifikansi parameter model ARIMA $([1,7,17],1,1)$ dengan menggunakan uji- t untuk melihat kesesuaian dengan data yang ada seperti berikut:

Uji Parameter AR (1)

Hipotesis:

$H_0 : \phi_1 = 0$ (parameter ϕ_1 tidak signifikan)

$H_1 : \phi_1 \neq 0$ (parameter ϕ_1 signifikan)

Statistik uji:

Dengan menggunakan persamaan (2.2) maka didapatkan,

$$\begin{aligned} t_{hitung} &= \frac{\hat{\phi}_1}{SE(\hat{\phi}_1)} \\ &= \frac{0,34470}{0,26686} \\ &= 1,29 \end{aligned}$$

Dengan tabel distribusi t diperoleh:

$$t_{tabel} = t_{0,025;96} = 1,960$$

Kriteria pengujian:

Karena $|t_{hitung}| < t_{tabel}$ maka H_0 diterima yang artinya parameter model tidak signifikan

Uji Parameter AR (7)

Hipotesis:

$H_0 : \phi_7 = 0$ (parameter ϕ_7 tidak signifikan)

$H_1 : \phi_7 \neq 0$ (parameter ϕ_7 signifikan)

Statistik uji:

Dengan menggunakan persamaan (2.2) maka didapatkan,

$$\begin{aligned} t_{hitung} &= \frac{\hat{\phi}_7}{SE(\hat{\phi}_7)} \\ &= \frac{-0,20315}{0,09773} \\ &= -2,08 \end{aligned}$$

Dengan tabel distribusi t diperoleh:

$$t_{tabel} = t_{0,025;96} = 1,960$$

Kriteria pengujian:

Karena $|t_{hitung}| > t_{tabel}$ maka H_0 diterima yang artinya parameter model signifikan

Uji Parameter AR (17)

Hipotesis:

$H_0 : \phi_{17} = 0$ (parameter ϕ_{17} tidak signifikan)

$H_1 : \phi_{17} \neq 0$ (parameter ϕ_{17} signifikan)

Statistik uji:

Dengan menggunakan persamaan (2.2) maka didapatkan,

$$\begin{aligned} t_{hitung} &= \frac{\hat{\phi}_{17}}{SE(\hat{\phi}_{17})} \\ &= \frac{-0,16951}{0,09979} \\ &= -1,70 \end{aligned}$$

Dengan tabel distribusi t diperoleh:

$$t_{tabel} = t_{0,025;96} = 1,960$$

Kriteria pengujian:

Karena $|t_{hitung}| < t_{tabel}$ maka H_0 diterima yang artinya parameter model tidak signifikan

Uji Parameter MA (1)

Hipotesis:

$H_0 : \theta_1 = 0$ (parameter θ_1 tidak signifikan)

$H_1 : \theta_1 \neq 0$ (parameter θ_1 signifikan)

Statistik uji:

Dengan menggunakan persamaan (2.2) maka didapatkan,

$$\begin{aligned} t_{hitung} &= \frac{\hat{\theta}_1}{SE(\hat{\theta}_1)} \\ &= \frac{0,05932}{0,29561} \\ &= 0,20 \end{aligned}$$

Dengan tabel distribusi t diperoleh:

$$t_{tabel} = t_{0,025;96} = 1,960$$

Kriteria pengujian:

Karena $|t_{hitung}| < t_{tabel}$ maka H_0 ditolak yang artinya parameter model tidak signifikan

Berdasarkan hasil uji signifikansi parameter pada model ARIMA ([1,7,17],1,1) menunjukkan parameter AR(7) signifikan namun pada parameter AR(1), AR(17), dan MA(1) tidak signifikan. Karena model ARIMA ([1,7,17],1,1) tidak memenuhi uji signifikansi parameter maka tahap pengujian residual white noise dan residual berdistribusi normal tidak perlu dilakukan.

Tahap selanjutnya adalah proses *overfitting*. Model yang dihasilkan dari proses *overfitting* akan dijadikan model alternatif yang kemudian dicari model yang terbaik. Untuk memilih satu model terbaik maka dipilih model ARIMA yang memenuhi uji parameter signifikan, residualnya bersifat *white noise* dan berdistribusi normal. Hasil pengujian signifikansi parameter model dan uji asumsi residual dapat dilihat pada Lampiran 3.

Dari Lampiran 3 dapat diketahui model ARIMA([1,7],1,0), ARIMA(0,1,1), dan ARIMA(1,1,[7,17]) memiliki parameter signifikan. Selanjutnya akan dilakukan pemeriksaan nilai MAPE pada model yang memenuhi uji signifikan parameter, uji *white noise*, dan uji normalitas.

Tabel 4. 8 MAPE Model ARIMA Tenor 10 Tahun

Model	MAPE
ARIMA ([1,7],1,0)	0,8050
ARIMA (0,1,1)	0,7918
ARIMA (1,1,[7,17])	0,8470

Dari Tabel 4.8 terlihat bahwa model ARIMA (0,1,1) memenuhi semua asumsi dan mempunyai nilai MAPE terkecil. Sehingga dapat disimpulkan bahwa model terbaik untuk peramalan *yield* tenor 10 tahun adalah ARIMA (0,1,1). Dengan menggunakan Persamaan (2.1) diperoleh persamaan model peramalan *yield* tenor 10 tahun adalah sebagai berikut:

$$Y_{10(t)} = Y_{t-1}^* + \theta_1 e_{t-1} + e_t \text{ dimana } Y_t^* = Y_t^{0,25} \quad (4.3)$$

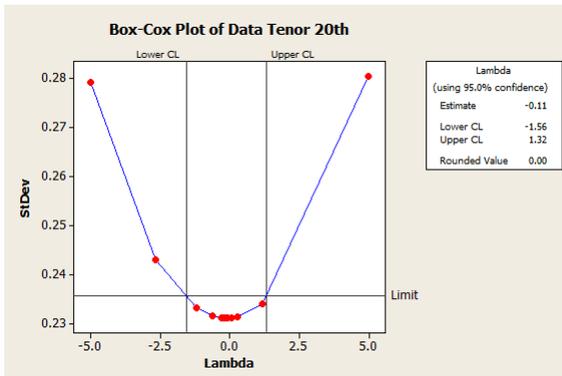
Kemudian akan dicari nilai parameter θ_1 menggunakan metode Kalman Filter dengan tujuan untuk memperkecil *noise* pada model ARIMA dan selanjutnya akan dilakukan peramalan *yield* tenor 10 tahun selama 3 bulan kedepan

4.2.4 *Yield* Tenor 20 Tahun

Langkah-langkah perumusan model ARIMA pada *Yield* Tenor 1 Tahun akan dijelaskan sebagai berikut.

1. Identifikasi Model ARIMA

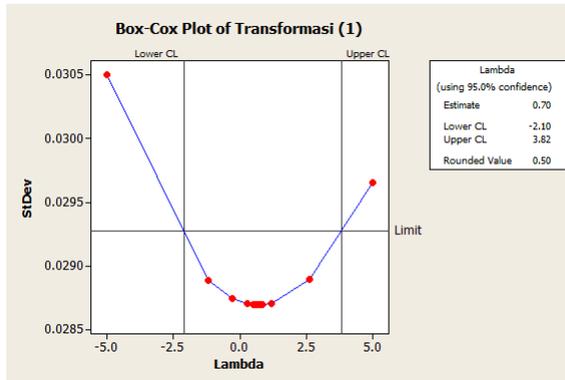
Langkah awal dalam merumuskan model ARIMA adalah dengan identifikasi stasioneritas baik secara varian maupun rata-rata terhadap data *yield* tenor 20 tahun. Untuk kestasioneran dalam varian dapat dilihat pada transformasi Box-Cox dimana dikatakan stasioner jika *rounded value*-nya adalah 1. Plot Transformasi Box-Cox dari data *yield* tenor 20 tahun dapat dilihat pada Gambar 4.18



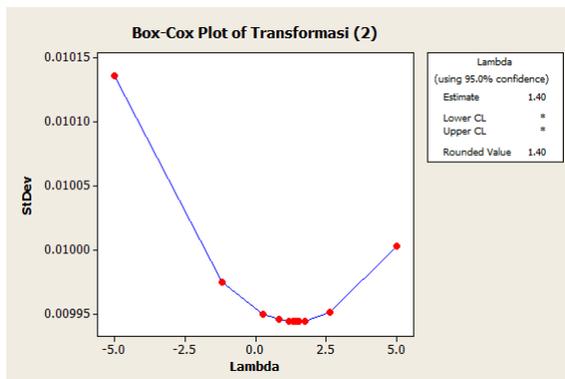
Gambar 4. 18 Box – Cox Data Tenor 20 Tahun

Gambar 4.18 menunjukkan nilai λ dengan nilai kepercayaan 95% berada diantara $-1,56$ dan $1,32$, dengan nilai *estimate* sebesar $-0,11$ dan *rounded value* sebesar $1,00$. Hal ini menunjukkan bahwa data belum stasioner terhadap varian karena nilai *rounded value*-nya tidak sama dengan 1. Oleh karena itu perlu dilakukan proses transformasi.

Pada Gambar 4.19 dan Gambar 4.20 terlihat terlihat *rounded value* belum bernilai 1 maka perlu dilakukan transformasi kembali. Pada Gambar 4.21 terlihat bahwa *rounded value* sama dengan 1 sehingga menunjukkan bahwa data sudah stasioner terhadap varian.

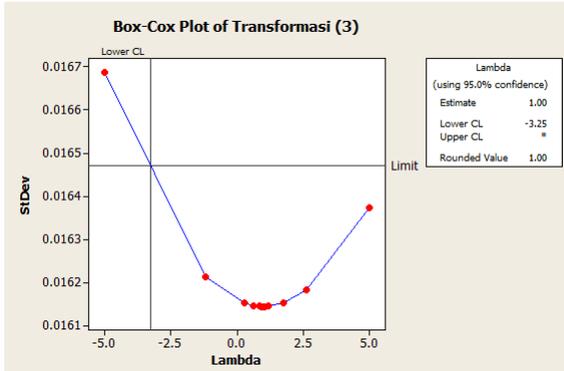


Gambar 4. 19 Box – Cox Transformasi (1)



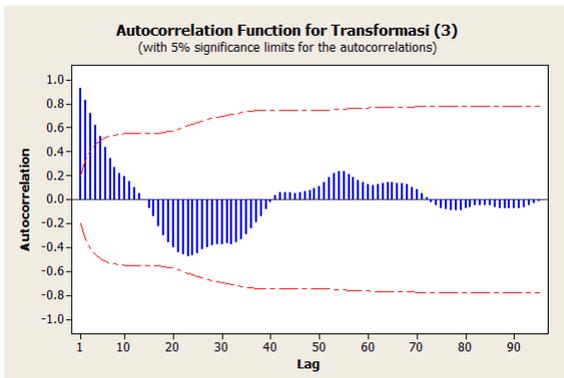
Gambar 4. 20 Box – Cox Transformasi (2)

Setelah data stasioner dalam varians maka akan dilihat apakah data sudah stasioner dalam rata-rata dapat dilihat dari plot ACF dari data yang sudah stasioner dalam varians pada Gambar 4.22.

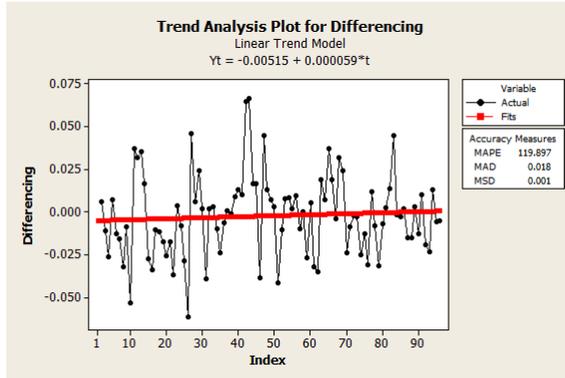


Gambar 4. 21 Box – Cox Transformasi (3)

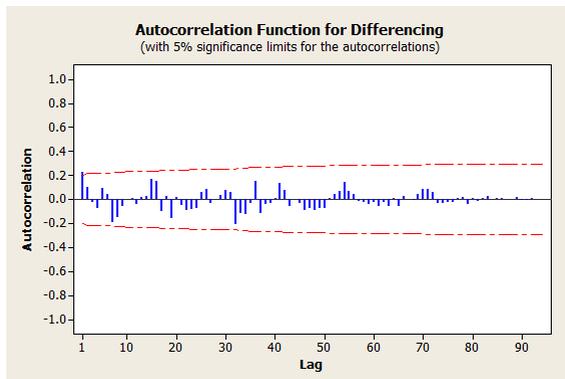
Dari Gambar 4.22 dapat dilihat bahwa plot ACF memiliki pola *dies down* atau bisa dikatakan mengikuti gelombang sinus. Dapat dilihat juga bahwa masih banyak *lag* yang keluar dari garis merah putus-putus (*significance limit*) dan diduga masih belum stasioner terhadap *mean* sehingga perlu dilakukan proses *differencing*. Pada Gambar 4.23 terlihat bahwa plot *trend analysis* berfluktuasi di sekitar nilai tengah dan mendekati sumbu horizontal yang berarti bahwa data sudah stasioner dalam varian maupun rata-rata.



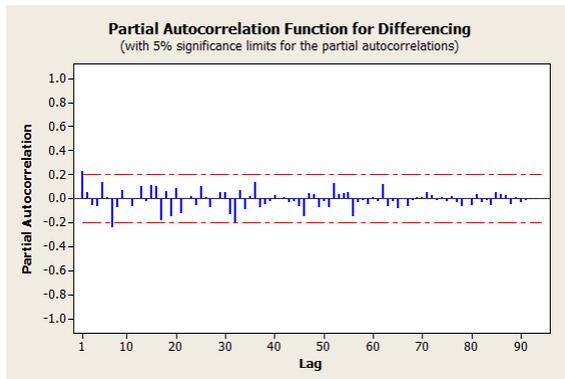
Gambar 4. 22 Plot ACF Data Transformasi (3)



Gambar 4. 23 Plot Trend Analysis Data Differencing



Gambar 4. 24 Plot ACF Differencing



Gambar 4. 25 Plot PACF Differencing

Langkah selanjutnya adalah identifikasi model ARIMA dari data yang sudah stasioner dalam varian maupun rata-rata melalui identifikasi plot ACF dan PACF. Plot ACF dapat dilihat pada Gambar 4.24 dan plot PACF dapat dilihat pada Gambar 4.25. Hasil identifikasi terlihat bahwa plot ACF keluar pada *lag* ke-1 sedangkan plot PACF keluar pada *lag* ke-1 dan ke-7. Sehingga didapatkan dugaan model sementara untuk data *yield* tenor 20 tahun adalah ARIMA([1,7],1,1).

2. Penaksiran dan Pengujian Parameter

Selanjutnya dilakukan estimasi parameter menggunakan metode *Maximum Likelihood* dengan software SAS seperti pada lampiran 8. Hasil estimasi ditunjukkan pada Tabel 4.19

Tabel 4. 9 *Estimasi Parameter Model ARIMA ([1,7],1,1)*

Parameter	Koefisien	SE	t-stat	P-value
AR(1)	0,412171	0,30154	1,37	0,1711
AR(7)	-0,19331	0,09704	-1,99	0,0464
MA(1)	0,20030	0,33435	0,60	0,5491

Langkah selanjutnya adalah uji signifikansi parameter model ARIMA([1,7],1,1) dengan menggunakan uji-t untuk melihat kesesuaian dengan data yang ada seperti berikut:

Uji Parameter AR (1)

Hipotesis:

$H_0 : \phi_1 = 0$ (parameter ϕ_1 tidak signifikan)

$H_1 : \phi_1 \neq 0$ (parameter ϕ_1 signifikan)

Statistik uji:

Dengan menggunakan persamaan (2.2) maka didapatkan,

$$\begin{aligned}
 t_{hitung} &= \frac{\hat{\phi}_1}{SE(\hat{\phi}_1)} \\
 &= \frac{0,412171}{0,30154} \\
 &= 1,37
 \end{aligned}$$

Dengan tabel distribusi t diperoleh:

$$t_{tabel} = t_{0,025;96} = 1,960$$

Kriteria pengujian:

Karena $|t_{hitung}| < t_{tabel}$, maka H_0 diterima yang artinya parameter model tidak signifikan

Uji Parameter AR (7)

Hipotesis:

$H_0 : \phi_7 = 0$ (parameter ϕ_7 tidak signifikan)

$H_1 : \phi_7 \neq 0$ (parameter ϕ_7 signifikan)

Statistik uji:

Dengan menggunakan persamaan (2.2) maka didapatkan,

$$\begin{aligned} t_{hitung} &= \frac{\hat{\phi}_7}{SE(\hat{\phi}_7)} \\ &= \frac{-0,19331}{0,09704} \\ &= -1,99 \end{aligned}$$

Dengan tabel distribusi t diperoleh:

$$t_{tabel} = t_{0,025;96} = 1,960$$

Kriteria pengujian:

Karena $|t_{hitung}| > t_{tabel}$ maka H_0 ditolak yang artinya parameter model signifikan

Uji Parameter MA (1)

Hipotesis:

$H_0 : \theta_1 = 0$ (parameter θ_1 tidak signifikan)

$H_1 : \theta_1 \neq 0$ (parameter θ_1 signifikan)

Statistik uji:

Dengan menggunakan persamaan (2.2) maka didapatkan,

$$\begin{aligned} t_{hitung} &= \frac{\hat{\theta}_1}{SE(\hat{\theta}_1)} \\ &= \frac{0,20030}{0,33435} \\ &= 0,60 \end{aligned}$$

Dengan tabel distribusi t diperoleh:

$$t_{tabel} = t_{0,025;94} = 1,960$$

Karena $|t_{hitung}| < t_{tabel}$ maka H_0 diterima yang artinya parameter model tidak tidak signifikan

Berdasarkan hasil uji signifikansi parameter pada model ARIMA ([1,7],1,1) menunjukkan parameter AR(7) signifikan namun parameter AR(1) dan MA(1) tidak signifikan. Karena model ARIMA ([1,7],1,1) tidak memenuhi uji signifikansi parameter maka tahap pengujian residual white noise dan residual berdistribusi normal tidak perlu dilakukan.

Tahap selanjutnya adalah proses *overfitting*. Model yang dihasilkan dari proses *overfitting* akan dijadikan model alternatif yang kemudian dicari model yang terbaik dengan memilih model ARIMA yang memenuhi uji parameter signifikan, residualnya bersifat *white noise* dan berdistribusi normal. Hasil pengujian signifikansi parameter model dan uji asumsi residual dapat dilihat pada Lampiran 4.

Dari Lampiran 4 dapat diketahui model ARIMA ([1,7],1,0) dan ARIMA(1,1,[7]) memiliki parameter signifikan . Selanjutnya akan dilakukan pemeriksaan nilai MAPE pada model yang memenuhi uji signifikan parameter, uji *white noise*, dan uji normalitas.

Tabel 4. 10 MAPE Model ARIMA Tenor 20 Tahun

Model	MAPE
ARIMA ([1,7],1,0)	0,8395
ARIMA (1,1,[7])	0,7977

Dari Tabel 4.10 terlihat bahwa model ARIMA (1,1,[7]) memenuhi semua asumsi dan mempunyai nilai MAPE terkecil. Sehingga dapat disimpulkan bahwa model terbaik untuk peramalan *yield* tenor 1 tahun adalah ARIMA (1,1,[7]). Dengan menggunakan Persamaan (2.1) diperoleh persamaan model peramalan *yield* tenor 20 tahun adalah sebagai berikut:

$$Y_{20(t)} = Y_{t-1}^* + \phi_1(Y_{t-1}^* - Y_{t-2}^*) - \theta_7 e_{t-7} + e_t$$

dimana $Y_t^* = (\ln Y_t)^{0,7}$ (4.4)

Kemudian akan dicari nilai parameter ϕ_1 dan θ_7 menggunakan metode Kalman Filter dengan tujuan untuk memperkecil *noise* pada model ARIMA dan selanjutnya akan dilakukan peramalan *yield* tenor 20 tahun selama 3 bulan kedepan

4.3 Estimasi Parameter dengan Kalman Filter

Pada tahap ini akan dilakukan penerapan Kalman Filter untuk mengestimasi parameter model ARIMA pada prediksi *yield* obligasi. Parameter *state* yang akan diestimasi adalah ϕ_t dan θ_t .

4.3.1 Yield Tenor 1 Tahun

Model ARIMA terbaik *yield* tenor 1 tahun yang akan digunakan pada penelitian ini adalah sebagai berikut (4.1):

$$Y_{1(t)} = Y_{t-1} - \theta_{23}e_{t-23} + e_t$$

Dengan koefisien θ_{23} adalah parameter yang akan diestimasi menggunakan Kalman Filter dan $Y_{1(t)}$ adalah nilai *yield*. Model ARIMA selanjutnya akan dikonstruksi ke dalam bentuk *state space* dengan state vektor $x(t) = [\theta_{23} \ Y_{1(t)}]^T$ dan akan diterapkan pada algoritma Kalman Filter sebagai berikut:

Nilai parameter θ_{23} bernilai konstan, maka:
 $(\theta_{23})_{t+1} = (\theta_{23})_t$

Sesuai dengan model ARIMA yang didapat, maka:
 $(Y_{1(t)})_{t+1} = (Y_{1(t)})_t - (\theta_{23}e_{t-23})_t + e_t$

Model sistem pada persamaan (2.6):

$$x_{t+1} = Ax_t + Bu_t + w_t$$

sehingga dapat dituliskan sebagai berikut:

$$\begin{bmatrix} \theta_{23} \\ Y_{1(t)} \end{bmatrix}_{t+1} = \begin{bmatrix} 1 & 0 \\ -e_{t-23} & 1 \end{bmatrix} \begin{bmatrix} \theta_{23} \\ Y_{1(t)} \end{bmatrix}_t + \begin{bmatrix} 0 \\ 1 \end{bmatrix} (e_t) + w_t$$

Model pengukuran pada persamaan (2.7):

$$z_t = H_t x_t + v_t$$

sehingga dapat dituliskan sebagai berikut:

$$z_t = Y_{1(t)} = [0 \ 1] \begin{bmatrix} \theta_{23} \\ Y_{1(t)} \end{bmatrix}_t + v_t$$

Setelah diperoleh model sistem dan pengukuran pada metode Kalman Filter, selanjutnya dilakukan tahap inisialisasi. Pada tahap inisialisasi akan diberikan nilai awal \hat{x}_0, Q, R, P_0 . Nilai awal θ_{23} diperoleh dari parameter model ARIMA menggunakan MLE sedangkan $Y_{1(t)}$ diperoleh dari nilai awal peramalan *yield* tenor 1 tahun. Untuk penambahan nilai *noise* model sistem (w_t) dan *noise* model pengukuran (v_t) dibangkitkan dari komputer melalui program Matlab.

Untuk nilai awal \hat{x}_0 dan P_0 diberikan sebagai berikut:

$$\hat{x}_0 = \begin{bmatrix} 0,2821 \\ 5,6076 \end{bmatrix}, P_0 = \begin{bmatrix} 0.001 & 0 \\ 0 & 0.1 \end{bmatrix}$$

Nilai awal variansi dari *noise* sistem Q_t dan *noise* pengukuran R_t diberikan sebagai berikut:

$$Q_t = \begin{bmatrix} Q & 0 \\ 0 & Q \end{bmatrix}, R_t = R$$

dimana $Q = 10^{-3}$ dan $R = 10^{-4}$

Selanjutnya masuk ke dalam tahap prediksi:

$$\hat{x}_{t+1}^- = A_t \hat{x}_t + B_t u_t$$

$$P_{t+1}^- = A_t P_t A_t^T + G_t Q_t G_t^T$$

Tahap selanjutnya adalah tahap koreksi. Pada tahap ini melibatkan Kalman gain sebagai berikut:

$$K_{t+1} = P_{t+1}^- H_{t+1}^T (H_{t+1} P_{t+1}^- H_{t+1}^T + R_{t+1})^{-1}$$

Lalu nilai \hat{x}_{t+1} diestimasi dengan menggunakan nilai \hat{x}_{t+1}^- yang diperoleh dari tahap prediksi.

$$\hat{x}_{t+1} = \hat{x}_{t+1}^- + K_{t+1} (z_{t+1} - H_{t+1} \hat{x}_{t+1}^-)$$

Kemudian, nilai P_{t+1} dicari menggunakan P_{t+1}^- yang telah dicari pada tahap prediksi.

$$P_{t+1} = (I - K_{t+1} H_{t+1}) P_{t+1}^-$$

Untuk proses simulasi estimasi parameter menggunakan Kalman Filter dilakukan dengan bantuan software Matlab. Hasil estimasi parameter model ARIMA pada *yield* tenor 1 tahun menggunakan Filter Kalman dapat dilihat pada Tabel 4.11

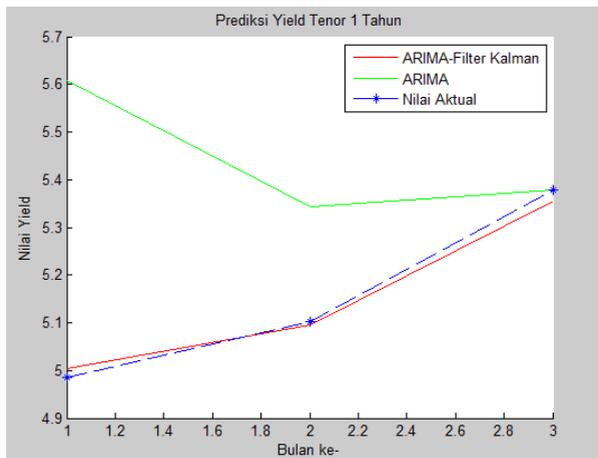
Tabel 4. 11 Hasil Estimasi Parameter Model ARIMA Tenor 1 Tahun Sebelum dan Sesudah menggunakan Kalman Filter

Faktor Pemanding		ARIMA	ARIMA-Kalman Filter
Koef	θ_{23}	0,2821	0,1996
Peramalan	$Y_{1(97)}$	5,6076	5,0038
	$Y_{1(98)}$	5,3424	5,0960
	$Y_{1(99)}$	5,3775	5,3545
MAPE		5,7393	0,3131

Parameter model ARIMA hasil estimasi Kalman Filter pada Tabel 4.11 disubstitusikan ke Persamaan (4.1), sehingga diperoleh persamaan model sabagai berikut:

$$Y_{1(t)} = Y_{t-1} - 0,1996 e_{t-23} + e_t$$

Dari hasil simulasi dilakukan prediksi *yield* tenor 1 tahun sebanyak 3 bulan kedepan. Perbandingan nilai aktual, hasil peramalan ARIMA dan hasil simulasi model ARIMA yang parameteranya diestimasi menggunakan Kalman Filter dapat dilihat pada Gambar 4.26



Gambar 4. 26 Hasil Simulasi Perbandingan ARIMA, ARIMA-Kalman Filter, dan Faktual

4.3.2 Yield Tenor 5 Tahun

Model ARIMA terbaik *yield* tenor 5 tahun yang akan digunakan pada penelitian ini adalah sebagai berikut:

$$Y_{5(t)} = Y_{t-1} - \theta_1 e_{t-1} - \theta_{32} e_{t-32} + e_t$$

Dengan koefisien θ_1 dan θ_{32} adalah parameter yang akan diestimasi menggunakan Kalman Filter dan $Y_{5(t)}$ adalah nilai *yield*. Model ARIMA selanjutnya akan dikonstruksi ke dalam bentuk *state space* dengan state vektor $x(t) = [\theta_1 \ \theta_{32} \ Y_{5(t)}]^T$ dan akan diterapkan pada algoritma Kalman Filter sebagai berikut:

Nilai parameter θ_1 dan θ_{32} bernilai konstan, maka:

$$(\theta_1)_{t+1} = (\theta_1)_t$$

$$(\theta_{32})_{t+1} = (\theta_{32})_t$$

Sesuai dengan model ARIMA yang didapat, maka:

$$(Y_{5(t)})_{t+1} = (Y_{5(t)})_t - (\theta_1 e_{t-1} + \theta_{32} e_{t-32})_t + e_t$$

Model sistem pada persamaan (2.6):

$$x_{t+1} = Ax_t + Bu_t + w_t$$

sehingga dapat dituliskan sebagai berikut:

$$\begin{bmatrix} \theta_1 \\ \theta_{32} \\ Y_{5(t)} \end{bmatrix}_{t+1} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ -e_{t-1} & -e_{t-32} & 1 \end{bmatrix} \begin{bmatrix} \theta_1 \\ \theta_{32} \\ Y_{5(t)} \end{bmatrix}_t + \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} (e_t) + w_t$$

Model pengukuran pada persamaan (2.7):

$$z_t = H_t x_t + v_t$$

sehingga dapat dituliskan sebagai berikut:

$$z_t = Y_{5(t)} = [0 \ 0 \ 1] \begin{bmatrix} \theta_1 \\ \theta_{32} \\ Y_t \end{bmatrix}_t$$

Setelah diperoleh model sistem dan pengukuran pada metode Kalman Filter, selanjutnya dilakukan tahap inisialisasi. Pada tahap inisialisasi akan diberikan nilai awal \hat{x}_0, Q, R, P_0 . Nilai awal θ_1 dan θ_7 diperoleh dari parameter model ARIMA menggunakan MLE sedangkan $Y_{5(t)}$ diambil nilai awal peramalan *yield* tenor 5 tahun. Untuk penambahan nilai *noise* model sistem (w_t) dan *noise* model

pengukuran (v_t) dibangkitkan dari komputer melalui program Matlab.

Untuk nilai awal \hat{x}_0 dan P_0 diberikan sebagai berikut:

$$\hat{x}_0 = \begin{bmatrix} -0,3376 \\ 0,3296 \\ 5,8025 \end{bmatrix}, P_0 = \begin{bmatrix} 0.001 & 0 & 0 \\ 0 & 0.001 & 0 \\ 0 & 0 & 0.1 \end{bmatrix}$$

Nilai awal variansi dari *noise* sistem Q_t dan *noise* pengukuran R_t diberikan sebagai berikut:

$$Q_t = \begin{bmatrix} Q & 0 & 0 \\ 0 & Q & 0 \\ 0 & 0 & Q \end{bmatrix}, R_t = R$$

dimana $Q = 10^{-3}$ dan $R = 10^{-4}$

Selanjutnya masuk ke dalam tahap prediksi:

$$\begin{aligned} \hat{x}_{t+1}^- &= A_t \hat{x}_t + B_t u_t \\ P_{t+1}^- &= A_t P_t A_t^T + G_t Q_t G_t^T \end{aligned}$$

Tahap selanjutnya adalah tahap koreksi. Pada tahap ini melibatkan Kalman gain sebagai berikut:

$$K_{t+1} = P_{t+1}^- H_{t+1}^T (H_{t+1} P_{t+1}^- H_{t+1}^T + R_{t+1})^{-1}$$

Lalu nilai \hat{x}_{t+1} diestimasi dengan menggunakan nilai \hat{x}_{t+1}^- yang diperoleh dari tahap prediksi.

$$\hat{x}_{t+1} = \hat{x}_{t+1}^- + K_{t+1} (z_{t+1} - H_{t+1} \hat{x}_{t+1}^-)$$

Kemudian, nilai P_{t+1} dicari menggunakan P_{t+1}^- yang telah dicari pada tahap prediksi.

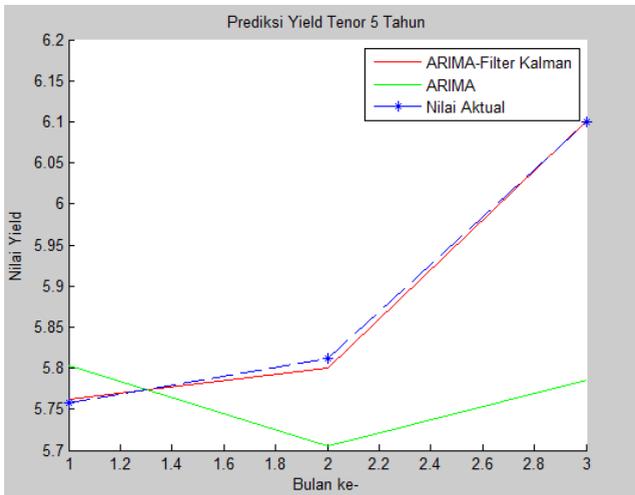
$$P_{t+1} = (I - K_{t+1} H_{t+1}) P_{t+1}^-$$

Untuk proses simulasi estimasi parameter menggunakan Kalman Filter dilakukan dengan software Matlab. Hasil estimasi parameter model ARIMA pada *yield* tenor 5 tahun menggunakan Filter Kalman dapat dilihat pada Tabel 4.12

Dari hasil simulasi dilakukan prediksi *yield* tenor 5 tahun sebanyak 3 bulan kedepan. Perbandingan nilai aktual, hasil peramalan ARIMA dan hasil simulasi model ARIMA yang parameternya diestimasi menggunakan Kalman Filter dapat dilihat pada Gambar 4.27

Tabel 4. 12 Hasil Estimasi Parameter Model ARIMA Tenor 5 Tahun Sebelum dan Sesudah menggunakan Kalman Filter

Faktor Perbandingan		ARIMA	ARIMA-Kalman Filter
Koef	θ_1	-0,3376	-0,9729
	θ_{32}	0,3296	0,2907
Peramalan	$Y_{1(97)}$	5,8025	5,7615
	$Y_{1(98)}$	5,7058	5,7996
	$Y_{1(99)}$	5,7853	6,1006
MAPE		2,5850	0,1019



Gambar 4. 27 Hasil Simulasi Perbandingan ARIMA, ARIMA-Kalman Filter, dan Faktual

Parameter model ARIMA hasil estimasi Kalman Filter pada Tabel 4.12 disubstitusikan ke Persamaan (4.2), sehingga diperoleh persamaan model sabagai berikut:

$$Y_{5(t)} = Y_{t-1} + 0,9729e_{t-1} - 0,2907e_{t-32} + e_t$$

4.3.3 Yield Tenor 10 Tahun

Model ARIMA terbaik *yield* tenor 10 tahun yang akan digunakan pada penelitian ini adalah sebagai berikut:

$$Y_{10(t)} = Y_{t-1} - \theta_1 e_{t-1} + e_t$$

Dengan koefisien θ_1 adalah parameter yang akan diestimasi menggunakan Kalman Filter dan $Y_{10(t)}$ adalah nilai *yield*. Model ARIMA selanjutnya akan dikonstruksi ke dalam bentuk *state space* dengan state vektor $x(t) = [\theta_1 \ Y_{10(t)}]^T$ dan akan diterapkan pada algoritma Kalman Filter sebagai berikut:

Nilai parameter θ_1 bernilai konstan, maka:

$$(\theta_1)_{t+1} = (\theta_1)_t$$

Sesuai dengan model ARIMA yang didapat, maka:

$$(Y_{10(t)})_{t+1} = (Y_{10(t)})_t - (\theta_1 e_{t-1})_t + e_t$$

Model sistem pada persamaan (2.6):

$$x_{t+1} = Ax_t + Bu_t + w_t$$

sehingga dapat dituliskan sebagai berikut:

$$\begin{bmatrix} \theta_1 \\ Y_{10(t)} \end{bmatrix}_{t+1} = \begin{bmatrix} 1 & 0 \\ -e_{t-1} & 1 \end{bmatrix} \begin{bmatrix} \theta_1 \\ Y_{10(t)} \end{bmatrix}_t + \begin{bmatrix} 0 \\ 1 \end{bmatrix} (e_t) + w_t$$

Model pengukuran pada persamaan (2.7):

$$z_t = H_t x_t + v_t$$

atau dapat juga ditulis:

$$z_t = Y_{10(t)} = [0 \ 1] \begin{bmatrix} \theta_1 \\ Y_t \end{bmatrix}_t$$

Setelah diperoleh model sistem dan pengukuran pada metode Kalman Filter, selanjutnya dilakukan tahap inisialisasi. Pada tahap inisialisasi akan diberikan nilai awal \hat{x}_0, Q, R, P_0 . Nilai awal θ_1 diperoleh dari koefisien parameter model ARIMA menggunakan MLE sedangkan $Y_{10(t)}$ diambil nilai awal peramalan *yield* tenor 10 tahun. Untuk penambahan nilai *noise* model sistem (w_t) dan *noise* model pengukuran (v_t) dibangkitkan dari komputer melalui program Matlab.

Untuk nilai awal \hat{x}_0 dan P_0 diberikan sebagai berikut:

$$\hat{x}_0 = \begin{bmatrix} -0,2343 \\ 1,5916 \end{bmatrix}, P_0 = \begin{bmatrix} 0,001 & 0 \\ 0 & 0,1 \end{bmatrix}$$

Nilai awal variansi dari *noise* sistem Q_t dan *noise* pengukuran R_t diberikan sebagai berikut:

$$Q_t = \begin{bmatrix} Q & 0 \\ 0 & Q \end{bmatrix}, R_t = R$$

dimana $Q = 10^{-3}$ dan $R = 10^{-4}$

Selanjutnya masuk ke dalam tahap prediksi:

$$\hat{x}_{t+1}^- = A_t \hat{x}_t + B_t u_t$$

$$P_{t+1}^- = A_t P_t A_t^T + G_t Q_t G_t^T$$

Tahap selanjutnya adalah tahap koreksi. Pada tahap ini melibatkan Kalman gain sebagai berikut:

$$K_{t+1} = P_{t+1}^- H_{t+1}^T (H_{t+1} P_{t+1}^- H_{t+1}^T + R_{t+1})^{-1}$$

Lalu nilai \hat{x}_{t+1} diestimasi dengan menggunakan nilai \hat{x}_{t+1}^- yang diperoleh dari tahap prediksi.

$$\hat{x}_{t+1} = \hat{x}_{t+1}^- + K_{t+1} (z_{t+1} - H_{t+1} \hat{x}_{t+1}^-)$$

Kemudian, nilai P_{t+1} dicari menggunakan P_{t+1}^- yang telah dicari pada tahap prediksi.

$$P_{t+1} = (I - K_{t+1} H_{t+1}) P_{t+1}^-$$

Untuk proses simulasi estimasi parameter menggunakan Kalman Filter dilakukan dengan software Matlab. Hasil estimasi parameter model ARIMA pada *yield* tenor 10 tahun menggunakan Filter Kalman dapat dilihat pada Tabel 4.13

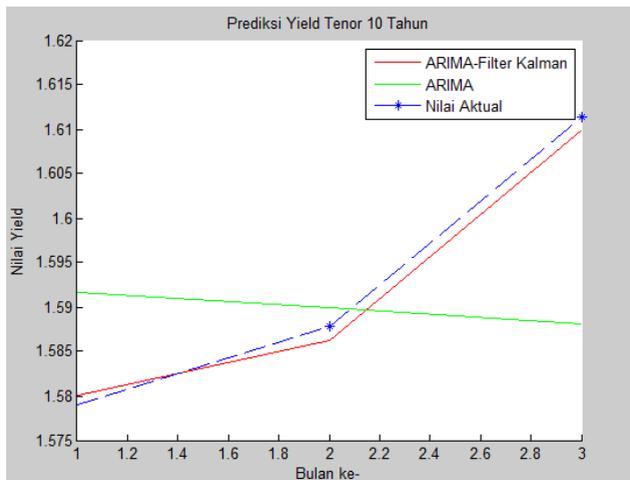
Dari hasil simulasi dilakukan prediksi *yield* tenor 10 tahun sebanyak 3 bulan kedepan. Perbandingan nilai aktual, hasil peramalan ARIMA dan hasil simulasi model ARIMA yang parameternya diestimasi menggunakan Kalman Filter dapat dilihat pada Gambar 4.28

Parameter model ARIMA hasil estimasi Kalman Filter pada Tabel 4.13 disubstitusikan ke Persamaan (4.3), sehingga diperoleh persamaan model sabagai berikut:

$$Y_{10(t)} = Y_{t-1} + 0,8565e_{t-1} + e_t$$

Tabel 4. 13 Hasil Estimasi Parameter Model ARIMA Tenor 10 Tahun Sebelum dan Sesudah menggunakan Kalman Filter

Faktor Pembanding		ARIMA	ARIMA-Filter Kalman
Koef	θ_1	-0,2343	-0,8565
Peramalan	$Y_{1(97)}$	1,5916	1,7024
	$Y_{1(98)}$	1,5899	1,6972
	$Y_{1(99)}$	1,5881	1,7156
MAPE		0,7918	0,0833



Gambar 4. 28 Hasil Simulasi Perbandingan ARIMA, ARIMA-Kalman Filter, dan Faktual

4.3.4 Yield Tenor 20 Tahun

Model ARIMA terbaik *yield* tenor 20 tahun yang akan digunakan pada penelitian ini adalah sebagai berikut:

$$Y_{20(t)} = Y_{t-1} + \phi_1(Y_{t-1} - Y_{t-2}) - \theta_7 e_{t-7} + e_t$$

Dengan koefisien ϕ_1 dan θ_7 adalah parameter yang akan diestimasi menggunakan Kalman Filter dan $Y_{20(t)}$ adalah nilai *yield*. Model ARIMA selanjutnya akan dikonstruksi ke dalam

bentuk *state space* dengan state vektor $x(t) = [\phi_1 \quad \theta_7 \quad Y_{20(t)}]^T$ dan akan diterapkan pada algoritma Kalman Filter sebagai berikut:

Nilai parameter ϕ_1 dan θ_7 bernilai konstan, maka:

$$(\phi_1)_{t+1} = (\phi_1)_t$$

$$(\theta_7)_{t+1} = (\theta_7)_t$$

Sesuai dengan model ARIMA yang didapat, maka:

$$(Y_{20(t)})_{t+1} = (Y_{20(t)})_t + (\phi_1(Y_{t-1} - Y_{t-2}))_t - (\theta_7 e_{t-7})_t + e_t$$

Model sistem pada persamaan (2.6):

$$x_{t+1} = Ax_t + Bu_t + w_t$$

sehingga dapat dituliskan sebagai berikut:

$$\begin{bmatrix} \phi_1 \\ \theta_7 \\ Y_{20(t)} \end{bmatrix}_{t+1} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ Y_{t-1} - Y_{t-2} & -e_{t-7} & 1 \end{bmatrix} \begin{bmatrix} \phi_1 \\ \theta_7 \\ Y_{20(t)} \end{bmatrix}_t + \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} (e_t) + w_t$$

Model pengukuran pada persamaan (2.7):

$$z_t = H_t x_t + v_t$$

sehingga dapat dituliskan sebagai berikut:

$$z_t = Y_{20(t)} = [0 \quad 0 \quad 1] \begin{bmatrix} \phi_1 \\ \theta_7 \\ Y_t \end{bmatrix}_t$$

Setelah diperoleh model sistem dan pengukuran pada metode Kalman Filter, selanjutnya dilakukan tahap inisialisasi. Pada tahap inisialisasi akan diberikan nilai awal \hat{x}_0, Q, R, P_0 . Nilai awal ϕ_1 dan θ_7 diperoleh dari koefisien parameter model ARIMA menggunakan MLE sedangkan $Y_{20(t)}$ diambil nilai awal peramalan *yield* tenor 20 tahun. Untuk penambahan nilai *noise* model sistem (w_t) dan *noise* model pengukuran (v_t) dibangkitkan dari komputer melalui program Matlab.

Untuk nilai awal \hat{x}_0 dan P_0 diberikan sebagai berikut:

$$\hat{x}_0 = \begin{bmatrix} 0,2263 \\ 0,2060 \\ 1,6077 \end{bmatrix}, P_0 = \begin{bmatrix} 0.001 & 0 & 0 \\ 0 & 0.001 & 0 \\ 0 & 0 & 0.1 \end{bmatrix}$$

Nilai awal variansi dari *noise* sistem Q_t dan *noise* pengukuran R_t diberikan sebagai berikut:

$$Q_t = \begin{bmatrix} Q & 0 & 0 \\ 0 & Q & 0 \\ 0 & 0 & Q \end{bmatrix}, R_t = R$$

dimana $Q = 10^{-3}$ dan $R = 10^{-4}$

Selanjutnya masuk ke dalam tahap prediksi:

$$\hat{x}_{t+1}^- = A_t \hat{x}_t + B_t u_t$$

$$P_{t+1}^- = A_t P_t A_t^T + G_t Q_t G_t^T$$

Tahap selanjutnya adalah tahap koreksi. Pada tahap ini melibatkan Kalman gain sebagai berikut:

$$K_{t+1} = P_{t+1}^- H_{t+1}^T (H_{t+1} P_{t+1}^- H_{t+1}^T + R_{t+1})^{-1}$$

Lalu nilai \hat{x}_{t+1} diestimasi dengan menggunakan nilai \hat{x}_{t+1}^- yang diperoleh dari tahap prediksi.

$$\hat{x}_{t+1} = \hat{x}_{t+1}^- + K_{t+1} (z_{t+1} - H_{t+1} \hat{x}_{t+1}^-)$$

Kemudian, nilai P_{t+1} dicari menggunakan P_{t+1}^- yang telah dicari pada tahap prediksi.

$$P_{t+1} = (I - K_{t+1} H_{t+1}) P_{t+1}^-$$

Untuk proses simulasi estimasi parameter menggunakan Kalman Filter dilakukan dengan software Matlab. Hasil estimasi parameter model ARIMA pada *yield* tenor 20 tahun menggunakan Filter Kalman dapat dilihat pada Tabel 4.14

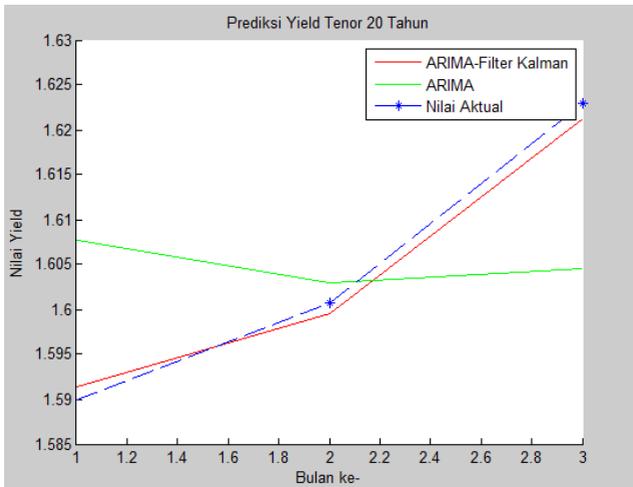
Tabel 4. 14 Hasil Estimasi Parameter Model ARIMA Tenor 20 Tahun Sebelum dan Sesudah menggunakan Kalman Filter

Faktor Pembanding		ARIMA	ARIMA- Kalman Filter
Koef	ϕ_1	0,2263	0,2774
	θ_7	0,2060	0,0552
Peramalan	$Y_{1(97)}$	1,6077	1,5914
	$Y_{1(98)}$	1,6029	1,5996
	$Y_{1(99)}$	1,6045	1,6213
MAPE		0,7977	0,0880

Parameter model ARIMA pada Tabel 4.14 disubstitusikan ke Persamaan (4.4), sehingga diperoleh persamaan model sabagai berikut:

$$Y_{20(t)} = Y_{t-1} + 0,2774Y_{t-1} + 0,0552e_{t-7} + e_t$$

Dari hasil simulasi dilakukan prediksi *yield* tenor 20 tahun sebanyak 3 bulan kedepan. Perbandingan nilai aktual, hasil peramalan ARIMA dan hasil simulasi model ARIMA yang parameternya diestimasi menggunakan Kalman Filter dapat dilihat pada Gambar 4.29



Gambar 4. 29 Hasil Simulasi Perbandingan ARIMA, ARIMA-Kalman Filter, dan Faktual

BAB V PENUTUP

Bab ini membahas mengenai kesimpulan dari tugas akhir dan saran yang dapat digunakan untuk pengembangan penelitian selanjutnya dengan topik yang sama.

5.1 Kesimpulan

Berdasarkan hasil analisis data *time series yield* obligasi Surat Utang Negara dapat disimpulkan bahwa:

1. Model terbaik peramalan pada masing-masing tenor adalah:

Model peramalan pada *yield* tenor 1 tahun adalah ARIMA(0,1,[23]) dan dinotasikan sebagai berikut:

$$Y_{1(t)} = Y_{t-1} + \theta_{23}e_{t-23} + e_t$$

Model peramalan pada *yield* tenor 5 tahun adalah ARIMA(0,1,[1,32]) dan dinotasikan sebagai berikut:

$$Y_{5(t)} = Y_{t-1} + \theta_1 e_{t-1} + \theta_{32} e_{t-32} + e_t$$

Model peramalan pada *yield* tenor 10 tahun adalah ARIMA(0,1,1) dan dinotasikan sebagai berikut:

$$Y_{10(t)} = Y_{t-1}^* + \theta_1 e_{t-1} + e_t$$

dimana $Y_t^* = Y_t^{0,25}$

Model peramalan pada *yield* tenor 20 tahun adalah ARIMA(1,1,[7]) dan dinotasikan sebagai berikut:

$$Y_{20(t)} = Y_{t-1}^* + \phi_1(Y_{t-1}^* - Y_{t-2}^*) - \theta_7 e_{t-7} + e_t$$

dimana $Y_t^* = (\ln Y_t)^{0,7}$

2. Dengan menggunakan Kalman Filter dalam estimasi parameter model ARIMA diperoleh model peramalan sebagai berikut:

Hasil estimasi parameter pada model ARIMA *yield* tenor 1 tahun adalah $\theta_{23} = 0,1996$

Hasil estimasi parameter pada model ARIMA *yield* tenor 5 tahun adalah $\theta_1 = -0,9729$ dan $\theta_{32} = 0,2907$

Hasil estimasi parameter pada model ARIMA *yield* tenor 10 tahun adalah $\theta_1 = -0,8565$

Hasil estimasi parameter pada model ARIMA *yield* tenor 20 tahun adalah $\phi_1 = 0,2774$ dan $\theta_7 = 0,0552$

3. Berdasarkan hasil simulasi, dapat disimpulkan bahwa penggunaan Kalman Filter dalam estimasi parameter model ARIMA dapat memperkecil nilai MAPE sehingga peramalan yang didapatkan menjadi lebih akurat.

5.2 Saran

Untuk pengembangan penelitian selanjutnya, metode Kalman Filter selain dapat diterapkan untuk mengestimasi parameter juga dapat diterapkan untuk mengestimasi *error*. Metode Kalman Filter juga dapat diterapkan pada model peramalan *time series* lainnya, seperti SARIMA dan *Artificial Neural Network* (ANN).

DAFTAR PUSTAKA

- [1] Hartana, P.K.R.S. (2010). *Pembentukan Kurva Yield Obligasi Pemerintah Berbunga Kupon Tetap dengan Menggunakan Permodelan Nelson Siegel Svensson dan Cubic Spline*. Tesis Magister Manajemen, Universitas Indonesia, Jakarta.
- [2] Fatimah, S. (2014). *Implementasi Model Dinamik Nelson Siegel pada Peramalan Yield to Maturity*. Tugas Akhir Jurusan Matematika, Universitas Indonesia, Jakarta.
- [3] Achmanda, A.S. (2017). *Model ARIMA - Filter Kalman untuk Prediksi Harga Komoditas Minyak Mentah*. Tugas Akhir Jurusan Matematika, Institut Teknologi Sepuluh Nopember, Surabaya.
- [4] Kurniawan, T. (2014). *Penerapan Metode Kalman Filter dalam Perbaikan Hasil Prediksi Cuaca dengan Metode ARIMA*. Tugas Akhir Jurusan Matematika, Institut Teknologi Sepuluh Nopember, Surabaya.
- [5] Wahyuningsih, Y. (2011). *Peramalan Yield dan Harga Obligasi Pemerintah dengan Pendekatan ARIMA dan BackPropagation-ANN*. Tugas Akhir Jurusan Statistika, Institut Teknologi Sepuluh Nopember, Surabaya.
- [6] Pamungkas, M.H. (2016). *Estimasi Parameter Model ARIMA Menggunakan Kalman Filter Untuk Peramalan Permintaan Darah (Studi Kasus : UTD PMI Surabaya)*. Tugas Akhir Jurusan Matematika ITS, Surabaya.
- [7] Makridakis, McGee, dan Wheelright, W. (1999). *Metode dan Aplikasi Peramalan*. Edisi Kedua. Terj. Andriyanto, U.S. Bina Rupa Aksara: Jakarta.
- [8] Wei, W.S. (1994). *Time Series Analysis: Univariate and Multivariate Method*. Second Edition. United State of America: Pearson Education, Inc.
- [9] Yati, Elvi. dkk. (2013). *Transformasi Box-Cox pada Analisis Regresi Linier Sederhana*. Jurnal Matematika UNAND. Vol. 2 No. 2 Hal. 115-122. ISSN : 2303-2910. Padang.
- [10] Syarifudin, A. N. N. dkk. (2018). *Perbandingan Metode Kalman Filter, Exetended Kalman Filter, dan Ensemble Kalman Filter pada Model Penyebaran Vidus HIV/AIDS*. Jurnal Limits. Vol. 15, No. 1. E-ISSN: 2579-8936. Surabaya.

LAMPIRAN 1
Data Yield Obligasi Surat Berharga Negara

No.	Periode	Waktu Jatuh Tempo (Tenor)			
		1	5	10	20
1	Jan-10	6.62	8.38	9.67	10.58
2	Feb-10	7.47	8.46	9.80	10.69
3	Mar-10	7.40	8.34	9.31	10.47
4	Apr-10	7.03	8.15	8.75	9.97
5	May-10	7.01	8.52	8.93	10.11
6	Jun-10	6.87	8.01	8.49	9.88
7	Jul-10	6.47	7.63	8.19	9.60
8	Aug-10	5.97	7.50	8.02	9.06
9	Sep-10	5.98	7.43	7.92	8.92
10	Oct-10	5.56	6.53	7.24	8.11
11	Nov-10	4.63	6.32	7.45	8.66
12	Dec-10	5.43	6.70	7.57	9.17
13	Jan-11	5.58	7.49	8.41	9.78
14	Feb-11	6.65	8.26	8.82	10.08
15	Mar-11	6.33	7.91	8.33	9.59
16	Apr-11	6.04	7.01	7.75	9.01
17	May-11	5.73	6.89	7.53	8.84
18	Jun-11	5.55	6.87	7.44	8.66
19	Jul-11	4.97	6.64	7.25	8.39
20	Aug-11	4.21	6.16	6.86	8.01
21	Sep-11	4.74	6.26	6.99	7.77
22	Oct-11	5.09	5.85	6.50	7.28
23	Nov-11	4.87	5.62	6.37	7.33
24	Dec-11	4.55	5.47	6.11	7.23
25	Jan-12	4.30	5.13	5.86	6.87
26	Feb-12	3.56	4.63	5.26	6.18
27	Mar-12	3.93	5.08	5.81	6.69
28	Apr-12	3.87	5.15	5.91	6.76
29	May-12	4.16	5.38	6.32	7.05
30	Jun-12	4.41	5.43	6.33	7.08
31	Jul-12	4.43	5.34	5.88	6.61
32	Aug-12	4.72	5.48	5.89	6.63

LAMPIRAN 1 (Lanjutan)

No.	Periode	Waktu Jatuh Tempo (Tenor)			
		1	5	10	20
33	Sep-12	4.90	5.59	5.94	6.67
34	Oct-12	4.74	5.44	5.77	6.56
35	Nov-12	4.34	5.09	5.44	6.29
36	Dec-12	4.07	4.80	5.23	6.23
37	Jan-13	3.91	4.62	5.17	6.23
38	Feb-13	3.80	4.71	5.24	6.22
39	Mar-13	3.78	4.87	5.41	6.32
40	Apr-13	3.76	5.00	5.48	6.46
41	May-13	4.03	4.95	5.62	6.57
42	Jun-13	5.31	5.84	6.57	7.35
43	Jul-13	6.39	7.07	7.74	8.27
44	Aug-13	6.60	7.50	8.04	8.51
45	Sep-13	6.64	7.73	8.32	8.77
46	Oct-13	5.94	7.15	7.60	8.18
47	Nov-13	6.28	7.65	8.24	8.86
48	Dec-13	6.62	8.00	8.50	9.08
49	Jan-14	6.42	8.04	8.71	9.20
50	Feb-14	5.91	7.91	8.64	9.25
51	Mar-14	6.84	7.69	8.02	8.58
52	Apr-14	6.57	7.55	7.87	8.42
53	May-14	6.51	7.58	7.97	8.54
54	Jun-14	6.48	7.68	8.06	8.67
55	Jul-14	6.62	7.77	8.04	8.69
56	Aug-14	6.85	7.94	8.20	8.85
57	Sep-14	6.74	7.95	8.16	8.69
58	Oct-14	6.83	8.01	8.21	8.70
59	Nov-14	6.45	7.71	7.85	8.29
60	Dec-14	6.42	7.78	7.94	8.36
61	Jan-15	6.69	7.37	7.60	7.90
62	Feb-15	6.33	6.95	7.18	7.43
63	Mar-15	6.44	7.18	7.36	7.68
64	Apr-15	6.56	7.36	7.42	7.78
65	May-15	7.07	7.87	8.01	8.31

LAMPIRAN 1 (Lanjutan)

No.	Periode	Waktu Jatuh Tempo (Tenor)			
		1	5	10	20
66	Jun-15	7.10	8.30	8.42	8.59
67	Jul-15	6.80	8.16	8.30	8.53
68	Aug-15	7.05	8.47	8.66	9.04
69	Sep-15	7.61	8.95	9.21	9.44
70	Oct-15	7.44	8.63	8.75	9.04
71	Nov-15	7.32	8.50	8.62	8.90
72	Dec-15	7.33	8.61	8.65	8.86
73	Jan-16	7.00	8.53	8.56	8.82
74	Feb-16	5.78	7.87	8.06	8.43
75	Mar-16	6.75	7.46	7.79	8.24
76	Apr-16	6.60	7.28	7.51	7.80
77	May-16	6.57	7.46	7.76	7.97
78	Jun-16	6.60	7.42	7.62	7.86
79	Jul-16	6.33	6.89	7.06	7.43
80	Aug-16	6.17	6.67	6.90	7.34
81	Sep-16	6.22	6.73	6.95	7.37
82	Oct-16	6.25	6.93	7.10	7.55
83	Nov-16	6.64	7.58	7.75	8.17
84	Dec-16	6.84	7.63	7.89	8.15
85	Jan-17	6.61	7.33	7.66	8.10
86	Feb-17	6.62	7.26	7.56	8.13
87	Mar-17	6.47	7.09	7.30	7.91
88	Apr-17	6.18	6.77	7.07	7.70
89	May-17	6.27	6.74	7.04	7.75
90	Jun-17	6.17	6.69	6.88	7.57
91	Jul-17	6.15	6.81	6.97	7.71
92	Aug-17	5.93	6.58	6.86	7.45
93	Sep-17	5.55	6.07	6.47	7.16
94	Oct-17	5.68	6.28	6.64	7.33
95	Nov-17	5.54	6.25	6.63	7.25
96	Dec-17	5.35	6.04	6.47	7.19
97	Jan-18	4.98	5.76	6.22	6.96

LAMPIRAN 1 (Lanjutan)

No.	Periode	Waktu Jatuh Tempo (Tenor)			
		1	5	10	20
98	Feb-18	5.10	5.81	6.36	7.09
99	Mar-18	5.38	6.10	6.74	7.37

Sumber: Kementerian Keuangan Republik Indonesia

LAMPIRAN 2

Hasil Uji Parameter Signifikan, Uji White Noise dan Uji Normalitas pada Yield Tenor 5 Tahun

Model	Uji Parameter Signifikan		Uji White noise	Uji Normalitas
ARIMA (0,1,[1,32])	MA(1)	Ya	Ya	Ya
	MA(32)	Ya		
ARIMA (1,1,1)	AR(1)	Tidak	Ya	Ya
	MA(1)	Tidak		
ARIMA (0,1,1)	MA(1)	Ya	Ya	Ya
ARIMA (1,1,[32])	AR(1)	Ya	Ya	Ya
	MA(32)	Ya		
ARIMA (0,1,[32])	MA(32)	Ya	Ya	Tidak
ARIMA (1,1,0)	AR(1)	Ya	Ya	Ya
ARIMA ([1,32],1,1)	AR(1)	Tidak	Ya	Ya
	AR(32)	Ya		
	MA(1)	Tidak		
ARIMA ([1,32],1,0)	AR(1)	Ya	Ya	Ya
	AR(32)	Ya		
ARIMA ([32],1,1)	AR(32)	Ya	Ya	Ya
	MA(1)	Ya		
ARIMA ([32],1,0)	AR(32)	Ya	Ya	Tidak

LAMPIRAN 3

Hasil Uji Parameter Signifikan, Uji White Noise dan Uji Normalitas pada Yield Tenor 10 Tahun

Model	Uji Parameter Signifikan		Uji White Noise	Uji Normalitas
ARIMA ([1,7,17],1,0)	AR(1)	Ya	Ya	Ya
	AR(7)	Ya		
	AR(17)	Tidak		
ARIMA ([1,7],1,1)	AR(1)	Tidak	Ya	Ya
	AR(7)	Ya		
	MA(1)	Tidak		
ARIMA ([1,7],1,0)	AR(1)	Ya	Ya	Ya
	AR(7)	Ya		
ARIMA ([1,17],1,1)	AR(1)	Tidak	Ya	Tidak
	AR(17)	Tidak		
	MA(1)	Tidak		
ARIMA ([1,17],1,0)	AR(1)	Ya	Ya	Tidak
	AR(17)	Tidak		
ARIMA ([7,17],1,1)	AR(7)	Tidak	Ya	Ya
	AR(17)	Tidak		
	MA(1)	Ya		
ARIMA ([7,17],1,0)	AR(7)	Tidak	Ya	Ya
	AR(17)	Tidak		
ARIMA (1,1,1)	AR(1)	Tidak	Ya	Tidak
	MA(1)	Tidak		
ARIMA (1,1,0)	AR(1)	Ya	Ya	Tidak
ARIMA ([7],1,1)	AR(7)	Tidak	Ya	Ya
	MA(1)	Ya		
ARIMA ([7],1,0)	AR(7)	Tidak	Ya	Ya
ARIMA ([17],1,1)	AR(17)	Tidak	Ya	Ya
	MA(1)	Ya		
ARIMA ([17],1,0)	AR(17)	Tidak	Ya	Ya

LAMPIRAN 3 (Lanjutan)

Model	Uji Parameter Signifikan		Uji <i>White Noise</i>	Uji Normalitas
ARIMA (0,1,1)	MA(1)	Ya	Ya	Ya
ARIMA (1,1,[1,7,17])	AR(1)	Tidak	Ya	Ya
	MA(1)	Tidak		
	MA(7)	Ya		
	MA(17)	Ya		
ARIMA (0,1,[1,7,17])	MA(1)	Ya	Ya	Ya
	MA(7)	Tidak		
	MA(17)	Tidak		
ARIMA (0,1,[1,7])	MA(1)	Ya	Ya	Ya
	MA(7)	Tidak		
ARIMA (1,1,[1,17])	AR(1)	Tidak	Ya	Ya
	MA(1)	Tidak		
	MA(17)	Tidak		
ARIMA (0,1,[1,17])	MA(1)	Ya	Ya	Ya
	MA(17)	Tidak		
ARIMA (1,1,[7,17])	AR(1)	Ya	Ya	Ya
	MA(7)	Ya		
	MA(17)	Ya		
ARIMA (0,1,[7,17])	MA(7)	Ya	Ya	Ya
	MA(17)	Tidak		
ARIMA (1,1,[7])	AR(1)	Ya	Ya	Ya
	MA(7)	Tidak		
ARIMA (0,1,[7])	MA(7)	Tidak	Ya	Ya
ARIMA (1,1,[17])	AR(1)	Ya	Ya	Tidak
	MA(17)	Tidak		
ARIMA (0,1,[17])	MA(17)	Tidak	Ya	Ya

LAMPIRAN 4

Hasil Uji Parameter Signifikan, Uji White Noise dan Uji Normalitas pada Yield Tenor 20 Tahun

Model	Uji Parameter Signifikan		Uji White noise	Uji Normalitas
ARIMA ([1,7],1,1)	AR(1)	Tidak	Ya	Tidak
	AR(7)	Ya		
	MA(1)	Tidak		
ARIMA ([1,7],1,0)	AR(1)	Ya	Ya	Ya
	AR(7)	Ya		
ARIMA (1,1,1)	AR(1)	Tidak	Ya	Tidak
	MA(1)	Tidak		
ARIMA (1,1,0)	AR(1)	Ya	Ya	Tidak
ARIMA ([7],1,1)	AR(7)	Tidak	Ya	Ya
	MA(1)	Tidak		
ARIMA (7,1,0)	AR(7)	Tidak	Ya	Ya
ARIMA (0,1,1)	MA(1)	Tidak	Ya	Ya
ARIMA (1,1,[1,7])	AR(1)	Tidak	Ya	Tidak
	MA(1)	Tidak		
	MA(7)	Tidak		
ARIMA (0,1,[1,7])	MA(1)	Tidak	Ya	Tidak
	MA(7)	Tidak		
ARIMA (1,1,[7])	AR(1)	Ya	Ya	Ya
	MA(7)	Ya		
ARIMA (0,1,[7])	MA(7)	Tidak	Ya	Tidak

LAMPIRAN 5

Hasil Estimasi Parameter Model ARIMA Yield Tenor 1 Tahun

1. ARIMA(23,1,0)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0048469	0.03342	-0.15	0.8847	0
AR1,1	-0.30263	0.10693	-2.83	0.0047	23
Constant Estimate			-0.00631		
Variance Estimate			0.163379		
Std Error Estimate			0.404201		
AIC			101.6763		
SBC			106.784		
Number of Residuals			95		

2. ARIMA(0,1,23)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0063346	0.03285	-0.19	0.8471	0
MA1,1	0.28217	0.11535	2.45	0.0144	23
Constant Estimate			-0.00633		
Variance Estimate			0.164492		
Std Error Estimate			0.405577		
AIC			102.0205		
SBC			107.1282		
Number of Residuals			95		

3. ARIMA ([23],1,[23])

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0048524	0.03324	-0.15	0.8839	0
MA1,1	0.06681	0.41189	0.16	0.8711	23
AR1,1	-0.24015	0.39842	-0.60	0.5467	23
Constant Estimate			-0.00602		
Variance Estimate			0.165105		
Std Error Estimate			0.406332		
AIC			103.6399		
SBC			111.3015		
Number of Residuals			95		

LAMPIRAN 6

Hasil Estimasi Parameter Model ARIMA Yield Tenor 1 Tahun

1. ARIMA(1,1,[1,32])

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.01905	0.03596	-0.53	0.5964	0
MA1,1	-0.06946	0.23672	-0.29	0.7692	1
MA1,2	0.40206	0.14742	2.73	0.0064	32
AR1,1	0.27005	0.22421	1.20	0.2284	1
Constant Estimate			-0.0139		
Variance Estimate			0.098855		
Std Error Estimate			0.314413		
AIC			59.44128		
SBC			69.65678		
Number of Residuals			95		

2. ARIMA(0,1,[1,32])

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.01988	0.03604	-0.55	0.5812	0
MA1,1	-0.33769	0.09891	-3.41	0.0006	1
MA1,2	0.32967	0.13518	2.44	0.0147	32
Constant Estimate			-0.01988		
Variance Estimate			0.100566		
Std Error Estimate			0.317121		
AIC			58.72203		
SBC			66.38366		
Number of Residuals			95		

LAMPIRAN 6 (Lanjutan)

3. ARIMA(1,1,1)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.02480	0.04819	-0.51	0.6068	0
MA1,1	-0.41846	0.23528	-1.78	0.0753	1
AR1,1	-0.01431	0.25844	-0.06	0.9558	1
Constant Estimate			-0.02515		
Variance Estimate			0.113667		
Std Error Estimate			0.337145		
AIC			66.15472		
SBC			73.81635		
Number of Residuals			95		

4. ARIMA(0,1,1)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.02480	0.04822	-0.51	0.6070	0
MA1,1	-0.40731	0.09492	-4.29	<.0001	1
Constant Estimate			-0.0248		
Variance Estimate			0.112449		
Std Error Estimate			0.335334		
AIC			64.15896		
SBC			69.26671		
Number of Residuals			95		

5. ARIMA(1,1,[32])

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.01902	0.03485	-0.55	0.5853	0
MA1,1	0.42095	0.14958	2.81	0.0049	32
AR1,1	0.31927	0.09560	3.34	0.0008	1
Constant Estimate			-0.01295		
Variance Estimate			0.097261		
Std Error Estimate			0.311868		
AIC			57.47882		
SBC			65.14045		
Number of Residuals			95		

LAMPIRAN 6 (Lanjutan)

6. ARIMA(0,1,[32])

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.01900	0.02455	-0.77	0.4388	0
MA1,1	0.44912	0.14911	3.01	0.0026	32

Constant Estimate	-0.019
Variance Estimate	0.10626
Std Error Estimate	0.325975
AIC	65.74864
SBC	70.85639
Number of Residuals	95

7. ARIMA(1,1,0)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.02504	0.05216	-0.48	0.6312	0
AR1,1	0.33283	0.09776	3.40	0.0007	1

Constant Estimate	-0.01671
Variance Estimate	0.116389
Std Error Estimate	0.341158
AIC	67.36671
SBC	72.47446
Number of Residuals	95

8. ARIMA([1,32],1,1)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.01352	0.03208	-0.42	0.6734	0
MA1,1	-0.28216	0.18529	-1.52	0.1278	1
AR1,1	0.09495	0.16246	0.58	0.5589	1
AR1,2	-0.44695	0.09830	-4.55	<.0001	32

Constant Estimate	-0.01828
Variance Estimate	0.09198
Std Error Estimate	0.303282
AIC	54.19393
SBC	64.40943
Number of Residuals	95

LAMPIRAN 6 (Lanjutan)

9. ARIMA([1,32],1,0)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.01172	0.03014	-0.39	0.6975	0
AR1,1	0.27902	0.08056	3.46	0.0005	1
AR1,2	-0.42936	0.09228	-4.65	<.0001	32
Constant Estimate			-0.01348		
Variance Estimate			0.093022		
Std Error Estimate			0.304996		
AIC			54.35062		
SBC			62.01225		
Number of Residuals			95		

10. ARIMA([32],1,1)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.01452	0.03173	-0.46	0.6472	0
MA1,1	-0.36605	0.09373	-3.91	<.0001	1
AR1,1	-0.44125	0.09912	-4.45	<.0001	32
Constant Estimate			-0.02093		
Variance Estimate			0.091638		
Std Error Estimate			0.302717		
AIC			52.58147		
SBC			60.24311		
Number of Residuals			95		

11. ARIMA([32],1,0)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.01395	0.02440	-0.57	0.5673	0
AR1,1	-0.46055	0.09685	-4.76	<.0001	32
Constant Estimate			-0.02038		
Variance Estimate			0.102877		
Std Error Estimate			0.320745		
AIC			63.15467		
SBC			68.26243		
Number of Residuals			95		

LAMPIRAN 7

Hasil Estimasi Model ARIMA Yield Tenor 10 Tahun

1. ARIMA([1,7,17],1,1)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0014013	0.0018572	-0.75	0.4505	0
MA1,1	0.05932	0.29561	0.20	0.8409	1
AR1,1	0.34470	0.26686	1.29	0.1965	1
AR1,2	-0.20315	0.09773	-2.08	0.0376	7
AR1,3	-0.16951	0.09979	-1.70	0.0894	17
Constant Estimate			-0.00144		
Variance Estimate			0.000363		
Std Error Estimate			0.019042		
AIC			-477.121		
SBC			-464.352		
Number of Residuals			95		

2. ARIMA ([1,7,17],1,0)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0014188	0.0018586	-0.76	0.4452	0
AR1,1	0.29328	0.09696	3.02	0.0025	1
AR1,2	-0.20478	0.09782	-2.09	0.0363	7
AR1,3	-0.17226	0.10106	-1.70	0.0883	17
Constant Estimate			-0.00154		
Variance Estimate			0.000359		
Std Error Estimate			0.018941		
AIC			-479.082		
SBC			-468.867		
Number of Residuals			95		

LAMPIRAN 7 (Lanjutan)

3. ARIMA([1,7],1,1)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0015528	0.0021348	-0.73	0.4670	0
MA1,1	0.04511	0.32398	0.14	0.8893	1
AR1,1	0.30660	0.30012	1.02	0.3070	1
AR1,2	-0.20232	0.09970	-2.03	0.0424	7
Constant Estimate			-0.00139		
Variance Estimate			0.000372		
Std Error Estimate			0.019291		
AIC			-476.226		
SBC			-466.01		
Number of Residuals			95		

4. ARIMA ([1,7],1,0)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0015586	0.0021242	-0.73	0.4631	0
AR1,1	0.26688	0.09794	2.73	0.0064	1
AR1,2	-0.20410	0.09902	-2.06	0.0393	7
Constant Estimate			-0.00146		
Variance Estimate			0.000368		
Std Error Estimate			0.019189		
AIC			-478.197		
SBC			-470.536		
Number of Residuals			95		

5. ARIMA ([1,17],1,1)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0015870	0.0023068	-0.69	0.4915	0
MA1,1	-0.02340	0.34728	-0.07	0.9463	1
AR1,1	0.26179	0.33004	0.79	0.4277	1
AR1,2	-0.17203	0.10457	-1.65	0.0999	17
Constant Estimate			-0.00144		
Variance Estimate			0.000378		
Std Error Estimate			0.019441		
AIC			-474.52		
SBC			-464.304		
Number of Residuals			95		

LAMPIRAN 7 (Lanjutan)

6. ARIMA ([1,17],1,0)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0015831	0.0023012	-0.69	0.4915	0
AR1,1	0.28340	0.09923	2.86	0.0043	1
AR1,2	-0.17061	0.10335	-1.65	0.0988	17
Constant Estimate			-0.0014		
Variance Estimate			0.000374		
Std Error Estimate			0.019336		
AIC			-476.515		
SBC			-468.854		
Number of Residuals			95		

7. ARIMA ([7,17],1,1)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0014965	0.0018575	-0.81	0.4205	0
MA1,1	-0.27105	0.10170	-2.67	0.0077	1
AR1,1	-0.19492	0.10181	-1.91	0.0556	7
AR1,2	-0.18164	0.10469	-1.74	0.0827	17
Constant Estimate			-0.00206		
Variance Estimate			0.000364		
Std Error Estimate			0.019067		
AIC			-477.903		
SBC			-467.688		
Number of Residuals			95		

8. ARIMA ([7,17],1,0)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0015362	0.0015888	-0.97	0.3336	0
AR1,1	-0.19070	0.10242	-1.86	0.0626	7
AR1,2	-0.12057	0.10514	-1.15	0.2514	17
Constant Estimate			-0.00201		
Variance Estimate			0.000392		
Std Error Estimate			0.0198		
AIC			-472.121		
SBC			-464.46		
Number of Residuals			95		

LAMPIRAN 7 (Lanjutan)

9. ARIMA (1,1,1)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0017699	0.0027086	-0.65	0.5135	0
MA1,1	0.0024308	0.40665	0.01	0.9952	1
AR1,1	0.25975	0.39236	0.66	0.5080	1
Constant Estimate			-0.00131		
Variance Estimate			0.000387		
Std Error Estimate			0.019668		
AIC			-473.847		
SBC			-466.185		
Number of Residuals			95		

10. ARIMA(1,1,0)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0017697	0.0026921	-0.66	0.5110	0
AR1,1	0.25747	0.10018	2.57	0.0102	1
Constant Estimate			-0.00131		
Variance Estimate			0.000383		
Std Error Estimate			0.019562		
AIC			-475.847		
SBC			-470.739		
Number of Residuals			95		

11. ARIMA ([7],1,1)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0015994	0.0020645	-0.77	0.4385	0
MA1,1	-0.23649	0.10152	-2.33	0.0198	1
AR1,1	-0.19712	0.10345	-1.91	0.0567	7
Constant Estimate			-0.00191		
Variance Estimate			0.000373		
Std Error Estimate			0.019316		
AIC			-477.013		
SBC			-469.351		
Number of Residuals			95		

LAMPIRAN 7 (Lanjutan)

12. ARIMA([7],1,0)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0016151	0.0017294	-0.93	0.3503	0
AR1,1	-0.19081	0.10253	-1.86	0.0628	7
Constant Estimate			-0.00192		
Variance Estimate			0.000394		
Std Error Estimate			0.019857		
AIC			-472.809		
SBC			-467.701		
Number of Residuals			95		

13. ARIMA ([17],1,1)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0016236	0.0021811	-0.74	0.4566	0
MA1,1	-0.26884	0.10117	-2.66	0.0079	1
AR1,1	-0.18334	0.10662	-1.72	0.0855	17
Constant Estimate			-0.00192		
Variance Estimate			0.000376		
Std Error Estimate			0.019378		
AIC			-476.08		
SBC			-468.418		
Number of Residuals			95		

14. ARIMA ([17],1,0)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0016685	0.0018749	-0.89	0.3735	0
AR1,1	-0.12018	0.10686	-1.12	0.2607	17
Constant Estimate			-0.00187		
Variance Estimate			0.000404		
Std Error Estimate			0.020098		
AIC			-470.528		
SBC			-465.42		
Number of Residuals			95		

LAMPIRAN 7 (Lanjutan)

15. ARIMA (0,1,1)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0017602	0.0024795	-0.71	0.4778	0
MA1,1	-0.23437	0.10093	-2.32	0.0202	1
Constant Estimate			-0.00176		
Variance Estimate			0.000385		
Std Error Estimate			0.019623		
AIC			-475.268		
SBC			-470.16		
Number of Residuals			95		

16. ARIMA (1,1[1,7,17])

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0011753	0.0016479	-0.71	0.4757	0
MA1,1	0.01578	0.27091	0.06	0.9536	1
MA1,2	0.23629	0.10785	2.19	0.0285	7
MA1,3	0.23326	0.11438	2.04	0.0414	17
AR1,1	0.31819	0.26276	1.21	0.2259	1
Constant Estimate			-0.0008		
Variance Estimate			0.000358		
Std Error Estimate			0.018921		
AIC			-477.825		
SBC			-465.056		
Number of Residuals			95		

17. ARIMA (0,1,[1,7,17])

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0013942	0.0017785	-0.78	0.4331	0
MA1,1	-0.25821	0.09962	-2.59	0.0095	1
MA1,2	0.18304	0.10353	1.77	0.0771	7
MA1,3	0.21118	0.10830	1.95	0.0512	17
Constant Estimate			-0.00139		
Variance Estimate			0.000362		
Std Error Estimate			0.019015		
AIC			-478.154		
SBC			-467.939		
Number of Residuals			95		

LAMPIRAN 7 (Lanjutan)

18. ARIMA (0,1,[1,7])

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0016185	0.0020953	-0.77	0.4399	0
MA1,1	-0.22341	0.10049	-2.22	0.0262	1
MA1,2	0.17967	0.10195	1.76	0.0780	7
Constant Estimate			-0.00162		
Variance Estimate			0.000376		
Std Error Estimate			0.019391		
AIC			-476.318		
SBC			-468.657		
Number of Residuals			95		

19. ARIMA (1,1,[1,17])

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0016049	0.0023074	-0.70	0.4867	0
MA1,1	-0.11485	0.31925	-0.36	0.7190	1
MA1,2	0.20298	0.11420	1.78	0.0755	17
AR1,1	0.18824	0.31853	0.59	0.5545	1
Constant Estimate			-0.0013		
Variance Estimate			0.000375		
Std Error Estimate			0.019368		
AIC			-475.053		
SBC			-464.837		
Number of Residuals			95		

20. ARIMA (0,1,[1,17])

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0016202	0.0022141	-0.73	0.4643	0
MA1,1	-0.28834	0.09943	-2.90	0.0037	1
MA1,2	0.19880	0.10813	1.84	0.0660	17
Constant Estimate			-0.00162		
Variance Estimate			0.000372		
Std Error Estimate			0.019288		
AIC			-476.779		
SBC			-469.117		
Number of Residuals			95		

LAMPIRAN 7 (Lanjutan)

21. ARIMA (1,1,[7,17])

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0011882	0.0016533	-0.72	0.4723	0
MA1,1	0.23450	0.10718	2.19	0.0287	7
MA1,2	0.23303	0.11366	2.05	0.0403	17
AR1,1	0.30458	0.10056	3.03	0.0025	1
Constant Estimate			-0.00083		
Variance Estimate			0.000354		
Std Error Estimate			0.018818		
AIC			-479.821		
SBC			-469.605		
Number of Residuals			95		

22. ARIMA (0,1,[7,17])

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0012543	0.0013303	-0.94	0.3458	0
MA1,1	0.20819	0.10538	1.98	0.0482	7
MA1,2	0.18666	0.11117	1.68	0.0931	17
Constant Estimate			-0.00125		
Variance Estimate			0.000388		
Std Error Estimate			0.019696		
AIC			-472.691		
SBC			-465.029		
Number of Residuals			95		

23. ARIMA (1,1,[7])

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0015921	0.0022110	-0.72	0.4715	0
MA1,1	0.19376	0.10502	1.85	0.0650	7
AR1,1	0.27035	0.10084	2.68	0.0073	1
Constant Estimate			-0.00116		
Variance Estimate			0.000371		
Std Error Estimate			0.019264		
AIC			-477.511		
SBC			-469.85		
Number of Residuals			95		

LAMPIRAN 7 (Lanjutan)

24. ARIMA (0,1,[7])

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0016134	0.0017266	-0.93	0.3501	0
MA1,1	0.16668	0.10389	1.60	0.1086	7
Constant Estimate			-0.00161		
Variance Estimate			0.000397		
Std Error Estimate			0.019915		
AIC			-472.321		
SBC			-467.213		
Number of Residuals			95		

25. ARIMA (1,1,[17])

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0015948	0.0023327	-0.68	0.4942	0
MA1,1	0.19612	0.11366	1.73	0.0844	17
AR1,1	0.29267	0.10052	2.91	0.0036	1
Constant Estimate			-0.00113		
Variance Estimate			0.000372		
Std Error Estimate			0.019281		
AIC			-476.931		
SBC			-469.27		
Number of Residuals			95		

26. ARIMA (0,1,[17])

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0016306	0.0018306	-0.89	0.3731	0
MA1,1	0.13509	0.11024	1.23	0.2204	17
Constant Estimate			-0.00163		
Variance Estimate			0.000403		
Std Error Estimate			0.020077		
AIC			-470.661		
SBC			-465.553		
Number of Residuals			95		

LAMPIRAN 8

Hasil Estimasi Model ARIMA Yield Tenor 20 Tahun

1.. ARIMA ([1,7],1,1)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0019911	0.0024396	-0.82	0.4144	0
MA1,1	0.20140	0.33442	0.60	0.5470	1
AR1,1	0.41326	0.30157	1.37	0.1706	1
AR1,2	-0.19337	0.09701	-1.99	0.0462	7
Constant Estimate			-0.00155		
Variance Estimate			0.000525		
Std Error Estimate			0.022912		
AIC			-443.558		
SBC			-433.342		
Number of Residuals			95		

2. ARIMA ([1,7],1,0)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0020378	0.0024554	-0.83	0.4066	0
AR1,1	0.23122	0.09908	2.33	0.0196	1
AR1,2	-0.19690	0.10028	-1.96	0.0496	7
Constant Estimate			-0.00197		
Variance Estimate			0.000523		
Std Error Estimate			0.022861		
AIC			-444.982		
SBC			-437.32		
Number of Residuals			95		

LAMPIRAN 8 (Lanjutan)

3. ARIMA (1,1,1)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0022505	0.0031894	-0.71	0.4804	0
MA1,1	0.13684	0.45411	0.30	0.7632	1
AR1,1	0.35403	0.42852	0.83	0.4087	1
Constant Estimate			-0.00145		
Variance Estimate			0.000546		
Std Error Estimate			0.023366		
AIC			-441.127		
SBC			-433.466		
Number of Residuals			95		

4. ARIMA (1,1,0)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0022464	0.0030615	-0.73	0.4631	0
AR1,1	0.22311	0.10101	2.21	0.0272	1
Constant Estimate			-0.00175		
Variance Estimate			0.000541		
Std Error Estimate			0.023259		
AIC			-442.976		
SBC			-437.869		
Number of Residuals			95		

5. ARIMA ([7],1,1)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0020889	0.0023949	-0.87	0.3831	0
MA1,1	-0.18557	0.10246	-1.81	0.0701	1
AR1,1	-0.18072	0.10381	-1.74	0.0817	7
Constant Estimate			-0.00247		
Variance Estimate			0.000531		
Std Error Estimate			0.023053		
AIC			-443.472		
SBC			-435.81		
Number of Residuals			95		

LAMPIRAN 8 (Lanjutan)

6. ARIMA ([7],1,0)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0020996	0.0020458	-1.03	0.3048	0
AR1,1	-0.18674	0.10276	-1.82	0.0692	7
Constant Estimate			-0.00249		
Variance Estimate			0.000548		
Std Error Estimate			0.023417		
AIC			-441.488		
SBC			-436.38		
Number of Residuals			95		

7. ARIMA (0,1,1)

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0022471	0.0028543	-0.79	0.4311	0
MA1,1	-0.19407	0.10177	-1.91	0.0565	1
Constant Estimate			-0.00225		
Variance Estimate			0.000545		
Std Error Estimate			0.023342		
AIC			-442.309		
SBC			-437.201		
Number of Residuals			95		

8. ARIMA (1,1,[1,7])

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0020299	0.0024773	-0.82	0.4125	0
MA1,1	0.18226	0.34853	0.52	0.6010	1
MA1,2	0.19867	0.10395	1.91	0.0560	7
AR1,1	0.39989	0.33071	1.21	0.2266	1
Constant Estimate			-0.00122		
Variance Estimate			0.000528		
Std Error Estimate			0.02298		
AIC			-443.036		
SBC			-432.82		
Number of Residuals			95		

LAMPIRAN 8 (Lanjutan)

9. ARIMA (0,1,[1,7])

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0020938	0.0023607	-0.89	0.3751	0
MA1,1	-0.17028	0.10134	-1.68	0.0929	1
MA1,2	0.18459	0.10282	1.80	0.0726	7
Constant Estimate			-0.00209		
Variance Estimate			0.000533		
Std Error Estimate			0.023095		
AIC			-443.119		
SBC			-435.457		
Number of Residuals			95		

10. ARIMA (1,1,[7])

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0020553	0.0024467	-0.84	0.4009	0
MA1,1	0.20603	0.10439	1.97	0.0484	7
AR1,1	0.22638	0.10189	2.22	0.0263	1
Constant Estimate			-0.00159		
Variance Estimate			0.000525		
Std Error Estimate			0.02291		
AIC			-444.57		
SBC			-436.909		
Number of Residuals			95		

11. ARIMA (0,1,[7])

The ARIMA Procedure
Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	-0.0020776	0.0019702	-1.05	0.2916	0
MA1,1	0.19318	0.10334	1.87	0.0616	7
Constant Estimate			-0.00208		
Variance Estimate			0.000548		
Std Error Estimate			0.023409		
AIC			-441.535		
SBC			-436.427		
Number of Residuals			95		

LAMPIRAN 9

Hasil Uji White Noise Model ARIMA Yield Tenor 1 Tahun

1. ARIMA([23],1,0)

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.61	5	0.6069	0.051	-0.055	-0.012	-0.068	-0.110	-0.113
12	5.03	11	0.9298	-0.046	-0.016	0.010	0.067	0.018	0.076
18	8.90	17	0.9433	0.044	0.073	0.076	-0.059	-0.127	-0.025
24	9.59	23	0.9935	0.008	0.049	0.041	-0.024	0.026	0.011

2. ARIMA(0,1,[23])

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.44	5	0.6325	0.044	-0.058	-0.016	-0.065	-0.105	-0.114
12	4.58	11	0.9497	-0.040	-0.012	0.009	0.065	0.014	0.066
18	7.47	17	0.9766	0.047	0.047	0.071	-0.053	-0.110	-0.018
24	8.11	23	0.9982	0.007	0.053	0.037	-0.025	0.011	0.013

3. ARIMA ([23],1,[23])

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.59	4	0.4645	0.049	-0.056	-0.012	-0.068	-0.108	-0.115
12	4.95	10	0.8943	-0.045	-0.016	0.009	0.068	0.018	0.073
18	8.60	16	0.9289	0.045	0.067	0.074	-0.058	-0.124	-0.024
24	9.32	22	0.9915	0.008	0.050	0.039	-0.024	0.030	0.013

LAMPIRAN 10

Hasil Uji White Noise Model ARIMA Yield Tenor 5 Tahun

1. ARIMA(1,1,[1,32])

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.17	3	0.3668	0.042	-0.127	-0.049	0.018	-0.024	0.101
12	9.04	9	0.4335	-0.207	-0.077	0.013	0.029	-0.064	0.043
18	13.21	15	0.5858	0.032	-0.003	0.075	0.121	-0.115	0.036
24	15.23	21	0.8110	-0.051	0.035	-0.058	0.029	-0.071	-0.054

2. ARIMA(0,1,[1,32])

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.98	4	0.7394	0.057	-0.042	-0.067	0.030	-0.033	0.089
12	8.26	10	0.6030	-0.222	-0.060	-0.013	0.035	-0.058	0.045
18	13.46	16	0.6388	0.032	0.025	0.088	0.136	-0.119	0.051
24	16.10	22	0.8109	-0.082	0.034	-0.061	0.016	-0.093	-0.025

3. ARIMA(1,1,1)

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	0.99	4	0.9114	0.003	-0.036	-0.068	0.015	0.032	0.051
12	5.79	10	0.8327	-0.195	-0.074	0.034	0.007	-0.025	0.016
18	12.56	16	0.7049	0.067	0.017	0.127	0.097	-0.125	0.109
24	16.64	22	0.7829	-0.139	0.027	-0.035	-0.012	-0.107	0.012

4. ARIMA(0,1,1)

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.01	5	0.9621	0.001	-0.040	-0.067	0.014	0.033	0.051
12	5.82	11	0.8854	-0.195	-0.074	0.035	0.006	-0.025	0.016
18	12.59	17	0.7631	0.067	0.015	0.127	0.096	-0.126	0.109
24	16.62	23	0.8274	-0.139	0.027	-0.034	-0.012	-0.106	0.011

LAMPIRAN 10 (Lanjutan)

5. ARIMA(1,1,[32])

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.65	4	0.4560	0.055	-0.142	-0.052	0.015	-0.020	0.099
12	9.46	10	0.4890	-0.203	-0.083	0.016	0.028	-0.064	0.043
18	13.28	16	0.6522	0.033	-0.005	0.072	0.114	-0.111	0.033
24	15.21	22	0.8531	-0.045	0.034	-0.056	0.030	-0.066	-0.060

6. ARIMA(0,1,[32])

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	10.67	5	0.0584	0.322	-0.036	-0.054	-0.010	-0.018	0.021
12	17.02	11	0.1074	-0.197	-0.132	-0.027	0.002	-0.041	0.037
18	20.21	17	0.2638	0.048	0.037	0.096	0.105	-0.061	-0.004
24	22.34	23	0.4998	-0.034	0.005	-0.050	-0.009	-0.079	-0.082

7. ARIMA(1,1,0)

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.86	5	0.4334	0.069	-0.177	-0.072	0.010	0.072	0.049
12	10.64	11	0.4738	-0.203	-0.091	0.060	0.015	-0.037	0.017
18	16.09	17	0.5174	0.056	0.011	0.140	0.078	-0.110	0.076
24	18.88	23	0.7084	-0.107	0.003	-0.001	-0.025	-0.101	-0.009

8. ARIMA([1,32],1,1)

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.93	3	0.5863	-0.002	-0.031	-0.022	0.016	-0.075	0.107
12	7.91	9	0.5434	-0.210	-0.071	-0.019	0.019	-0.070	0.044
18	12.70	15	0.6258	-0.003	-0.013	0.068	0.131	-0.121	0.064
24	15.24	21	0.8107	-0.066	0.066	-0.070	0.029	-0.068	-0.036

9. ARIMA([1,32],1,0)

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.68	4	0.6124	0.077	-0.110	-0.020	0.000	-0.039	0.082
12	8.31	10	0.5986	-0.195	-0.097	0.001	-0.000	-0.071	0.028
18	11.84	16	0.7548	-0.005	-0.030	0.075	0.099	-0.101	0.060
24	13.46	22	0.9195	-0.037	0.050	-0.041	0.016	-0.060	-0.059

LAMPIRAN 10 (Lanjutan)

10. ARIMA([32],1,1)

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.01	4	0.7344	0.014	0.001	-0.041	0.024	-0.079	0.104
12	8.31	10	0.5985	-0.217	-0.066	-0.032	0.026	-0.067	0.045
18	13.35	16	0.6470	-0.001	0.003	0.069	0.142	-0.121	0.059
24	16.33	22	0.7992	-0.075	0.067	-0.078	0.030	-0.077	-0.029

11. ARIMA([32],1,0)

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	11.23	5	0.0470	0.334	-0.003	-0.029	-0.018	-0.043	0.008
12	18.37	11	0.0734	-0.203	-0.147	-0.050	-0.009	-0.045	0.021
18	22.14	17	0.1795	0.012	0.024	0.113	0.126	-0.055	-0.006
24	24.21	23	0.3921	-0.033	0.020	-0.047	-0.018	-0.076	-0.081

LAMPIRAN 11

Hasil Uji White Noise Model ARIMA Yield Tenor 10 Tahun

1. ARIMA([1,7,17],1,1)

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.56	2	0.2784	0.001	0.021	-0.067	-0.065	0.073	0.102
12	4.04	8	0.8533	-0.004	0.033	0.020	-0.098	0.043	-0.026
18	8.75	14	0.8470	0.025	-0.014	0.098	0.135	-0.041	0.099
24	12.32	20	0.9047	-0.123	0.038	-0.058	0.057	-0.025	-0.070

2. ARIMA([1,7,17],1,0)

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.50	3	0.4758	-0.005	0.034	-0.063	-0.063	0.073	0.100
12	4.02	9	0.9104	-0.006	0.022	0.017	-0.102	0.046	-0.027
18	8.78	15	0.8889	0.029	-0.013	0.099	0.137	-0.041	0.097
24	12.51	21	0.9247	-0.126	0.039	-0.061	0.057	-0.027	-0.071

3. ARIMA([1,7],1,1)

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.89	3	0.4095	0.001	0.022	-0.087	-0.061	0.068	0.109
12	4.06	9	0.9073	0.014	0.026	0.015	-0.080	0.018	-0.055
18	13.25	15	0.5829	0.025	0.016	0.137	0.145	-0.188	0.051
24	17.33	21	0.6907	-0.142	0.068	-0.041	0.047	-0.039	-0.054

4. ARIMA ([1,7],1,0)

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.81	4	0.5896	-0.005	0.032	-0.084	-0.058	0.067	0.108
12	4.01	10	0.9471	0.014	0.018	0.013	-0.082	0.020	-0.055
18	13.31	16	0.6500	0.027	0.015	0.136	0.147	-0.189	0.055
24	17.50	22	0.7353	-0.144	0.069	-0.043	0.047	-0.039	-0.053

LAMPIRAN 11 (Lanjutan)

5. ARIMA ([1,17],1,1)

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
6	1.65	3	0.6483	0.003	0.035	-0.038	-0.048	0.059	0.087	
12	8.03	9	0.5316	-0.214	-0.068	-0.031	-0.083	0.044	-0.005	
18	13.32	15	0.5776	-0.002	0.033	0.117	0.150	-0.016	0.089	
24	16.84	21	0.7208	-0.125	0.049	-0.067	0.009	-0.070	-0.029	

6. ARIMA ([1,17],1,0)

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
6	1.66	4	0.7980	0.004	0.030	-0.040	-0.048	0.061	0.088	
12	8.01	10	0.6281	-0.214	-0.069	-0.030	-0.082	0.043	-0.005	
18	13.32	16	0.6494	-0.003	0.032	0.117	0.150	-0.017	0.090	
24	16.76	22	0.7763	-0.124	0.049	-0.066	0.009	-0.070	-0.029	

7. ARIMA ([7,17],1,1)

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
6	2.98	3	0.3951	0.030	0.095	-0.064	-0.050	0.072	0.087	
12	5.05	9	0.8303	-0.023	-0.049	0.007	-0.108	0.056	-0.036	
18	10.08	15	0.8146	0.040	0.005	0.122	0.150	-0.027	0.060	
24	14.11	21	0.8647	-0.127	0.042	-0.074	0.049	-0.048	-0.067	

8. ARIMA ([7,17],1,0)

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
6	11.11	4	0.0253	0.289	0.082	-0.057	-0.049	0.077	0.102	
12	12.37	10	0.2608	-0.007	-0.048	-0.031	-0.089	0.012	-0.021	
18	19.25	16	0.2560	0.031	0.055	0.167	0.164	-0.025	0.008	
24	22.07	22	0.4556	-0.107	0.003	-0.046	0.015	-0.054	-0.078	

9. ARIMA (1,1,1)

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
6	2.00	4	0.7359	0.002	0.021	-0.066	-0.040	0.066	0.094	
12	7.03	10	0.7224	-0.198	-0.069	-0.029	-0.033	0.027	-0.033	
18	16.71	16	0.4046	-0.008	0.057	0.155	0.162	-0.165	0.046	
24	21.13	22	0.5128	-0.140	0.078	-0.053	-0.010	-0.085	-0.013	

LAMPIRAN 11 (Lanjutan)

10. ARIMA(1,1,0)

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.99	5	0.8498	0.002	0.021	-0.066	-0.040	0.065	0.094
12	7.03	11	0.7969	-0.198	-0.069	-0.029	-0.033	0.027	-0.033
18	16.70	17	0.4745	-0.008	0.057	0.155	0.162	-0.165	0.047
24	21.13	23	0.5732	-0.140	0.078	-0.053	-0.010	-0.085	-0.013

11. ARIMA ([7],1,1)

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.08	4	0.5452	0.025	0.087	-0.080	-0.044	0.066	0.098
12	4.58	10	0.9176	0.002	-0.041	0.006	-0.089	0.030	-0.057
18	14.14	16	0.5886	0.035	0.021	0.142	0.156	-0.179	0.059
24	18.69	22	0.6646	-0.150	0.070	-0.057	0.041	-0.053	-0.045

12. ARIMA([7],1,0)

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	9.97	5	0.0762	0.265	0.074	-0.068	-0.046	0.076	0.110
12	11.09	11	0.4354	0.009	-0.041	-0.024	-0.080	-0.003	-0.042
18	19.88	17	0.2896	0.027	0.063	0.180	0.146	-0.129	-0.015
24	22.73	23	0.4768	-0.120	0.024	-0.033	0.014	-0.055	-0.062

13. ARIMA ([17],1,1)

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.04	4	0.7278	0.028	0.092	-0.039	-0.039	0.044	0.077
12	8.65	10	0.5654	-0.213	-0.075	-0.039	-0.088	0.046	-0.009
18	14.07	16	0.5935	0.010	0.053	0.126	0.156	-0.002	0.057
24	18.13	22	0.6982	-0.130	0.047	-0.079	0.008	-0.081	-0.031

14. ARIMA ([17],1,0)

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	9.30	5	0.0977	0.284	0.082	-0.032	-0.038	0.055	0.041
12	16.64	11	0.1189	-0.203	-0.131	-0.075	-0.072	0.017	-0.005
18	25.39	17	0.0863	0.018	0.095	0.185	0.178	-0.004	0.009
24	28.73	23	0.1896	-0.108	0.006	-0.061	-0.037	-0.089	-0.044

LAMPIRAN 11 (Lanjutan)

15. ARIMA (0,1,1)

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.10	5	0.8355	0.023	0.079	-0.060	-0.030	0.050	0.084
12	7.15	11	0.7869	-0.195	-0.071	-0.042	-0.039	0.023	-0.031
18	16.85	17	0.4647	0.003	0.069	0.149	0.168	-0.159	0.054
24	21.81	23	0.5315	-0.150	0.075	-0.065	-0.009	-0.089	-0.010

16. ARIMA (1,1,[1,7,17])

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.38	2	0.1842	0.007	0.025	-0.106	-0.071	0.077	0.101
12	5.62	8	0.6892	-0.012	-0.041	0.009	-0.125	0.053	-0.016
18	9.33	14	0.8090	0.015	0.010	0.101	0.132	-0.002	0.062
24	12.32	20	0.9047	-0.114	0.025	-0.072	0.065	-0.032	-0.013

17. ARIMA (0,1,[1,7,17])

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.23	3	0.3578	0.050	0.092	-0.080	-0.048	0.069	0.087
12	6.43	9	0.6964	-0.050	-0.095	0.007	-0.120	0.057	-0.024
18	10.90	15	0.7597	0.022	0.036	0.124	0.145	-0.001	0.020
24	13.77	21	0.8791	-0.102	0.028	-0.075	0.046	-0.063	-0.018

18. ARIMA (0,1,[1,7])

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.08	4	0.5449	0.043	0.087	-0.085	-0.039	0.063	0.091
12	5.29	10	0.8709	-0.023	-0.085	0.014	-0.094	0.035	-0.050
18	15.23	16	0.5080	0.031	0.051	0.146	0.164	-0.176	0.049
24	19.96	22	0.5856	-0.147	0.072	-0.064	0.035	-0.066	-0.044

19. ARIMA (1,1,[1,17])

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.80	3	0.6143	-0.004	0.040	-0.042	-0.051	0.061	0.089
12	8.55	9	0.4796	-0.220	-0.062	-0.027	-0.089	0.053	-0.013
18	12.88	15	0.6113	-0.001	0.047	0.112	0.145	0.004	0.040
24	16.42	21	0.7454	-0.117	0.048	-0.068	0.017	-0.078	-0.040

LAMPIRAN 11 (Lanjutan)

20. ARIMA (0,1,[1,17])

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.01	4	0.7337	0.015	0.082	-0.042	-0.043	0.049	0.082
12	8.79	10	0.5521	-0.218	-0.067	-0.035	-0.088	0.053	-0.020
18	13.59	16	0.6291	0.005	0.063	0.122	0.149	0.006	0.014
24	17.08	22	0.7590	-0.108	0.044	-0.075	0.013	-0.084	-0.040

21. ARIMA (1,1,[7,17])

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.33	3	0.3433	0.005	0.029	-0.104	-0.070	0.077	0.101
12	5.63	9	0.7766	-0.014	-0.044	0.010	-0.126	0.054	-0.016
18	9.32	15	0.8599	0.016	0.010	0.101	0.132	-0.002	0.060
24	12.33	21	0.9304	-0.114	0.026	-0.073	0.065	-0.034	-0.013

22. ARIMA (0,1,[7,17])

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	11.95	4	0.0177	0.299	0.087	-0.070	-0.056	0.072	0.101
12	13.54	10	0.1952	-0.010	-0.048	-0.035	-0.104	0.011	-0.009
18	20.49	16	0.1989	0.029	0.070	0.160	0.166	0.022	0.025
24	22.51	22	0.4299	-0.098	-0.010	-0.056	0.020	-0.041	-0.039

23. ARIMA (1,1,[7])

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.84	4	0.5843	0.001	0.032	-0.095	-0.056	0.066	0.102
12	4.20	10	0.9378	-0.010	-0.037	0.008	-0.088	0.027	-0.051
18	14.47	16	0.5640	0.023	0.044	0.150	0.156	-0.191	0.047
24	18.79	22	0.6583	-0.140	0.075	-0.050	0.044	-0.052	-0.053

24. ARIMA (0,1,[7])

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	9.94	5	0.0770	0.269	0.077	-0.069	-0.047	0.070	0.101
12	11.11	11	0.4342	-0.019	-0.048	-0.029	-0.078	-0.004	-0.036
18	21.14	17	0.2200	0.031	0.094	0.192	0.151	-0.129	-0.022
24	24.18	23	0.3938	-0.121	0.026	-0.036	0.006	-0.063	-0.062

LAMPIRAN 11 (Lanjutan)

25. ARIMA (1,1,[17])

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
6	1.89	4	0.7552	0.004	0.013	-0.050	-0.053	0.068	0.091	
12	8.48	10	0.5824	-0.219	-0.065	-0.026	-0.085	0.049	-0.009	
18	12.85	16	0.6834	-0.004	0.038	0.111	0.145	-0.000	0.054	
24	16.29	22	0.8013	-0.120	0.046	-0.062	0.014	-0.075	-0.038	

26. ARIMA (0,1,[17])

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
6	9.30	5	0.0978	0.284	0.080	-0.033	-0.038	0.056	0.040	
12	16.77	11	0.1148	-0.205	-0.130	-0.077	-0.076	0.015	-0.006	
18	25.26	17	0.0890	0.018	0.093	0.180	0.178	0.007	0.016	
24	28.46	23	0.1989	-0.103	0.007	-0.060	-0.035	-0.090	-0.046	

LAMPIRAN 12

Hasil Uji White Noise Model ARIMA Yield Tenor 20 Tahun

1.. ARIMA ([1,7],1,1)

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.65	3	0.1989	-0.005	0.050	-0.060	-0.131	0.119	0.091
12	5.37	9	0.8009	0.007	-0.007	0.030	-0.004	0.001	-0.074
18	13.55	15	0.5599	0.040	-0.056	0.113	0.130	-0.163	0.094
24	20.11	21	0.5141	-0.194	0.057	-0.041	-0.035	-0.010	-0.097

2. ARIMA ([1,7],1,0)

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.61	4	0.3299	-0.028	0.085	-0.042	-0.119	0.122	0.081
12	5.44	10	0.8602	0.006	-0.038	0.017	-0.018	0.007	-0.074
18	14.56	16	0.5568	0.050	-0.062	0.110	0.137	-0.170	0.109
24	21.58	22	0.4850	-0.200	0.064	-0.050	-0.035	-0.009	-0.097

3. ARIMA (1,1,1)

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.34	4	0.5032	-0.001	0.035	-0.042	-0.104	0.115	0.074
12	8.66	10	0.5643	-0.185	-0.113	-0.024	0.018	0.018	-0.048
18	17.24	16	0.3703	0.013	-0.017	0.152	0.149	-0.147	0.079
24	23.77	22	0.3595	-0.185	0.068	-0.033	-0.067	-0.057	-0.073

4. ARIMA (1,1,0)

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.19	5	0.6700	-0.009	0.062	-0.028	-0.100	0.109	0.068
12	8.32	11	0.6848	-0.183	-0.109	-0.028	0.012	0.016	-0.047
18	16.98	17	0.4554	0.019	-0.017	0.147	0.149	-0.148	0.088
24	23.77	23	0.4165	-0.190	0.068	-0.039	-0.068	-0.055	-0.073

LAMPIRAN 12 (Lanjutan)

5. ARIMA ([7],1,1)

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
6	4.50	4	0.3431	0.023	0.116	-0.039	-0.101	0.117	0.073	
12	5.93	10	0.8213	-0.012	-0.086	0.006	-0.027	0.015	-0.069	
18	14.63	16	0.5519	0.047	-0.048	0.119	0.145	-0.160	0.097	
24	21.49	22	0.4909	-0.196	0.058	-0.058	-0.042	-0.027	-0.090	

6. ARIMA ([7],1,0)

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
6	9.07	5	0.1063	0.221	0.112	-0.037	-0.086	0.111	0.092	
12	10.28	11	0.5052	-0.008	-0.084	-0.013	-0.024	-0.003	-0.058	
18	16.34	17	0.5001	0.026	-0.019	0.134	0.136	-0.116	0.033	
24	21.84	23	0.5301	-0.167	0.012	-0.055	-0.056	-0.049	-0.089	

7. ARIMA (0,1,1)

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
6	3.25	5	0.6620	0.021	0.100	-0.023	-0.091	0.098	0.057	
12	8.35	11	0.6817	-0.180	-0.111	-0.038	0.004	0.015	-0.046	
18	16.78	17	0.4694	0.025	-0.007	0.144	0.151	-0.143	0.086	
24	23.78	23	0.4161	-0.192	0.062	-0.050	-0.071	-0.058	-0.072	

8. ARIMA (1,1,[1,7])

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
6	4.59	3	0.2041	-0.002	0.051	-0.072	-0.128	0.115	0.087	
12	5.49	9	0.7898	-0.000	-0.050	0.016	-0.022	0.003	-0.070	
18	14.33	15	0.5007	0.042	-0.023	0.133	0.147	-0.165	0.082	
24	20.74	21	0.4750	-0.191	0.062	-0.038	-0.028	-0.016	-0.096	

9. ARIMA (0,1,[1,7])

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
6	4.35	4	0.3611	0.044	0.116	-0.048	-0.092	0.110	0.070	
12	6.57	10	0.7656	-0.015	-0.120	0.016	-0.041	0.021	-0.061	
18	14.88	16	0.5338	0.043	-0.015	0.119	0.155	-0.156	0.081	
24	21.41	22	0.4953	-0.189	0.054	-0.062	-0.039	-0.039	-0.088	

LAMPIRAN 12 (Lanjutan)

10. ARIMA (1,1,[7])

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.33	4	0.3627	-0.014	0.086	-0.056	-0.112	0.116	0.077
12	5.78	10	0.8337	0.004	-0.085	0.019	-0.034	0.014	-0.067
18	14.84	16	0.5362	0.048	-0.025	0.119	0.151	-0.170	0.093
24	21.55	22	0.4871	-0.193	0.064	-0.051	-0.030	-0.020	-0.095

11. ARIMA (0,1,[7])

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	9.32	5	0.0971	0.227	0.116	-0.042	-0.086	0.105	0.090
12	10.44	11	0.4913	-0.005	-0.081	-0.009	-0.031	-0.005	-0.053
18	16.92	17	0.4598	0.033	0.014	0.143	0.141	-0.116	0.024
24	22.49	23	0.4910	-0.167	0.010	-0.055	-0.053	-0.051	-0.092

LAMPIRAN 13

Hasil Uji Normalitas Model ARIMA Yield Tenor 1 Tahun

1. ARIMA([23],1,0)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.959735	Pr < W 0.0052
Kolmogorov-Smirnov	D 0.079802	Pr > D 0.1398
Cramer-von Mises	W-Sq 0.163385	Pr > W-Sq 0.0169
Anderson-Darling	A-Sq 1.206309	Pr > A-Sq <0.0050

2. ARIMA(0,1,[23])

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.959645	Pr < W 0.0051
Kolmogorov-Smirnov	D 0.080285	Pr > D 0.1344
Cramer-von Mises	W-Sq 0.164737	Pr > W-Sq 0.0162
Anderson-Darling	A-Sq 1.22264	Pr > A-Sq <0.0050

3. ARIMA ([23],1,[23])

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.959545	Pr < W 0.0050
Kolmogorov-Smirnov	D 0.079794	Pr > D 0.1399
Cramer-von Mises	W-Sq 0.163412	Pr > W-Sq 0.0169
Anderson-Darling	A-Sq 1.211089	Pr > A-Sq <0.0050

LAMPIRAN 14

Hasil Uji Normalitas Model ARIMA Yield Tenor 5 Tahun

1. ARIMA(1,1,[1,32])

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.990846	Pr < W 0.7623
Kolmogorov-Smirnov	D 0.056244	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.060222	Pr > W-Sq >0.2500
Anderson-Darling	A-Sq 0.342801	Pr > A-Sq >0.2500

2. ARIMA(0,1,[1,32])

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.984216	Pr < W 0.3116
Kolmogorov-Smirnov	D 0.080413	Pr > D 0.1330
Cramer-von Mises	W-Sq 0.111614	Pr > W-Sq 0.0814
Anderson-Darling	A-Sq 0.596667	Pr > A-Sq 0.1211

3. ARIMA(1,1,1)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.979885	Pr < W 0.1521
Kolmogorov-Smirnov	D 0.082555	Pr > D 0.1091
Cramer-von Mises	W-Sq 0.130104	Pr > W-Sq 0.0446
Anderson-Darling	A-Sq 0.744104	Pr > A-Sq 0.0508

4. ARIMA(0,1,1)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.980151	Pr < W 0.1591
Kolmogorov-Smirnov	D 0.082826	Pr > D 0.1060
Cramer-von Mises	W-Sq 0.1289	Pr > W-Sq 0.0459
Anderson-Darling	A-Sq 0.735946	Pr > A-Sq 0.0542

LAMPIRAN 14 (Lanjutan)

5. ARIMA(1,1,[32])

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.991094	Pr < W 0.7807
Kolmogorov-Smirnov	D 0.052806	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.056824	Pr > W-Sq >0.2500
Anderson-Darling	A-Sq 0.329646	Pr > A-Sq >0.2500

6. ARIMA(0,1,[32])

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.965428	Pr < W 0.0130
Kolmogorov-Smirnov	D 0.102262	Pr > D 0.0157
Cramer-von Mises	W-Sq 0.195078	Pr > W-Sq 0.0061
Anderson-Darling	A-Sq 1.120183	Pr > A-Sq 0.0062

7. ARIMA(1,1,0)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.9843	Pr < W 0.3158
Kolmogorov-Smirnov	D 0.083108	Pr > D 0.1029
Cramer-von Mises	W-Sq 0.098742	Pr > W-Sq 0.1182
Anderson-Darling	A-Sq 0.570802	Pr > A-Sq 0.1397

8. ARIMA([1,32],1,1)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.989093	Pr < W 0.6279
Kolmogorov-Smirnov	D 0.062075	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.069276	Pr > W-Sq >0.2500
Anderson-Darling	A-Sq 0.429356	Pr > A-Sq >0.2500

LAMPIRAN 14 (Lanjutan)

9. ARIMA([1,32],1,0)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.989983	Pr < W 0.6966
Kolmogorov-Smirnov	D 0.047314	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.051247	Pr > W-Sq >0.2500
Anderson-Darling	A-Sq 0.361094	Pr > A-Sq >0.2500

10. ARIMA([32],1,1)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.986126	Pr < W 0.4184
Kolmogorov-Smirnov	D 0.068019	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.095077	Pr > W-Sq 0.1324
Anderson-Darling	A-Sq 0.553585	Pr > A-Sq 0.1532

11. ARIMA([32],1,0)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.966409	Pr < W 0.0153
Kolmogorov-Smirnov	D 0.102538	Pr > D 0.0152
Cramer-von Mises	W-Sq 0.1791	Pr > W-Sq 0.0096
Anderson-Darling	A-Sq 1.050894	Pr > A-Sq 0.0090

LAMPIRAN 15

Hasil Uji Normalitas Model ARIMA Yield Tenor 10 Tahun

1. ARIMA([1,7,17],1,1)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.975323	Pr < W 0.0695
Kolmogorov-Smirnov	D 0.074478	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.095865	Pr > W-Sq 0.1293
Anderson-Darling	A-Sq 0.667886	Pr > A-Sq 0.0825

2. ARIMA([1,7,17],1,0)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.976111	Pr < W 0.0796
Kolmogorov-Smirnov	D 0.074344	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.091447	Pr > W-Sq 0.1464
Anderson-Darling	A-Sq 0.640301	Pr > A-Sq 0.0940

3. ARIMA([1,7],1,1)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.970808	Pr < W 0.0320
Kolmogorov-Smirnov	D 0.074317	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.097793	Pr > W-Sq 0.1219
Anderson-Darling	A-Sq 0.711914	Pr > A-Sq 0.0642

4. ARIMA ([1,7],1,0)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.970601	Pr < W 0.0309
Kolmogorov-Smirnov	D 0.073752	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.100333	Pr > W-Sq 0.1121
Anderson-Darling	A-Sq 0.722796	Pr > A-Sq 0.0596

LAMPIRAN 15 (Lanjutan)

5. ARIMA ([1,17],1,1)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.967408	Pr < W 0.0181
Kolmogorov-Smirnov	D 0.096872	Pr > D 0.0264
Cramer-von Mises	W-Sq 0.115015	Pr > W-Sq 0.0736
Anderson-Darling	A-Sq 0.810301	Pr > A-Sq 0.0366

6. ARIMA ([1,17],1,0)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.967244	Pr < W 0.0176
Kolmogorov-Smirnov	D 0.096954	Pr > D 0.0261
Cramer-von Mises	W-Sq 0.116584	Pr > W-Sq 0.0700
Anderson-Darling	A-Sq 0.81847	Pr > A-Sq 0.0349

7. ARIMA ([7,17],1,1)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.977907	Pr < W 0.1084
Kolmogorov-Smirnov	D 0.06939	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.079168	Pr > W-Sq 0.2171
Anderson-Darling	A-Sq 0.569137	Pr > A-Sq 0.1409

8. ARIMA ([7,17],1,0)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.978305	Pr < W 0.1160
Kolmogorov-Smirnov	D 0.077277	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.05591	Pr > W-Sq >0.2500
Anderson-Darling	A-Sq 0.441935	Pr > A-Sq >0.2500

LAMPIRAN 15 (Lanjutan)

9. ARIMA (1,1,1)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.964155	Pr < W 0.0106
Kolmogorov-Smirnov	D 0.094008	Pr > D 0.0381
Cramer-von Mises	W-Sq 0.120657	Pr > W-Sq 0.0607
Anderson-Darling	A-Sq 0.862989	Pr > A-Sq 0.0256

10. ARIMA(1,1,0)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.964137	Pr < W 0.0105
Kolmogorov-Smirnov	D 0.093307	Pr > D 0.0410
Cramer-von Mises	W-Sq 0.12069	Pr > W-Sq 0.0606
Anderson-Darling	A-Sq 0.863294	Pr > A-Sq 0.0256

11. ARIMA ([7],1,1)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.969133	Pr < W 0.0241
Kolmogorov-Smirnov	D 0.065635	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.110318	Pr > W-Sq 0.0843
Anderson-Darling	A-Sq 0.773289	Pr > A-Sq 0.0443

12. ARIMA([7],1,0)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.973867	Pr < W 0.0541
Kolmogorov-Smirnov	D 0.065501	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.067609	Pr > W-Sq >0.2500
Anderson-Darling	A-Sq 0.50586	Pr > A-Sq 0.2061

LAMPIRAN 15 (Lanjutan)

13. ARIMA ([17],1,1)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.968391	Pr < W 0.0213
Kolmogorov-Smirnov	D 0.075114	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.101295	Pr > W-Sq 0.1084
Anderson-Darling	A-Sq 0.751803	Pr > A-Sq 0.0488

14. ARIMA ([17],1,0)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.968395	Pr < W 0.0213
Kolmogorov-Smirnov	D 0.074525	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.080671	Pr > W-Sq 0.2083
Anderson-Darling	A-Sq 0.624844	Pr > A-Sq 0.1008

15. ARIMA (0,1,1)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.962143	Pr < W 0.0076
Kolmogorov-Smirnov	D 0.075711	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.123131	Pr > W-Sq 0.0550
Anderson-Darling	A-Sq 0.897093	Pr > A-Sq 0.0221

16. ARIMA (1,1[1,7,17])

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.979404	Pr < W 0.1401
Kolmogorov-Smirnov	D 0.062011	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.071664	Pr > W-Sq >0.2500
Anderson-Darling	A-Sq 0.528531	Pr > A-Sq 0.1809

LAMPIRAN 15 (Lanjutan)

17. ARIMA (0,1,[1,7,17])

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.979226	Pr < W 0.1359
Kolmogorov-Smirnov	D 0.072928	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.070933	Pr > W-Sq >0.2500
Anderson-Darling	A-Sq 0.507837	Pr > A-Sq 0.2039

18. ARIMA (0,1,[1,7])

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.967259	Pr < W 0.0176
Kolmogorov-Smirnov	D 0.080299	Pr > D 0.1343
Cramer-von Mises	W-Sq 0.115397	Pr > W-Sq 0.0727
Anderson-Darling	A-Sq 0.801961	Pr > A-Sq 0.0383

19. ARIMA (1,1,[1,17])

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.969969	Pr < W 0.0278
Kolmogorov-Smirnov	D 0.086255	Pr > D 0.0813
Cramer-von Mises	W-Sq 0.09544	Pr > W-Sq 0.1310
Anderson-Darling	A-Sq 0.696012	Pr > A-Sq 0.0708

20. ARIMA (0,1,[1,17])

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.96952	Pr < W 0.0258
Kolmogorov-Smirnov	D 0.073606	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.09205	Pr > W-Sq 0.1441
Anderson-Darling	A-Sq 0.694831	Pr > A-Sq 0.0713

LAMPIRAN 15 (Lanjutan)

21. ARIMA (1,1,[7,17])

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.979513	Pr < W 0.1427
Kolmogorov-Smirnov	D 0.061854	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.071557	Pr > W-Sq >0.2500
Anderson-Darling	A-Sq 0.525338	Pr > A-Sq 0.1845

22. ARIMA (0,1,[7,17])

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.980758	Pr < W 0.1763
Kolmogorov-Smirnov	D 0.058914	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.042649	Pr > W-Sq >0.2500
Anderson-Darling	A-Sq 0.368234	Pr > A-Sq >0.2500

23. ARIMA (1,1,[7])

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.966894	Pr < W 0.0166
Kolmogorov-Smirnov	D 0.071694	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.118662	Pr > W-Sq 0.0653
Anderson-Darling	A-Sq 0.825838	Pr > A-Sq 0.0334

24. ARIMA (0,1,[7])

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.971685	Pr < W 0.0372
Kolmogorov-Smirnov	D 0.070436	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.06733	Pr > W-Sq >0.2500
Anderson-Darling	A-Sq 0.524095	Pr > A-Sq 0.1859

LAMPIRAN 15 (Lanjutan)

25. ARIMA (1,1,[17])

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.969337	Pr < W 0.0250
Kolmogorov-Smirnov	D 0.091909	Pr > D 0.0467
Cramer-von Mises	W-Sq 0.100795	Pr > W-Sq 0.1103
Anderson-Darling	A-Sq 0.724995	Pr > A-Sq 0.0587

26. ARIMA (0,1,[17])

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.9692	Pr < W 0.0244
Kolmogorov-Smirnov	D 0.073798	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.078378	Pr > W-Sq 0.2218
Anderson-Darling	A-Sq 0.60828	Pr > A-Sq 0.1127

LAMPIRAN 16

Hasil Uji Normalitas Model ARIMA Yield Tenor 20 Tahun

1.. ARIMA ([1,7],1,1)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.977926	Pr < W 0.1088
Kolmogorov-Smirnov	D 0.093822	Pr > D 0.0389
Cramer-von Mises	W-Sq 0.104068	Pr > W-Sq 0.0986
Anderson-Darling	A-Sq 0.685441	Pr > A-Sq 0.0752

2. ARIMA ([1,7],1,0)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.976599	Pr < W 0.0865
Kolmogorov-Smirnov	D 0.09029	Pr > D 0.0553
Cramer-von Mises	W-Sq 0.101763	Pr > W-Sq 0.1065
Anderson-Darling	A-Sq 0.690558	Pr > A-Sq 0.0731

3. ARIMA (1,1,1)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.973541	Pr < W 0.0511
Kolmogorov-Smirnov	D 0.095922	Pr > D 0.0303
Cramer-von Mises	W-Sq 0.112509	Pr > W-Sq 0.0793
Anderson-Darling	A-Sq 0.762744	Pr > A-Sq 0.0465

4. ARIMA (1,1,0)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.97327	Pr < W 0.0488
Kolmogorov-Smirnov	D 0.099029	Pr > D 0.0217
Cramer-von Mises	W-Sq 0.112919	Pr > W-Sq 0.0784
Anderson-Darling	A-Sq 0.769368	Pr > A-Sq 0.0451

LAMPIRAN 16 (Lanjutan)

5. ARIMA ([7],1,1)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.97728	Pr < W 0.0973
Kolmogorov-Smirnov	D 0.089216	Pr > D 0.0622
Cramer-von Mises	W-Sq 0.106038	Pr > W-Sq 0.0941
Anderson-Darling	A-Sq 0.699551	Pr > A-Sq 0.0693

6. ARIMA ([7],1,0)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.986903	Pr < W 0.4687
Kolmogorov-Smirnov	D 0.068504	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.066046	Pr > W-Sq >0.2500
Anderson-Darling	A-Sq 0.423902	Pr > A-Sq >0.2500

7. ARIMA (0,1,1)

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.974549	Pr < W 0.0608
Kolmogorov-Smirnov	D 0.088166	Pr > D 0.0690
Cramer-von Mises	W-Sq 0.107752	Pr > W-Sq 0.0902
Anderson-Darling	A-Sq 0.746957	Pr > A-Sq 0.0498

8. ARIMA (1,1,[1,7])

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.973417	Pr < W 0.0500
Kolmogorov-Smirnov	D 0.091315	Pr > D 0.0491
Cramer-von Mises	W-Sq 0.121956	Pr > W-Sq 0.0577
Anderson-Darling	A-Sq 0.803503	Pr > A-Sq 0.0380

LAMPIRAN 16 (Lanjutan)

9. ARIMA (0,1,[1,7])

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.977875	Pr < W 0.1078
Kolmogorov-Smirnov	D 0.093107	Pr > D 0.0418
Cramer-von Mises	W-Sq 0.097481	Pr > W-Sq 0.1231
Anderson-Darling	A-Sq 0.65964	Pr > A-Sq 0.0859

10. ARIMA (1,1,[7])

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.973969	Pr < W 0.0550
Kolmogorov-Smirnov	D 0.086609	Pr > D 0.0790
Cramer-von Mises	W-Sq 0.111092	Pr > W-Sq 0.0826
Anderson-Darling	A-Sq 0.756104	Pr > A-Sq 0.0479

11. ARIMA (0,1,[7])

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.987066	Pr < W 0.4798
Kolmogorov-Smirnov	D 0.067788	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.065369	Pr > W-Sq >0.2500
Anderson-Darling	A-Sq 0.413888	Pr > A-Sq >0.2500

LAMPIRAN 17

Listing Program Kalman Filter untuk Estimasi Parameter Model ARIMA Yield Tenor 1 Tahun

```
%Model Terbaik = ARIMA(0,1,[23])

%Data yang diperlukan
a=xlsread('Data_Asli_1.xlsx'); %Data Aktual
Yield Periode Januari 2010 hingga Maret 2018
b=xlsread('Residual_1.xlsx'); %Data Residual
c=xlsread('Forecast_1.xlsx'); %Data Peramalan
ARIMA
b(96)=-0.4626;
b(97)=-0.1026;
b(98)= 0.0765;
b(99)= 0.2643;

%Tahap Inisialisasi
n =length(a); %Jumlah data
Q =0.001; %System noise strength
R =0.0001; %Measurement noise strength
Qk =eye(2)*Q; %Nilai matriks error kovarian
noise
Rk =R; %Nilai matriks error kovarian
measurement
x0 =[0.28217;5.6]; %Nilai matriks x0 awal
P =eye(2)*0.05; %Nilai matriks error kovarian
sistem awal
H =[0 1]; %Nilai matriks H
x0kf=x0;
xtot0=x0;
xsist0=x0;
x0sist=x0;

for t=97:n
A = [ 0 1 ;
      -b(t-23) 0];
B = [0; a(t-1)+b(t)];
z = a(t);
%Tahap Prediksi
xpre = A*x0kf+B;
Ppre = A*P*A'+Qk;
```

LAMPIRAN 17 (Lanjutan)

```
%Tahap Koreksi
Kgain = Ppre*H'*inv(H*Ppre*H'+Rk); %Kalman gain
Pkor = (eye(2)-Kgain*H)*Ppre; %Kovarian error
xkor = xpre + Kgain*(z-(H*xpre)); %Estimasi
x0kf = xkor;
P = Pkor;
xtot = [xtot0 xkor];
xtot0 = xtot;
end

figure(1)
hold on
plot(xtot(2,2:4), 'r')
plot(c, 'g')
plot(a(97:n), '--*b')
title('Prediksi Yield Tenor 1 Tahun')
legend('ARIMA-Filter Kalman', 'ARIMA', 'Nilai
Aktual')
xlabel('Bulan ke-')
ylabel('Nilai Yield')

smape(1) = 0;
smapekf(1) = 0;
for t=1:3
% Persamaan Mape ARIMA
ap1(t) = (abs(a(96+t)-c(t))/a(96+t))*100;
smape(t+1) = ap1(t)+smape(t);
% Persamaan Mape Filter Kalman
ape(t) = (abs(a(96+t)-
xtot(2,t+1))/a(96+t))*100;
smapekf(t+1)= ape(t)+smapekf(t);
end

mape_arima = smape(t+1)/3; % MAPE ARIMA
strcat('MAPE ARIMA = ', num2str(mape_arima))
mape_kf=smapekf(t+1)/3; % MAPE KF-ARIMA
strcat('MAPE Filter Kalman = ', num2str(mape_kf))
```

LAMPIRAN 18

Listing Program Kalman Filter untuk Estimasi Parameter Model ARIMA Yield Tenor 5 Tahun

```
%Model Terbaik = ARIMA(0,1,[1,32])
%Data yang diperlukan
a=xlsread('Data_Asli_5.xlsx'); %Data Aktual
Yield Periode Januari 2010 hingga Maret 2018
b=xlsread('Residual_5.xlsx'); %Data Residual
c=xlsread('Forecast_5.xlsx'); %Data Peramalan
ARIMA
b(96)= 0.0057;
b(97)=-0.2053;
b(98)= 0.0237;
b(99)= 0.3993;

%Tahap Inisialisasi
n =length(a); %Jumlah data
Q =0.001; %System noise strength
R =0.0001; %Measurement noise strength
Qk =eye(3)*Q; %Nilai matriks error kovarian
noise
Rk =R; %Nilai matriks error kovarian
measurement
x0 =[-0.337;0.329;5.8]; %Nilai matriks x0 awal
P =eye(3)*0.05; %Nilai matriks error kovarian
sistem awal
H =[0 0 1]; %Nilai matriks H
x0kf=x0;
xtot0=x0;
xsist0=x0;
x0sist=x0;
for t=97:n
A =[1 0 0;
0 1 0;
-b(t-1) -b(t-32) 0];
B = [0; 0; a(t-1)+b(t)];
z = a(t);
%Tahap Prediksi
xpre = A*x0kf+B;
Ppre = A*P*A'+Qk;
```

LAMPIRAN 18 (Lanjutan)

```

%Tahap Koreksi
Kgain = Ppre*H'*inv(H*Ppre*H'+Rk); %Kalman gain
Pkor = (eye(3)-Kgain*H)*Ppre; %Kovarian error
xkor = xpre + Kgain*(z-(H*xpre)); %Estimasi
x0kf = xkor;
P = Pkor;
xtot = [xtot0 xkor];
xtot0 = xtot;
end

figure(1)
hold on
plot(xtot(3,2:4), 'r')
plot(c, 'g')
plot(a(97:n), '--*b')
title('Prediksi Yield Tenor 5 Tahun')
legend('ARIMA-Filter Kalman', 'ARIMA', 'Nilai
Aktual')
xlabel('Bulan ke-')
ylabel('Nilai Yield')

smape(1) = 0;
smapekf(1) = 0;
for t=1:3
% Persamaan Mape ARIMA
ap1(t) = (abs(a(96+t)-c(t))/a(96+t))*100;
smape(t+1) = ap1(t)+smape(t);
% Persamaan Mape Filter Kalman
ape(t) = (abs(a(96+t)-
xtot(3,t+1))/a(96+t))*100;
smapekf(t+1)= ape(t)+smapekf(t);
end
mape_arima = smape(t+1)/3; % MAPE ARIMA
strcat('MAPE ARIMA = ', num2str(mape_arima))
mape_kf=smapekf(t+1)/3; % MAPE KF-ARIMA
strcat('MAPE Filter Kalman = ', num2str(mape_kf))

```

LAMPIRAN 19

Listing Program Kalman Filter untuk Estimasi Parameter Model ARIMA Yield Tenor 10 Tahun

```
%Model Terbaik = ARIMA(0,1,1)
%Data yang diperlukan
a=xlsread('Data_Asli_10(trans).xlsx'); %Data
Aktual Yield Periode Januari 2010 hingga Maret
2018
b=xlsread('Residual_10.xlsx'); %Data Residual
c=xlsread('Forecast_10.xlsx'); %Data Peramalan
ARIMA
b(96)=-0.0039;
b(97)=-0.0126;
b(98)= 0.0105;
b(99)= 0.0273;

%Tahap Inisialisasi
n =length(a); %Jumlah data
Q =0.001; %System noise strength
R =0.0001; %Measurement noise strength
Qk =eye(2)*Q; %Nilai matriks error kovarian
noise
Rk =R; %Nilai matriks error kovarian
measurement
x0 =[-0.234;1.59]; %Nilai matriks x0 awal
P =eye(2)*0.05; %Nilai matriks error kovarian
sistem awal
H =[0 1]; %Nilai matriks H
x0kf=x0;
xtot0=x0;
xsist0=x0;
x0sist=x0;
for t=97:n
A = [1 0 ;
     -b(t-96) 0];
B = [0; a(t-1)+b(t)];
z = a(t);

%Tahap Prediksi
xpre = A*x0kf+B;
Ppre = A*P*A' +Qk;
```

LAMPIRAN 19 (Lanjutan)

```
%Tahap Koreksi
Kgain = Ppre*H'*inv(H*Ppre*H'+Rk); %Kalman gain
Pkor = (eye(2)-Kgain*H)*Ppre; %Kovarian error
xkor = xpre + Kgain*(z-(H*xpre)); %Estimasi
x0kf = xkor;
P = Pkor;
xtot = [xtot0 xkor];
xtot0 =xtot;
end

figure(1)
hold on
plot(xtot(2,2:4), 'r')
plot(c, 'g')
plot(a(97:n), '--*b')
title('Prediksi Yield Tenor 10 Tahun')
legend('ARIMA-Filter Kalman', 'ARIMA', 'Nilai
Aktual')
xlabel('Bulan ke-')
ylabel('Nilai Yield')

smape(1) = 0;
smapekf(1) = 0;
for t=1:3
% Persamaan Mape ARIMA
apl(t) = (abs(a(96+t)-c(t)))/a(96+t))*100;
smape(t+1) = apl(t)+smape(t);
% Persamaan Mape Filter Kalman
ape(t) = (abs(a(96+t)-
xtot(2,t+1)))/a(96+t))*100;
smapekf(t+1)= ape(t)+smapekf(t);
end

mape_arima = smape(t+1)/3; % MAPE ARIMA
strcat('MAPE ARIMA = ', num2str(mape_arima))
mape_kf=smapekf(t+1)/3; % MAPE KF-ARIMA
strcat('MAPE Filter Kalman = ', num2str(mape_kf))
```

LAMPIRAN 20

Listing Program Kalman Filter untuk Estimasi Parameter Model ARIMA Yield Tenor 10 Tahun

```
%Model Terbaik = ARIMA(0,1,[1,32])
%Data yang diperlukan
a=xlsread('Data_Asli_20(trans).xlsx'); %Data
Aktual Yield Periode Januari 2010 hingga Maret
2018
b=xlsread('Residual_20.xlsx'); %Data Residual
c=xlsread('Forecast_20.xlsx'); %Data Peramalan
ARIMA
b(96)= 0.0068;
b(97)=-0.0190;
b(98)= 0.0159;
b(99)= 0.0263;

%Tahap Inisialisasi
n =length(a); %Jumlah data
Q =0.001; %System noise strength
R =0.0001; %Measurement noise strength
Qk =eye(3)*Q; %Nilai matriks error kovarian
noise
Rk =R; %Nilai matriks error kovarian
measurement
x0 =[0.2263;0.2060;1.6]; %Nilai matriks x0 awal
P =eye(3)*0.05; %Nilai matriks error kovarian
sistem awal
H =[0 0 1]; %Nilai matriks H
x0kf=x0;
xtot0=x0;
xsist0=x0;
x0sist=x0;
for t=97:n
A = [1 0 0 ;
      0 1 0 ;
      (a(t-1)-a(t-2)) -b(t-7) 0];
B = [0; 0; a(t-1)+b(t)];
z = a(t);
%Tahap Prediksi
xpre = A*x0kf+B;
Ppre = A*P*A'+Qk;
```

LAMPIRAN 20 (Lanjutan)

```
%Tahap Koreksi
Kgain = Ppre*H'*inv(H*Ppre*H'+Rk); %Kalman gain
Pkor = (eye(3)-Kgain*H)*Ppre; %Kovarian error
xkor = xpre + Kgain*(z-(H*xpre)); %Estimasi
x0kf = xkor;
P = Pkor;

xtot = [xtot0 xkor];
xtot0 =xtot;
end

figure(1)
hold on
plot(xtot(3,2:4), 'r')
plot(c, 'g')
plot(a(97:n), '--*b')
title('Prediksi Yield Tenor 20 Tahun')
legend('ARIMA-Filter Kalman', 'ARIMA', 'Nilai
Aktual')
xlabel('Bulan ke-')
ylabel('Nilai Yield')

smape(1) = 0;
smapekf(1) = 0;
for t=1:3
% Persamaan Mape ARIMA
ap1(t) = (abs(a(96+t)-c(t))/a(96+t))*100;
smape(t+1) = ap1(t)+smape(t);
% Persamaan Mape Filter Kalman
ape(t) = (abs(a(96+t)-
xtot(3,t+1))/a(96+t))*100;
smapekf(t+1)= ape(t)+smapekf(t);
end
mape_arima = smape(t+1)/3; % MAPE ARIMA
strcat('MAPE ARIMA = ', num2str(mape_arima))
mape_kf=smapekf(t+1)/3; % MAPE KF-ARIMA
strcat('MAPE Filter Kalman = ', num2str(mape_kf))
```

BIODATA PENULIS



Nama lengkap penulis adalah Wulan Dwi Puspitasari, lahir di Malang pada tanggal 14 Juli 1996. Pendidikan formal yang ditempuh yaitu TK Dharma Wanita (1999-2001), SDN 3 Bangorejo (2002-2007), SMPN 1 Cluring (2007-2011), dan SMAN 1 Genteng (2011-2014). Pada tahun 2014, penulis melanjutkan pendidikan ke jenjang S-1 dengan diterima di Institut Teknologi Sepuluh Nopember (ITS) Surabaya di Departemen Matematika dengan bidang minat matematika terapan. Selama menempuh perkuliahan penulis mengikuti beberapa kegiatan organisasi mahasiswa seperti menjadi *staff* Departemen Dalam Negeri HIMATIKA ITS 2015/2016, *Kabiro Kajian Strategis Internal Affair Department HIMATIKA ITS 2016/2017*, Pemandu ITS. Selain itu penulis juga menjadi salah satu Asisten Dosen Kalkulus ITS.

Kontak bisa dihubungi :

Email : wulan.dwipuspitasari@gmail.com