



PERPUSTAKAAN PUSAT
UNIVERSITAS INDONESIA

DEPARTEMEN PENDIDIKAN NASIONAL
UNIVERSITAS INDONESIA
FAKULTAS EKONOMI
PROGRAM STUDI MAGISTER MANAJEMEN

KARYA AKHIR

CHAOS DALAM FUTURES PRICES CPO

(Studi Empiris pada Commodity and Monetary Exchange of Malaysia)

Diajukan Oleh :

KIE ENG TJUN
66 99 24 073 X

T

382.4
Kie
e (1)

UNTUK MEMENUHI SEBAGIAN DARI SYARAT-SYARAT
GUNA MENCAPAI GELAR
MAGISTER MANAJEMEN
2001



UNIVERSITAS INDONESIA
FAKULTAS EKONOMI
PROGRAM STUDI MAGISTER MANAJEMEN

TANDA PERSETUJUAN KARYA AKHIR

Nama : Kie Eng Tjun
Nomor Mahasiswa : 66 99 24 073 X
Konsentrasi : Manajemen Internasional

Judul Karya Akhir : Chaos dalam Futures Prices CPO
(Studi Empiris pada Commodity andd Monetary Exchange
of Malaysia)

PERPUSTAKAAN PUSAT
UNIVERSITAS INDONESIA
-Pembelian/Hadiah dari

FE

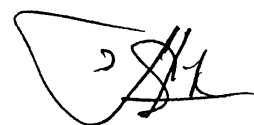
Diterima tgl: 15 NOV 2001

06898

Tanggal : 20/7/01
Ketua Program Studi
Magister Manajemen


: Dr. Ronny K. Muntoro

Tanggal : 20/7/01
Pembimbing Karya Akhir : Dr. Bambang Hermanto



Zen mind, Beginners's mind

It is the open mind,

the attitude that includes both doubt and possibility,

the ability to see things always as fresh and new

In the Beginner's mind there are many possibilities,

but in the Expert's there are few

- Zen Master



Untuk istriku tersayang, Ivonne

Dukungan, dorongan, dan terutama cintamu

mewujudkan ini

Dan untuk buah kasih kita berdua, Gaby

Keceriaannya mewarnai kehidupan kita

Kita akan selalu bersama dalam naungan kasihNya

KATA PENGANTAR

Puji syukur bagi Allah Yang Maha Tinggi atas segala karunia yang dilimpahkan-Nya sehingga penulis dapat menyelesaikan karya akhir ini. Karya akhir ini merupakan laporan dari hasil penelitian yang telah dilakukan penulis sebagai salah satu syarat untuk memperoleh gelar Magister Manajemen pada Program Studi Magister Manajemen Universitas Indonesia.

Selesainya karya akhir ini tidak terlepas dari bantuan dari berbagai pihak. Terima kasih dan penghargaan setingginya penulis sampaikan kepada :

1. Bapak Dr. Bambang Hermanto, selaku dosen pembimbing karya akhir atas segala arahan dan masukan yang diberikan. Keterbukaan dan kebebasan yang diberikan beliau kepada penulis untuk mengeksplorasi “wilayah yang kurang dikenal” memungkinkan terwujudnya karya akhir ini.
2. Bapak Dr. Ronny K. Muntoro selaku Ketua Program Studi Magister Manajemen Universitas Indonesia.
3. Seluruh dosen MM-UI yang telah membagikan ilmunya.
4. Seluruh staf dan karyawan MM-UI.

Dengan segala kerendahan hati, penulis menyadari bahwa karya akhir ini masih banyak kekurangannya. Semoga penelitian-penelitian selanjutnya memperbaiki kekurangan yang ada.

Jakarta, Mei 2001

Penulis.

RINGKASAN EKSEKUTIF

Futures prices series CPO (crude palm oil) COMMEMEX Malaysia sepanjang 20 tahun (23 Okt 1980 – 31 Mar 2000) menunjukkan distribusi yang tidak normal (leptokurtis), memiliki pola autokorelasi yang sangat lambat menuju nol, dan tampak memiliki suatu siklus nonperiodik. Penyimpangan dari normalitas dapat merupakan simptom adanya proses nonlinier dinamis.

Pengujian ARCH standar dengan LM Test menunjukkan adanya efek ARCH. Tetapi pola autokorelasi residual kuadrat dari semua frekwensi *time series* yang diteliti (bulanan, mingguan, dan harian) meluruh dengan sangat lambat dan tidak teratur, dan keadaan ini bukanlah perilaku dari proses ARCH. Proses ARCH umumnya memiliki *unconditional third moment* sama dengan nol, yaitu distribusi yang simetris, tetapi semua *time series* dalam penelitian ini menunjukkan *skewness* yang positif (*positively skewed*).

Model GARCH(1,1) mencirikan bahwa *unconditional second moment* pada *time series* adalah tidak terhingga. Tetapi Dickey–Fuller Test dan Phillips–Perron Test semuanya menyimpulkan bahwa *time series* adalah stasioner dengan nilai rata-rata dan variansi yang terhingga. Sehingga model GARCH(1,1) juga kurang cocok merepresentasikan *prices series CPO COMMEMEX Malaysia*.

Komoditi minyak kelapa sawit (*palm oil*) dalam perdagangan minyak nabati dunia dewasa ini menduduki urutan kedua setelah minyak kedelai (*soybean oil*). Malaysia tercatat sebagai produsen CPO (*crude palm oil*) terbesar di dunia, kontribusinya adalah 49,7 % dari total produksi CPO dunia. Minyak sawit dan minyak inti sawit bagi Malaysia merupakan penghasil devisa terbesar setelah minyak. Sekarang ini Malaysia mengeksport 99,8 % dari

minyak sawitnya dalam bentuk produk-produk rafinasi dan fraksinasi. Industri sawit di Malaysia dikelola dengan sangat baik dan ditunjang oleh rencana pembangunan 5 tahun Malaysia.

Mempertimbangkan hal-hal di atas, maka pergerakan harga CPO seharusnya ada unsur deterministiknya tidak sekedar pergerakan yang random. Juga diharapkan adanya suatu siklus pergerakan harga CPO yang berkaitan dengan faktor-faktor deterministik tersebut. Dalam karya akhir ini penulis bertujuan membuktikan eksistensi *deterministic chaos* dalam *future prices* CPO COMMEMX Malaysia.

Proses *chaotic* dapat menunjukkan perilaku stokastik yang dibangkitkan oleh suatu sistem deterministik. Karena dinamika yang teramati tampak seperti proses random, maka metoda konvensional akan cenderung menyimpulkan proses tersebut sebagai *random walk*. Sistem nonlinear dinamis tidak menghasilkan suatu solusi optimal tunggal, ia menghasilkan suatu ruang kemungkinan solusi berganda (*multiple possible solutions*), sehingga tidak berlaku konsep equilibrium statis. Sistem nonlinear dinamis merupakan suatu *time-dependent feedback mechanism*, dengan demikian sistem harus dipandang sebagai proses yang memiliki suatu *memory*, bukannya suatu proses yang *independent*.

Karakteristik *chaos* yang penting adalah adanya *attractor* berdimensi *fractal* (noninteger). Algoritma yang dikembangkan oleh Grassberger & Procaccia mengestimasi nilai *fractal dimension* ini dengan *correlation dimension*. Karakteristik penting lainnya yang dapat menjelaskan perilaku *deterministic chaos* adalah maximum Lyapunov exponent yang bertanda positif. Penulis menggunakan algoritma Wolf untuk menghitung maximum Lyapunov exponent secara numerik.

Parameter penting yang diperlukan oleh kedua algoritma ini yaitu panjang rata-rata siklus nonperiodik diperoleh dengan menggunakan R/S Analysis yang dikembangkan oleh Hurst. Ditemukan panjang rata-rata siklus nonperiodik adalah 42 bulan.

Penulis menemukan *correlation dimension* dan Maximum Lyapunov exponent untuk ketiga frekwensi data *futures prices series* CPO COMMEMX Malaysia (bulanan, mingguan, dan harian), untuk ketiga *time series* tersebut *correlation dimension* terletak antara 1 – 2, yang merupakan *low dimension chaos*. Maximum Lyapunov exponent untuk ketiga *time series* adalah masing-masing 0,0638, 0,006, dan 0,0037.

Noninteger correlation dimension dan maximum Lyapunov exponent yang positif mengindikasikan adanya proses *deterministic chaos*.

Temuan struktur *chaotic* akan berimplikasi terhadap semakin mendalamnya pengertian kita tentang perilaku dari *futures markets* seperti prediktabilitas dan persistensi *futures prices*, adanya siklus intrinsik yang nonperiodik, dan dapat memberikan saran-saran untuk pemodelan yang lebih baik.

DAFTAR ISI

	Halaman
KATA PENGANTAR	i
RINGKASAN EKSEKUTIF	ii
DAFTAR ISI	v
DAFTAR GAMBAR	x
DAFTAR TABEL	xiii
DAFTAR LAMPIRAN	xvi
BAB I PENDAHULUAN	1
1.1 LATAR BELAKANG	1
1.2 PERUMUSAN MASALAH	2
1.3 TUJUAN PENELITIAN	3
1.4 LINGKUP PENELITIAN	4
1.5 SISTEMATIKA PENELITIAN	4
1.6 SISTEMATIKA PENULISAN	6
BAB II TELAAH KEPUSTAKAAN	8
2.1 FUTURES PRICES	8
2.2 SIFAT SISTEM NONLINIER	9
2.3 MEMBEDAKAN PROSES STOKASTIK DAN DETERMINISTIC CHAOS	13

2.4	PHASE SPACE	15
2.5	PHASE POTRAIT DARI SISTEM YANG DIKETAHUI PERSAMA- AN GERAKNYA	17
2.6	PHASE POTRAIT DARI SISTEM YANG TIDAK DIKETAHUI PERSAMAAN GERAKNYA	18
2.7	REKONSTRUKSI DYNAMICAL SYSTEM DALAM PHASE SPACE	21
2.8	FRACTAL DIMENSION	23
2.9	GEOMETRI ATTRACTOR DAN FRACTAL	25
2.10	CORRELATION DIMENSION	26
2.11	CORRELATION INTEGRAL DARI SUATU TIME SERIES	27
2.12	TEMPORAL CORRELATION	28
2.13	LYAPUNOV EXPONENT	30
2.14	MENGHITUNG MAXIMUM LYAPUNOV EXPONENT PADA TIME SERIES	32
2.15	HAL-HAL YANG PERLU DIPERHATIKAN PADA UJI EMPIRIS	34
2.15.1	Data Yang Terlalu Jarang	34
2.15.2	Noise	35
2.15.3	Persamaan Kontinu, Persamaan Diskrit, dan Skala Waktu	37
2.15.4	Data Empiris Biasanya Terletak Di “Daerah Abu-abu”	38
2.15.5	Prinsip Superposisi Tidak Berlaku Pada Sistem Nonlinier	39
2.15.6	Masalah Differencing : Proses Whitening	39
2.15.7	Perubahan Attractor Oleh Residual Test	40
2.15.8	Nonstasionaritas dan Nonnormalitas	41

2.16	RESCALED RANGE (R/S) ANALYSIS	42
BAB III	SISTEMATIKA PENELITIAN	48
3.1	PERLUKAH ANALISIS NONLINIER ?	48
3.2	TAHAPAN PENELITIAN	48
3.3	DATA TREATMENT	50
3.4	PENGUJIAN NORMALITAS	53
3.5	PENGUJIAN STASIONARITAS	54
3.6	PENGAMATAN POLA AUTOKORELASI	54
3.7	PENGUJIAN ARCH	55
3.8	RESCALED RANGE ANALYSIS (R/S ANALYSIS)	57
3.9	ESTIMASI CORRELATION DIMENSION	60
3.10	PERHITUNGAN NUMERIK MAXIMUM LYAPUNOV EXPONENT	64
BAB IV	ANALISIS DAN PEMBAHASAN	68
4.1	NORMALITAS	68
4.2	STASIONARITAS	68
4.3	PENGAMATAN STRUKTUR AUTOKORELASI	69
4.4	PENGUJIAN ARCH	71
4.5	R/S ANALYSIS	74
4.5.1	Time Series Data Bulanan (MAL)	74
4.5.2	Time Series Data Mingguan (WAL)	77
4.5.3	Time Series Data Harian (DAL)	78

4.6	ESTIMASI CORRELATION DIMENSION	81
4.6.1	Estimasi Correlation Dimension Pada Time Series MA1	81
4.6.1.1	Tanpa Noise Filtering dan Penghilangan Efek Temporal Correlation	81
4.6.1.2	Noise Filtering dan Penghilangan efek Temporal Correlation	86
4.6.1.3	Shuffled Test Atau Scrambling Test	89
4.6.2	Estimasi Correlation Dimension Pada Time Series WA1	91
4.6.2.1	Tanpa Noise Filtering dan Penghilangan Efek Temporal Correlation	91
4.6.2.2	Noise Filtering dan Penghilangan efek Temporal Correlation	93
4.6.2.3	Shuffled Test Atau Scrambling Test	95
4.6.3	Estimasi Correlation Dimension Pada Time Series DA1	96
4.6.3.1	Tanpa Noise Filtering dan Penghilangan Efek Temporal Correlation	96
4.6.3.2	Noise Filtering dan Penghilangan efek Temporal Correlation	98
4.6.3.3	Shuffled Test Atau Scrambling Test	100
4.7	ESTIMASI MAXIMUM LYAPUNOV EXPONENT	105
4.7.1	Estimasi Maximum Lyapunov Pada Time Series MA1	105
4.7.2	Estimasi Maximum Lyapunov Pada Time Series MA1	106
4.7.3	Estimasi Maximum Lyapunov Pada Time Series MA1	108
4.8	ANALISIS AKHIR UNTUK PEMBUKTIAN CHAOS	109
4.9	IMPLIKASI DARI TEMUAN CHAOS	111
4.10	PREDIKTABILITAS FUTURES PRICES	113

4.11	MANFAAT TEMUAN CHAOS DALAM FUTURES MARKET CPO	114
BAB V	KESIMPULAN DAN SARAN	119
5.1	KESIMPULAN	119
5.2	SARAN	121
DAFTAR PUSTAKA		124



DAFTAR GAMBAR

Gambar	Halaman	
2.1	Grafik Persamaan Logistic : Nilai Kritis	10
2.2	Bifurcation Diagram : Persamaan Logistic	11
2.3	Grafik Henon : Sensitive Dependence On Initial Condition	12
2.4	Henon Map : Time Series x dan y	17
2.5	Henon Map : Phase Potrait	18
2.6	Duplikasi Phase Potrait Henon Map	19
2.7	Sketsa Algoritma Wolf	34
2.8	Hubungan Antara Pendekatan Deterministik dan Probabilistik	42
3.1	Diagram Alir Tahap Penelitian	50
4.1	R/S Plot dan V Statistics : Data Bulanan MAL	75
4.2	R/S Plot dan V Statistics : Data Mingguan WAL	77
4.3	R/S Plot dan V Statistics : Data Harian DAL	79
4.4	Grafik $\log C(m, \epsilon)$ vs $\log \epsilon$ dan Grafik Slopes vs $\log \epsilon$, MA1	82
4.5	Sampel Time Series MA1 Yang Difilter	85
4.6	Pengaruh Filtrasi Terhadap Daerah Plateau	85
4.7	Space-Time Separation Plot MA1	86
4.8	Slopes Setelah Noise Filtering 1 % , LAG = 50, MA1	87
4.9	Slopes Setelah Noise Filtering 5 % dan 10 % , LAG = 50, MA1	88
4.10	Slopes Setelah Noise Filtering 5 % , LAG = 25 dan 64 , MA1	89
4.11	Grafik $\log C(m, \epsilon)$ vs $\log \epsilon$ dan Slopes vs $\log \epsilon$, Shuffled MA1	90

4.12	Grafik Log $C(m, \epsilon)$ vs Log ϵ dan Grafik Slopes vs Log ϵ , WA1	91
4.13	Space-Time Separation Plot WA1	92
4.14	Slopes Setelah Noise Filtering 1 % , LAG = 220, WA1	93
4.15	Slopes Setelah Noise Filtering 5 % dan 10 % , LAG = 220, WA1	94
4.16	Slopes Setelah Noise Filtering 5 % , LAG = 100 dan 280, WA1	95
4.17	Grafik Log $C(m, \epsilon)$ vs Log ϵ dan Slopes vs Log ϵ , Shuffled WA1	96
4.18	Grafik Log $C(m, \epsilon)$ vs Log ϵ dan Grafik Slopes vs Log ϵ , DA1	97
4.19	Space-Time Separation Plot DA1	98
4.20	Slopes Setelah Noise Filtering 1 % , LAG = 1300, DA1	98
4.21	Slopes Setelah Noise Filtering 5 % dan 10 % , LAG = 1300, DA1	99
4.22	Slopes Setelah Noise Filtering 5 % , LAG = 300 dan 1800, DA1	100
4.23	Grafik Log $C(m, \epsilon)$ vs Log ϵ dan Slopes vs Log ϵ , Shuffled DA1	101
4.24	Gambar 4.24 Grafik Running Average ZLYAP vs Evolusi , MA1	106
4.25	Grafik Running Average ZLYAP vs Evolusi , WA1	107
4.26	Grafik Running Average ZLYAP vs Evolusi , DA1	108
L4.1	Correlogram Dari Logaritmic Prices Differences Bulanan MAL	G
L4.2	Correlogram Residual Kuadrat ARIMA(1,1) MAL	H
L4.3	Correlogram Residual Kuadrat ARCH(1) dan GARCH(1) MAL	I
L4.4	Correlogram Dari Logaritmic Prices Differences Mingguan WAL	J
L4.5	Correlogram Residual Kuadrat ARIMA(1,1) WAL	K
L4.6	Correlogram Residual Kuadrat ARCH(2) WAL	L
L4.7	Correlogram Dari Logaritmic Prices Differences Harian DAL	M
L4.8	Correlogram Residual Kuadrat ARIMA(1,1) DAL	N

L4.9	Correlogram Residual Kuadrat ARCH(2) DAL	O
L6.1	Correlogram Log-Linear Detrending MA1	AA
L6.2	Correlogram Log-Linear Detrending WA1	BB




DAFTAR TABEL

Tabel		Halaman
3.1	Daftar Nama File dan Jumlah Data Dalam Time series	52
3.2	Parameter Yang Dipakai Pada Log-Linear Detrending	53
3.3	Parameter Untuk Estimasi Correlation dimension	61
3.4	Parameter Untuk Estimasi Maximum Lyapunov Exponent	65
4.1	LM Test Untuk Melihat Adanya Efek ARCH(1)	72
4.2	Nilai Estimasi Correlation Dimension*	104
4.3	Nilai Aproksimasi Maximum Lyapunov Exponent	109
L2.1	Uji Normalitas Pada <i>Prices Series</i> Sebelum dan Sesudah <i>Adjustment</i>	B
L2.2	Uji Normalitas Pada Logaritmic Prices Differences	B
L2.3	Uji Normalitas Pada Log-Linear Detrending	B
L3.1	Uji Stasionaritas Pada <i>Time Series</i> Data Harian	C
L3.2	Uji Stasionaritas Pada <i>Time Series</i> Data Mingguan	C
L3.3	Uji Stasionaritas Pada <i>Time Series</i> Data Bulanan	C
L4.1	Model ARCH(1) dan GARCH(1) Untuk Time Series MAL	D
L4.2	Model ARCH(1) dan GARCH(1) Untuk Time Series MAL	D
L4.3	Model ARCH(2) Untuk Time Series WAL	E
L4.4	Model ARIMA(1,1) Untuk Time Series DAL	E
L4.5	Model ARCH(2) Untuk Time Series DAL	F
L5.1	Analysis dan V Statistic : Data Bulanan MAL	P
L5.2	Hasil Regresi : Data Bulanan MAL	P

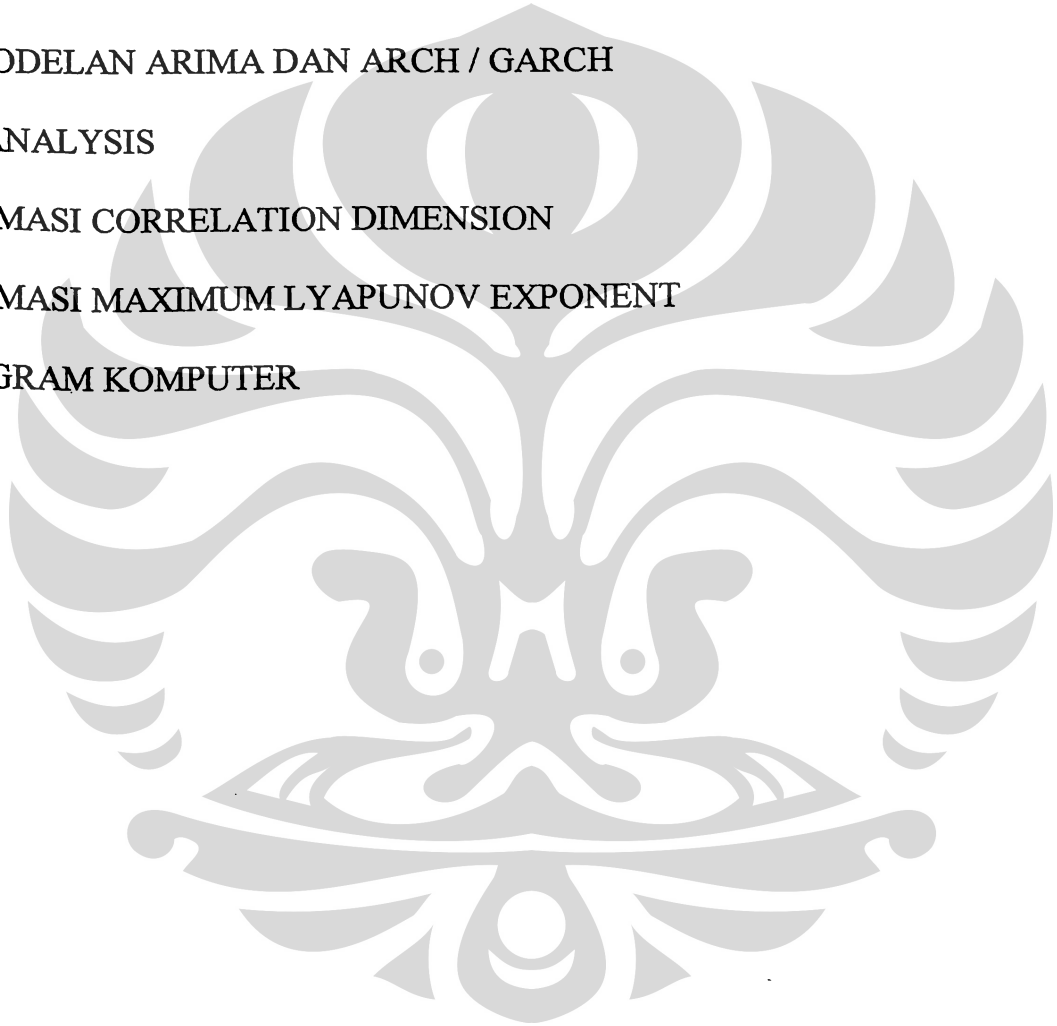
L5.3	R/S Analysis dan V Statistic : Data Mingguan WAL	Q
L5.4	Hasil Regresi : Data Mingguan WAL	Q
L5.5	R/S Analysis dan V Statistic : Data Harian DAL	R
L5.6	Hasil Regresi : Data Harian DAL	R
L6.1	Log C(m,e) vs log ϵ , MA1 , No Lag , No Filter	S
L6.2	Local Slopes vs log ϵ , MA1, No Lag, No Filter	S
L6.3	Local Slopes vs log ϵ , MA1, Lag = 50, Filter = 1 %	S
L6.4	Local Slopes vs log ϵ , MA1, Lag = 50, Filter = 5 %	T
L6.5	Local Slopes vs log ϵ , MA1, Lag = 50, Filter = 10 %	T
L6.6	Local Slopes vs log ϵ , MA1, Lag = 25, Filter = 5 %	T
L6.7	Local Slopes vs log ϵ , MA1, Lag = 64, Filter = 5 %	U
L6.8	Log C(m,e) vs log ϵ WA1 , No Lag , No Filter	U
L6.9	Local Slopes vs log ϵ , WA1, No Lag, No Filter	U
L6.10	Local Slopes vs log ϵ , WA1, Lag = 220, Filter = 1 %	V
L6.11	Local Slopes vs log ϵ , WA1, Lag = 220, Filter = 5 %	V
L6.12	Local Slopes vs log ϵ , WA1, Lag = 220, Filter = 10 %	V
L6.13	Local Slopes vs log ϵ , WA1, Lag = 100, Filter = 5 %	W
L6.14	Local Slopes vs log ϵ , WA1, Lag = 280, Filter = 5 %	W
L6.15	Log C(m,e) vs log ϵ , DA1, No Lag , No Filter	W
L6.16	Tabel L6.16 Local Slopes vs log ϵ , DA1, No Lag, No Filter	X
L6.17	Local Slopes vs log ϵ , DA1, Lag = 1300, Filter = 1 %	X

L6.18	Local Slopes vs $\log \varepsilon$, DA1, Lag = 1300, Filter = 5 %	X
L6.19	Local Slopes vs $\log \varepsilon$, DA1, Lag = 1300, Filter = 10 %	Y
L6.20	Local Slopes vs $\log \varepsilon$, DA1, Lag = 300, Filter = 5 %	Y
L6.21	Local Slopes vs $\log \varepsilon$, DA1, Lag = 1800, Filter = 5 %	Y
L7.1	Running Average Lyapunov Exponent Untuk MA1	Z
L7.2.	Running Average Lyapunov Exponent Untuk WA1	Z
L7.3	Running Average Lyapunov Exponent Untuk DA1	Z



DAFTAR LAMPIRAN

Lampiran	Halaman
1 PRICES SERIES SEBELUM DAN SETELAH ADJUSTMENT	A
2 HASIL UJI NORMALITAS	B
3 HASIL UJI STASIONARITAS	C
4 PEMODELAN ARIMA DAN ARCH / GARCH	D
5 R/S ANALYSIS	P
6 ESTIMASI CORRELATION DIMENSION	S
7 ESTIMASI MAXIMUM LYAPUNOV EXPONENT	Z
8 PROGRAM KOMPUTER	DD



BABI

PENDAHULUAN

1.1 LATAR BELAKANG

Riset *chaos* telah lama menarik perhatian komunitas ilmuwan. Bukti-bukti empiris adanya *chaotic structure* secara meyakinkan ditemukan dalam dinamika fluida (Brandstater dan Swinney, 1987), kimia (Argoul et al., 1987), dan biologi (Guevara, Glass, dan Shrier, 1981). Bukti-bukti yang relatif kurang meyakinkan datang dari epidemiologi, dinamika populasi, meteorologi, dan astronomi (Pool, 1989). Studi empiris *chaos* pada ekonomi dimulai dipublikasikan pada pertengahan tahun 1980-an a.l. oleh Chen (1984, 1987), Sayers (1985), Brock (1986), Chen dan Barnett (1987, 1988), Brock dan Sayers (1988), Scheinkman dan Le Baron (1989). Hasilnya masih merupakan kontroversi yang diperdebatkan.¹

Aplikasi *chaos theory* pada pasar modal dan finansial dapat dilihat a.l. pada penelitian-penelitian Peters (1991), Dechert dan Gencay (1992), Le Baron (1994), Bask (1996). Aplikasi pada *futures markets* dilakukan a.l. oleh Frank dan Stengos (1989), Chavas dan Holt (1991), Blank (1991), De Coster (1992), Cromwell dan Labys (1993), Yang dan Brorsen (1992,1993), Kohzadi dan Boyd (1995), Wei dan Leuthold (1998). Hasilnya beragam, sebagian tidak berhasil menemukan adanya *chaotic structure* dalam data yang dianalisisnya, sebagian lagi mengklaim menemukan struktur yang dimaksud. Klaim perlu disikapi dengan hati-hati karena kualitas hasil temuan sangat dipengaruhi oleh

¹ Chen, P., "Searching for Economic Chaos: A Challenge to Econometric Practice and Nonlinear Tests." in Day, R.H. & Chen P., eds. "Nonlinear Dynamics and Evolutionary Economics", Oxford University Press, 1993, hal: 217.

ketepatan penerapan metoda / teknik yang dipakai, kualitas serta kuantitas data yang dipakai, dan *data treatment* sebelum pemrosesan.

1.2 PERUMUSAN MASALAH

Komoditi minyak kelapa sawit (*palm oil*) dalam perdagangan minyak nabati dunia dewasa ini menduduki urutan kedua setelah minyak kedelai (*soybean oil*). Dewasa ini Malaysia tercatat sebagai produsen CPO (*crude palm oil*) terbesar di dunia, kontribusinya adalah 49,7 % dari total produksi CPO dunia.² Minyak sawit dan minyak inti sawit bagi Malaysia merupakan penghasil devisa terbesar setelah minyak. Sekarang ini Malaysia mengekspor 99,8 % dari minyak sawitnya dalam bentuk produk-produk rafinasi dan fraksinasi. Industri sawit di Malaysia dikelola dengan sangat baik. Saat terjadi *booming* perkebunan sawit, dibentuklah Palm Oil Research Institute of Malaysia (PORIM). Pada tahap awal PORIM memang bertujuan untuk menemukan promosi dengan baik dan ditunjang oleh rencana pembangunan 5 tahun Malaysia, maka Malaysia telah berhasil menjadi negara penghasil dan pengekspor terbesar minyak sawit dunia sampai saat ini.³

Mempertimbangkan hal-hal di atas, maka pergerakan harga CPO seharusnya ada unsur deterministiknya tidak sekedar pergerakan yang random. Juga diharapkan adanya suatu siklus pergerakan harga CPO yang berkaitan dengan faktor-faktor deterministik tersebut.

Selain itu, *time series* dari *futures prices* CPO pada Commodity and Monetary Exchange of Malaysia (COMMEX Malaysia) sepanjang 20 tahun (23 Okt 1980 – 31 Mar 2000) menunjukkan distribusi yang tidak normal (*leptokurtis*), memiliki pola autokorelasi yang

² Studi Tentang Pemasaran CPO dan Perkebunan Kelapa Sawit di Indonesia, 1999, Prepared by PT. CAPRICORN Indonesia Consult Inc., hal: 48.

³ *Ibid*, hal: 52.

sangat lambat menuju 0, dan tampak memiliki suatu siklus nonperiodik. Penyimpangan dari normalitas dapat merupakan simptom adanya proses nonlinier dinamis (Fang et al. 1994).⁴

Dalam karya akhir ini dilakukan pengujian empiris terhadap *futures prices series* tersebut untuk membuktikan adanya struktur nonlinier dinamis khususnya *chaotic structure*.

Melakukan pengujian empiris – terutama pada proses nonlinier dinamis - lebih sulit dilakukan dibandingkan dengan studi teoritis karena dunia nyata jauh lebih kompleks dibandingkan dengan model matematis yang disederhanakan yang hanya merupakan pendekatan terhadap beberapa aspek fenomena empiris.. Apalagi jika penerapannya masih dalam tahap “bayi” seperti penerapan *chaos theory* dalam bidang-bidang ekonomi, finansial, pasar modal, dan *futures markets*.

Untuk membuktikan adanya *chaotic structure* secara empiris dapat digunakan beberapa alternatif metoda dan teknik. Penulis menerapkan metoda yang dinamakan *Correlation Dimension* yang dikembangkan oleh Grassberger & Procaccia dan memakai algoritma Wolf untuk menemukan maximum Lyapunov exponent.

Untuk menghindari kesalahan dalam penerapan metoda dan teknik tersebut penulis memperhatikan beberapa *pitfalls* dan *rule of thumb* dari hasil penelitian-penelitian sebelumnya.

1.3 TUJUAN PENELITIAN

Tujuan pertama – sesuai dengan sifat karya akhir ini yang tidak terstruktur – adalah

⁴ Wei, A. ; Leuthold, R. M., “Long Agricultural Futures Prices: ARCH, Long Memory, or Chaos Process?”, OFOR Paper Number 98-03, May 1998, hal: 12.

lebih bersifat akademis yaitu memahami *chaos theory* dan menerapkannya di bidang yang relevan di sekolah bisnis.

Tujuan kedua – sesuai dengan pengujian empiris yang dilakukan terhadap *commodity futures market* yang sesungguhnya – adalah lebih bersifat praktis yaitu membuktikan adanya struktur nonlinier dinamis khususnya *chaotic structure* dalam *futures prices* CPO COMMEMX Malaysia. Temuan *chaotic structure* akan berimplikasi terhadap semakin mendalamnya pengertian kita tentang perilaku dari *futures markets* seperti prediktabilitas dan persistensi *futures prices*, adanya siklus intrinsik yang nonperiodik, dan dapat memberikan saran-saran untuk pemodelan yang lebih baik.

1.4 LINGKUP PENELITIAN

Lingkup penelitian mencakup pokok-pokok sebagai berikut :

- Penelitian dilakukan terhadap data *univariate time series* yaitu *futures prices series* dari COMMEMX Malaysia sepanjang 20 tahun (23 Okt 1980 – 31 Mar 2000).
- Penelitian hanya sampai tahap pembuktian ada / tidaknya struktur nonlinier dinamis khususnya *chaotic structure*, tetapi tidak sampai pada pembuatan model matematisnya.

1.5 SISTEMATIKA PENELITIAN

Karya akhir ini membahas metoda-metoda nonlinier untuk menganalisis *time series* yang relatif kurang dimengerti dibandingkan dengan metoda-metoda klasik untuk proses linier stokastik, sehingga analisis akan memiliki landasan yang lebih kokoh jika dilakukan uji hipotesis nol bahwa *time series* dapat direpresentasikan oleh model linier.

Oleh karena itu penelitian dimulai dari mencari kemungkinan pemodelan linier stokastik ARIMA, nonlinieritasnya direpresentasikan dengan model ARCH (GARCH). Jika model ARCH (GARCH) kurang meyakinkan maka barulah dilakukan pengujian *chaos*.

Penelitian disusun menurut tahap-tahap sebagai berikut :

1. *Data treatment*

Mengkonstruksi *time series* sepanjang 20 tahun dari *futures prices* kontrak terdekat (1 bulan) akan menimbulkan masalah adanya *price "jump"* pada saat terjadi pergantian kontrak, oleh karena itu perlu diadakan *roll-over adjustment*. Kekosongan data yang disebabkan oleh *public holiday, market holiday, trading suspended, dan market suspended* perlu diisi. *Growth / trend* pada *futures prices* juga perlu dihilangkan dengan melakukan *detrending* pada *time series*.

2. Uji normalitas

Uji normalitas dilakukan sebagai pengamatan visual pertama karena penyimpangan dari normalitas memberikan dorongan selanjutnya untuk pencarian adanya proses nonlinier dinamis dibalik *time series*.

3. Tahap pemodelan linier stokastik ARIMA dan nonlinier stokastik ARCH (GARCH)

- Uji stasionaritas lemah (*weak stationary test*)
- Pengamatan pola autokorelasi dan autokorelasi parsial
- Pengujian ARCH pada residual

Tahap-tahap selanjutnya dilakukan jika pemodelan ARIMA dan ARCH (GARCH) hasilnya tidak terlalu meyakinkan (kuat).

4. Rescaled range (R/S) analysis

- Menghitung Hurst exponent H dan *expected value*-nya untuk membuktikan random tidaknya *time series* tersebut.
- Menghitung panjang siklus nonperiodik untuk digunakan sebagai parameter pada estimasi *correlation dimension* dan maximum Lyapunov exponent.

5. Pembuktian adanya *chaotic structure*

- *Noise filtering*
- Menghilangkan *temporal correlation*
- Estimasi *correlation dimension* dan maximum Lyapunov exponent
- Analisa final untuk menyimpulkan ada tidaknya *chaotic structure*

1.6 SISTEMATIKA PENULISAN

BAB I : PENDAHULUAN

Berisi latar belakang, perumusan masalah, tujuan penelitian, lingkup penelitian, sistematika penelitian, dan sistematika penulisan.

BAB II : TELAAH KEPUSTAKAAN

Berisi landasan teoritis dan metoda analisis yang dilakukan dalam penelitian ini. Topik mencakup dasar-dasar sistem nonlinier dinamis, metoda / teknik dan algoritma yang dipakai dalam penelitian ini, dan hal-hal yang perlu diperhatikan dalam pengujian empiris.

BAB III : METODOLOGI PENELITIAN

Berisi rincian langkah-langkah yang dilakukan dalam penelitian untuk membuktikan ada / tidaknya stuktur nonlinier dinamis khususnya *chaotic structure* dalam *futures prices* CPO COMMEX Malaysia.

BAB IV : ANALISIS DAN PEMBAHASAN

Berisi analisis terhadap temuan yang diperoleh pada bab sebelumnya dan membandingkannya dengan teori atau beberapa percobaan empiris sejenis yang pernah dilakukan peneliti lain.

BAB V : KESIMPULAN DAN SARAN

Kesimpulan dari pembahasan yang telah dilakukan pada bab sebelumnya diberikan disini. Juga diberikan saran-saran untuk penelitian-penelitian selanjutnya dan saran-saran-saran praktis untuk pelaku pasar sebagai implikasi dari hasil penelitian.

BAB II

TELAAH KEPUSTAKAAN

2.1 FUTURES PRICES

Seperti umumnya *time series* finansial lainnya, *futures prices* CPO (*crude palm oil*) COMMEMX Malaysia menunjukkan distribusi yang tidak normal (leptokurtis), memiliki pola autokorelasi yang sangat lambat menuju nol, dan tampak memiliki suatu siklus nonperiodik. Penyimpangan dari normalitas dapat merupakan simptom adanya proses nonlinier dinamis (Fang et al. 1994).¹

Dalam *futures market* agrikultural seringkali suatu perubahan *futures prices* yang besar diikuti oleh perubahan yang lebih besar, secara tiba-tiba proses berubah ke perubahan kecil diikuti oleh perubahan yang lebih kecil, dan tampak seperti siklus tetapi durasinya nonperiodik. *Futures volatility* tidak tetap sepanjang waktu karena variansi umumnya meningkat seiring dengan semakin dekatnya kontrak ke *maturity time*.

Keadaan ini dapat mencirikan suatu proses ARCH, karena proses ARCH dapat bersifat stasioner dengan nilai rata-rata yang konstan dan variansi yang tetap dan terbatas (*fixed and finite variance*), walaupun variansi kondisional-nya bergantung pada waktu.

Jadi model ARCH menganggap struktur nonlinier dari suatu *time series* berasal dari variansi kondisional yang bergantung pada waktu. Walaupun model ARCH menganggap pergerakan harga yang tidak beraturan adalah fenomena endogen dari pasar, model ini masih merupakan model stokastik.

¹ Wei, A. ; Leuthold, R. M., "Long Agricultural Futures Prices: ARCH, Long Memory, or Chaos Process?", OFOR Paper Number 98-03, May 1998, hal: 12.

Kemungkinan lain yang perlu diselidiki adalah *time series* tersebut dihasilkan oleh suatu proses nonlinier dinamis.

2.2 SIFAT SISTEM NONLINIER

Karena persamaan linier hanya dapat memberikan solusi yang tumbuh secara eksponensial atau berosilasi secara periodik, maka semua perilaku sistem yang tidak beraturan harus datang dari masukan random eksternal ke dalam sistem (fenomena eksogen). *Chaos theory* menjelaskan bahwa masukan random bukan satu-satunya sumber ketidakteraturan pada keluaran sistem : *nonlinier chaotic systems* dapat menghasilkan keluaran yang sangat tidak teratur melalui persamaan gerak yang murni deterministik (fenomena endogen). Tentu saja sebuah sistem yang memiliki baik nonlinieritas maupun masukan random akan menghasilkan keluaran yang tidak beraturan.²

Untuk memberikan gambaran intuitif bahwa suatu persamaan nonlinier sederhana sekalipun dapat menghasilkan perilaku *chaotic*, diberikan persamaan Logistic :

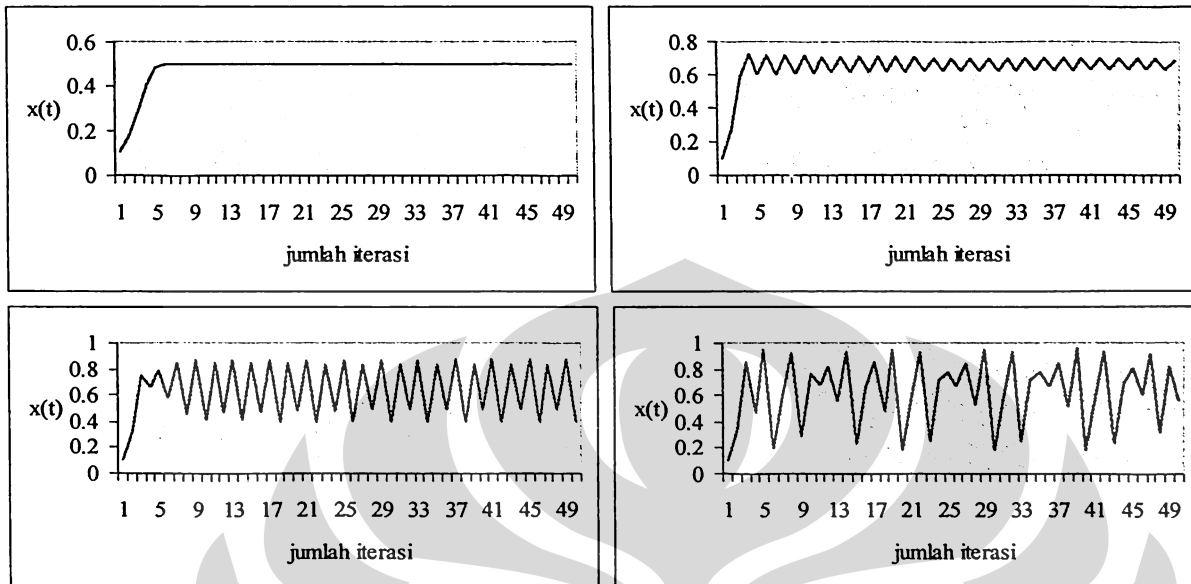
$$x_{t+1} = a x_t(1 - x_t)$$

dengan : $0 < x \leq 1, \quad 0 < a \leq 4$

Pada nilai $a = 2$, setelah suatu *initial transient* , sistem diam di satu nilai x yang stabil, menaikkan nilai a sampai 2,4 tetap menghasilkan konvergensi tetapi x stabil di suatu nilai yang lebih tinggi. Hal yang menarik terjadi pada saat a mencapai 3, tiba-tiba sistem tidak diam di satu nilai tetapi berosilasi di antara 2 nilai x . Pemisahan dari 1 solusi menjadi 2 solusi potensial disebut *bifurcation*.

² Kantz, Holger ; Schreiber, Thomas, "Nonlinear Time Series Analysis", Cambridge University Press, 2000, hal: 3.

Jika nilai a terus dinaikkan sampai sekitar 3,45 (nilai aktualnya adalah 3,44948.....), sistem kembali hilang kestabilan, dan timbul 4 kemungkinan solusi.




Grafik merupakan keluaran dari persamaan Logistic : $x_{t+1} = a(1 - x_t)$, dimana $x_0 = 0,1$, dan a masing-masing 2 ; 3 ; 3,48 ; dan 3,8.

Gambar 2.1 Grafik Persamaan Logistic : Nilai Kritis

Nilai kritis semakin rapat jaraknya, pada $a = 3,544$ diperoleh 8 solusi, pada $a = 3,5644$ diperoleh 16 solusi, pada $a = 3,5688$ diperoleh 32 solusi, dan pada $a = 3,56962$ diperoleh 64 solusi. Kenaikan terus berlanjut hingga nilai $a = 3,6$ (tepatnya 3,569945672...), pada titik ini sistem kehilangan stabilitas, jumlah solusi menjadi tak terhingga. Kita melihat *chaos* dan *time series* yang dihasilkan oleh persamaan ini tampak seperti random. Jika analisis statistik dilakukan pada *time series* ini maka akan dikualifikasikan sebagai random. Persamaan sederhana ini memberikan suatu perilaku yang kompleks, dari suatu persamaan deterministik yang sederhana dapat dibangkitkan *chaos*.³ Gambar 2.2 merupakan *bifurcation diagram*

³ Peters, E. E., "Chaos and Order in The Capital Markets", John Wiley & Sons Inc., 1991, hal: 125.

yang menggambarkan hubungan antara x_t (sumbu vertikal) dengan a (sumbu horisontal), yang memperlihatkan struktur *fractal* dan karakteristik utamanya yaitu *self similarity*.




Sumber: Peters, E. E., "Chaos and Order in The Capital Markets", John Wiley & Sons Inc. , 1991., hal : 8.

Gambar 2.2 Bifurcation Diagram : Persamaan Logistic

Dari contoh sederhana ini dapat dilihat beberapa karakteristik penting dari sistem nonlinier dinamis :

- Merupakan sistem umpan balik, apa yang terjadi sekarang dipengaruhi oleh keadaan-keadaan sebelumnya , x_{t+n} merupakan produk dari x_t .
- Ada beberapa nilai kritis dimana lebih dari satu keadaan kesetimbangan eksis.

- Sistem adalah *fractal*, karakteristik *fractal* dapat dilihat dengan jelas pada Gambar 2.2. Pada $a = 3,75$ ada suatu *band of stability*. Tetapi dalam setiap gambar ada gambar yang lebih kecil dan identik dengan gambar yang lebih besar tadi. Jika gambar yang lebih kecil diperbesar maka di dalamnya juga terdapat *band of stability*, dimana versi yang lebih kecil dari gambar utama berdiam. Pada skala yang terus semakin mengecil, perulangan yang sama dapat terus dijumpai. Sifat *self similarity* merupakan karakteristik dari sistem nonlinier dinamis dan merupakan simptomatik dari proses umpan balik nonlinier. Kompleksitas ini hanya terjadi jika sistem jauh dari keadaan setimbang.⁴
- Terakhir adalah sifat *sensitive dependence on initial conditions*. Jika persamaan digunakan sebagai model peramalan, maka perbedaan yang sangat kecil di x_t akan mengakibatkan perbedaan yang sangat besar di x_{t+n} seperti terlihat pada Gambar 2.3.



Grafik merupakan keluaran dari persamaan Henon : $x_{t+1} = 1 + y_t - a x_t^2$, $y_{t+1} = b x_t$ dengan $x_0 = y_0 = 0,500$ (kurva hitam) dan $x_0 = y_0 = 0,501$ (kurva merah)

Gambar 2.3 Grafik Henon : Sensitive Dependence On Initial Condition

⁴ Peters, E. E ., (1991), *op. cit.*, hal: 9.

Karakteristik-karakteristik tersebut mengindikasikan bahwa jika pasar adalah sistem nonlinier dinamis, maka dapat diperkirakan adanya :

- *Long-term correlation & trends* (efek dari umpan balik nonlinier).
- Perilaku pasar yang *erratic* pada situasi dan kondisi tertentu (adanya nilai kritis).
- Suatu *time series* yang memiliki karakteristik statistik yang mirip pada beberapa skala waktu yang berbeda (struktur *fractal*).
- Hasil prediksi yang semakin jauh semakin menyimpang dengan cepat (*sensitive dependence on initial conditions*).

2.3 MEMBEDAKAN PROSES STOKASTIK DAN DETERMINISTIC CHAOS

Dalam studi empiris adalah mudah menemukan bukti untuk mengklaim bahwa *time series* yang tampak seperti random sebenarnya nonlinier dinamis, yang sulit adalah menentukan jenis nonlinier dinamis tersebut. Ada empat kemungkinan untuk menjelaskan *time series* : proses linier stokastik, *deterministic chaos* diskrit, *deterministic chaos* kontinu, dan *nonlinear deterministic chaos plus noise*.⁵ Pengujian dan pemodelan yang terakhir masih dalam tahap “bayi”, karena *noise* yang terdapat dalam *time series* empiris dapat dengan mudah merusak struktur *deterministic chaos* yang hampir tak kentara. Bagaimana kita menentukan bahwa suatu *time series* dihasilkan oleh salah satu proses di atas ?

Beberapa tahap diperlukan untuk menjawab apakah suatu *time series* dihasilkan oleh proses *deterministic chaos*.

⁵ Chen, P., “Searching for Economic Chaos: A Challenge to Econometric Practice and Nonlinear Tests.” in Day, R.H. & Chen P., eds. “Nonlinear Dynamics and Evolutionary Economics”, Oxford University Press, 1993, hal: 218.

Pertama, dinamika yang mengatur evolusi *time series* harus direkonstruksi karena persamaan gerak spesifiknya tidak diketahui. Dalam kasus dimana *dynamical system* (evolusi waktu dalam suatu *phase space*) adalah tersembunyi dalam sebuah “kotak hitam”, Takens (1981) mendemonstrasikan bahwa adalah mungkin merekonstruksikan dinamika yang tidak diketahui hanya dengan menggunakan *scalar time series* yang terobservasi. Dinamika yang direkonstruksi adalah ekuivalen dengan *dynamical system* yang tersembunyi dalam “kotak hitam” dalam pengertian bahwa keduanya bersama-sama memiliki *dynamical properties* tertentu, misalnya Lyapunov exponent dari dinamika yang direkonstruksi dan Lyapunov exponent dari *dynamical system* yang tidak diketahui adalah ekuivalen.⁶

Setelah merekonstruksi dinamika tersebut, tahap selanjutnya adalah estimasi parameter-parameter yang mencirikan *chaotic dynamical system*, diantaranya yang digunakan pada karya akhir ini adalah metoda *correlation dimension* dari Grassberger & Procaccia dan maximum Lyapunov exponent.

Tahap terakhir adalah melakukan *shuffle test* dari Scheinkman dan LeBaron (1989). *Shuffle test* dapat dilakukan karena ada kecenderungan pada *time series* yang terdiri dari *noise* dan data terstruktur untuk menyimpang dari perilaku ideal dalam estimasi *correlation dimension*.⁷ *Shuffle test* menguji hipotesis terhadap *correlation dimension* yang dihitung dari *noise time series* yang sama distribusinya dengan *time series* aktual. Untuk setiap *time series* aktual, dibentuk 20 buah *artificial noise time series* dengan panjang data dan distribusi yang sama dengan *time series* aktual, caranya adalah dengan mengacak (*shuffle*) *time series* aktual. Hipotesis nol adalah bahwa *time series* aktual (atau *unshuffled time*

⁶ Bask, M., “Deterministic Chaos in Swedish Exchange Rates?”, Departement of Economics Umea University, hal: 4.

⁷ DeCoster, G. P. ; Labys, W.C. ; Mitchell, D. W. , “Evidence of Chaos in Commodity Futures Prices” , dalam Peters, C. ; Warwick, B., eds, “The Handbook of Managed Futures”, Irwin, 1997, hal: 467.

series) adalah *random noise*. Jika sedikitnya 95 % dari *correlation dimension* yang dihitung dari *shuffled time series* lebih besar dibandingkan dengan yang dihitung dari *unshuffled time series* maka hipotesis alternatif bahwa *time series* adalah nonrandom diterima.

2.4 PHASE SPACE

Pengamatan visual terhadap data dalam sistem nonlinier dinamis sangat penting karena biasanya sistem ini tidak memiliki solusi tunggal. Biasanya terdapat solusi berganda, bahkan tak terhingga jumlahnya. Banyak *chaotic system* memiliki jumlah solusi yang tidak terhingga tetapi terletak dalam *finite space*. Sistem tertarik (*attracted*) ke suatu *region of space* (daerah dimana solusi-solusi terletak), dan *attractor* (himpunan kemungkinan solusi-solusi) sering memiliki dimensi *fractal* (dimensi berupa bilangan *noninteger*).

Pengamatan akan mudah jika kita mengetahui semua variabel dalam sistem. Jika terdapat dua variabel fungsi waktu, maka plot satu variabel sebagai x dan yang lainnya sebagai y pada grafik Cartesian standar. Kita plot nilai satu variabel terhadap variabel yang lainnya pada titik waktu yang sama. Plot ini dinamakan *phase portrait* dari sistem tersebut yang terletak di dalam *phase space*. Dimensi *phase space* tergantung dari jumlah variabel dalam sistem. Pengamatan visual dapat dilakukan jika jumlah variabel adalah 2 atau 3, sedangkan jika lebih dari 3 maka hanya dapat dilakukan secara matematis.

Bentuk *attractor* yang paling sederhana adalah *point attractor*. *Point attractor* misalnya bisa diperoleh dari plot variabel-variabel posisi dan kecepatan ayunan bandul yang teredam. *Phase portrait* berupa lintasan spiral yang berakhir pada suatu titik dimana bandul berhenti. Jika ayunan bandul tidak teredam maka *phase portrait* akan berbentuk lingkaran yang disebut *limit cycle*. *Attractor* ini dihasilkan oleh sistem-sistem yang memiliki

siklus periodik reguler. Ekonometrika klasik cenderung memandang sistem ekonomi sebagai sistem kesetimbangan (*point attractor*), atau sebagai sistem kesetimbangan yang bervariasi secara periodik (*limit cycle*). Tetapi kenyataan empiris tidak mendukung pandangan ini, *economic time series* dicirikan oleh siklus nonperiodik (siklus yang tidak memiliki *characteristic length* atau *time scale*). Sistem-sistem nonlinier dinamis cenderung menghasilkan siklus nonperiodik ini.

Jika pada bandul yang sedang mengayun teredam ini diberikan dorongan dengan besar tenaga yang random, tetapi diberikan pada selang waktu yang tetap, maka *phase portrait* akan berbeda untuk setiap siklus. Siklus yang dihitung dari puncak ke puncak ayunan dinamakan orbit. Karena bandul tidak dapat menyelesaikan satu siklus secara alamiah, *phase portrait*-nya akan terdiri dari orbit-orbit yang tidak pernah sama dan tidak pernah periodik. *Phase portrait* akan tampak random dan *chaotic*, tetapi tetap terbatas dalam suatu jangkauan tertentu (amplitudo maksimum ayunan bandul), arah putaran tetap sama walaupun ukuran dan waktu orbit akan berubah. *Attractor* jenis ini dinamakan *chaotic attractor* atau *strange attractor*. Karena *strange attractor* memiliki dimensi *fractal* maka Mandelbrot menyebutnya *fractal attractor*.⁸ Kesetimbangan terletak pada suatu *region of phase space*, suatu daerah yang terbatas dengan jumlah solusi yang tidak terhingga (*infinite number of solutions in a finite space*).

Phase space memberikan gambaran mengenai dinamika yang mendasari sistem. Pada sistem-sistem yang persamaan geraknya diketahui, mengkonstruksi *phase space* adalah pekerjaan mudah. Untuk sistem-sistem yang tidak diketahui pun *phase space* dapat direkonstruksi dari *scalar time series* yang tersedia.

⁸ Peters, E. E., (1991), *op.cit.*, hal: 140.


2.5 PHASE POTRAIT DARI SISTEM YANG DIKETAHUI PERSAMAAN GERAKNYA

Henon map merupakan contoh *iterative map* 2 dimensi, persamaan geraknya adalah :

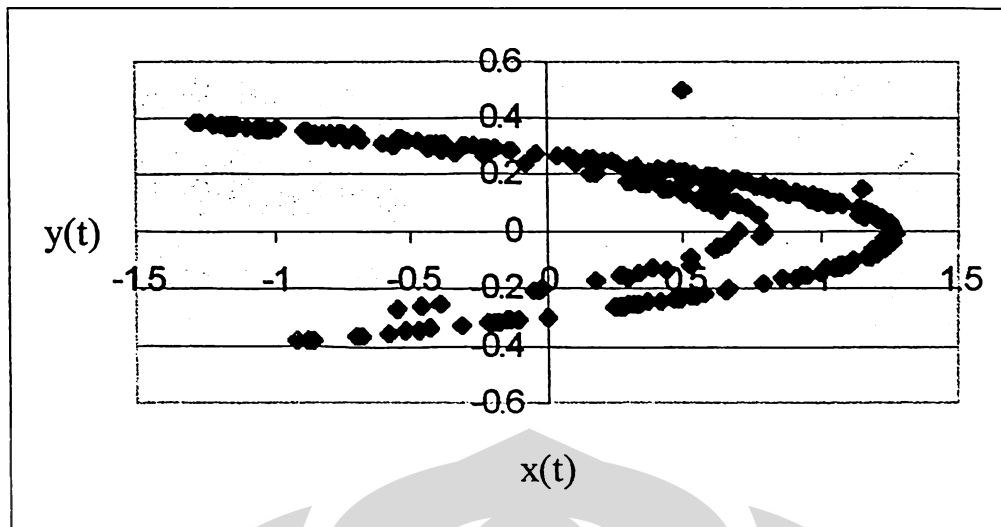
$$x_{t+1} = 1 + y_t - a x_t^2$$

$$y_{t+1} = b x_t$$

Pada $a = 1,40$ dan $b = 0,30$ dihasilkan kondisi *chaotic*, Gambar 2.4 memperlihatkan plot nilai *time series* x_t dan y_t , perhatikan pergerakan yang random dari kedua *time series* tersebut. *Phase portrait* diperlihatkan pada Gambar 2.5, tampak suatu struktur yang tidak random.



Gambar 2.4 Henon Map : Time Series x dan y




Gambar 2.5 Henon Map : Phase Potrait

Sistem ini memiliki 2 derajat kebebasan : x dan y , tiap nilai x tergantung dari nilai x dan y sebelumnya, tiap nilai y tergantung dari nilai x sebelumnya. Nilai-nilai pada *time series* tergantung nilai awal yang diberikan. Sedangkan *phase space* selalu tampak sama, tidak tergantung pada nilai awal yang diberikan (atau *time series* apa yang dihasilkan). Berapapun nilai awal (atau *initial condition*) yang dipilih grafik selalu tampak sama., sistem ditarik ke bentuk ini yang merupakan *strange attractor* sistem.

2.6 PHASE POTRAIT DARI SISTEM YANG TIDAK DIKETAHUI PERSAMAAN GERAKNYA

Packard et al. (1980) menguraikan metoda sederhana yang dikembangkan oleh Ruelle untuk merekonstruksi *phase space* dari 1 variabel dinamis.⁹ Caranya adalah mengisi dimensi-dimensi lain dengan versi tertunda dari dimensi yang dapat diamati. Hal ini dapat dilakukan karena sistem nonlinier dinamis adalah *interdependent simultaneous system*. Nilai

⁹ *Ibid*, hal: 152.



Gambar 2.5 Henon Map : Phase Potrait


Sistem ini memiliki 2 derajat kebebasan : x dan y , tiap nilai x tergantung dari nilai x dan y sebelumnya, tiap nilai y tergantung dari nilai x sebelumnya. Nilai-nilai pada *time series* tergantung nilai awal yang diberikan. Sedangkan *phase space* selalu tampak sama, tidak tergantung pada nilai awal yang diberikan (atau *time series* apa yang dihasilkan). Berapapun nilai awal (atau *initial condition*) yang dipilih grafik selalu tampak sama., sistem ditarik ke bentuk ini yang merupakan *strange attractor* sistem.

2.6 PHASE POTRAIT DARI SISTEM YANG TIDAK DIKETAHUI PERSAMAAN GERAKNYA

Packard et al. (1980) menguraikan metoda sederhana yang dikembangkan oleh Ruelle untuk merekonstruksi *phase space* dari 1 variabel dinamis.⁹ Caranya adalah mengisi dimensi-dimensi lain dengan versi tertunda dari dimensi yang dapat diamati. Hal ini dapat dilakukan karena sistem nonlinier dinamis adalah *interdependent simultaneous system*. Nilai

⁹ *Ibid*, hal: 152.

tiap variabel saat sekarang adalah transformasi dari nilai-nilai variabel-variabel di masa lalu. Walaupun *time series* y_t tidak diketahui, *phase space* Henon map masih dapat dihasilkan hanya dari *time series* x_t dan *time series* lain yang dibentuk dari *time series* x_t yang ditunda (x_{t+T}), seperti diperlihatkan pada Gambar 2.6 yang merupakan duplikasi *phase space* Henon map pada Gambar 2.5.



Gambar 2.6 Duplikasi Phase Potrait Henon Map

Ruelle membuktikan secara matematis bahwa *phase space* yang direkonstruksikan mempunyai *fractal dimension* dan Lyapunov exponent yang sama dengan *phase space* “asli” yang berasal dari 2 variabel. Kita mengetahui Henon *attractor* adalah 2 dimensi karena kita mengetahui persamaan geraknya. Memiliki hanya 1 variabel dan tidak memiliki informasi lainnya tentunya sangat membatasi. Berapa dimensi yang harus digunakan ?, Berapa waktu tunda yang tepat ?. Kita terpaksa harus melakukan usaha coba-coba !

Pertama, dimensionalitas *attractor* tidak berubah selama kita menempatkannya di dalam dimensi yang lebih tinggi dari dimensi *attractor* tersebut. Seperti bidang datar 2

dimensi yang ditempatkan dalam ruang 3 dimensi tetap merupakan objek 2 dimensi, sebuah garis 1 dimensi yang ditempatkan dalam ruang 2 atau 3 dimensi tetap merupakan objek 1 dimensi. Sebuah *attractor*, jika benar-benar merupakan sistem nonlinier dinamis akan tetap mempertahankan dimensinya selama kita menaikkan *embedding dimension* melebihi *fractal dimension*-nya (*embedding dimension* adalah dimensi ruang tempat objek diletakkan). Hal ini disebabkan karena titik-titik data adalah berkorelasi dan tetap “menggumpal” selama di tempatkan di ruang yang dimensinya lebih tinggi dari dirinya. Jika data adalah random, titik-titik data tidak berkorelasi dan akan memenuhi ruang tempatnya di tempatkan. Bayangkan seperti partikel-partikel gas yang saling tidak berkorelasi dan akan memenuhi seluruh ruang yang ditempatinya, sedangkan partikel-partikel zat padat saling berkorelasi sehingga volumenya tidak tergantung pada dimensi ruang yang ditempatinya. Selama kita merekonstruksi *attractor* dalam dimensi yang lebih tinggi dibandingkan dimensi *attractor* “asli”, maka dimensionalitas bukan merupakan masalah.

Kedua, penentuan waktu tunda yang tepat juga dapat diselesaikan dengan mudah.

Wolf et al. (1985) menentukan bahwa estimasi yang baik diperoleh dari hubungan :

$$m \times T = Q$$

dimana : $m =$ *embedding dimension*

$T =$ waktu tunda

$Q =$ periode rata-rata orbit

Periode rata-rata orbit dihitung dengan menggunakan Rescaled Range (R/S) analysis yang mengestimasi periode rata-rata suatu *time series* melalui panjang waktu yang diperlukan oleh suatu pengamatan untuk kehilangan korelasinya.

Dengan menggunakan *phase space* yang sudah direkonstruksikan selanjutnya kita dapat mengukur besaran-besaran sistem nonlinier dinamis yang lain seperti *correlation dimension* dan Lyapunov exponent.

2.7 REKONSTRUKSI DYNAMICAL SYSTEM DALAM PHASE SPACE

Misal $f : \mathbb{R}^n \rightarrow \mathbb{R}^n$ adalah *dynamical system* yang menggambarkan evolusi sistem CPO *futures market* COMMEMX Malaysia dalam *phase space* sepanjang waktu :

$$S_{t+1} = f(S_t) \quad (2.1)$$

dimana S_t adalah *state* sistem tersebut pada waktu t (per definisi : *state* adalah jumlah minimum variabel v_1, v_2, \dots, v_n yang dispesifikasikan pada waktu $t = t_0$ dan bersama-sama dengan sinyal masukan u_1, u_2, \dots, u_m menentukan *state* di masa depan pada $t \geq t_0$).¹⁰ Dalam proses evolusi ini terlibat banyak variabel internal maupun eksternal yang mempengaruhi sistem, seperti : pasokan – permintaan, kebijakan pemerintah, musim & cuaca, produk substitusi, dan sebagainya. Tentunya tidak semua variabel terobservasi, sehingga yang berasosiasi dengan *dynamical system* dalam persamaan di atas adalah *observer function* :

$h : \mathbb{R}^n \rightarrow \mathbb{R}$ yang menghasilkan data skalar misalnya dalam bentuk *futures prices time series* :

$$\begin{cases} x_t = h(S_t) + \gamma \varepsilon_t \\ \varepsilon_t \sim IID(0,1) \end{cases} \quad (2.2)$$

¹⁰ Shinnars, S. M., “Modern Control System Theory and Application”, Second Edition, Addison-Wesley Publishing Company, 1980, hal: 63.

dimana γ adalah *noise level* dan ε_t adalah kesalahan pengukuran. Jadi suatu N titik *futures prices time series* $\{x_1, \dots, x_N\}$ dapat diobservasi. Perlu diingat bahwa *observational noise* juga masuk ke dalam *time series* tersebut.

Menurut Takens (1981), adalah mungkin merekonstruksi dinamika sistem pada persamaan (2.1) hanya dengan menggunakan *scalar time series* yang dihasilkan oleh persamaan (2.2). Jelasnya titik-titik data dalam *observed scalar time series* mengandung informasi tentang *unobserved state variables* sehingga dapat digunakan untuk mendefinisikan suatu *state* pada saat sekarang.

$$\text{Misalkan : } X = (X_1, \dots, X_M)' \quad (2.3)$$

adalah *reconstructed trajectory* dimana X_t adalah *reconstructed state* pada waktu t , dan M adalah jumlah *state* dalam *reconstructed trajectory* tersebut. Masing-masing X_t adalah

$$X_t = \{x_t, x_{t+T}, \dots, x_{t+(m-1)T}\} \quad (2.4)$$

dimana : $t = 1, \dots, N - m + 1$, m adalah *embedding dimension*, dan T adalah waktu tunda.

X adalah *m-dimensional vector* dalam *phase space* atau dalam notasi matriks X adalah matriks $M \times m$ dimana M, m , dan N memenuhi hubungan : $M = N - m + 1$.

Takens (1981) membuktikan bahwa ada suatu peta antara *original n-dimensional state* S_t dan *m-dimensional state* yang direkonstruksi X_t . Peta tersebut merupakan *smooth map* yang dapat melakukan transformasi kordinat satu ke satu dan mempunyai *smooth inverse* jika dipenuhi $m > 2n$. Ini berarti bahwa peta tersebut mempertahankan (tidak merubah) informasi topologis (misalnya Lyapunov exponent) dari *dynamical system* yang

tidak diketahui yang dipetakan. Biasanya peta menginduksi fungsi $g : \mathbb{R}^m \rightarrow \mathbb{R}^m$ pada *reconstructed trajectory* :

$$X_{t+1} = g(X_t) \quad (2.5)$$

yang berkonjugasi secara topologis dengan *dynamical system* yang tidak diketahui f dalam persamaan (2.1). Jadi g dalam persamaan (2.5) adalah *reconstructed dynamical system*.¹¹

Hal ini mungkin bisa dibayangkan (walaupun tidak persis) seperti kita yang bisa mengenal, membedakan, dan membayangkan ribuan wajah orang walaupun informasi detailnya tidak mungkin dan tak akan bisa diperoleh.

2.8 FRACTAL DIMENSION

Kita cenderung menganggap objek yang memiliki kedalaman sebagai 3 dimensi. Secara matematis hal tersebut tidak benar karena objek 3 dimensi sejati harus pejal (tidak memiliki rongga) dan tidak ada *gap* pada permukaannya. Bola yang dibentuk dari kepalan selembar kertas bukan merupakan objek 3 dimensi, bola kertas tersebut mempunyai dimensi *noninteger* antara 2 dan 3 yang disebut *fractal dimension*. Geometri Euclidean (yang hanya mengenal dimensi *integer*) tidak dapat menerangkan dimensionalitas objek seperti bola kertas. Bola kertas tersebut tidak dapat digambarkan / direproduksi dengan menggunakan geometri Euclidean, kecuali melalui interpolasi linier yang sangat banyak. Menggunakan Calculus, permukaan bola kertas adalah *not differentiable*. Geometri *fractal* merupakan geometri yang alamiah karena kebanyakan objek-objek alamiah seperti pohon, gunung, awan, dan garis pantai berdimensi *fractal*.

Kegagalan geometri Euclidean untuk menggambarkan objek-objek alamiah sangat membatasi kemampuannya untuk menerangkan bagaimana objek-objek tersebut terbentuk.

¹¹ Bask, M., *op.cit.*, hal: 5.

Untuk *time series* misalnya, geometri klasik tidak dapat menjelaskan hubungan sebab akibat yang mendasari struktur yang menghasilkan *time series* tersebut, kecuali jika *time series* tersebut *random walk* (sebuah *time series* akan random jika ia dipengaruhi oleh jumlah peristiwa yang sangat besar dan sama peluang terjadinya, atau dalam istilah statistika disebut jumlah derajat kebebasan atau faktor-faktor yang mempengaruhi sistem adalah sangat besar).

Ruang dimana objek terletak di dalamnya disebut *embedding dimension* atau *topological dimension*. *Fractal dimension* memperlihatkan bagaimana suatu objek fisik (atau *time series*) memenuhi ruang tersebut. Cara objek fisik (atau *time series*) memenuhi ruangnya ditentukan oleh semua faktor yang mempengaruhi pembentukan objek fisik (atau *time series*) tersebut.

Sifat *fractal objects* adalah dimensionalitas-nya tetap jika objek ditempatkan dalam *embedding dimension* yang lebih besar dibandingkan *fractal dimension*-nya. *Fractal objects* tidak memenuhi semua *embedding dimension*-nya karena bagian-bagiannya adalah berhubungan atau berkorelasi (benda padat tidak menyebar karena adanya ikatan antar molekul, dalam hal lain korelasi “mengikat” titik-titik data dalam *time series*) . Distribusi random seperti *white noise* tidak memiliki karakteristik seperti ini sehingga *white noise* akan segera memenuhi *embedding dimension* seperti gas yang memenuhi seluruh volume ruangnya.

Fractal dimension untuk *time series* sedikit berbeda dengan *fractal dimension* untuk *state space*. Suatu *time series* memiliki dimensi antara 1 hingga 2, karena hanya ada 1 variabel. Hanya *random time series* yang memiliki dimensi 2 karena titik-titiknya dapat

memenuhi seluruh bidang datar. *Phase space* menyertakan semua variabel dalam sistem, dimensionalitasnya tergantung pada kompleksitas sistem yang diamati.

Fractal dimension memberikan informasi penting tentang hal yang mendasari sistem. Bilangan *integer* selanjutnya terhadap *fractal dimension* merupakan jumlah minimum variabel dinamis yang diperlukan untuk memodelkan dinamika sistem.¹²

2.9 GEOMETRI ATTRACTOR DAN FRACTAL

Sensitive dependence on initial condition pada evolusi sistem merupakan manifestasi dari sifat dinamik *chaotic system*. Perilaku “aneh” dalam dimensi waktu ini mempunyai pasangannya dalam geometri *phase space* yang dibentuk oleh *nontransient trajectories* sistem, yaitu *attractor*. *Attractor* dari *chaotic system* umumnya memiliki bentuk geometris yang rumit, sehingga sering dinamakan *strange attractor*. Karena dalam sistem deterministik *trajectories* tidak boleh berpotongan maka *attractor* dari suatu *chaotic flow* (sistem yang dapat digambarkan oleh *autonomous differential equations* atau *flow*) harus berdimensi lebih dari 2. Tetapi sedikit lebih dari 2 adalah cukup dan *fractal* berdimensi $2 + \varepsilon$ dapat bersifat *chaotic*, seperti *attractor* Lorenz yang berdimensi 2,08.

Map-like system tentunya dapat bersifat *chaotic* walaupun dimensinya kurang dari 2, seperti Henon map yang berdimensi 1,26.

Dengan demikian, *strange attractor* dengan dimensi *fractional (noninteger)* adalah ciri khas *chaotic system*. Dimensi *noninteger* diberikan pada objek geometris yang menunjukkan sifat *self-similarity* dan struktur pada semua skala.¹³

¹² Peters, E. E., (1991), *op.cit.*, hal: 155.

¹³ Kantz, Holger ; Schreiber, Thomas, *op.cit.*, hal: 69.

2.10 CORRELATION DIMENSION

Ada beberapa cara untuk mengkuantifikasi sifat *self-similarity* suatu objek geometris oleh suatu dimensi, tetapi tentunya kita memerlukan definisi yang konsisten dengan gagasan dimensi jika diterapkan pada objek *nonfractal* : titik berdimensi 0 , garis berdimensi 1 , bidang datar berdimensi 2 , dan seterusnya. Disamping itu kita juga harus mempertimbangkan kenyataan praktis bahwa objek geometris tersebut harus direkonstruksi dari sejumlah titik-titik sampel data yang terbatas dan mengandung *error*. Gagasan ini disebut *correlation dimension*, dan dikembangkan oleh Grassberger dan Procaccia (1983) sebagai pendekatan terhadap *fractal dimension* melalui *correlation integral* (*correlation sum*).

Correlation integral untuk sekumpulan titik X_n dalam suatu *phase space* adalah fraksi dari semua kemungkinan pasangan-pasangan titik-titik yang jaraknya lebih kecil dari ϵ dalam suatu *particular norm*. Rumus dasarnya adalah :

$$C(\epsilon) = \frac{2}{N(N-1)} \sum_{i=1}^N \sum_{j=i+1}^N \Theta(\epsilon - \|X_i - X_j\|) \quad (2.6)$$

dimana Θ adalah Heaviside step function, $\Theta(x) = 0$ jika $x \leq 0$ dan $\Theta(x) = 1$ jika $x > 0$.

Penjumlahan menghitung pasangan (X_i, X_j) yang jaraknya lebih kecil dari ϵ . Dalam limit jumlah titik data yang tidak terhingga ($N \rightarrow \infty$) dan ϵ yang kecil diharapkan skala C memenuhi *power law* :

$$C(\epsilon) \propto \epsilon^D \quad \text{atau} \quad \log C(\epsilon) = D \log \epsilon + \text{konstanta} \quad (2.7)$$

Correlation dimension D didefinisikan sebagai :

$$d(N, \epsilon) = \frac{\partial \ln C(\epsilon, N)}{\partial \ln \epsilon},$$

$$D = \lim_{\varepsilon \rightarrow 0} \lim_{N \rightarrow \infty} d(N, \varepsilon) \quad (2.8)$$

Kedua limit memberikan kesulitan pada kondisi praktis : N dibatasi oleh ukuran sampel sedangkan jangkauan ε ke bawah dibatasi oleh akurasi data dan kurangnya jumlah pasangan titik-titik (*near neighbours*) pada skala yang kecil.

Sebelum sampai pada rincian bagaimana memperkirakan *correlation integral* dan dimensi *time series*, marilah kita tinjau beberapa pertimbangan berikut.

Dimensi, Lyapunov exponent, dan sebagainya adalah besaran untuk mengukur sifat-sifat suatu sinyal. Besaran itu bukan semata-mata memadatkan banyak pengukuran menjadi suatu bilangan tertentu, tetapi besaran itu diperlukan untuk memperdalam pengetahuan kita mengenai sistem yang melatar belakangi, hal yang tidak bisa diperoleh melalui statistika klasik. Besaran seperti ini harus *invariant*, artinya besaran tidak tergantung pada prosedur pengukuran, resolusi data, detail pengukuran, kordinat yang dipilih, dan sebagainya.

Walaupun *correlation dimension* adalah *invariant*, tetapi *correlation integral* pada skala ε_0 tertentu adalah tidak *invariant*. Sehingga kita tidak bisa memakai $d(N, \varepsilon_0)$ sebagai perkiraan untuk D . Jika selanjutnya kita memperoleh nilai D (dengan beberapa *error bars*) sebagai *correlation dimension* untuk sistem tersebut, maka kita harus memastikan bahwa nilai ini tahan (*robust*) terhadap berbagai variasi teknik pengukuran dan pengolahan data.

2.11 CORRELATION INTEGRAL DARI SUATU TIME SERIES

Setelah *embedding vectors* direkonstruksi, estimasi *correlation dimension* dilakukan dalam 2 tahap. Pertama, menghitung *correlation integral* $C(\varepsilon)$ menurut persamaan (2.6) untuk suatu jangkauan nilai ε tertentu, dilakukan untuk beberapa nilai *embedding dimension*

m. Kemudian amati kurva $\log C(m, \epsilon)$ vs $\log \epsilon$ untuk melihat tanda-tanda (*signature*) *self-similarity*, yaitu adanya bagian kurva-kurva $\log C(m, \epsilon)$ yang lurus dan paralel satu dengan yang lainnya. Jika tanda-tanda meyakinkan, *correlation dimension* diperkirakan dengan menghitung kemiringan kurva (*local slope*) $C(m, \epsilon)$ vs ϵ menurut persamaan (2.7).

Tetapi ada suatu catatan teknis yang perlu ditekankan disini. Hanya pada sistem-sistem ideal seperti *random noise* murni atau *attractor* yang sangat jelas perilakunya yang dapat menghasilkan *correlation dimension* yang gamblang. Ini berarti *time series* empiris tidak akan pernah menghasilkan *correlation dimension* yang gamblang. Jika tidak ada *plateau region* pada plot *local slope* atau tidak ada tanda-tanda saturasi dari plot $\log C(m, \epsilon)$ vs $\log \epsilon$ maka *correlation dimension* adalah tidak terlacak. Nilai numeris dalam perhitungan *correlation dimension* jangan dulu diterima sebelum plot $C(m, \epsilon)$ vs ϵ diamati dengan seksama. Hal ini bukan merupakan kelemahan algoritma-algoritma tersebut; suatu *time series* empiris bisa terletak di dalam “daerah abu-abu” antara random murni (i.i.d) dan benar-benar deterministik, dan mengajukan pertanyaan ya / tidak tidak akan menghasilkan jawaban yang berarti.

2.12 TEMPORAL CORRELATION

Data – dalam bentuk *embedding vectors* – dapat dianggap sebagai *random sample* yang diambil dari suatu distribusi probabilitas *embedding vectors* milik *attractor* yang sesungguhnya. Ekstrapolasi dari data yang jumlahnya terbatas digunakan untuk mengestimasi *correlation integral* dari *attractor* yang sesungguhnya itu.

Penghitungan *correlation integral* melalui persamaan (2.6) akan *bias* jika pasangan-pasangan titik-titik yang dihitung dalam persamaan tidak bebas secara statistik, dimensi yang terukur menjadi lebih kecil dari seharusnya (*underestimated*).

Evolusi waktu yang kontinu akan menyebabkan *embedding vectors* yang berturutan dalam skala waktu juga akan berdekatan dalam *phase space*. Jadi penyebab utama *temporal correlations* adalah kenyataan bahwa data yang berdekatan dalam skala waktu juga berdekatan dalam *state space*, keadaan ini terjadi bukan saja pada sistem deterministik murni tetapi juga pada sistem stokastik. Sinyal stokastik yang sebenarnya memiliki dimensi tidak terhingga dapat terukur sebagai dimensi terhingga bahkan dimensi rendah.

Masalah ini diatasi dengan mengeluarkan pasangan-pasangan yang berkorelasi, biasanya kasus ini terjadi jika titik-titik berdekatan dalam skala waktu, bukan yang berdekatan dalam geometri *attractor*. Penjumlahan dilakukan setelah *correlation time* $t_{\min} = \eta_{\min} \Delta t$ berakhir, sehingga persamaan (2.6) harus dimodifikasi menjadi :

$$C(\varepsilon) = \frac{2}{(N-\eta_{\min})(N-\eta_{\min}-1)} \sum_{i=1}^N \sum_{j=i+\eta_{\min}}^N \Theta(\varepsilon - \|X_i - X_j\|) \quad (2.9)$$

Perlu diingat bahwa t_{\min} tidak mesti sama dengan *average correlation time* yang didefinisikan sebagai waktu yang diperlukan fungsi autokorelasi untuk meluruh ke $1/e$.

Provenzale (1992) memperkenalkan *space time separation plot* untuk mendeteksi nonstasionaritas dan *temporal correlations* sehingga bisa diperkirakan nilai *correlation time* t_{\min} .¹⁴ Dengan adanya *temporal correlations* maka kemungkinan suatu pasangan titik-titik mempunyai jarak lebih kecil dari ε tidak hanya tergantung dari ε tetapi juga pada skala waktu antara 2 titik tersebut. Ketergantungan ini dapat dideteksi dengan memplot jumlah

¹⁴ *Ibid*, hal: 270.

pasangan-pasangan sebagai fungsi dari 2 variabel yaitu *time separation* Δt dan *spatial distance* ε . Hanya untuk nilai-nilai Δt dimana garis-garis kontur mendatar (secara rata-rata, karena umumnya garis kontur bergelombang) maka *temporal correlation* tidak menghasilkan *artefacts* pada *correlation integral*.

2.13 LYAPUNOV EXPONENT

Ciri yang menonjol dari *chaotic system* adalah tidak dapat diramalkannya masa depan sistem (*unpredictability*), kecuali untuk perioda yang sangat pendek, walaupun evolusinya deterministik. Hal yang tampak kontradiktif ini tidak ada hubungannya dengan pengaruh dari luar sistem – yang dalam data empiris selalu terjadi – seperti terlihat pada persamaan matematika *chaotic system*. Sifat tidak dapat diramalkan ini merupakan konsekwensi dari ketidakstabilan solusi-solusi, dicerminkan oleh apa yang dinamakan *sensitive dependence on initial conditions*. Perbedaan kecil kondisi awal antar *trajectories* akan melebar dengan sangat cepat dalam beberapa langkah ke depan, dan setiap detail pada waktu awal, yang tidak teramati sekalipun, akan menentukan persisnya lintasan *trajectories*.

Konsep *sensitive dependence on initial conditions* dapat dilihat dari 2 sudut pandang. Dari sudut pandang pertama, konsep menerangkan tentang kesulitan untuk menspesifikasikan model. Walaupun pembuat model mengetahui persamaan gerak sistem, tetapi akurasi prediksi model ini tergantung dari masukannya. Semakin jauh kita pergi dalam sumbu waktu, semakin tidak akurat prediksi yang dihasilkan karena sistem nonlinier akan memperkuat *error*. Ini adalah interpretasi “*forward looking*” untuk *sensitive dependence on initial conditions*.

Menurut sudut pandang kedua, sistem itu sendiri membangkitkan ketidakteraturan melalui proses pencampuran (*mixing process*) dan setelah mencapai suatu titik tertentu semua informasi mengenai kondisi awal akan hilang. Dimana kita berada sekarang ditentukan keberadaan sebelumnya. Proses evolusi bisa sangat kompleks dan diperkuat oleh nonlinieritas, sehingga kita tidak bisa berjalan mundur dan menguraikan kembali (*unmix*) sistem tersebut. Kita tidak bisa menguraikan sistem dengan akurasi yang memadai untuk menemukan kembali dari mana kita datang. Ini adalah interpretasi “*backward looking*” untuk *sensitive dependence on initial conditions*.

Kedua sudut pandang ini dapat dikombinasikan menuju suatu kesinambungan. Dimana kita berada sekarang ditentukan oleh keberadaan sebelumnya, dan bagaimana akurasi prediksi kita mengenai masa depan tergantung dari sejauh mana kita memahami tentang keberadaan kita sekarang. Suatu peristiwa dapat mempengaruhi masa depan sampai tak hingga, walaupun sistem itu sendiri hanya “mengingat” peristiwa itu untuk waktu yang terbatas.¹⁵

Kenyataan bahwa *trajectories* berdivergensi dengan lambat dalam perjalanan waktunya tidak akan begitu menarik perhatian kita karena hal ini umum ditemukan pada sistem-sistem periodik. Disebut *chaos* jika separasi berjalan cepat secara eksponensial, nilai rata-rata eksponen ini merupakan kuantifikasi dari “kekuatan” *chaos* dan disebut Lyapunov exponent. Kita dapat menetapkan jumlah Lyapunov exponent sebanyak dimensi *phase space*. Sehingga kita membatasi pada maximum Lyapunov exponent λ .

¹⁵ Peters, E. E. , (1991), *op.cit.*, hal: 146.

Misalkan X_{n1} dan X_{n2} adalah 2 buah titik dalam *phase space* dengan jarak $\| X_{n1} - X_{n2} \| = \delta_0 \ll 1$. Jarak antara dua *trajectories* yang berasal dari titik-titik tersebut pada waktu n adalah $\delta_{\Delta n} = \| X_{n1+\Delta n} - X_{n2+\Delta n} \|$. Maka λ ditentukan oleh :

$$\delta_{\Delta n} \cong \delta_0 e^{\lambda \Delta n}, \quad \delta_{\Delta n} \ll 1, \quad \Delta n \gg 1 \quad (2.10)$$

Jika λ positif berarti ada divergensi dari *trajectories* yang berdekatan, atau adanya *chaos*. Secara alami, 2 *trajectories* tidak dapat berpisah melebihi ukuran *attractor*-nya, sehingga persamaan (2.10) hanya valid dalam selang waktu Δn jika $\delta_{\Delta n}$ tetap kecil, jika syarat ini tidak dipenuhi akan terjadi saturasi jarak. Secara matematis diperlukan suatu limit $\delta_0 \rightarrow 0$ sehingga limit $\Delta n \rightarrow \infty$ dapat dilaksanakan tanpa mengakibatkan efek saturasi. Hanya jika limit kedua terpenuhi, maka eksponen λ terdefiniskan dengan baik dan merupakan besaran *invariant*.

Maximum Lyapunov exponent λ adalah negatif untuk sistem yang stabil pada suatu titik tetap. Untuk sistem yang bergerak secara periodik atau kuasiperiodik, lintasan berakhir pada suatu *limit cycle*, 2 *trajectories* hanya dapat saling mendekati atau menjauhi lebih lambat dibandingkan secara eksponensial, dalam kasus ini λ adalah 0. *Chaotic system* memiliki λ positif. Jika sistem deterministik dicemari oleh *random noise*, pada skala kecil ia akan dicirikan oleh proses difusi, dengan $\delta_{\Delta n}$ bertumbuh menurut $\sqrt{\Delta n}$, sehingga λ adalah tak terhingga. Tetapi jika hanya *additive measurement error*, maka kita dapat tetap bisa mencoba menghitung λ , misalnya setelah *noise* pada *time series* difilter.

2.14 MENGHITUNG MAXIMUM LYAPUNOV EXPONENT PADA TIME SERIES

Karena maximum Lyapunov exponent λ yang positif merupakan pertanda adanya *chaos*, maka sangat menarik untuk menerapkannya pada suatu *time series*. Wolf et al. (1985) mengembangkan suatu metoda numerik untuk menghitung λ dengan menggunakan rekonstruksi *phase space*.

Caranya adalah sebagai berikut :

Pilih 2 titik dalam *phase space*, letaknya minimal 1 periode rata-rata orbit. Setelah 1 interval waktu tertentu (periode evolusi), jarak antara kedua titik diukur. Jika jarak menjadi terlalu jauh, pilih titik pengganti dengan sudut orientasi yang sama dengan titik semula. Orientasi pasangan titik baru harus semirip mungkin dengan pasangan titik lama.

Titik pengganti diperlukan agar kita hanya mengukur divergensi dalam *phase space*. Jika titik-titik terlalu jauh, mereka akan melipat satu terhadap yang lain (*folding*) sehingga akan terukur sebagai konvergensi, konvergensi bukan merupakan bagian dari λ .¹⁶


Gambar 2.7 merupakan sketsa dari algoritma ini, persamaannya adalah :

$$\lambda = (1/t) \sum_{i=1}^m \log_2 \left(\frac{L'(t_{i+1})}{L(t_i)} \right) \quad (2.11)$$

Tetapi metoda ini mempunyai keterbatasan untuk digunakan pada data empiris, karena *random noise* dapat menghasilkan λ yang juga positif. Walaupun begitu λ tetap dapat mengungkapkan *chaos* jika besaran λ^{-1} nilainya dekat dengan *decorrelation time* T_d .¹⁷ Jika diduga kuat ada *random noise* dalam *time series*, dianjurkan untuk memeriksa *phase potrait* dan bandingkan *decorrelation time* T_d dengan λ^{-1} .

¹⁶ *Ibid*, hal: 159.

¹⁷ Chen, P. , *op.cit.*, hal: 222.



Sumber : Peters, E. E., "Chaos and Order in The Capital Markets", John Wiley & Sons Inc. , 1991., hal : 159.

Gambar 2.7 Sketsa Algoritma Wolf

2.15 HAL-HAL YANG PERLU DIPERHATIKAN PADA UJI EMPIRIS

Pengujian empiris lebih sulit dilakukan daripada studi teoritis karena dunia nyata jauh lebih kompleks dibandingkan model matematis yang disederhanakan. Chen (1993)¹⁸ menjelaskan beberapa masalah dalam mendeteksi *chaos* pada data empiris, yang digolongkan menjadi :

- Kesalahan yang umum terjadi akibat kurangnya informasi dalam pengujian empiris.
- Keterbatasan spesifik dari statistika untuk membedakan proses stokastik dengan *chaotic process*.

2.15.1 Data Yang Terlalu Jarang

Umumnya indikator ekonomi dan finansial terdiri dari hanya beberapa ratus titik data yang melingkupi hanya beberapa siklus naturalnya. Kekurangan ini sangat membatasi daya guna pelbagai *tools* yang biasa digunakan dalam studi *nonlinear dynamics* (seperti

¹⁸ *Loc. cit.*

Poincare map, spectral analysis, saddle-orbit analysis, dan yang lainnya) dalam mendeteksi *intrinsic irregularity* yang sebenarnya ada di dalam data itu.

Beberapa algoritma tetap dapat memberikan keluaran yang masih berguna walaupun data masukannya jarang, tetapi kinerjanya banyak berkurang. Yang lebih parah, kadang-kadang menghasilkan *numerical artifacts* yang menyesatkan.

Data yang jarang mendatangkan masalah besar pada penghitungan dimensi. Jumlah data minimum N_D yang diperlukan dalam estimasi dimensi mempunyai hubungan eksponensial dengan dimensi tersebut D , yaitu : $N_D = h^D$, dimana h bervariasi tergantung *attractor*-nya. Contohnya untuk model Mackey-Glass, data yang diperlukan untuk $D = 2$ adalah $N_D > 500$ titik ; dan untuk $D = 3$ adalah $N_D > 10.000$ titik. Secara umum 10 – 100 titik per siklus diperlukan pada model Mackey – Glass.

Kesalahan relatif perhitungan *correlation dimension* juga tergantung dari jumlah siklus alamiah sistem yang terlingkup dalam *time series*. Kesalahan relatif 1 % untuk 100 siklus, 3 % untuk 30 siklus, 8 % untuk 10 siklus, dan 18 % jika hanya 5 siklus. Sebagai “*rule of thumb*”, dimensionalitas yang teramati dalam data empiris tidak dapat lebih dari 5 dan *embedding dimension* dalam perhitungan tidak boleh lebih dari 10 jika jumlah data kurang dari 10.000 titik.

2.15.2 Noise

Data eksperimental umumnya selalu terkontaminasi oleh *noise*, *noise* adalah bagian yang tidak diinginkan dari data.

Measurement (additive) noise adalah gangguan terhadap observasi oleh *error* yang tidak tergantung dari dinamika sistem. Misalnya dinamika sistem memenuhi hubungan :

$x_{n+1} = F(x_n)$, tetapi hasil pengukuran skalar menghasilkan $s_n = s(x_n + \eta_n)$, dimana $s(x)$ adalah suatu fungsi yang memetakan titik-titik x_n pada *attractor* menjadi bilangan-bilangan riil s_n hasil pengukuran, *series* $\{\eta_n\}$ adalah *measurement noise*. Pembulatan (*truncation*) akibat adanya *minimum price fluctuation* dan *daily price limit* pada *futures prices* agrikultural dianggap menimbulkan *measurement noise*.¹⁹

Dynamical noise adalah proses umpan balik dimana ke dalam sistem diumpangkan sejumlah kecil *random* pada tiap langkah iterasi : $x_{n+1} = F(x_n + \eta_n)$
Kedua jenis *noise* tersebut tidak bisa dibedakan *a posteriori* berdasarkan hanya pada data *time series*. Biasanya *dynamical noise* lebih banyak menimbulkan masalah pada pemrosesan data daripada *measurement noise*, karena pada kasus terakhir *trajectory* bersih yang berdekatan masih selalu bisa diperoleh.

Noise membatasi kinerja algoritma yang sederhana, tetapi hal ini bukan merupakan kelemahan algoritma tersebut, karena *noise* itu sendiri merupakan faktor pembatas utama bagi prediktabilitas *deterministic systems*. Konsekwensi dari *noise* yang paling serius adalah rusaknya struktur *self-similarity* dari *strange attractor* yang terletak dalam sistem. *Self-similarity* direfleksikan oleh *correlation integral*, dan penskalaan menurut *power law* tidak berlaku dengan adanya *noise*. Kasusnya tidak menjadi lebih baik pada penghitungan Lyapunov exponent maupun entropi.

Jelaslah bahwa *noise* adalah *omnipresent phenomenon* yang tak dapat diabaikan begitu saja dan harus dilakukan sesuatu untuk mengatasinya. Langkah pertama adalah mengamati efeknya saat menganalisis data : *self-similarity* tidak tampak secara visual,

¹⁹ Wei, A. ; Leuthold, R. M., *op.cit.*, hal: 33.

correlation integral $C(m, \varepsilon)$ berdimensi tinggi pada skala ε yang kecil, *trajectories* yang berdekatan berdivergensi secara difusif (mengikuti *power law*) daripada eksponensial.

Jika *noise level* tidak begitu besar dan dalam *time series* dirasakan adanya unsur deterministik yang kuat, dapat dicoba langkah berikutnya yaitu memisahkan sinyal deterministik dari *noise* dengan cara *filtering*.

Untuk memfilter *noise* dapat digunakan metoda-metoda : *simple nonlinear noise reduction*, *noise reduction by gradient descent*, dan *local projective noise reduction*.²⁰ Dalam karya akhir ini digunakan metoda yang pertama.

2.15.3 Persamaan Kontinu, Persamaan Diskrit, dan Skala Waktu

Pada model empiris, pemilihan skala waktu dapat sangat mempengaruhi estimasi dan verifikasi. Skala waktu seharusnya ditentukan oleh dinamika natural dari proses yang dipelajari.²¹ Contohnya : pada dinamika populasi serangga, periode reproduksi serangga pada generasi yang tidak *overlap* dapat digunakan sebagai skala waktu yang natural (*natural time unit*) untuk mengkonstruksi *difference equation*.

Sistem yang bergerak secara kontinu dengan periode natural atau intrinsik harus disampel pada interval yang berhubungan dengan frekwensi intrinsik tersebut. Misalnya jika mempelajari kadar gula dalam darah manusia yang siklus natural-nya sekitar 24 jam. Dalam hal ini 24 sampel kadar gula dalam darah yang diambil tiap 1 jam adalah lebih merepresentasikan sistem dibandingkan dengan 60 sampel yang diambil tiap 1 menit.

²⁰ Ketiga metoda noise reduction ini dijelaskan secara rinci dan matematis dalam : Kantz, Holger ; Schreiber, Thomas , "Nonlinear Time Series Analysis", juga diberikan program komputer dalam bahasa Fortran dan C.

²¹ Chen, P. , *op.cit.*, hal: 224.

Kita tidak bisa sembarang memilih skala waktu tanpa didasari analisis teoritis dan pembuktian empiris. Koopmans (1950) menganjurkan menggantikan model stokastik diskrit dengan model stokastik kontinu jika korelasi serial lebih panjang dibandingkan dengan satuan waktu.

Pada rekonstruksi *phase space* perlu dipilih waktu tunda T yang tepat. Dalam karya akhir ini, penulis memperhatikan anjuran Wolf et al. (1985) bahwa estimasi yang baik untuk T pada *embedding dimension* m diperoleh dari hubungan : $T = Q / m$

Periode rata-rata orbit Q dihitung dengan menggunakan Rescaled Range (R/S) analysis dari Hurst.

Model *autoregressive* dan *moving average* (ARMA) dapat merepresentasikan *time series* yang dihasilkan oleh proses *chaotic* diskrit seperti persamaan Logistic dan Henon jika interval waktunya adalah intrinsik, tetapi tidak berhasil jika *time series* diperoleh melalui sampel pada interval waktu yang bukan intrinsik. Untuk model kontinu seperti persamaan Lorenz atau Mackey – Glass, model ARMA cocok dengan *time series* hanya jika interval waktu *sampling* kira-kira sama dengan perioda rata-rata orbital. Jadi berhasil atau tidaknya model ARMA merepresentasikan suatu *time series* tidak dapat mengindikasikan apakah *time series* tersebut dihasilkan oleh proses stokastik atau *chaos*.

2.15.4 Data Empiris Biasanya Terletak Di “Daerah Abu-abu”

Inferensi statistik dikembangkan untuk menguji proses stokastik dengan distribusi *identical independent distribution* (i.i.d). Sampai sejauh mana inferensi statistik dapat menangani *chaotic process* masih merupakan pertanyaan yang terbuka.

Proses stokastik dan *chaotic* adalah dua kutub yang berdasarkan pada asumsi yang bertentangan. Kebanyakan kasus-kasus empiris terletak dalam “daerah abu-abu” antara *chaos* dan *noise*. Terdapat kesenjangan antara sifat statis inferensi statistik dengan kompleksitas dinamis perilaku *chaotic*.

2.15.5 Prinsip Superposisi Tidak Berlaku Pada Sistem Nonlinier

Dalam model stokastik linier, variabel-variabel yang berinteraksi dapat dipisahkan dan solusi analitis dapat diperoleh karena dapat diterapkan prinsip superposisi dari solusi-solusi parsial linier. Tetapi prinsip superposisi tidak berlaku pada sistem nonlinier karena sistem secara keseluruhan adalah lebih besar dibandingkan penjumlahan komponen-komponennya (sifat *inseparability* dari sistem nonlinier).

Persamaan nonlinier dinamis jarang sekali menghasilkan solusi analitis yang tertutup, suatu solusi optimal yang “rapi” tidak akan diperoleh, melainkan kemungkinan solusi berganda. Jika diterapkan regresi pada sistem nonlinier dinamis, maka hasilnya akan menimbulkan keraguan. Sedangkan sifat *inseparability* sangat menyulitkan pengembangan *statistical tools* untuk menguji *chaos*.

2.15.6 Masalah Differencing : Proses Whitening

Differencing umum diterapkan dalam ekonometrika untuk memperoleh suatu *time series* yang stasioner dari *time series* semula yang tidak stasioner.

Brock (1986) berargumentasi bahwa dimensionalitas *time series* yang difilter tetap sama dengan *time series* aslinya. Tetapi sulit sekali untuk menilai hasil dari operasi *differencing* karena kepekaannya terhadap interval waktu yang digunakan pada proses *differencing*.

Dalam prakteknya prosedur *differencing* merupakan “*whitening process*” yang memangkas autokorelasi dan menaikkan variansi pada suatu *time series*. Sejauh ini belum ada argumentasi teoritis dan bukti numeris yang memperlihatkan invariansi dimensionalitas terhadap *difference transformation*.

2.15.7 Perubahan Attractor Oleh Residual Test

Agar yakin bahwa struktur yang diperiksa benar-benar nonlinier, Brock (1986) menerapkan *residual test*, yaitu menggunakan filter ARMA untuk mengambil bagian linier dari *time series*, selanjutnya pengujian dilakukan pada residual proses ARMA. Tetapi kemudian ditemukan bahwa proses *moving average* menambahkan *random noise* pada residual yang bisa menghapus struktur *fractal* (Garcia-Pelayo and Schieve, 1991). Untuk proses *autoregressive* akibatnya lebih tidak kentara, ukuran metrik *fractal dimension* adalah invarian, tetapi sebagian besar *probability dimensions*-nya tidak invarian. Sedangkan diketahui bahwa definisi *correlation dimension* adalah berhubungan dengan kuadrat dari *probability density*.

Time series finansial sering memiliki variansi yang berubah terhadap waktu yang dapat menghasilkan estimasi *correlation dimension* yang menunjukkan struktur nonlinier deterministik padahal sebenarnya tidak ada struktur demikian dalam data.²² Variansi yang berubah terhadap waktu dapat dihasilkan oleh proses ARCH yang stokastik ataupun proses *deterministic chaos*. Sehingga filter ARCH digunakan untuk mengambil proses ARCH dari *time series*, selanjutnya estimasi dilakukan pada residual ARCH.

Belum ada kesimpulan yang jelas tentang *residual test* dalam eksperimen numeris

²² DeCoster, G. P. ; Labys, W.C. ; Mitchell, D. W., *op.cit.*, hal: 467.


yang dilakukan oleh Chen (1993). DeCoster (1997) memakai residual test, sedangkan dan Wei dan Leuthold (1998) menghindarinya. Dalam karya akhir ini penghitungan *correlation dimension* maupun maximum Lyapunov exponent tidak dilakukan pada residual ARMA maupun residual ARCH.

2.15.8 Nonstasionaritas dan Nonnormalitas

Nonstasionaritas dan nonnormalitas sering ditemukan pada *time series* ekonomik karena ekonomi adalah sistem terbuka. Menghadapi masalah itu dalam kerangka kerja konvensional yang berdasarkan pada proses i.i.d merupakan pekerjaan yang sulit. Adanya pendekatan deterministik dan pendekatan stokastik dalam ekonomi teoritis menggambarkan pemikiran yang bertentangan antara mekanisme endogen dan mekanisme eksogen.

Tetapi dalam fisika teoritis, deskripsi deterministik dan deskripsi probabilistik dalam proses dinamis merupakan *complementary tools* dalam kerangka kerja dinamis yang manunggal. Sebagai contoh, reaksi kimia dapat digambarkan oleh persamaan diferensial (deterministik) atau sebuah persamaan induk. Fungsi distribusi probabilitas dalam persamaan induk dapat diperoleh melalui penyelesaian sebuah persamaan diferensial parsial (deterministik). Dalam kasus persamaan Fokker – Planck, puncak dari fungsi distribusi atau nilai rata-rata berkembang sepanjang jalur yang dapat direpresentasikan oleh lintasan dari persamaan deterministik yang bersangkutan. Oleh karena itu kedua pendekatan itu adalah ekuivalen sewaktu fungsi distribusi adalah unimodal. Tetapi selama *bifurcation* pada nilai kritis beberapa parameter kontrol, fluktuasi akan begitu besar sehingga nilai rata-rata tidak lagi merepresentasikan situasi yang paling mungkin terjadi karena fungsi distribusi mungkin menjadi *multihumped*.

Hubungan antara pendekatan deterministik dan pendekatan probabilistik diilustrasikan pada Gambar 2.8. Pendek kata, antara dua titik *bifurcation*, proses dinamis mengikuti sebuah jalur deterministik, yang dapat digambarkan oleh nilai rata-rata sewaktu proses memiliki sebuah distribusi *unimodal*. Inferensi statistik atau proses i.i.d dapat diaplikasikan kira-kira hanya pada situasi ini. Model *bifurcation* sangat berguna untuk memahami nonkontinuitas, nonstasionaritas, dan nonnormalitas dalam ekonomi riil sewaktu *econometricians* dibingungkan oleh fase berganda karakter dari evolusi ekonomi



Sumber : Chen, P. , "Searching for Economic Chaos: A Challenge to Econometric Practice and Nonlinear Tests." in Day, R.H. & Chen P. , eds. " Nonlinear Dynamics and Evolutionary Economics", Oxford University Press, 1993, hal: 231.

Gambar 2.8 Hubungan Antara Pendekatan Deterministik dan Probabilistik

2.16 RESCALED RANGE (R/S) ANALYSIS

Telah disinggung di depan bahwa, penentuan waktu tunda T diperoleh dari hubungan $T = Q / m$. Periode rata-rata orbit Q dihitung menggunakan Rescaled Range (R/S) analysis yang dikembangkan oleh Hurst. R/S analysis cukup handal dan dapat

diterapkan pada semua *time series*, tidak memerlukan persyaratan distribusi Gaussian, dan dapat membedakan *time series* random dan nonrandom, persistensi, dan durasi siklus periodik dan nonperiodik.

Hurst tertarik pada karya Einstein (1908) mengenai gerak Brown (suatu lintasan acak yang ditempuh partikel dalam fluida). Gerak Brown menjadi model utama untuk *random walk process*. Einstein menemukan bahwa jarak yang ditempuh partikel sama dengan akar dari waktu yang diperlukan untuk mengukurnya, atau :

$$R = T^{0,50} \quad (2.12)$$

dimana : R = jarak yang ditempuh

T = waktu

Untuk menstandarisasi pengukuran sepanjang waktu, Hurst menciptakan suatu rasio tanpa dimensi dengan cara membagi jangkauan (*range*) dengan standar deviasi pengukuran.

Dari suatu *time series* sepanjang N dibentuk A buah segmen-segmen *time series* sepanjang n , sehingga berlaku hubungan : $A \times n = N$

Tiap segmen diberi nama I_a , $a = 1, 2, 3, \dots, A$

Tiap elemen data dalam segmen I_a diberi nama : $N_{k,a}$, $k = 1, 2, 3, \dots, n$

Nilai rata-rata segmen I_a adalah : $e_a = (1/n) \sum_{k=1}^n N_{k,a}$

Time series deviasi kumulatif sepanjang periode a didefinisikan sebagai:

$$x_{k,a} = \sum_{i=1}^k (N_{i,a} - e_a) \quad , \quad k = 1, 2, 3, \dots, n$$

Range adalah perbedaan antara nilai maksimum dan minimum $x_{k,a}$ dalam setiap segmen I_a :

$$RI_a = \max (x_{k,a}) - \min (x_{k,a}).$$

Standar deviasi dalam setiap segmen :

$$SI_a : \sqrt{(1/n) \sum_{k=1}^n (N_{k,a} - e_a)^2}$$

Agar dapat diperbandingkan dengan pelbagai *time series*, *range* tiap segmen RI_a dinormalisasi dengan membaginya dengan standar deviasi SI_a nya masing-masing, sehingga *rescaled range* untuk segmen tersebut adalah RI_a / SI_a . Karena ada A buah segmen dengan panjang data n maka rata-rata R/S untuk segmen sepanjang n adalah :

$$(R/S)_n = (1/A) \sum_{a=1}^A (RI_a / SI_a)$$

Hurst menemukan bahwa *rescaled range* ini harus naik sesuai hubungan :

$$(R/S)_n = c n^H, \text{ atau}$$

$$\log (R/S)_n = \log c + H \log n \tag{2.13}$$

dimana : $H =$ Hurst exponent
 $c =$ konstanta

Jika $H = 0,5$ atau *range* dari deviasi kumulatif naik sesuai dengan waktu dipangkatkan $0,5$, maka *time series* adalah *random walk*. Jika $H \neq 0,5$ maka titik-titik pengamatan dalam *time series* adalah tidak bebas. Tiap pengamatan membawa “*memory*” dari semua kejadian yang mendahuluinya. Ini bukan merupakan *short-term memory* atau Markovian memory, melainkan *long-term memory* yang secara teoritis berlangsung selamanya. Peristiwa yang baru terjadi memberikan dampak yang lebih besar dibandingkan peristiwa yang lebih jauh, tetapi tetap ada pengaruh residual.²³

²³ Peters, E. E., (1991), *op.cit.*, hal: 64.

Dengan demikian waktu adalah suatu proses iteratif, dampak dari peristiwa sekarang terhadap peristiwa di depannya dapat diekspresikan sebagai korelasi : $C = 2^{(2H-1)} - 1$,dimana C adalah ukuran korelasi ²⁴.

Ada 3 klasifikasi untuk *Hurst exponent* H : (1) $H = 0,5$, (2) $0 \leq H < 0,5$, dan(3) $0,5 < H < 1$. H sama dengan $0,5$ menunjukkan suatu *random series*. Peristiwa-peristiwa adalah *random* dan tidak berkorelasi , ukuran korelasi $C = 0$. Peristiwa yang terjadi sekarang tidak mempengaruhi peristiwa-peristiwa selanjutnya.

Time series yang memiliki $0,5 < H < 1$ dinamakan *persistent series* atau *trend-reinforcing series*. Kecenderungan (*trend*) jelas terlihat, jika *series* naik (turun) di periode sebelumnya maka besar kemungkinannya untuk tetap naik (turun) di periode berikutnya. Kekuatan perilaku *trend-reinforcing* atau persistensi bertambah besar jika H mendekati 1 atau 100 % korelasi. Sebaliknya semakin dekat H ke $0,5$, *time series* semakin *random* dan kecenderungan semakin tidak terlihat. *Persistent series* adalah *fractional Brownian motion* atau *biased random walks*. Kekuatan *bias* tergantung dari seberapa jauh H di atas $0,5$.

Time series yang memiliki $0 \leq H < 0,5$ dinamakan *antipersistence series* atau *ergodic series*. Jika *series* naik (turun) di periode sebelumnya maka besar kemungkinannya untuk turun (naik) di periode berikutnya. Kekuatan perilaku antipersistensi tergantung pada seberapa jauh H mendekati 0 . Semakin dekat H ke 0 , semakin dekat ukuran korelasi C bergerak ke arah $-0,5$ atau korelasi negatif. *Time series* semacam ini lebih “bergerigi” atau lebih *volatile* dibandingkan dengan *random series* karena mengandung lebih banyak pembalikan-pembalikan.

²⁴ Pengukuran korelasi ini tidak ada hubungannya dengan Autocorrelation Function (ACF) . ACF mengasumsikan distribusi Gaussian atau near Gaussian dan ACF dapat bekerja dengan baik dalam menentukan ketergantungan jangka pendek. Tapi jika digunakan pada *time series nonGaussian* maka korelasi jangka panjang yang terukur akan lebih kecil dari yang seharusnya (*understate*).

Untuk mengevaluasi signifikansi dari R/S analysis, diperlukan suatu *confidence test* terhadap hasil estimasi, $E(R/S)_n$ adalah *expected R/S value* terhadap *random null hypothesis* bahwa *time series* adalah random, menurut persamaan Anis - Llyold yang dimodifikasi oleh Peters :²⁵

$$E(R/S)_n = ((n - 0,5) / n) \times (n \times \pi / 2)^{-0,5} \times \sum_{r=1}^{n-1} \sqrt{(n-r)/r} \quad (2.14)$$

Karena nilai R/S adalah variabel random yang terdistribusi normal, maka H juga akan terdistribusi normal, sehingga variansi H adalah : $\text{var}(H)_n = 1 / n$. (2.15)

Komponen periodik dari suatu sinyal dapat dideteksi oleh R/S analysis karena suatu sistem yang periodik berhubungan dengan *limit cycle* (atau *attractor* yang sejenis) sehingga *phase potrait* akan merupakan suatu *bounded set*. Misalnya jika sinyal berbentuk sinus murni, maka *time series* yang dihasilkan akan dibatasi (*bounded*) oleh amplitudo sinyal tersebut, karena *range* tidak dapat tumbuh melebihi amplitudo, maka nilai R/S akan mencapai nilai maksimum setelah mencapai 1 siklus penuh. R/S analysis pun mampu mendeteksi adanya sub-siklus jika sinyalnya merupakan superposisi beberapa sinyal yang berbeda frekwensinya.

Dalam *chaotic system* terdapat siklus nonperiodik, siklus tersebut mempunyai durasi rata-rata tetapi berapa persisnya durasi siklus selanjutnya tidak diketahui. R/S analysis juga dapat digunakan untuk mendeteksi siklus periodik maupun nonperiodik.²⁶

Plot log (R/S) terhadap log n menunjukkan suatu *breaks* (patahan) atau *flattening* (menjadi datar) pada akhir siklus karena pada titik tersebut nilai R/S berhenti bertumbuh. Ada cara yang lebih mudah untuk melihat patahan sehingga dapat memberikan estimasi

²⁵ Peters, E. E., "Fractal Market Analysis", John Wiley & Sons Inc. , 1994, hal: 71.

²⁶ *Ibid*, hal: 88.

panjang siklus dengan lebih jelas. Hurst mengembangkan V statistic yang didefinisikan sebagai :

$$V_n = (R/S)_n / \sqrt{n} \quad (2.15)$$

Rasio ini akan berupa garis horisontal jika R/S statistik berskala menurut akar waktu. Dengan perkataan lain kurva akan mendatar jika proses adalah random ($H = 0,5$).

Sedangkan jika proses adalah persisten dan R/S berskala dengan laju yang lebih cepat dari akar waktu ($0,5 < H < 1$) maka kurva akan miring ke atas (*positive slope*). Sebaliknya jika proses adalah antipersisten ($0 \leq H < 0,5$) maka kurva akan miring ke bawah (*negative slope*). Dengan mem-plot V pada sumbu y dan log n pada sumbu x, maka patahan adalah saat kurva V mendatar.

R/S analysis memiliki kelemahan yaitu peka terhadap *short-range dependence*. Ketergantungan linier dapat menyebabkan *bias* pada Hurst exponent (tampak signifikan padahal tidak ada *long-memory process*, atau disebut *type I error*).

Lo dan Mac Kinlay (1999) memodifikasi R/S analysis sehingga hasilnya tidak dipengaruhi oleh *short memory process*. Caranya adalah dengan memasukkan *weighted autocovariance* sampai lag $q < n$ pada denominator SI_a . Tetapi tidak ada petunjuk berapa nilai q yang tepat.²⁷

Peters (1994) menggunakan residual AR(1) dari *logaritmik prices differences* untuk mengeliminasi, atau setidaknya mengurangi ketergantungan linier. Proses ini dinamakan *detrending* atau *prewhitening*. Pada kasus-kasus lain, *detrending* dapat menghapus informasi tertentu. Tetapi pada kasus R/S analysis, *detrending* dapat menghilangkan korelasi serial atau *short-memory* yang merupakan problem utama.²⁸

²⁷ Lo, A.W. ; MacKinlay, A.C., "A Non-Random Walk Down Wall Street", Princeton University Press, Princeton, New Jersey, 1999, hal: 159.

²⁸ Peters, E. E., (1994), *op.cit.*, hal: 108.

BAB III

SISTEMATIKA PENELITIAN

3.1 PERLUKAH ANALISIS NONLINIER ?

Pada bagian-bagian sebelumnya telah dibahas mengenai algoritma untuk mengestimasi *correlation dimension* dan *maximum Lyapunov exponent* dari *time series* empiris. Kita juga mengetahui adanya persyaratan yang ketat pada kualitas maupun kuantitas data masukan. Karya akhir ini membahas metoda-metoda untuk menganalisis *time series* nonlinier yang relatif kurang dimengerti dibandingkan dengan metoda-metoda klasik untuk proses linier stokastik.

Sebelum menerapkan analisis nonlinier pada suatu *time series* ada baiknya diajukan pertanyaan-pertanyaan sebagai berikut :

Apakah struktur yang nampak pada data ditimbulkan oleh nonlinieritas atau hanya oleh korelasi linier ? Apakah ketidakteraturan atau nonperiodisitas data kemungkinan besar disebabkan oleh nonlinier deterministik, masukan random ke sistem, atau parameter yang berfluktuasi ?

Analisis akan memiliki landasan yang lebih kokoh jika dilakukan uji hipotesis bahwa data dapat direpresentasikan oleh model linier.

3.2 TAHAPAN PENELITIAN

Penelitian dimulai dari mencari kemungkinan pemodelan linier stokastik ARIMA, nonlinieritasnya direpresentasikan dengan model ARCH (GARCH). Jika model ARCH (GARCH) kurang meyakinkan maka barulah dilakukan pengujian *chaos*.

Penelitian disusun menurut tahap-tahap sebagai berikut :

1. *Data treatment* , meliputi :

- Pengisian data *time series* yang kosong akibat adanya *public holiday, market holiday, trading suspended, dan market suspended*.
- Mengadakan *roll-over adjustment* untuk mengatasi masalah adanya *price "jump"* saat terjadi pergantian kontrak.
- Melakukan *detrending* pada *time series* untuk menghilangkan *growth / trend* pada *futures prices*.

2. Uji normalitas dilaksanakan dengan mengamati kurtosis, *skewness*, dan Jarque-Bera statistic.

3. Tahap pemodelan linier stokastik ARIMA dan nonlinier stokastik ARCH (GARCH)

- Untuk menguji stasionaritas digunakan Dickey-Fuller test dan Phillips-Perron test.
- Pengamatan pola autokorelasi dan autokorelasi parsial.
- Pengujian ARCH pada residual : pengamatan pola autokorelasi dan autokorelasi parsial residual kuadrat dan Lagrange Multiplier (LM) test.

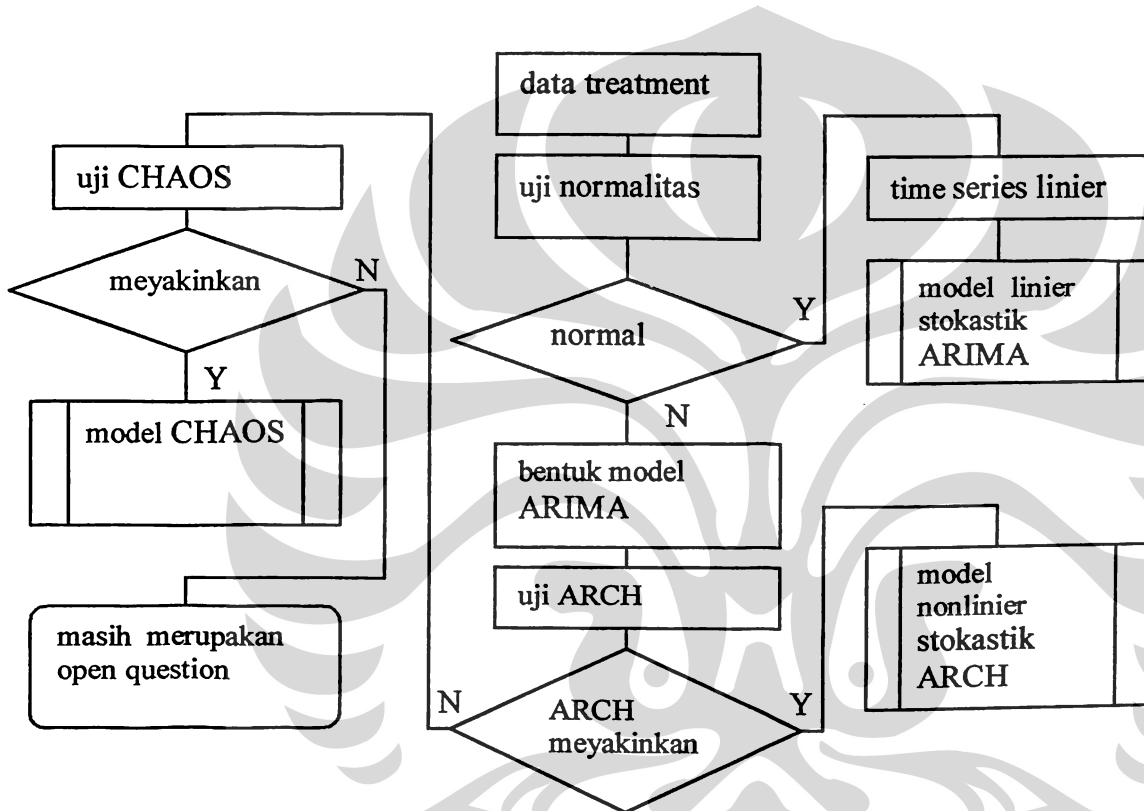
Tahap-tahap selanjutnya dilakukan jika pemodelan ARIMA dan ARCH (GARCH) hasilnya tidak terlalu meyakinkan (kuat).

4. Rescaled range (R/S) analysis

- Menghitung Hurst exponent H dan *expected value*-nya untuk membuktikan random tidaknya *time series* tersebut.
- Menghitung panjang siklus nonperiodik untuk digunakan sebagai parameter pada estimasi *correlation dimension* dan maximum Lyapunov exponent.

5. Pembuktian adanya *chaotic structure*

- *Noise filtering*
- Menghilangkan *temporal correlation*
- Estimasi *correlation dimension* dan *maximum Lyapunov exponent*
- Analisa final untuk menyimpulkan ada tidaknya *chaotic structure*.



Gambar 3.1 Diagram Alir Tahap Penelitian

3.3 DATA TREATMENT

Dalam penelitian ini digunakan data *futures prices* CPO dari Commodity and Monetary Exchange of Malaysia (COMMEX Malaysia) sepanjang 20 tahun (23 Okt 1980 – 31 Mar 2000).

Time series dikonstruksi dari *futures prices* kontrak terdekat (1 bulan). *Daily prices* adalah *settlement price* tiap *trading day* (*trading day* adalah 5 hari dalam 1 minggu kalender), *weekly prices* adalah *settlement price* tiap hari Jum'at, sedangkan *monthly prices* adalah *settlement price* di hari terakhir *trading day* tiap bulan kalender.

Kekosongan dalam *daily prices series* disebabkan oleh *public holiday*, *market holiday*, *trading suspended*, dan *market suspended*; karena frekwensinya sangat jarang dan durasinya pendek maka kekosongan ini diisi dengan *price* hari terdekat sebelumnya.

Mengkonstruksi *price series* dari kontrak terdekat menimbulkan masalah adanya *price "jump"* saat terjadi pergantian kontrak (di COMMEEX Malaysia kontrak 1 bulan *expired* setiap tanggal 15 atau hari terdekat sebelumnya jika tanggal 15 merupakan *non-trading day*). Dalam penelitian ini digunakan prosedur "*roll-over*" untuk menghindari efek "*jump*" tadi. Saat terjadi perpindahan kontrak pada hari terakhir kontrak lama, selisih *prices* antara kontrak lama dengan kontrak baru diamati, kemudian semua *prices* kontrak baru disesuaikan (*adjusted*) dengan selisih ini. Walaupun terjadi perubahan *prices*, tetapi karena dalam penelitian ini digunakan *prices differences* maka tidak akan jadi masalah, yang lebih penting efek "*jump*" dapat dihindari.¹

Perbandingan kurva *time series* sebelum dan sesudah *adjustment* dapat dilihat di Lampiran 1.

Metoda *detrending* yang digunakan dalam R/S analysis dan pemodelan ARMA adalah *logaritmik prices differences*. Pada R/S analysis *logaritmik return* lebih cocok digunakan dibandingkan *percentage change in prices*. *Range* yang digunakan dalam R/S

¹ Wei, A. ; Leuthold, R. M., "Long Agricultural Futures Prices: ARCH, Long Memory, or Chaos Process?", OFOR Paper Number 98-03, May 1998, hal: 11.

analysis adalah *cumulative deviation* dari nilai rata-rata, *logaritmik returns* bersifat menjumlahkan terhadap *cumulative return*².

$$s_t = \log (P_t / P_{t-1}) \quad \text{dimana :} \quad s_t = \text{hasil } \textit{logaritmik prices differences}$$

$$P_t = \textit{original prices series}$$

Metoda alternatif yang disebut *log-linear detrending* sering digunakan pada analisis *chaos*³: estimasi *correlation dimension*, dan maximum Lyapunov exponent.

$$s_t = \ln (P_t) - (k_0 + k_1 t) \quad \text{dimana :} \quad s_t = \text{hasil } \textit{log-linear detrending}$$

$$P_t = \textit{original prices series}$$

$$k_0 = \text{perpotongan}$$

$$k_1 = \text{laju pertumbuhan}$$

Tahap *data treatment* ini menghasilkan keluaran 6 buah file dalam format ASCII file (*.PRN) yang akan dipergunakan sebagai masukan untuk tahap-tahap selanjutnya.

Tabel 3.1 Daftar Nama File dan Jumlah Data Dalam Time Series

File (*.PRN)	Jml. Data	Keterangan
DAL	5070	Daily, adjusted, logaritmik prices diff.
WAL	1014	Weekly, adjusted, logaritmik prices diff.
MAL	233	Monthly, adjusted, logaritmik prices diff.
DA1	5071	Daily, adjusted, log-linear detrending
WA1	1015	Weekly, adjusted, log-linear detrending
MA1	234	Monthly, adjusted, log-linear detrending

² Peters, E. E., "Chaos and Order in The Capital Markets", John Wiley & Sons Inc., 1991, hal: 81.

³ Chen, P. , "Searching for Economic Chaos: A Challenge to Econometric Practice and Nonlinear Tests." in Day, R.H. & Chen P. , eds. " Nonlinear Dynamics and Evolutionary Economics", Oxford University Press, 1993, hal: 233.

Tabel 3.2 Parameter Yang Dipakai Pada Log-Linear Detrending

Series	k_0	k_1
DA1	7,224238	0,000230
WA1	7,222435	0,001152
MA1	7,217394	0,00502

3.4 PENGUJIAN NORMALITAS

Uji normalitas yang banyak digunakan dan sering disertakan dalam perangkat lunak statistika adalah Jarque-Bera test (JB test). JB test mengukur S (*skewness*, yaitu ukuran ketidak-simetrisan pola distribusi) dan K (*kurtosis*, yaitu perbandingan ketinggian / kedataran pola distribusi terhadap distribusi normal). Untuk distribusi normal *skewness* adalah 0 dan *kurtosis* adalah 3, sehingga JB adalah 0.⁴

Uji statistik Jarque dan Bera adalah sebagai berikut :

$$JB = (n/6) \times (S^2 + (K - 3)^2 / n)$$

, n adalah jumlah sampel

Persamaan di atas secara asimtotis (jika jumlah sampel sangat besar) mengikuti distribusi χ^2 dengan 2 derajat kebebasan.

JB test yang ada dalam perangkat lunak EviewsTM digunakan untuk menguji normalitas 3 buah *logaritmik prices differences time series* (DAL, WAL, dan MAL) dan 3 buah *log-linear detrending* (DA1, WA1, dan MA1).

Uji normalitas juga dilakukan pada *prices series* sebelum *adjustment* (D, W, dan M) dan setelah *adjustment* (DA, WA, dan MA).

⁴ Gujarati, D. N., "Essentials of Econometrics", Second Edition, Irwin/McGraw-Hill Inc., Singapore, 1999, hal: 178.

Hasil uji normalitas dicantumkan pada Lampiran 2.

3.5 PENGUJIAN STASIONARITAS

Sifat *time series* lain yang penting adalah stasionaritas, yang diperhatikan disini adalah *covariance stationarity* atau *weak stationarity*. Augmented Dickey-Fuller test (ADF test) yang ada di dalam perangkat lunak Eviews™ digunakan untuk menguji stasionaritas 3 buah *logaritmik prices differences time series* (DAL, WAL, dan MAL) dan 3 buah *log-linear detrending* (DA1, WA1, dan MA1).

Uji stasionaritas juga dilakukan pada *prices series* sebelum *adjustment* (D, W, dan M) dan setelah *adjustment* (DA, WA, dan MA). Tetapi karena semua *time series* di atas diduga mengandung *heteroscedasticity*, maka dilakukan juga Phillips-Perron semi-parametric test (PP test) yang lebih andal dalam menghadapi autokorelasi dan *heteroscedasticity* dalam bentuk yang tidak diketahui.

Hasil uji stasionaritas dicantumkan pada Lampiran 3.

3.6 PENGAMATAN POLA AUTOKORELASI

Pada pemodelan linier stokastik ARMA(p,q), pengamatan visual pada pola autokorelasi dan autokorelasi parsial dapat menganjurkan bentuk ARMA(p,q) yang memadai untuk *time series* tersebut.

- Autokorelasi parsial dari proses AR(p) secara teoritis adalah 0 pada lag > p.
- Autokorelasi dari proses MA(q) secara teoritis adalah 0 pada lag > q.
- Autokorelasi dari proses ARMA(p,q) menurun secara bertahap atau berosilasi dimulai pada lag q. Sedangkan autokorelasi parsial dari proses ARMA(p,q) akan menurun secara bertahap dimulai pada lag p.

Pada saat yang sama pola ini memberikan informasi yang sangat penting untuk pemodelan nonlinier dinamis.⁵ *Correlogram* yang terdapat dalam perangkat lunak Eviews™ digunakan untuk mengamati pola autokorelasi dan autokorelasi parsial ke 3 *logarithmic prices differences time series* DAL, WAL, dan MAL. Pola autokorelasi dan autokorelasi parsial ke 3 *log-linear detrending time series* DA1, WA1, dan MA1 juga diamati terutama *decorrelation time* T_d , karena nilai T_d ada hubungannya dengan maximum Lyapunov exponent.⁶

Correlogram dalam Eviews™ juga menampilkan Ljung-Box Q-statistics dan p-values. Q-statistics sering digunakan untuk menguji apakah *time series* tersebut adalah *white noise*.

Pola autokorelasi dan autokorelasi parsial, Q-statistics, dan p-value untuk *time series* di atas dapat dilihat di Lampiran 4.

3.7 PENGUJIAN ARCH

Model ARCH mengakui adanya nonnormalitas pada data yang distribusinya tidak dikondisikan (*unconditional distribution of the data*). Dengan asumsi adanya distribusi yang normal pada data yang telah dikondisionalkan, maka struktur ARCH dibangun untuk “menangkap” *time-dependent variance* tersebut. Menggunakan fungsi variansi sebagai salah satu variabel dalam pemodelan mengakibatkan *maximum likelihood estimates of mean* menjadi lebih efisien dan konsisten. *Time series* data finansial sering memperlihatkan distribusi yang tidak normal *dengan time-varying volatility*, sehingga model ARCH menjadi sangat populer dalam pemodelan *time series* data finansial.⁷

⁵ Chen, P., *op.cit.*, hal: 218.

⁶ *Ibid*, hal: 222.

⁷ Wei, A.; Leuthold, R. M., *op.cit.*, hal : 16.

Untuk mendefinisikan proses ARCH, misalkan ada suatu *time series* Y_t yang dihasilkan oleh suatu proses stokastik AR(p) :

$$Y_t = \alpha_0 + \sum_{j=1}^p \alpha_j Y_{t-j} + \varepsilon_t$$

Dan ada suatu information set $\Psi_{t-1} = \{Y_{t-1}, Y_{t-2}, \dots\}$ sehingga :

$$\varepsilon_t | \Psi_{t-1} \sim N(0, h)$$

dimana :
$$h_t = \theta_0 + \sum_{i=1}^k \theta_i \varepsilon_{t-i}^2$$

dengan $\theta_0 > 0$, $\theta_i \geq 0$, $i = 1, \dots, k$ untuk menjamin variansi yang dikondisikan positif.

Proses Y_t dinamakan AR(p) dengan ARCH(k) error.

Dalam persamaan di atas, variansi yang dikondisikan dari *error* saat ini ε_t merupakan *increasing function* dari k *error* sebelumnya ε_{t-i} , $i = 1, \dots, k$. Sehingga *error* yang besar (dalam nilai absolut) cenderung diikuti oleh *error* yang besar, dan *error* yang kecil diikuti oleh *error* yang kecil. Nilai k menentukan persistensi suatu *error* dalam pengkondisian variansi *errors* berikutnya. Semakin besar nilai k, semakin panjang *spiking period* berlangsung. Oleh karena itu *spikes* tersebut bukan dihasilkan oleh perubahan struktural dari luar, tetapi oleh ketergantungan nonlinier yang dapat diperkirakan.

Autokorelasi dari residual kuadrat memberikan bukti adanya efek ARCH. Lagrange Multiplier (LM) test digunakan pada residual kuadrat untuk melakukan uji ARCH(k) terhadap hipotesis nol bahwa tidak ada efek ARCH, nilai statistik pengujian memiliki

distribusi χ^2 dengan k derajat kebebasan. Nilai yang melebihi nilai kritis pada tabel χ^2 memberikan bukti adanya efek ARCH (atau GARCH).⁸

Standar Lagrange Multiplier test (LM test) yang terdapat dalam perangkat lunak Eviews™ digunakan untuk menguji apakah terdapat efek ARCH(1) di dalam residual ARMA(p,q) *time series* DAL, WAL, dan MAL.

Karena ARCH(1) adalah struktur yang paling sederhana dalam ARCH dan varian-nya, maka jika ARCH(1) eksis maka dapat dilakukan penyelidikan selanjutnya untuk mencari struktur ARCH atau varian-nya yang lebih sesuai. Pengujian selanjutnya dilakukan pada autokorelasi dan autokorelasi parsial *residual square* dari residual ARIMA(p,d,q) untuk mencari k dan g dari GARCH(k,g).

Pola autokorelasi dan autokorelasi parsial, Q-statistics, dan p-value untuk *time series* di atas dapat dilihat di Lampiran 4.

3.8 RESCALED RANGE ANALYSIS (R/S ANALYSIS)

R/S analysis adalah proses yang sederhana tetapi membutuhkan banyak perhitungan.

Berikut adalah uraian langkah-langkah yang *executable*⁹ :

1. *Time series* dengan panjang data M dikonversi menjadi *time series* dengan panjang $N = M - 1$ yang merupakan rasio logaritmis :
$$N_i = \log(M_{i+1} / M_i) \quad , \quad i = 1, 2, 3, \dots, (M - 1)$$
2. Bagi *time series* dengan panjang N menjadi A buah *time series* masing-masing panjangnya n (dimulai dengan $n = 10$), sehingga berlaku $A \times n = N$. Beri masing-

⁸ Greene, W. H., "Econometrics Analysis", Prentice Hall International, Inc., Fourth Edition, 2000, hal : 808.

⁹ Peters, E. E., "Fractal Market Analysis", John Wiley & Sons Inc. , 1994, hal : 62.

masing subperiod *time series* dengan panjang n tersebut label I_a dengan $a = 1, 2, 3, \dots$,

A. Masing-masing elemen dalam subperiod I_a diberi label $N_{k,a}$ dengan $k = 1, 2, 3, \dots, n$.

Untuk setiap I_a dengan panjang data n , nilai rata-rata didefinisikan sebagai :

$$e_a = (1/n) \times \sum_{k=1}^n N_{k,a}$$

3. Bentuk *time series* dari *accumulated departures* terhadap nilai rata-rata untuk tiap-tiap subperiod I_a :

$$X_{k,a} = \sum_{i=1}^k (N_{i,a} - e_a) \quad , \quad k = 1, \dots, n$$

4. *Range* didefinisikan sebagai nilai maksimum dikurangi nilai minimum

$X_{k,a}$ di dalam masing-masing subperiod I_a :

$$R_{I_a} = \max(X_{k,a}) - \min(X_{k,a}) \quad , \quad 1 \leq k \leq n$$

5. Standar deviasi sampel dihitung untuk setiap subperiod I_a :

$$S_{I_a} = (1/n) \times \sqrt{\sum_{k=1}^n (N_{k,a} - e_a)^2}$$

6. Tiap *range* R_{I_a} dinormalisasikan (di *rescaled*) dengan membaginya terhadap S_{I_a} miliknya. Sehingga *rescaled range* untuk masing-masing subperiod I_a adalah sama dengan R_{I_a} / S_{I_a} . Dari langkah 2 di atas ada A *contiguous* subperiods dengan panjang n . Sehingga nilai rata-rata R/S untuk *time series* sepanjang n adalah

$$(R/S)_n = (1/A) \times \sum_{a=1}^A (R_{I_a} / S_{I_a})$$

7. Gunakan nilai n berikutnya, tetapi N harus habis dibagi n . Ulangi langkah 2 s/d 6 hingga nilai $n = N / 2$.

Program komputer digunakan untuk mengeksekusi langkah-langkah di atas (*source code* RSanalysis dapat dilihat pada Lampiran 8). Berkas masukan dan keluaran untuk program ini ber-format ASCII (*.PRN). Langkah 1 tidak dilakukan di dalam program ini karena berkas masukan sudah dalam bentuk logaritmis.

Sebagai berkas masukan akan digunakan residual AR(1) dari *time series* : DAL, WAL , dan MAL. Panjang data N dipilih agar menghasilkan sebanyak mungkin faktor kelipatan bulat untuk $n = 10$ sampai dengan $N / 2$, misalnya $N = 5070$ mempunyai 18 buah faktor kelipatan bulat untuk $n = 10, 13, 15, 26, \dots, 2535$; sedangkan 5060 mempunyai 19 buah faktor kelipatan bulat untuk $n = 10, 11, 20, 22, \dots, 2530$.

Berkas keluaran menghasilkan 5 kolom data $\log n$, $\log (R/S)$, $\log E(R/S)$, $(R/S)/\sqrt{n}$, dan $E(R/S)/\sqrt{n}$. Jumlah baris data tergantung dari jumlah faktor kelipatan bulat (misal untuk $N = 5060$ akan terdapat 19 baris data).

Pengolahan data selanjutnya dilakukan dengan menggunakan perangkat lunak Eviews™, sebagai berikut :

- Plot $\log (R/S)$ dan $\log E(R/S)$ pada sumbu Y dan $\log n$ pada sumbu X.
- Regresi OLS antara $\log n$ sebagai variabel bebas dan $\log (R/S)$ sebagai variabel tak bebas. Kemiringan (*slope*) adalah nilai Hurst exponent H , sesuai dengan persamaan :
$$\log (R/S)_n = \log (c) + H * \log (n).$$

- Plot $(R/S)/\sqrt{n}$ dan $E(R/S)/\sqrt{n}$ pada sumbu Y dan $\log n$ pada sumbu X adalah kurva V-statistics. Siklus nonperiodik terjadi saat *slope* kurva berubah dari positif menjadi negatif (terjadinya patahan).

Hasil dari R/S analysis dapat dilihat pada Lampiran 5.

3.9 ESTIMASI CORRELATION DIMENSION

Untuk meng-eksekusi persamaan (2.9), pertama-tama harus direkonstruksi *phase space*. Parameter yang perlu ditetapkan adalah *embedding dimension* (m) dan *lag* yang dipergunakan sewaktu me-rekonstruksi *phase space* (T). Menurut teorema Taken, untuk memperoleh hasil estimasi yang baik, *embedding dimension* untuk suatu *phase space* harus memenuhi kondisi $m \geq 2U + 1$, dimana U adalah Hausdorff dimension. Secara praktis nilai U dapat didekati dengan *correlation dimension* D sehingga dapat dipakai hubungan $m \geq 2D + 1$.¹⁰

Biasanya *chaos* dengan *correlation dimension* kurang dari 5 dianggap *low-dimension chaos*. Penelitian ini bertujuan mencari *low-dimension chaos* karena *low-dimension chaos* lebih punya kegunaan praktis dibandingkan *chaos* yang berdimensi lebih tinggi.. Dalam penelitian ini *embedding dimension* di-set mulai dari 2 sampai dengan 10 dengan kenaikan 1, cukup untuk mendeteksi *low-dimension chaos*.

Parameter T harus ditentukan menurut hubungan : $T = Q / m$, dimana Q adalah panjang perioda rata-rata siklus non periodik yang telah dihitung melalui R/S analysis.

¹⁰ Wei, A. ; Leuthold, R. M., *op. cit.*, hal : 25

Parameter lain yang penting adalah nilai bilangan kecil sembarang ϵ . Estimasi *correlation dimension* sangat sensitif terhadap nilai ϵ . Dalam proses penghitungan *correlation dimension*, nilai ϵ dimulai dengan suatu nilai kecil sembarang tertentu yang kemudian diturunkan secara bertahap menuju 0. Jika nilai awal ϵ terlalu dekat ke 0, maka semua *correlation integral* akan segera menjadi 0 begitu nilai ϵ diturunkan menuju 0. Sebaliknya jika nilai awal ϵ terlalu jauh dari 0, maka semua *correlation integral* akan segera menjadi 1 begitu nilai ϵ diturunkan menuju 0. Nilai ϵ harus di-set sedemikian rupa sehingga jika *embedding dimension* menuju maksimum dan ϵ menuju 0, *correlation integral* terletak antara 0 dan 1.

Menurut eksperimen Wolf (1985), ϵ minimum harus ditentukan sebesar 10 % dari jangkauan data *time series* yang digunakan (selisih antara nilai terbesar dengan nilai terkecil data).¹¹

Tabel 3.3 mencantumkan Q yang didapatkan dari R/S analysis dan ϵ minimum yang dihitung dari *time series* yang dipakai.

Tabel 3.3 Parameter Untuk Estimasi Correlation Dimension

Series	G	ϵ
DA1	1012	0,12
WA1	200	0,12
MA1	42	0,11

Langkah-langkah penghitungan *correlation dimension* :

1. Rekonstruksi sebuah *phase space* dimulai dengan *embedding dimension* $m = 2$, *time lag* T ditentukan melalui hubungan $T = Q / m$, dimana Q adalah panjang orbit siklus

¹¹ *Ibid*, hal: 26.

nonperiodik yang telah dihitung dengan R/S analysis. Ambil bilangan bulat terdekat jika Q / m tidak menghasilkan bilangan bulat.

2. Mulai menghitung dengan suatu ε yang kecil, sebagai *rule of thumb* nilai ε adalah 10 % selisih nilai terbesar dengan nilai terkecil dalam *time series*.
3. Hitung *correlation integral* $C_m(\varepsilon)$ untuk nilai m dan ε tersebut dihitung menurut persamaan di atas.
4. Untuk suatu dimensi m , C_m dihitung untuk nilai ε bertambah besar (dilakukan 14 kali kenaikan).
5. Ulangi langkah 1 sampai dengan 4 untuk nilai dimensi m berikutnya sampai dengan 10.

Program komputer digunakan untuk mengeksekusi langkah-langkah di atas, *source code* CorrDim dapat dilihat pada Lampiran 8. Berkas masukan dan keluaran untuk program ini ber-format ASCII (*.PRN).

Sebagai berkas masukan akan digunakan *time series* : DA1, WA1, dan MA1, setiap kali dieksekusi, program menghasilkan 2 berkas keluaran.

Berkas keluaran pertama terdiri dari 10 kolom : kolom 1 s/d 9 adalah data $\log C(m, \varepsilon)$ untuk dimensi 2 s/d 10, kolom 10 adalah data $\log \varepsilon$. Jumlah baris data adalah 14 sesuai dengan langkah kenaikan ε .

Pengolahan data selanjutnya dilakukan dengan menggunakan perangkat lunak Eviews™ sebagai berikut :

- Plot $\log C(m, \varepsilon)$ pada sumbu Y dan $\log \varepsilon$ pada sumbu X.

- Amati apakah ada daerah dimana kurva paralel satu sama lainnya, di daerah ini berlaku hubungan *power law* $C(\varepsilon) \propto \varepsilon^D$. Hanya jika ada daerah seperti ini maka dapat dilakukan langkah selanjutnya :
- Regresi OLS antara $\log \varepsilon$ sebagai variabel bebas dan $\log C(m, \varepsilon)$ sebagai variabel tak bebas pada bagian kurva yang linier. Kemiringan (*slope*) adalah nilai *correlation dimension* D untuk *embedding dimension* m sesuai persamaan :

$$\log (C_m) = D * \log (R) + \text{konstanta.}$$

Berkas keluaran kedua terdiri dari 10 kolom : kolom 1 s/d 9 adalah data *slopes* untuk dimensi 2 s/d 10 , kolom 10 adalah data $\log \varepsilon$. Jumlah baris data adalah 13 sesuai dengan langkah kenaikan ε dikurangi 1 langkah.

Pengolahan data selanjutnya dilakukan dengan menggunakan perangkat lunak Eviews™ sebagai berikut :

- Plot *slopes* pada sumbu Y dan $\log \varepsilon$ pada sumbu X.
- Amati apakah ada daerah *plateau* yang stabil pada kurva, pengamatan ini lebih jelas dibandingkan dengan mengamati kurva-kurva paralel seperti pada langkah di atas. Di daerah *plateau* yang stabil inilah terletak nilai *correlation dimension* yang dicari.

Jika pada estimasi *correlation dimension* ini dapat diamati adanya *plateau* yang stabil tetapi nilai *correlation dimension* dirasakan terlalu kecil dari seharusnya (*underestimate*), maka *temporal correlation* pada *time series* harus dihilangkan. *Temporal correlation* dapat diamati pada *space-time separation plot*, dan diamati kapan kurva

mencapai saturasi. Estimasi dilakukan setelah pasangan titik-titik yang jaraknya kurang dari *correlation time* $t_{\min} = \eta_{\min} \Delta t$ dibuang.

Selain itu untuk mendapatkan hasil estimasi yang baik, pada *time series* juga perlu dilakukan penyaringan (*filtering*) *noise* secukupnya.

Dalam karya akhir ini dibuat program StPlot untuk membuat *space-time separation plot* dan program NoiseFilt untuk melakukan algoritma *simple noise reduction*.

Hasil estimasi *correlation dimension* dapat dilihat pada Lampiran 6.

3.10 PERHITUNGAN NUMERIK MAXIMUM LYAPUNOV EXPONENT

Untuk meng-eksekusi persamaan (2.11), pertama-tama harus direkonstruksi *phase space*. Parameter yang perlu ditetapkan adalah *embedding dimension* (m) harus lebih besar dibandingkan dengan *phase space* dari *attractor* yang mendasari.¹²

Parameter T ditentukan menurut hubungan : $T = Q / m$, dimana Q adalah panjang perioda rata-rata siklus non periodik yang telah dihitung melalui R/S analysis.

Nilai parameter-parameter lain harus dicoba dengan eksperimen, tetapi Wolf et al. (1985) memberiklan suatu *rule of thumb*.

Parameter *evolution time* (EVOLV) ditentukan untuk mengukur efek divergensi, *evolution time* harus cukup panjang untuk mengukur *stretching*, tapi juga jangan terlalu panjang karena terjadi *folding* pada *attractor*. Wolf menganjurkan agar *evolution time* jangan lebih dari 10 % dari panjang *attractor* dalam *phase space* (jumlah baris dalam matriks *phase space*).

¹² Peters, E. E ., (1991), *op. cit.*, hal: 158.

Jarak maksimum divergensi sebelum titik pengganti ditemukan (SCALMAX) dianjurkan sebesar 10 % dari *range* data *time series*, sedangkan jarak minimum divergensi (SCALMIN) dianjurkan 10 % dari SCALMAX.

Tabel 3.4 mencantumkan nilai parameter yang akan dipakai.

Tabel 3.4 Parameter Untuk Estimasi Maximum Lyapunov Exponent

Series	G	m	SCALMAX	SCALMIN	EVOLV
DA1	1012	3	0,12	0,012	*
WA1	200	3	0,12	0,012	*
MA1	42	3	0,11	0,011	*

* dicoba sampai diperoleh kurva yang mengalami saturasi

Langkah-langkah penghitungan maximum Lyapunov exponent :

1. Rekonstruksi sebuah *phase space* dengan *embedding dimension* m , *time lag* T ditentukan melalui hubungan $T = Q / m$, dimana Q adalah panjang orbit siklus nonperiodik yang telah dihitung dengan R/S analysis. Ambil bilangan bulat terdekat jika Q / m tidak menghasilkan bilangan bulat.
2. Cari 2 titik terbaik pada *phase space* yang letaknya minimal 1 perioda rata-rata, jarak awalnya yang diberi notasi DI harus $> SCALMIN$.
3. Setelah 1 interval waktu tertentu (EVOLV), jarak antara kedua titik diukur lagi beri notasi DF .
4. Evaluasi $\log_2(DF/DI)$.
5. Jika jarak menjadi terlalu jauh, pilih titik pengganti dengan sudut orientasi yang sama dengan titik semula. Orientasi pasangan titik baru harus semirip mungkin dengan pasangan titik lama.

6. Ulangi langkah 3 s/d 5 beberapa kali sambil dihitung *running average*-nya (ZLYAP) sebagai indikator apakah hasil perhitungan diam (saturasi) di suatu nilai tertentu dan untuk memperoleh indikasi apakah hasil perhitungan dapat dipercaya.

Program komputer digunakan untuk mengeksekusi langkah-langkah di atas, *source code* LyapExp dapat dilihat pada Lampiran 8. Berkas masukan dan keluaran untuk program ini berformat ASCII (*.PRN).

Sebagai berkas masukan akan digunakan *time series* : DA1, WA1, dan MA1, setiap kali dieksekusi, program menghasilkan 1 berkas keluaran.

Berkas keluaran terdiri dari 2 kolom : kolom 1 adalah data ZLYAP, kolom 2 adalah data EVOLV x ITS. Jumlah baris data sesuai jumlah baris matriks *state space* dan EVOLV.

Pengolahan data selanjutnya dilakukan dengan menggunakan perangkat lunak Eviews™ sebagai berikut :

- Plot ZLYAP pada sumbu Y dan EVOLV x ITS pada sumbu X.
- Amati apakah kurva saturasi pada suatu nilai ZLYAP tertentu. Jika tidak ulangi dengan nilai parameter EVOLV yang lain. ZLYAP saturasi adalah maximum Lyapunov exponent λ yang dicari. Periksa apakah nilai λ^{-1} mendekati *decorrelation time* T_d .

Dalam percobaan yang dilakukan penulis, nilai λ yang baik diperoleh jika *temporal correlation* pada *time series* dihilangkan, caranya dengan memasukkan nilai parameter LAG dalam algoritma Wolf kira-kira sama dengan nilai η_{\min} .

Selain itu untuk mendapatkan hasil estimasi yang baik, pada *time series* juga perlu dilakukan penyaringan (*filtering*) *noise* secukupnya mengingat algoritma Wolf cukup peka terhadap *noise*.

Hasil estimasi maximum Lyapunov exponent dapat dilihat pada Lampiran 7.



BAB IV

ANALISIS DAN PEMBAHASAN

4.1 NORMALITAS

Time series dari *futures prices* maupun *logaritmik prices differences* CPO COMMEMX Malaysia sepanjang 20 tahun (23 Okt 1980 – 31 Mar 2000) menunjukkan distribusi yang tidak normal dengan *skewness* dan *kurtosis* yang besar, seperti yang ditunjukkan pada Tabel L2.1, Tabel L2.2, dan Tabel L2.3 dalam Lampiran 2 :

- Penyimpangan terhadap distribusi normal pada data harian lebih besar dibandingkan dengan data mingguan dan bulanan ($JB\ D > JB\ W > JB\ M$, $JB\ DA > JB\ WA > JB\ MA$, $JB\ DAL > JB\ WAL > JB\ MAL$, $JB\ DA1 > JB\ WA1 > JB\ MA1$), artinya semakin tinggi frekwensi data semakin tidak normal distribusinya.
- Setelah *adjustment*, data menunjukkan distribusi yang semakin mendekati normal. ($JB\ DA < JB\ D$, $JB\ WA < JB\ W$, $JB\ MA < JB\ M$).

Deviasi yang besar terhadap distribusi normal bisa jadi merupakan ciri-ciri adanya proses nonlinier dinamis (Fang et al. 1994).¹

4.2 STASIONARITAS

Dapat dilihat pada Lampiran 3 :

- *Prices series* sebelum (D, W, M) maupun sesudah *adjustment* (DA, WA, MA) nonstasioner.

¹ Wei, A. ; Leuthold, R. M., "Long Agricultural Futures Prices: ARCH, Long Memory, or Chaos Process?", OFOR Paper Number 98-03, May 1998, hal: 12.

- *Time series* dalam bentuk *logaritmik prices differences* (DAL, WAL, MAL) stasioner.
- *Time series* dalam bentuk *log-linear detrending* stasioner pada *critical level* 10 % (WA1, MA1). *Time series* DA1 belum stasioner pada *critical level* 10 %.
- Pada *time series* dalam bentuk *logaritmik prices differences*, data harian lebih stasioner dibandingkan dengan data mingguan dan bulanan ($Z, \tau_{DAL} > Z, \tau_{WAL} > Z, \tau_{MAL}$). Artinya semakin tinggi frekwensi data, semakin stasioner.
- Pada *time series* dalam bentuk *log-linear detrending* (DA1, WA1, MA1) dan *time series* setelah *adjustment* (DA, WA, MA) data bulanan lebih stasioner dibandingkan dengan data mingguan dan harian ($Z, \tau_{MA1} > Z, \tau_{WA1} > Z, \tau_{DA1}$; $Z, \tau_{MA} > Z, \tau_{WA} > Z, \tau_{DA}$). Artinya semakin rendah frekwensi data, semakin stasioner.

Pada *time series* dalam bentuk *logaritmik prices differences*, Phillips-Perron Z statistics yang melepaskan asumsi bahwa *error term* adalah *white noise* nilainya 2 kali lebih besar dibandingkan Dickey-Fuller τ statistics.

4.3 PENGAMATAN STRUKTUR AUTOKORELASI

Walaupun tidak mungkin memperoleh deskripsi lengkap mengenai proses dalam suatu *time series*, pola autokorelasi dapat memberikan deskripsi parsial mengenai *time series* tersebut yang cukup membantu dalam mengembangkan model.² Secara sepintas pola autokorelasi dan *decorrelation time* bisa digunakan untuk membedakan proses linier stokastik, *deterministic chaos* diskrit, dan *deterministic chaos* kontinu.³

² Jarret, J., "Business Forecasting Methods", Second Ed., Basil Blackwell Inc., Cambridge, 1991, hal: 257.

³ Chen, P. , "Searching for Economic Chaos: A Challenge to Econometric Practice and Nonlinear Tests." in Day, R.H. & Chen P. , eds. " Nonlinear Dynamics and Evolutionary Economics", Oxford University Press, 1993, hal: 221.

Autokorelasi pada *futures prices* CPO COMMEEX Malaysia menunjukkan pola yang menuju ke 0 dengan sangat lambat. Menurut Taylor (1986), pola *autokorelasi* yang berlangsung lama (*long lasting*) mencirikan bahwa *time series* tersebut dihasilkan oleh suatu proses nonlinier dengan *time-varying variance*.⁴ Pola autokorelasi bekerja dengan baik dalam menentukan ketergantungan jangka pendek (*short-term dependence*), tetapi tidak bekerja dengan baik pada proses-proses *long-memory non Gaussian*.⁵ Walaupun begitu *decorrelation time* (saat pertama pola autokorelasi menyentuh batas 0) merupakan informasi yang penting untuk mengindikasikan *long-memory process*.

Pada Lampiran 4 dapat dilihat pola autokorelasi dan autokorelasi parsial untuk *logaritmik prices differences time series* harian, mingguan, dan bulanan (DAL, WAL, dan MAL), yang menunjukkan karakteristik sebagai berikut :

- Koefisien autokorelasi dan autokorelasi parsial relatif kecil. Koefisien terbesar autokorelasi dan autokorelasi parsial menurut nilai absolut (posisi) masing-masing adalah 0,093 (10) dan 0,087 (10) untuk data harian (DAL); 0,246 (1) dan 0,246 (1) untuk data mingguan (WAL); 0,302 (4) dan 0,223 (4) untuk data bulanan (MAL).
- Koefisien autokorelasi dan autokorelasi parsial pertama tidak selalu yang terbesar dibandingkan dengan koefisien autokorelasi dan autokorelasi parsial pada *lag* selanjutnya.
- Beberapa koefisien autokorelasi dan autokorelasi parsial pada *lag* yang lebih jauh melewati batas *significant*.

⁴ Wei, A.; Leuthold, R. M., *op.cit.*, hal:11.

⁵ Peters, E. E., "Chaos and Order in The Capital Markets", John Wiley & Sons Inc., 1991, hal: 71.

Hal ini menandakan bahwa ketergantungan antara data-data yang berdekatan tidak selalu lebih kuat dibandingkan dengan data-data yang lebih berjauhan, atau informasi pasar yang baru tidak selalu lebih berguna dibandingkan informasi lama.

- Koefisien autokorelasi dan autokorelasi parsial tidak tampak mengecil dengan semakin besarnya *lag*.
- Autokorelasi dan autokorelasi parsial tidak memperlihatkan adanya suatu pola musiman ataupun siklus periodik lainnya.

Pengamatan visual pada pola autokorelasi dan autokorelasi parsial dapat menganjurkan model ARMA(p,q) yang memadai untuk *time series* tersebut. Analisa *correlogram* pada *time series* DAL, WAL, dan MAL memperlihatkan suatu pola yang tidak teratur sehingga tidak dapat menganjurkan suatu model ARIMA(p,d,q) tertentu.

Walaupun begitu, pada penelitian ini dicoba model yang terbaik yaitu ARMA(1,1). Residual ARMA(1,1) akan digunakan pada tahap selanjutnya (pengujian ARCH).

Karena dalam penelitian ini digunakan *prices differences* maka persamaan ARMA (1,1) di atas ekuivalen dengan ARIMA(1,1,1).

4.4 PENGUJIAN ARCH

Sepanjang perioda sampel, *time series* memperlihatkan standar deviasi sekuensial yang variasi-nya tidak merata dan terdapat lompatan-lompatan yang menandakan adanya *time-dependent conditional variances*. Pengujian normalitas memperlihatkan distribusi dengan *skewness* dan *kurtosis* yang besar. Tetapi *unit root test* menyarankan adanya *unconditional mean* dan *variance* yang *finite* dan *constant*. Pola autokorelasi dan

autokorelasi parsial memperlihatkan *short-term dependence* yang lemah. *Magnitude* autokorelasi walaupun kecil tetapi sangat persisten. Semua gejala di atas adalah pertanda adanya struktur nonlinier dinamis seperti yang diargumentasikan oleh Taylor (1986).⁶

Standar Langrange Multiplier test (LM test) yang terdapat dalam perangkat lunak Eviews™ digunakan untuk menguji apakah terdapat efek ARCH(1) di dalam residual ARMA(1,1) *time series* DAL, WAL, dan MAL.

Tabel 4.1 LM Test Untuk Melihat Adanya Efek ARCH(1)

Series	LM statistics
DAL	2700,533
WAL	162,62
MAL	57,61
critical value (1 %)	6,63

Hipotesis nol adalah tidak ada ARCH. Nilai kritis adalah distribusi χ^2 dengan 1 derajat kebebasan. Semua LM statistics lebih besar dibandingkan nilai kritis sampai tingkat kepercayaan 1 %. Hipotesis nol ditolak di semua *time series*, LM test menganjurkan adanya struktur ARCH(1) dalam ke 3 *time series* tersebut. Semakin tinggi frekwensi data semakin tinggi nilai LM statistics-nya.

Karena ARCH(1) adalah struktur yang paling sederhana dalam ARCH dan varian-nya, maka jika ARCH(1) eksis maka dapat dilakukan penyelidikan selanjutnya untuk mencari struktur ARCH atau varian-nya yang lebih sesuai.

⁶ Wei, A. ; Leuthold, R. M., *op. cit.*, Hal: 16.

Pengamatan selanjutnya dilakukan pada pola autokorelasi dan autokorelasi parsial residual kuadrat dari proses ARMA(1,1) untuk memperkirakan k dan g proses ARCH (k) atau GARCH (k,g). Pola autokorelasi dan autokorelasi parsial dapat dilihat pada Lampiran 4.

- Untuk *time series* MAL koefisien autokorelasi dan autokorelasi parsial terbesar masing-masing 0,448 (1) dan 0,448 (1). Tidak ada pola *decay* yang jelas, autokorelasi yang masih *significant* tampak pada *lag* 2, 4, 5, 6, 15, 16, 17, 18, dan 19. Autokorelasi parsial yang masih *significant* tampak pada *lag* 2, 3, 4, 5, 6, 15, 16, 18, 20, dan 34.
- Untuk *time series* WAL koefisien autokorelasi dan autokorelasi parsial terbesar masing-masing 0,372 (1) dan 0,372 (1). Autokorelasi menunjukkan pola *decay* dan mencapai batas *insignificant* di *lag* 10, tetapi autokorelasi yang *significant* muncul lagi pada selang *lag* 13 sampai 26. Autokorelasi parsial menunjukkan pola osilasi yang mencapai batas *insignificant* pada *lag* 5. Autokorelasi parsial yang masih *significant* tampak pada *lag* 6, 13, 16, 20, 21, 22, 25, 27, 28, 42, dan 43.
- Untuk *time series* DAL koefisien autokorelasi dan autokorelasi parsial terbesar masing-masing 0,590 (1) dan 0,590 (1). Autokorelasi dan autokorelasi parsial menunjukkan pola *decay* yang sangat lambat. Autokorelasi dan autokorelasi parsial masih *significant* sampai pada *lag* 60.

Autokorelasi dan autokorelasi parsial menembus batas *significant* secara acak, dan tidak ada kesimpulan yang dapat diambil apakah secara statistik autokorelasi dan autokorelasi parsial akan *decay* menuju nol. Secara umum pola autokorelasi dan autokorelasi parsial untuk ke 3

time series tersebut tidak menunjukkan suatu pola yang dapat menganjurkan suatu model ARCH(k) atau GARCH(k,g) tertentu.

Bisa diargumentasikan bahwa spesifikasi ARMA(p,q) yang tidak tepat bertanggung jawab terhadap tidak jelasnya struktur autokorelasi dan autokorelasi parsial residual kuadrat. Bisa saja *time series* tersebut sebenarnya adalah proses ARCH atau GARCH murni sehingga persamaan conditional mean hanya berbentuk $Y_t = e_t$. Jika argumentasi ini dapat diterima maka struktur autokorelasi dan autokorelasi parsial residual kuadrat Y_t^2 seharusnya menjadi lebih baik. Tetapi dalam kenyataannya hasilnya tetap sama dengan spesifikasi ARMA(p,q).⁷

Walaupun residual kuadrat ARCH(2) memperlihatkan pola yang relatif lebih “bersih” (lihat pola autokorelasi dan autokorelasi parsial di Lampiran 4), tetapi data-data di atas menunjukkan bahwa ARCH dan GARCH bukan merupakan interpretasi yang lengkap bagi proses ini.

4.5 R/S ANALYSIS

Dalam penelitian ini R/S analysis diterapkan pada residual AR(1) *logaritmik prices differences* data bulanan sepanjang 210 bulan (MAL), data mingguan sepanjang 1000 minggu (WAL), dan data harian sepanjang 5060 hari (DAL). Siklus nonperiodik Q yang dihitung dari ketiga macam data ini harus konsisten.


4.5.1 Time Series Data Bulanan (MAL)

Tabel L5.1 pada Lampiran 5 memperlihatkan data berkas keluaran yang dihasilkan oleh R/S analysis pada *time series* MAL.

⁷ *Ibid*, hal: 19

Gambar 4.1 memperlihatkan plot $\log(R/S)_n$ vs $\log n$ berdasarkan data pada tabel tersebut, juga plot $\log E(R/S)_n$ yang merupakan hipotesis nol bahwa sistem adalah random.

Untuk menentukan nilai Hurst exponent H maka dilakukan regresi OLS antara $\log n$ sebagai variabel bebas dan $\log(R/S)_n$ sebagai variabel tak bebas. Kemiringan (*slope*) adalah perkiraan nilai Hurst exponent H , sesuai dengan persamaan : $\log(R/S)_n = \log c + H \log n$.



Gambar 4.1 R/S Plot dan V Statistics : Residual AR(1) Data Bulanan MAL

Jika *time series* tidak random, maka pada suatu nilai n tertentu *time series* akan berkonvergensi ke nilai $H = 0,5$ karena *memory effect* melemah ke suatu titik yang tak terukur. Dengan perkataan lain, pada observasi dengan n yang panjang dapat diharapkan timbul sifat yang sama seperti *regular brownian motion* atau *random walk* murni pada saat *memory effect* ter-disipasi. Oleh karena itu regresi harus dilakukan sebelum dicapai konvergensi pada $H = 0,5$.

Pada kurva $\log(R/S)$ terlihat patahan pada $n = 42$ (antilog $1,623 \approx 42$).

Pada kurva V-statistics (yaitu kurva $(R/S)_n/\sqrt{n}$ dan $E(R/S)_n/\sqrt{n}$ terhadap $\log n$), patahan dapat dilihat dengan lebih jelas. Jika *series* menunjukkan persistensi ($H > 0,5$) maka rasio R/S akan menaik, saat *slope* melewati *random walk* ($H = 0,5$) maka ia akan paralel dengan kurva $E(R/S)$, sehingga pada saat peralihan akan terlihat patahan.

Pada Gambar 4-1, V-statistics berhenti naik setelah $n = 42$

Oleh karena itu regresi untuk menentukan nilai H harus dilakukan pada $10 \leq n \leq 42$.

Tabel L5.2 menunjukkan hasil regresi $(R/S)_n$ dan $E(R/S)_n$ terhadap n .

Hurst exponent H terukur = 0,6970 dengan signifikansi sebesar 0,77 standar deviasi, yang dihitung dari :

$$\begin{aligned}
 H &= 0,6970 \\
 \text{Expected H atau } E(H) &= 0,6440 \\
 \text{Standar deviasi } (\sigma) &= (1/210)^{0,5} \\
 &= 0,0690 \\
 \text{Signifikansi Hurst exponent H} &= (0,6970 - 0,6440) / 0,0690 \\
 &= 0,77 \sigma .
 \end{aligned}$$

R/S analysis juga memungkinkan kita untuk mengukur panjang siklus rata-rata suatu *time series*. Dalam sistem nonlinier dinamis, panjang siklus rata-rata adalah panjang waktu yang diperlukan sistem untuk “melupakan” kondisi mula.

Jadi *long memory process* bekerja untuk nilai n kurang dari 42 bulan karena *range* berhenti bertumbuh setelah mencapai titik $n = 42$. Pada titik $n = 42$ *long memory process* terdisipasi., data yang terpisah lebih dari 42 bulan memiliki korelasi yang hampir tak terukur, observasi R/S mulai berperilaku *erratic* dan random.

Temuan :

- Siklus nonperiodik *time series* MAL adalah 42 bulan.
- Hurst exponent H untuk *time series* data bulanan (MAL) adalah 0,6970 dengan signifikansi $0,77 \sigma$. Hipotesis nol bahwa *time series* MAL adalah random tidak dapat ditolak secara signifikan.

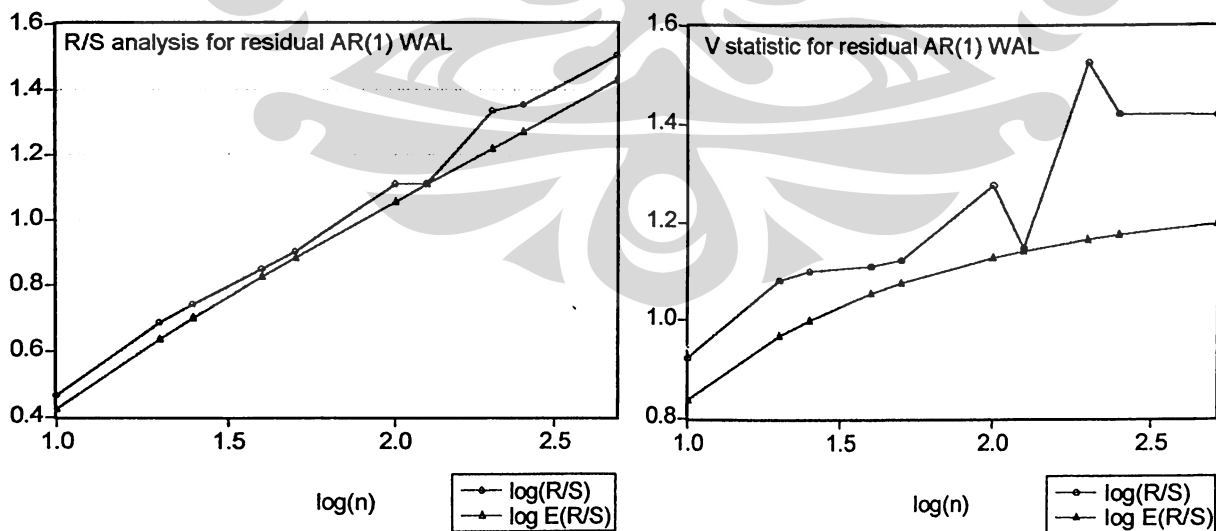
4.5.2 Time Series Data Mingguan (WAL)

Tabel L5.3 pada Lampiran 5 memperlihatkan data berkas keluaran yang dihasilkan oleh R/S analysis pada *time series* WAL.

Gambar 4.2 memperlihatkan plot $\log(R/S)_n$ vs $\log n$ berdasarkan data pada tabel tersebut, juga plot $\log E(R/S)_n$.

Pada kurva $\log(R/S)$ terlihat patahan pada $n = 200$ (antilog $2,3010 \approx 200$).

Pada kurva V-statistics (yaitu kurva $(R/S)_n/\sqrt{n}$ dan $E(R/S)_n/\sqrt{n}$ terhadap $\log n$), patahan dapat dilihat dengan lebih jelas.



Gambar 4.2 R/S Plot dan V Statistics : Residual AR(1) Data Mingguan WAL

Pada Gambar 4.2 , V-statistics berhenti naik setelah $n = 200$.

Oleh karena itu regresi untuk menentukan nilai H harus dilakukan pada $10 \leq n \leq 200$.

Tabel L5.4 menunjukkan hasil regresi $(R/S)_n$ dan $E(R/S)_n$ terhadap n.

Terlihat adanya penyimpangan dari hipotesis nol sebesar 0,75 standar deviasi, yang dihitung dari :

$$\begin{aligned} H &= 0,6276 \\ \text{Expected H} &= 0,6040 \\ \text{Standar deviasi } (\sigma) &= (1/1000)^{0,5} \\ &= 0,0316 \\ \text{Signifikansi Hurst exponent H} &= (0,6276 - 0,6040) / 0,0316 \\ &= 0,75 \sigma \end{aligned}$$

Temuan :

- Siklus nonperiodik *time series* WAL adalah 200 minggu.
- Hurst exponent H untuk *time series* data mingguan (WAL) adalah 0,6276 dengan signifikansi $0,75 \sigma$. Hipotesis nol bahwa *time series* WAL adalah random tidak dapat ditolak secara signifikan.

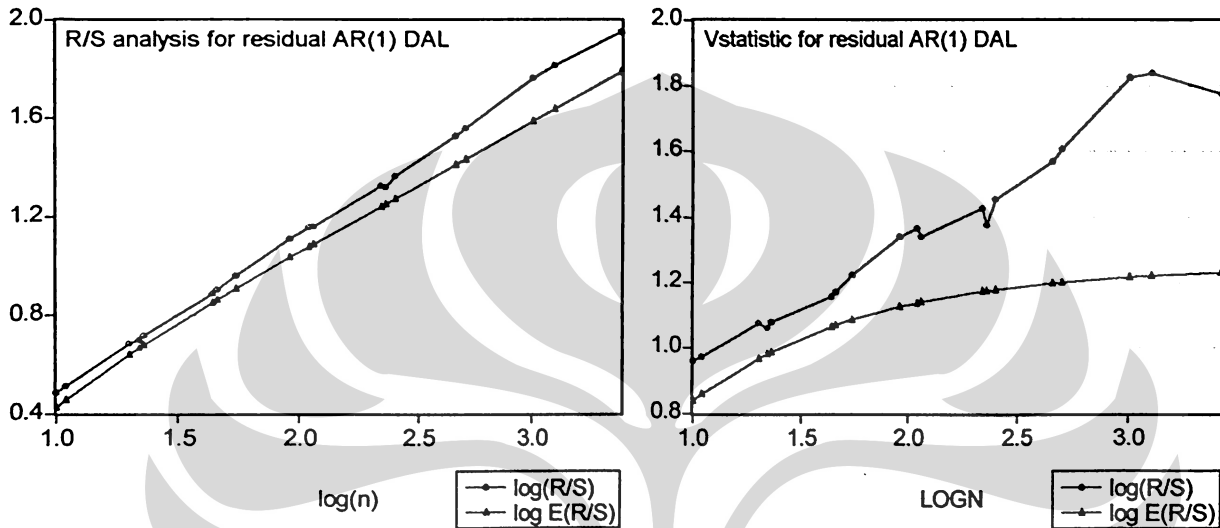
4.5.3 Time Series Data Harian (DAL)

Tabel L5.5 pada Lampiran 5 memperlihatkan data berkas keluaran yang dihasilkan oleh R/S analysis pada *time series* DAL.

Gambar 4.3 memperlihatkan plot $\log(R/S)_n$ vs $\log n$ berdasarkan data pada tabel tersebut , juga plot $\log E(R/S)_n$.

Pada kurva $\log(R/S)$ terlihat patahan pada $n = 1012$ (antilog $3,0052 \approx 1012$).

Pada kurva V-statistics (yaitu kurva $(R/S)_n/\sqrt{n}$ dan $E(R/S)_n/\sqrt{n}$ terhadap $\log n$), patahan dapat dilihat dengan lebih jelas.



Gambar 4.3 R/S Plot dan V Statistics : Residual AR(1) Data Harian DAL

Pada Gambar 4.3 , V-statistics berhenti naik setelah $n = 1012$.

Oleh karena itu regresi untuk menentukan nilai H harus dilakukan pada $10 \leq n \leq 1012$.

Tabel L5.5 menunjukkan hasil regresi $(R/S)_n$ dan $E(R/S)_n$ terhadap n.

Terlihat adanya penyimpangan dari hipotesis nol sebesar 3,80 standar deviasi, yang dihitung dari :

$$H = 0,6305$$

$$\text{Expected H} = 0,5771$$

$$\text{Standar deviasi } (\sigma) = (1/5060)^{0,5}$$

$$= 0,0141$$

$$\begin{aligned} \text{Signifikansi Hurst exponent } H &= (0,6305 - 0,5771) / 0,0141 \\ &= 3,80 \sigma \end{aligned}$$

Temuan :

- Siklus nonperiodik *time series* DAL adalah 1012 hari.
- Hurst exponent H untuk *time series* data harian (DAL) adalah 0,6305 dengan signifikansi 3,80 σ . Hipotesis nol bahwa *time series* WAL adalah random ditolak secara signifikan. Karena $H > 0,5$ maka terbukti *time series* DAL adalah tidak random tetapi memiliki sifat persistensi.

Kesimpulan yang didapatkan dari R/S analysis :

1. Dari semua frekwensi data *time series* yang dianalisis, hanya *time series* harian yang dapat menolak hipotesis nol secara signifikan. Tetapi ada kemungkinan metoda residual AR(1) tidak menghilangkan semua *short-range dependence* pada *time series* harian, sehingga perilaku *time series* yang diperkirakan oleh R/S analysis tersebut bukan berasal dari *long-term memory*, melainkan hanya merupakan simptom dari *short-term memory*. Disini tidak bisa disimpulkan apakah ketiga *time series* tersebut adalah random atau bukan.
2. Hurst exponent diharapkan naik dengan semakin rendahnya frekwensi sampling karena frekwensi sampling yang rendah mengurangi dampak *noise* dan menghilangkan dampak *fractional noise* yang ada pada frekwensi yang lebih tinggi. Tetapi Hurst exponent data harian yang lebih tinggi dibandingkan data mingguan menunjukkan bahwa *short-range dependence* pada *time series* harian belum tereliminasi.

3. Durasi siklus nonperiodik *time series* DAL kurang lebih 5 kali durasi siklus nonperiodik *time series* WAL , yaitu $1012 / 200 = 5,06$. Durasi siklus nonperiodik *time series* WAL terletak antara 4 - 5 kali durasi siklus nonperiodik *time series* MAL, yaitu $200 / 42 = 4,76$. Hal ini konsisten dengan perbandingan frekwensi sampling ketiga *time series* tersebut. *Time series* DAL dibentuk dari *settlement price* setiap *trading day* (5 hari dalam 1 minggu kalender). *Time series* WAL dibentuk dari *settlement price* tiap hari Jum'at. Sedangkan *time series* MAL dibentuk dari *settlement price* di hari terakhir *trading day* tiap bulan kalender, dan dalam tiap bulan kalender bisa terdapat 4 atau 5 hari Jum'at.
4. Jika *time series* adalah *Gaussian random walk*, *white noise* akan tampak sama di semua frekwensi, sehingga tidak akan ada siklus tertentu. Jika patahan pada kurva V statistic terjadi pada suatu *time series* dengan frekwensi sampling tertentu tapi tidak tampak pada frekwensi sampling yang lain, maka patahan itu adalah suatu *artifact*, bukan siklus sesungguhnya. Penampakan siklus yang konsisten pada ketiga frekwensi data dapat membuktikan bahwa ketiga *time series* tersebut bukanlah random.

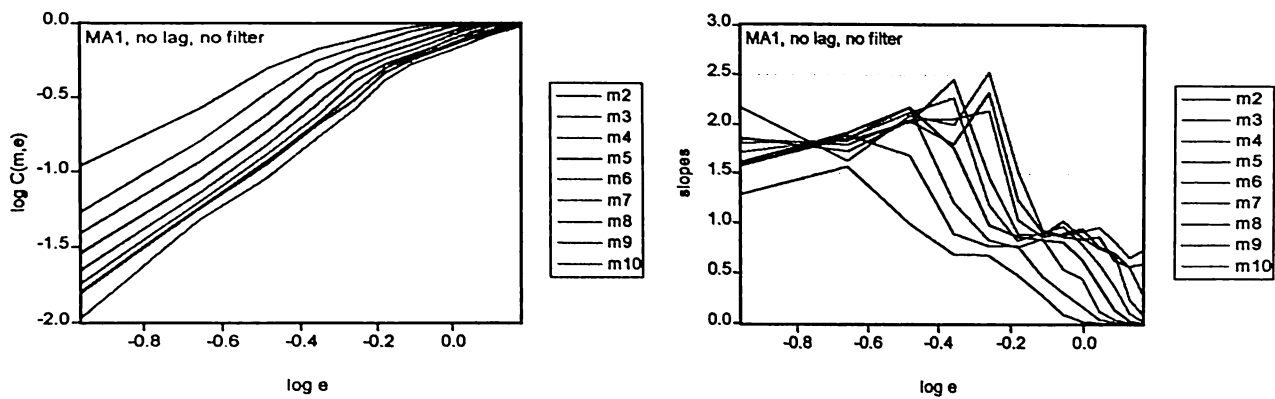
4.6 ESTIMASI CORRELATION DIMENSION

4.6.1 Estimasi Correlation Dimension Pada Time Series MA1.

4.6.1.1 Tanpa Noise Filtering dan Penghilangan Efek Temporal Correlation

Tabel L6.1 dan Tabel L6.2 pada Lampiran 6 memperlihatkan data berkas keluaran perhitungan *correlation integral* pada *time series* MA1 asli (tidak difilter) dan parameter $LAG = 0$.

Gambar 4.4 memperlihatkan plot *correlation integral* $\log C(m, \epsilon)$ vs $\log \epsilon$ dan plot *slopes* vs $\log \epsilon$ berdasarkan data pada kedua tabel tersebut.



Gambar 4.4 Grafik Log C(m,ε) vs Log ε dan Grafik Slopes vs Log ε, MA1

Pada grafik $\log C(m, \epsilon)$ vs $\log \epsilon$ terlihat ada bagian kurva-kurva $\log C(m, \epsilon)$ yang lurus dan paralel satu dengan yang lainnya, hal ini mencerminkan adanya struktur *fractal* atau adanya perilaku *power law* pada $C(m, \epsilon)$ sebagai tanda-tanda (*signature*) *self-similarity*.

Nilai *correlation dimension* diestimasi pada *saturated slope* dalam daerah *plateau* (daerah *plateau* adalah berkorespondensi dengan daerah linier dari plot $\log C(m, \epsilon)$ vs $\log \epsilon$).⁸ Walaupun berfluktuasi, nilai *slopes* di daerah *plateau* tidak banyak berubah untuk $m \geq 6$.

Dari Tabel L6.2 dapat dilihat nilai tersebut kira-kira 0,88 (nilai *up-bond slope* pada daerah *plateau*). Walaupun telah diperoleh suatu nilai estimasi *correlation dimension*, ada hal yang mesti dipertimbangkan, yaitu nilai estimasi yang tampak terlalu kecil (*underestimated*).

Tetapi sebelum membahas metoda-metoda untuk mengatasi hal tersebut ada baiknya disinggung mengenai karakteristik grafik $C(m, \epsilon)$ vs ϵ .

Grafik dapat dibagi menjadi 4 daerah yang berbeda tergantung dari jangkauan ϵ mulai dari skala yang besar sampai skala kecil.⁹

⁸ Chen, P., *op.cit*, hal: 238.

⁹ Kantz, Holger ; Schreiber, Thomas, "Nonlinear Time Series Analysis", Cambridge University Press, 2000, hal: 77.

- Dalam daerah ϵ yang besar (disebut *macroscopic regime*, daerah grafik paling kanan), *correlation integral* tidak memperlihatkan suatu *scaling* karena struktur makroskopis *attractor* menentukan nilainya, sehingga *local scaling exponent* sekaligus tergantung pada *embedding dimension* m dan ϵ .
- Dalam daerah ϵ yang lebih kecil, suatu *scaling range* yang baik mungkin dapat ditemukan. Untuk sebuah *self similar object*, *local scaling exponent* adalah konstan untuk semua *embedding dimension* $m_{\min} > D$ (D adalah *correlation dimension* objek tersebut). Jika tampak *plateau* yang meyakinkan, maka *scaling exponent* dapat digunakan sebagai estimasi untuk *correlation dimension*.
- Pada skala ϵ yang lebih kecil lagi terletak “daerah *noise*”. Jika data mengandung *noise*, maka pada skala ϵ yang lebih kecil dari beberapa lipat *noise level*, algoritma akan mendeteksi bahwa titik-titik data tidak dapat diikat / dibatasi oleh suatu *struktur fractal*, tetapi akan menyebar keseluruh *state space*. Sehingga *local scaling exponent* naik dan pada saat ϵ mencapai *noise level* maka *correlation integral* akan mencapai nilai *embedding dimension* (seperti gas yang memenuhi seluruh ruang yang ditempatinya). Dalam grafik *slope* vs $\log \epsilon$ di atas kita lihat adanya kurva tajam yang mencuat ke atas, di bagian tengah grafik.
- Lebih jauh lagi, dengan ϵ yang semakin mengecil (daerah paling kiri pada grafik) akan ditemui masalah *lack of neighbors*, karena dengan nilai ϵ yang sangat kecil semakin sedikit jumlah pasangan titik-titik yang dihitung. Kesalahan statistik menjadi efek yang dominan dan kurva sangat berfluktuasi. Dalam penelitian ini jumlah pasangan titik-titik (*neighbors*) minimal ditetapkan 10. Untuk memperbaiki keadaan, gunakan nilai

minimal yang lebih besar tetapi tentunya diperlukan jumlah titik-titik data yang lebih besar.

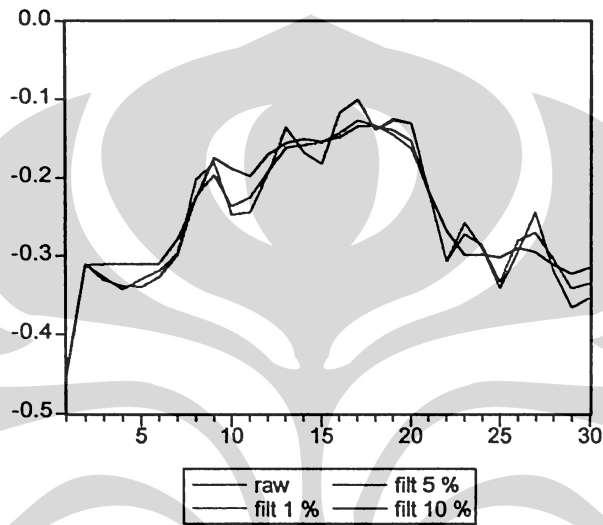
Untuk memperbaiki hasil estimasi, pada penelitian ini ditempuh 2 cara :

1. Noise filtering : Dalam penelitian ini diterapkan algoritma *simple noise reduction*, program komputer NoiseFilt mengambil masukan *time series* yang akan difilter, berkas keluarannya merupakan *time series* yang sudah difilter.

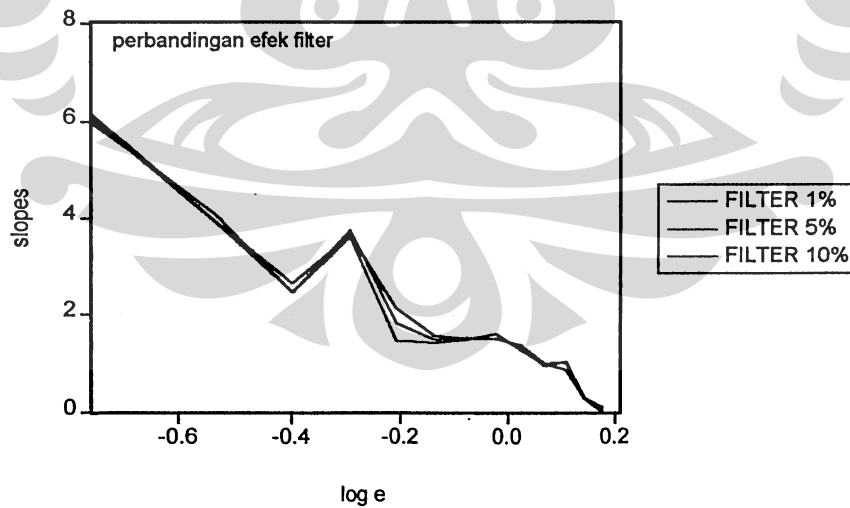
Gambar 4.5 menunjukkan sampel *time series* yang terdiri dari : *time series* asal (*raw*), dan *time series* yang masing-masing difilter sebesar 1 %, 5 %, dan 10 % dari *range* data *time series* tersebut. Gambar 4.6 memperlihatkan efek filtrasi yang menggunakan algoritma *simple noise reduction* terhadap daerah *plateau*. Sebagai perbandingan digunakan *embedding dimension* m yang sama yaitu 8, masing-masing kurva adalah *time series* MA1 yang difilter 1 %, 5 %, dan 10 % dari *range* data MA1. Semakin besar tingkat filtrasi semakin lebar daerah *plateau*-nya.

2. Menghilangkan temporal correlation : Provenzale (1992) memperkenalkan *space time separation plot* dengan cara memplot jumlah pasangan-pasangan titik sebagai fungsi dari dua variabel yaitu *time separation* Δt dan *spatial distance* ϵ untuk mendeteksi nonstasionaritas dan *temporal correlations*. Hanya untuk nilai-nilai Δt dimana garis-garis kontur mendatar (secara rata-rata, karena garis kontur umumnya bergelombang) maka *temporal correlation* tidak menghasilkan *artefacts* pada *correlation integral*. Program komputer StPlot digunakan untuk mengamati pola *space-time separation plot* ini, *source code* bisa dilihat di Lampiran 8.

Gambar 4.7 adalah *space-time separation plot* untuk *time series* MA1, terlihat kontur-nya tidak pernah mendatar. Frekwensi dominan dalam sistem terrefleksikan dalam kurva. Osilasi seperti ini tidak membahayakan selama periode observasi lebih panjang dibandingkan dengan panjang siklus.¹⁰ Harus diperhatikan 50 step pertama dimana kontur naik terus. Jika pada perhitungan *correlation integral*, titik-titik yang berjarak kurang dari

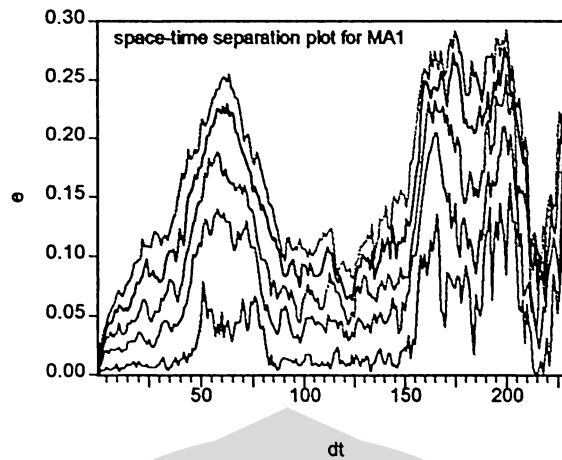


Gambar 4.5 : Sampel Time Series MA1 Yang Difilter



Gambar 4.6 Pengaruh Filtrasi Terhadap Daerah Plateau

¹⁰ *Ibid*, hal: 83.



Gambar 4.7 Space-Time Separation Plot MA1

50 tidak dibuang (dengan memberi nilai parameter $LAG = 50$ pada program komputer *CorrDim*), maka akan didapatkan hasil yang merupakan *artefacts*.


4.6.1.2 Noise Filtering dan Penghilangan Efek Temporal Correlation.

Tabel L6.3 pada Lampiran 6 memperlihatkan data berkas keluaran perhitungan *correlation integral* setelah *time series* MA1 difilter sebesar 1 % dari *range* datanya, dan diberi $LAG = 50$. Gambar 4.8 memperlihatkan plot *slopes* terhadap $\log \varepsilon$ berdasarkan data pada tabel tersebut.

Nilai *correlation dimension* diestimasi pada *saturated slope* dalam daerah *plateau*.

Walaupun berfluktuasi, nilai *slopes* di daerah *plateau* tidak banyak berubah untuk $m \geq 6$.

Dari Tabel L6.3 dapat dilihat nilai tersebut kira-kira 1,53 (nilai *up-bond slope* pada daerah *plateau*).



Gambar 4.8 Slopes Setelah Noise Filtering 1 % , LAG = 50, MA1

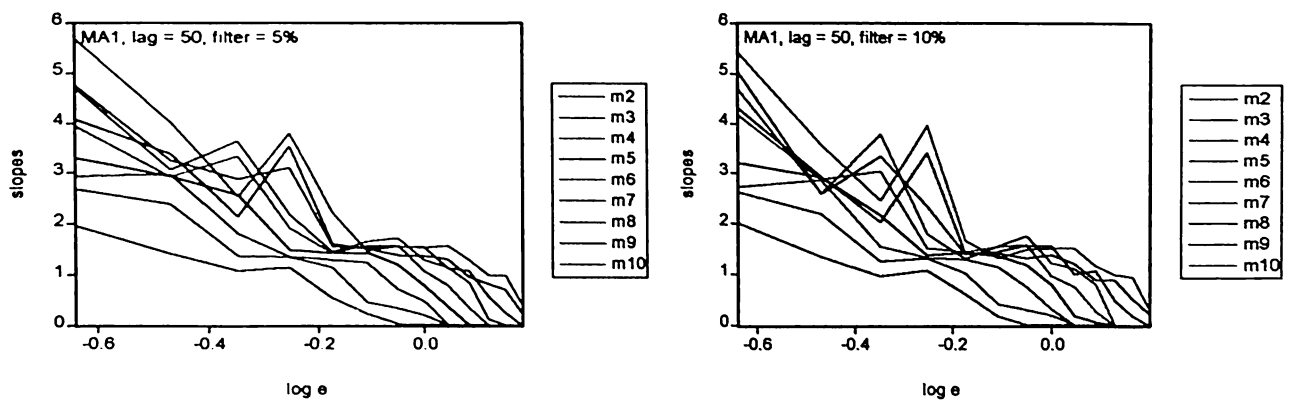
Chen (1993) mengestimasi *correlation dimension* dari *monetary aggregate*. Chen yang sangat hati-hati dalam klaim mendeteksi *chaotic structure*, menemukan *correlation dimension* dari *monetary aggregate* berkisar antara 1,3 sampai 1,5.¹¹ Hasil yang cukup baik mengingat datanya yang hanya 195 titik observasi bulanan.

Untuk melihat efek filtrasi, akan dicoba dengan 2 *time series* yang berasal dari MA1 masing-masing difilter sebesar 5 % dan 10 % dari *range* datanya, sedangkan nilai parameter LAG untuk keduanya tetap 50.

Tabel L6.4 dan Tabel L6.5 pada Lampiran 6 masing-masing memperlihatkan data berkas keluaran perhitungan *correlation integral* setelah *time series* MA1 masing-masing difilter sebesar 5 % dan 10 % dari *range* datanya, parameter LAG keduanya adalah 50.

Gambar 4.9 memperlihatkan plot *slopes* terhadap $\log \varepsilon$ berdasarkan data pada kedua tabel tersebut.

¹¹ Chen, P. , *op.cit.*, hal: 238.



Gambar 4.9 Slopes Setelah Noise Filtering 5 % dan 10 %, LAG = 50, MA1

Walaupun berfluktuasi, nilai *slopes* di daerah *plateau* untuk kedua *time series* tidak banyak berubah untuk $m \geq 6$.

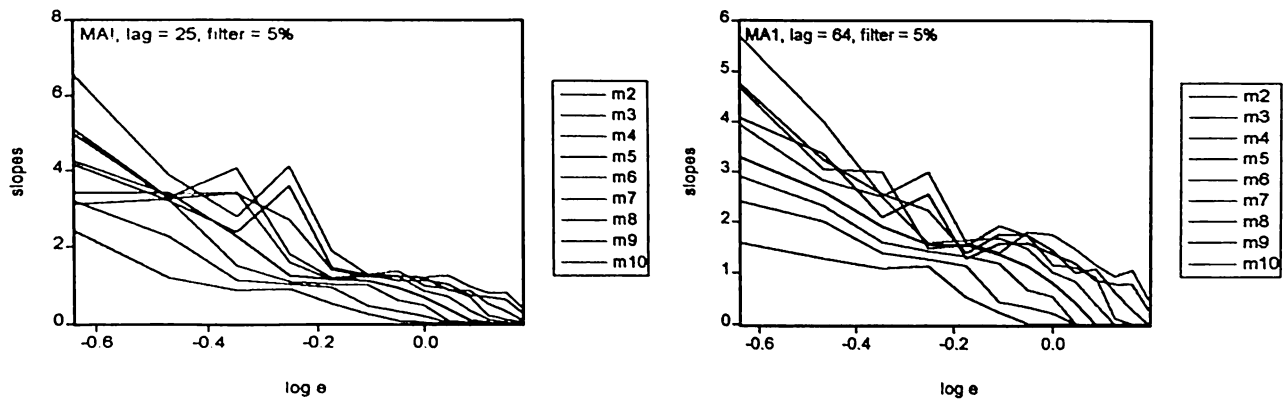
Untuk *time series* pertama, yang difilter sebesar 5 % dari *range* datanya, pada Tabel L6.4 dapat dilihat nilai tersebut kira-kira 1,51 (nilai *up-bond slope* pada daerah *plateau*).

Sedangkan untuk *time series* kedua, yang difilter sebesar 10 % dari *range* datanya, pada Tabel L6.5 dapat dilihat nilai tersebut kira-kira 1,51 (nilai *up-bond slope* pada daerah *plateau*).

Untuk melihat efek *temporal correlation*, akan dicoba dengan 2 *time series* yang berasal dari MA1 setelah *time series* MA1 difilter sebesar 5 % dari *range* datanya, sedangkan parameter LAG masing-masing adalah $25 < \eta_{\min}$ dan $64 > \eta_{\min}$.

Tabel L6.6 dan Tabel L6.7 pada Lampiran 6 masing-masing memperlihatkan data berkas keluaran perhitungan *correlation integral*. Gambar 4.10 memperlihatkan plot *slopes* terhadap $\log \varepsilon$ berdasarkan data pada 2 tabel tersebut.

Walaupun berfluktuasi, nilai *slopes* di daerah *plateau* untuk kedua *time series* tidak banyak berubah untuk $m \geq 6$.



Gambar 4.10 Slopes Setelah Noise Filtering 5 %, LAG = 25 dan 64 , MA1

Untuk *time series* pertama , dengan parameter LAG = 25, pada Tabel L6.6 dapat dilihat nilai tersebut kira-kira 1,20 (nilai *up-bond slope* pada daerah *plateau*).

Sedangkan untuk *time series* kedua, dengan parameter LAG = 64, pada Tabel L6.7 dapat dilihat nilai tersebut kira-kira 1,8 (nilai *up-bond slope* pada daerah *plateau*).

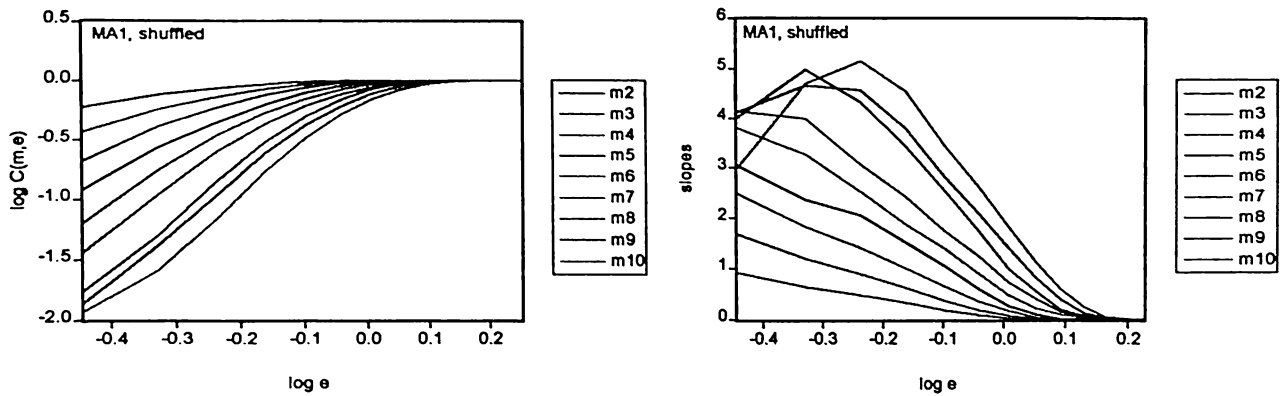
4.6.1.3 Shuffled Test atau Scrambling Test

Gambar 4.11 memperlihatkan plot *correlation integral* $\log C(m, \epsilon)$ terhadap $\log \epsilon$ dan plot *slopes* terhadap $\log \epsilon$ jika *time series* MA1 diacak (*shuffled*).

Shuffled merusak struktur korelasi antar titik-titik data, tetapi besaran statistik seperti rata-rata, standar deviasi, kurtosis, *skewness*, dan Jarque-Bera masih tetap sama.

Pada grafik $\log C(m, \epsilon)$ vs $\log \epsilon$ tidak tampak adanya bagian kurva-kurva $\log C(m, \epsilon)$ yang lurus dan paralel satu dengan yang lainnya, hal ini mencerminkan tidak adanya suatu struktur *fractal*, kurva-kurva yang bentuknya seperti itu dihasilkan oleh *time series* random.

Juga tidak dijumpai adanya *saturated slope* dalam daerah *plateau*. Terjadi lonjakan pada “daerah *noise*” yang disebabkan karena *correlation integral* menuju nilai *embedding*



Gambar 4.11 Grafik Log C(m,ε) vs Log ε dan Slopes vs Log ε, Shuffled MA1

dimension , tetapi pada bagian kiri grafik – karena adanya masalah *lack of neighbors* – maka kurva tidak mencapai *embedding dimension* (terutama pada *embedding dimension* m yang besar).

Menurut Peters (1991), jika *time series* bukan merupakan *chaotic attractor*, *correlation dimension* harus tidak berubah. Tetapi jika merupakan *strange attractor*, maka *scrambling* akan merusak struktur *attractor*, dan *correlation dimension* akan naik.¹² Peters (1991) memperlihatkannya dengan membandingkan dengan kurva $\log C(m, \epsilon)$ yang semakin tegak (*slope*-nya membesar). Tetapi pertanyaannya, bagaimana caranya mengestimasi *correlation dimension* jika pada plot *slopes* vs $\log \epsilon$, tidak terdapat daerah *plateau* seperti yang terlihat pada Gambar 4.11 ?

Pada penelitian ini tidak dilakukan estimasi *correlation dimension* pada *time series* yang di-*scrambling*. Penulis membuat 20 buah *scrambled time series*, kemudian mengamati plot $\log C(m, \epsilon)$ vs $\log \epsilon$ dan plot *slopes* vs $\log \epsilon$. Ternyata semuanya menghasilkan pola

¹² Peters, E. E., (1991), *op.cit*, hal: 184.

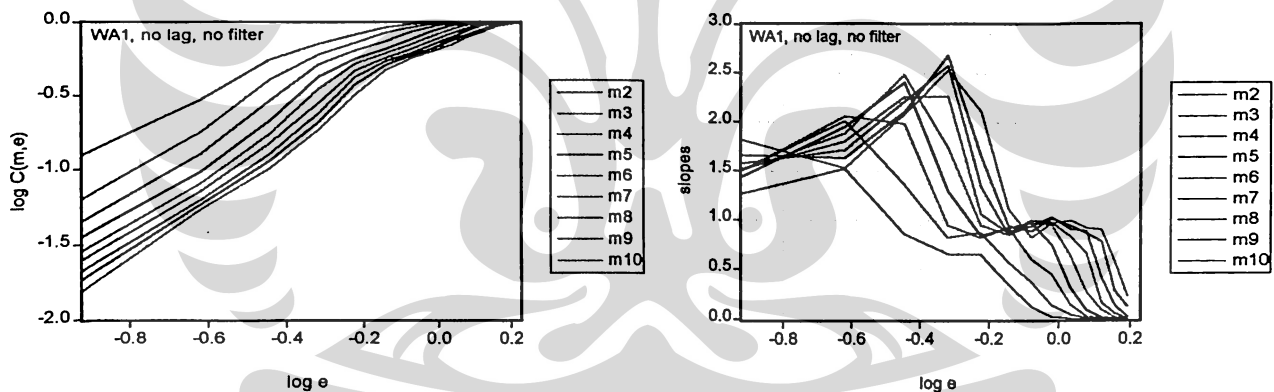
grafik yang mirip dengan Gambar 4.11. Penulis juga membuat beberapa *time series* yang dihasilkan dari *random generator*, ternyata pola plotnya juga mirip dengan Gambar 4.11.

4.6.2 Estimasi Correlation Dimension Pada Time Series WA1.

4.6.2.1 Tanpa Noise Filtering dan Penghilangan Efek Temporal Correlation

Tabel L6.8 dan Tabel L6.9 pada Lampiran 6 memperlihatkan data berkas keluaran perhitungan *correlation integral* pada *time series* WA1 asli (tidak difilter) dan parameter $LAG = 0$.

Gambar 4.12 memperlihatkan plot *correlation integral* $\log C(m, \epsilon)$ vs $\log \epsilon$ dan plot *slopes* vs $\log \epsilon$ berdasarkan data pada kedua tabel tersebut.



Gambar 4.12 Grafik $\log C(m, \epsilon)$ vs $\log \epsilon$ dan Grafik Slopes vs $\log \epsilon$, WA1

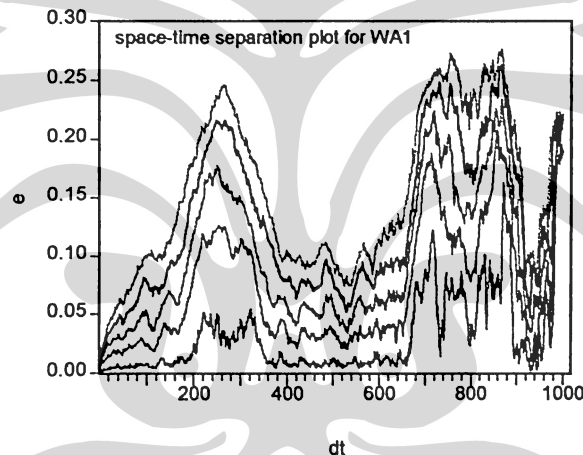
Pada grafik $\log C(m, \epsilon)$ vs $\log \epsilon$ terlihat ada bagian kurva-kurva $\log C(m, \epsilon)$ yang lurus dan paralel satu dengan yang lainnya, seperti pada *time series* MA1.

Nilai *correlation dimension* diestimasi pada *saturated slope* dalam daerah *plateau*. Walaupun berfluktuasi, nilai *slopes* di daerah *plateau* tidak banyak berubah untuk $m \geq 6$.

Dari Tabel L6.9 dapat dilihat nilai tersebut kira-kira 1,0 (nilai *up-bond slope* pada daerah *plateau*). Walaupun telah diperoleh suatu nilai *correlation dimension*, ada hal yang mesti dipertimbangkan, yaitu nilai *correlation dimension* yang tampak terlalu kecil (*underestimated*) dan integer, *correlation dimension* yang integer bukan merupakan *strange attractor*.

Prosedur yang sama, yaitu *noise filtering* dan penghilangan efek *temporal correlation* digunakan untuk mengatasi masalah ini.

Gambar 4.13 adalah *space-time separation plot* untuk *time series* WA1, terlihat kontur-nya tidak pernah mendatar.

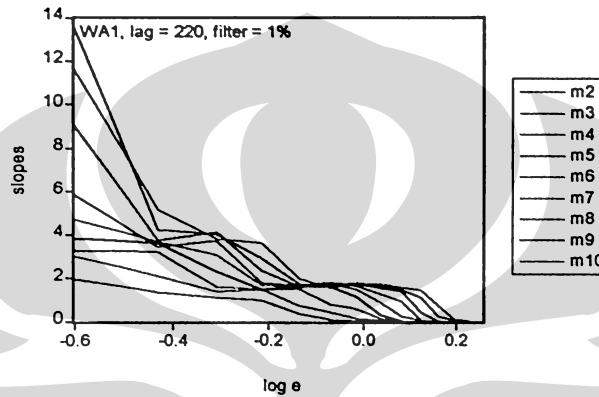


Gambar 4.13 Space-Time Separation Plot WA1

Harus diperhatikan 220 step pertama dimana kontur naik terus. Jika pada perhitungan *correlation integral*, titik-titik yang berjarak kurang dari 220 tidak dibuang (dengan memberi nilai parameter $LAG = 220$ pada program komputer *CorrDim*), maka akan didapatkan hasil yang merupakan *artefacts*.

4.6.2.2 Setelah Noise Filtering dan Penghilangan Efek Temporal Correlation .

Tabel L6.10 pada Lampiran 6 memperlihatkan data berkas keluaran perhitungan *correlation integral* setelah *time series* WA1 difilter sebesar 1 % dari *range* datanya, dan $LAG = 220$. Gambar 4.14 memperlihatkan plot *slopes* terhadap $\log \varepsilon$ berdasarkan data pada tabel tersebut.



Gambar 4.14 Slopes Setelah Noise Filtering 1 % , LAG = 220, WA1

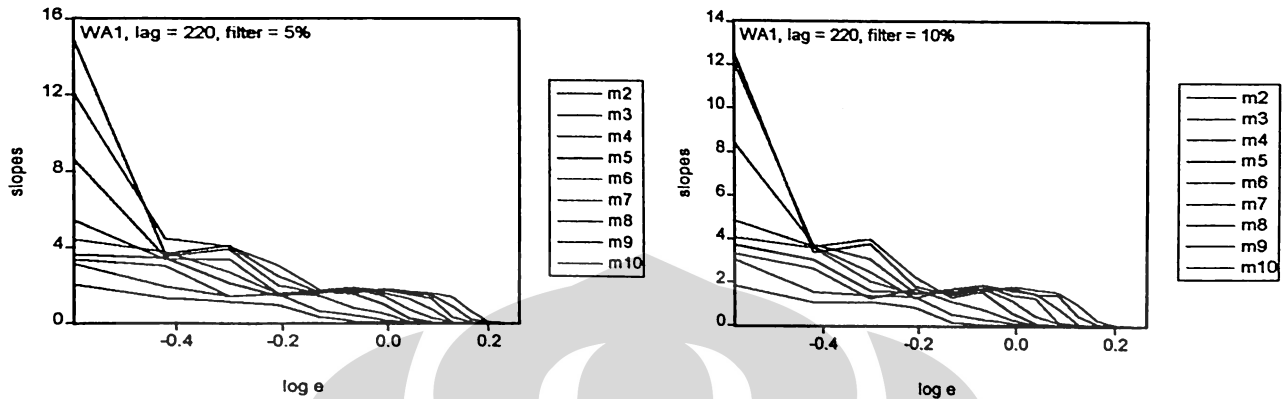
Nilai *correlation dimension* diestimasi pada *saturated slope* dalam daerah *plateau*. Walaupun berfluktuasi, nilai *slopes* di daerah *plateau* tidak banyak berubah untuk $m \geq 6$.

Dari Tabel L6.10 dapat dilihat nilai tersebut kira-kira 1,76 (nilai *up-bond slope* pada daerah *plateau*).

Untuk melihat efek filtrasi, akan dicoba dengan 2 *time series* yang berasal dari WA1 masing-masing difilter sebesar 5 % dan 10 % dari *range* datanya, sedangkan nilai parameter LAG untuk keduanya tetap 220.

Tabel L6.11 dan Tabel L6.12 pada Lampiran 6 masing-masing memperlihatkan data berkas keluaran perhitungan *correlation integral* setelah *time series* WA1 masing-masing difilter sebesar 5 % dan 10 % dari *range* datanya, parameter LAG keduanya adalah 220.

Gambar 4.15 memperlihatkan plot *slopes* terhadap $\log \varepsilon$ berdasarkan data pada kedua tabel tersebut.



Gambar 4.15 Slopes Setelah Noise Filtering 5 % dan 10 %, LAG = 220, WA1

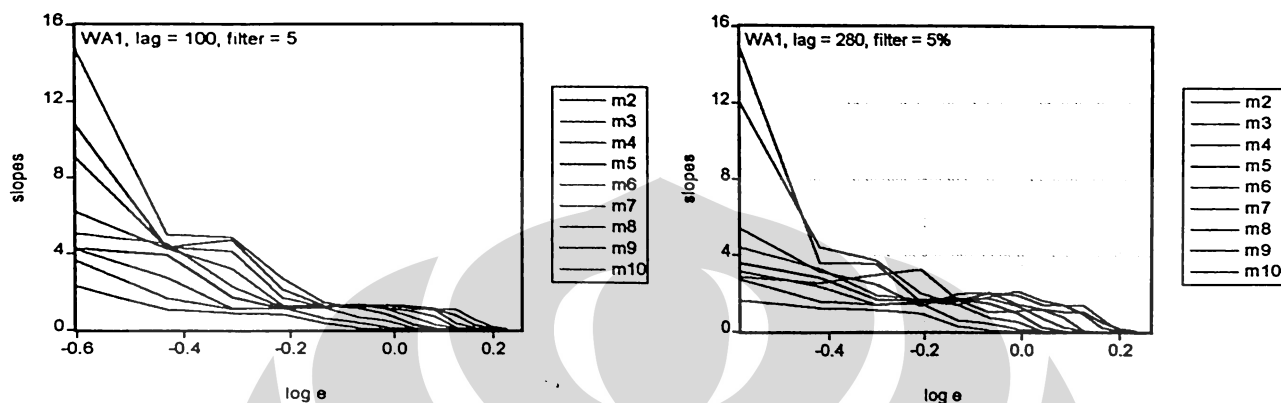
Untuk *time series* pertama, yang difilter sebesar 5 % dari *range* datanya, pada Tabel L6.11 dapat dilihat nilai tersebut kira-kira 1,79 (nilai *up-bond slope* pada daerah *plateau*). Sedangkan untuk *time series* kedua, yang difilter sebesar 10 % dari *range* datanya, pada Tabel L6.12 dapat dilihat nilai tersebut kira-kira 1,82 (nilai *up-bond slope* pada daerah *plateau*).

Untuk melihat efek *temporal correlation*, akan dicoba dengan 2 *time series* yang berasal dari WA1 setelah *time series* WA1 difilter sebesar 5 % dari *range* datanya, sedangkan parameter LAG masing-masing adalah $100 < \eta_{\min}$ dan $280 > \eta_{\min}$.

Tabel L6.13 dan Tabel L6.14 pada Lampiran 6 masing-masing memperlihatkan data berkas keluaran perhitungan *correlation integral*. Gambar 4.16 memperlihatkan plot *slopes* terhadap $\log \varepsilon$ berdasarkan data pada 2 tabel tersebut.

Untuk *time series* pertama, dengan parameter LAG = 100, pada Tabel L6.13 dapat dilihat nilai tersebut kira-kira 1,32 (nilai *up-bond slope* pada daerah *plateau*).

Sedangkan untuk *time series* kedua, dengan parameter LAG = 280, pada Tabel L6.14 dapat dilihat nilai tersebut terletak antara 1,83 (nilai *up-bond slope* pada daerah *plateau*).



Gambar 4.16 Slopes Setelah Noise Filtering 5 %, LAG = 100 dan 280, WA1

4.6.2.3 Shuffled Test Atau Scrambling Test

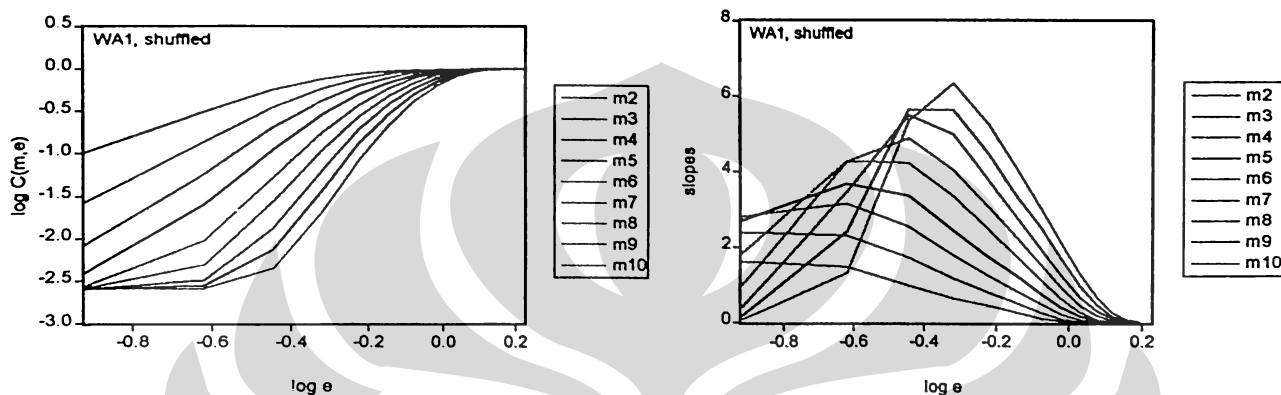
Gambar 4.17 memperlihatkan plot *correlation integral* $\log C(m, \epsilon)$ terhadap $\log \epsilon$ dan plot *slopes* terhadap $\log \epsilon$ jika *time series* WA1 diacak (*shuffled*).

Shuffled merusak struktur korelasi antar titik-titik data, tetapi besaran statistik seperti mean, standar deviasi, kurtosis, *skewness*, dan Jarque-Bera masih tetap sama.

Pada grafik $\log C(m, \epsilon)$ vs $\log \epsilon$ tidak tampak adanya bagian kurva-kurva $\log C(m, \epsilon)$ yang lurus dan paralel satu dengan yang lainnya, hal ini mencerminkan tidak adanya suatu struktur *fractal*, kurva-kurva yang bentuknya seperti itu dihasilkan oleh *time series* random.

Juga tidak dijumpai adanya *saturated slope* dalam daerah *plateau*. Terjadi lonjakan pada “daerah *noise*” yang disebabkan karena *correlation integral* menuju nilai *embedding dimension*, tetapi pada bagian kiri grafik – karena adanya masalah *lack of neighbors* – maka kurva tidak mencapai *embedding dimension* (terutama pada *embedding dimension* m yang besar).

Penulis membuat 20 buah *scrambled time series*, kemudian mengamati plot $\log C(m, \epsilon)$ vs $\log \epsilon$ dan plot *slopes* vs $\log \epsilon$. Ternyata semuanya menghasilkan pola grafik yang mirip dengan Gambar 4.17. Penulis juga membuat beberapa *time series* yang dihasilkan dari *random generator*, ternyata pola plotnya juga mirip dengan Gambar 4.17.



Gambar 4.17 Grafik Log $C(m, \epsilon)$ vs Log ϵ dan Slopes vs Log ϵ , Shuffled WA1

4.6.3 Estimasi Correlation Dimension Pada Time Series DA1.

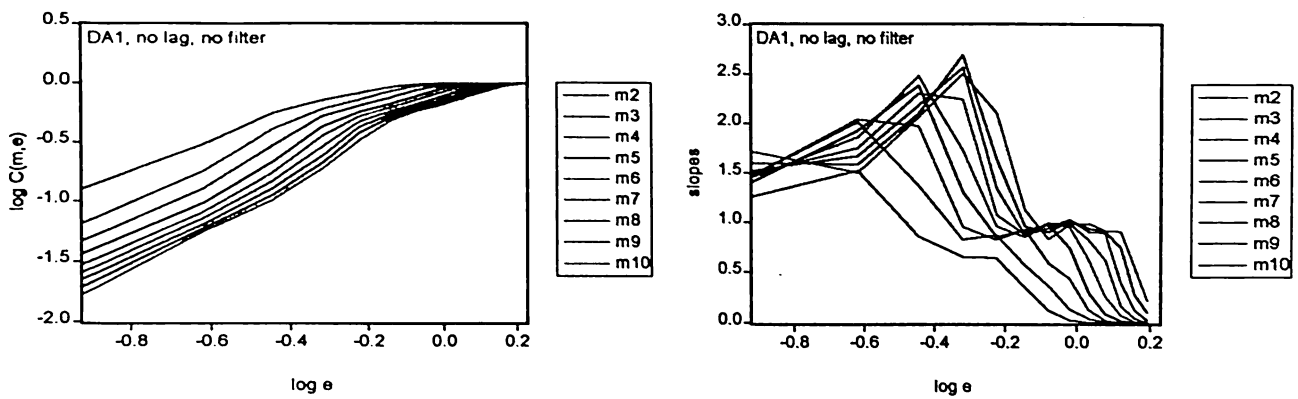
4.6.3.1 Tanpa Noise Filtering dan Penghilangan Efek Temporal Correlation

Tabel L6.15 dan Tabel L6.16 pada Lampiran 6 memperlihatkan data berkas keluaran perhitungan *correlation integral* pada *time series* DA1 asli (tidak difilter) dan parameter $LAG = 0$.

Gambar 4.18 memperlihatkan plot *correlation integral* $\log C(m, \epsilon)$ vs $\log \epsilon$ dan plot *slopes* vs $\log \epsilon$ berdasarkan data pada kedua tabel tersebut.

Pada grafik $\log C(m, \epsilon)$ vs $\log \epsilon$ terlihat ada bagian kurva-kurva $\log C(m, \epsilon)$ yang lurus dan paralel satu dengan yang lainnya, seperti pada *time series* MA1.

Nilai *correlation dimension* diestimasi pada *saturated slope* dalam daerah *plateau*. Walaupun berfluktuasi, nilai *slopes* di daerah *plateau* tidak banyak berubah untuk $m \geq 6$.



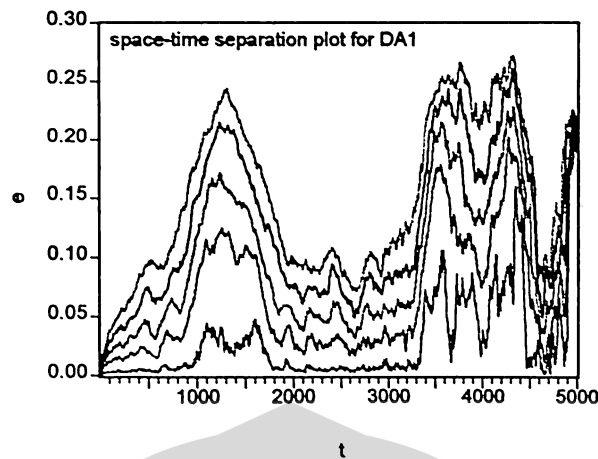
Gambar 4.18 Grafik Log C(m, ϵ) vs Log ϵ dan Grafik Slopes vs Log ϵ , DA1

Dari Tabel L6.16 dapat dilihat nilai tersebut kira-kira 0,98 (nilai *up-bond slope* pada daerah *plateau*). Walaupun telah diperoleh suatu nilai *correlation dimension*, ada hal yang mesti dipertimbangkan, yaitu nilai *correlation dimension* yang tampak terlalu kecil (*underestimated*) dan mendekati 1.

Prosedur yang sama, yaitu *noise filtering* dan penghilangan efek *temporal correlation* dipakai untuk mengatasi hal ini.

Gambar 4.19 adalah *space-time separation plot* untuk *time series* DA1, terlihat kontur-nya tidak pernah mendatar.

Harus diperhatikan 1300 step pertama dimana kontur naik terus. Jika pada perhitungan *correlation integral*, titik-titik yang berjarak kurang dari 1300 tidak dibuang (dengan memberi nilai parameter LAG = 1300 pada program komputer CorrDim), maka akan didapatkan hasil yang merupakan *artefacts*.

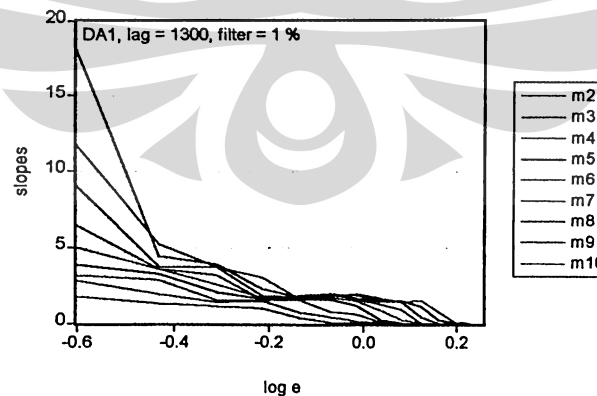


Gambar 4.19 Space-Time Separation Plot DA1

4.6.3.2 Noise Filtering dan Penghilangan Efek Temporal Correlation .

Tabel L6.17 pada Lampiran 6 memperlihatkan data berkas keluaran perhitungan *correlation integral* setelah *time series* DA1 difilter sebesar 1 % dari *range* datanya, dan $LAG = 1300$. Gambar 4.20 memperlihatkan plot *slopes* terhadap $\log \varepsilon$ berdasarkan data pada tabel tersebut.

Nilai *correlation dimension* diestimasi pada *saturated slope* dalam daerah *plateau*. Walaupun berfluktuasi, nilai *slopes* di daerah *plateau* tidak banyak berubah untuk $m \geq 6$.



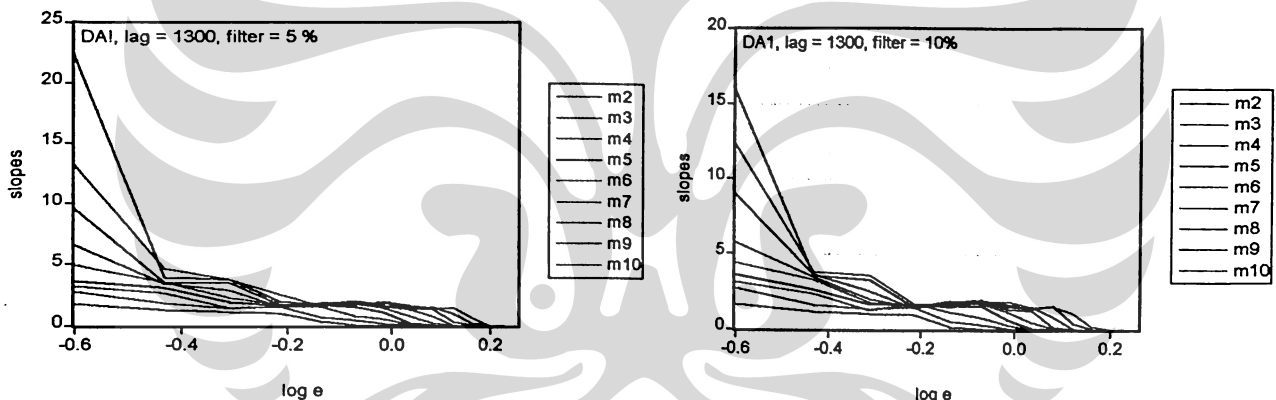
Gambar 4.20 Slopes Setelah Noise Filtering 1 % , LAG = 1300, DA1

Dari Tabel L6.17 dapat dilihat nilai tersebut kira-kira 1,96 (nilai *up-bond slope* pada daerah *plateau*).

Untuk melihat efek filtrasi, akan dicoba dengan 2 *time series* yang berasal dari DA1 masing-masing difilter sebesar 5 % dan 10 % dari *range* datanya, sedangkan nilai parameter LAG untuk keduanya tetap 1300.

Tabel L6.18 dan Tabel L6.19 pada Lampiran 6 masing-masing memperlihatkan data berkas keluaran perhitungan *correlation integral* setelah *time series* DA1 masing-masing difilter sebesar 5 % dan 10 % dari *range* datanya, parameter LAG keduanya adalah 1300.

Gambar 4.21 memperlihatkan plot *slopes* terhadap $\log \varepsilon$ berdasarkan data pada kedua tabel tersebut.




Gambar 4.21 Slopes Setelah Noise Filtering 5 % dan 10 %, LAG = 1300, DA1

Untuk *time series* pertama, yang difilter sebesar 5 % dari *range* datanya, pada Tabel L6.18 dapat dilihat nilai tersebut kira-kira 1,71 (nilai *up-bond slope* pada daerah *plateau*).

Sedangkan untuk *time series* kedua, yang difilter sebesar 10 % dari *range* datanya, pada Tabel L6.19 dapat dilihat nilai tersebut kira-kira 1,86 (nilai *up-bond slope* pada daerah *plateau*).

Untuk melihat efek *temporal correlation*, akan dicoba dengan 2 *time series* yang berasal dari DA1 setelah *time series* DA1 difilter sebesar 5 % dari *range* datanya, sedangkan parameter LAG masing-masing adalah $300 < \eta_{\min}$ dan $1800 > \eta_{\min}$.

Tabel L6.20 dan Tabel L6.21 pada Lampiran 6 masing-masing memperlihatkan data berkas keluaran perhitungan *correlation integral*. Gambar 4.22 memperlihatkan plot *slopes* terhadap $\log \varepsilon$ berdasarkan data pada 2 tabel tersebut.



Gambar 4.22 Slopes Setelah Noise Filtering 5 %, LAG = 300 dan 1800, DA1

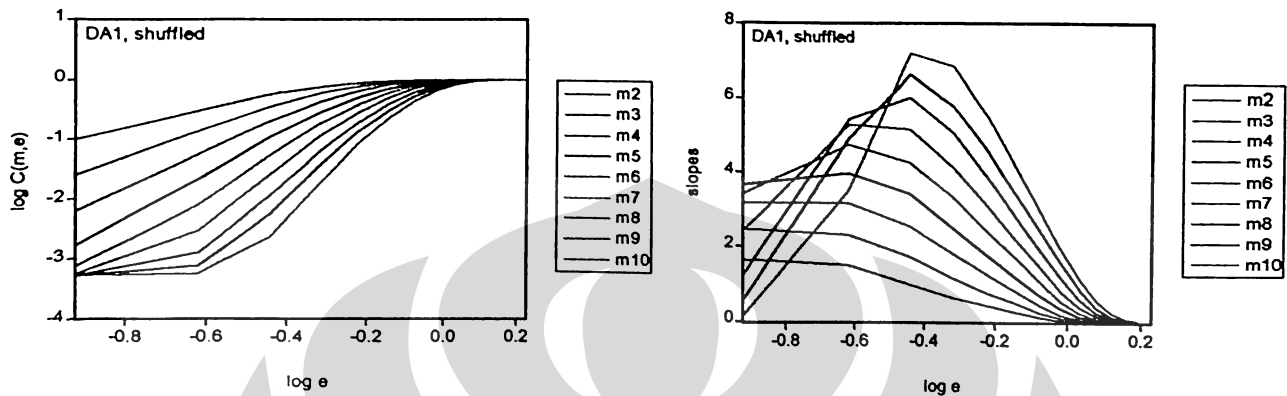
Untuk *time series* pertama, dengan parameter LAG = 300, pada Tabel L6.20 dapat dilihat nilai tersebut kira-kira 1,0 (nilai *up-bond slope* pada daerah *plateau*).

Sedangkan untuk *time series* kedua, dengan parameter LAG = 1800, pada Tabel L6.21 dapat dilihat nilai tersebut terletak antara 2,50 (nilai *up-bond slope* pada daerah *plateau*).

4.6.3.3 Shuffled Test atau Scrambling Test

Gambar 4.23 memperlihatkan plot *correlation integral* $\log C(m, \varepsilon)$ terhadap $\log \varepsilon$ dan plot *slopes* terhadap $\log \varepsilon$ jika *time series* DA1 diacak (*shuffled*).

Shuffled merusak struktur korelasi antar titik-titik data, tetapi besaran statistik seperti mean, standar deviasi, kurtosis, *skewness*, dan Jarque-Bera masih tetap sama.



Gambar 4.23 Grafik $\log C(m, \epsilon)$ vs $\log \epsilon$ dan Slopes vs $\log \epsilon$, Shuffled DA1

Pada grafik $\log C(m, \epsilon)$ vs $\log \epsilon$ tidak tampak adanya bagian kurva-kurva $\log C(m, \epsilon)$ yang lurus dan paralel satu dengan yang lainnya, hal ini mencerminkan tidak adanya suatu struktur *fractal*, kurva-kurva yang bentuknya seperti itu dihasilkan oleh *time series* random. Juga tidak dijumpai adanya *saturated slope* dalam daerah *plateau*. Terjadi lonjakan pada “daerah *noise*” yang disebabkan karena *correlation integral* menuju nilai *embedding dimension*, tetapi pada bagian kiri grafik – karena adanya masalah *lack of neighbors* – maka kurva tidak mencapai *embedding dimension* (terutama pada *embedding dimension* m yang besar).

Penulis membuat 20 buah *scrambled time series*, kemudian mengamati plot $\log C(m, \epsilon)$ vs $\log \epsilon$ dan plot *slopes* vs $\log \epsilon$. Ternyata semuanya menghasilkan pola grafik yang mirip dengan Gambar 4.23. Penulis juga membuat beberapa *time series* yang dihasilkan dari *random generator*, ternyata pola plotnya juga mirip dengan Gambar 4.23.

Temuan :

Estimasi *correlation dimension* dilakukan pada 3 macam frekwensi *time series* : data bulanan (MA1), data mingguan (WA1), dan data harian (DA1); masing-masing tanpa / dengan penghilangan efek *temporal correlation* dan tanpa / dengan *noise filtering*. Hal-hal yang dapat diamati adalah :

- *Noise filtering* dengan algoritma *simple noise reduction* ternyata cukup efektif menghilangkan *noise* pada *time series*. Pada ketiga macam *time series* tersebut efek pengurangan *noise* dapat dilihat pada grafik *slopes* vs $\log \epsilon$, yang ditandai dengan menghilang / berkurangnya amplitudo cuatan tajam ke atas di daerah *noise* (*noise regime*) pada bagian tengah skala ϵ . Semakin tinggi frekwensi *time series* semakin “kuat” efek filtrasi. Hal ini disebabkan karena *time series* yang frekwensinya tinggi lebih *noisy* dibandingkan dengan *time series* yang frekwensinya lebih rendah.
- Jika pengaruh *temporal correlation* dikurangi / dihilangkan, maka daerah *plateau* semakin meluas, semakin konvergen, dan nilainya tidak lagi *understated*. Walaupun begitu, terjadi efek sampingan, yaitu peningkatan nilai *slopes* di daerah *lack of neighbors* pada bagian kiri grafik.
- Efek *temporal correlation* harus dihilangkan untuk memperbaiki nilai estimasi *correlation dimension* yang dirasakan *understated*. Pasangan titik-titik yang jaraknya kurang dari $t_{\min} = \eta_{\min} \Delta t$ dibuang dari penjumlahan *correlation integral*. Tentunya penjumlahan *correlation integral* akan kehilangan beberapa pasangan titik-titik “real”, dan kesalahan statistik yang terjadi sebanding dengan fraksi $2\eta_{\min}/N$.¹³ Oleh karena itu penghilangan *temporal correlation* yang berlebihan dengan memakai $LAG > \eta_{\min}$

¹³ Kantz, Holger ; Schreiber, Thomas , *op.cit.*, hal: 74.

akan memperbesar nilai estimasi *correlation dimension*. Tetapi berapa tepatnya nilai η_{\min} masih memerlukan pertimbangan lain jika kontur-nya bergelombang.¹⁴ Biasanya diambil nilai η_{\min} setelah kontur tidak naik lagi.

- Dengan melakukan *noise filtering* dan penghilangan efek *temporal correlation* secara tepat maka akan didapatkan nilai estimasi *correlation dimension* yang lebih baik.

Kesimpulan yang didapatkan dari estimasi *correlation dimension* :

Menurut *chaos theory*, 2 aspek harus diperhatikan pada waktu mengestimasi *correlation dimension* pada suatu *time series*. Pertama adalah melihat *local slopes* mengalami saturasi saat *embedding dimension* dinaikkan. Hanya jika terjadi saturasi maka nilai *slopes* tersebut merupakan estimasi dari *correlation dimension*. Kedua adalah mengamati besarnya nilai saturasi tersebut. Secara praktis *high correlation dimension* tidak dapat membedakan proses stokastik murni dengan proses deterministik. *Low correlation dimension*, biasanya kurang dari 5, lebih berguna untuk kegunaan praktis karena *chaotic system* berdimensi rendah lebih mungkin disimulasikan.¹⁵

Disamping itu sifat unik *chaotic process* adalah *attractor*-nya biasanya berdimensi noninteger (*fractal dimension*) - salah satu penyebab penampakan yang seolah-olah random.

Tabel 4.2 mencantumkan hasil estimasi *correlation dimension* pada 3 macam *time series* yang berbeda frekwensinya : *prices series* bulanan MA1, *prices series* mingguan WA1, dan *prices series* harian DA1 dengan parameter-parameter tingkat filtrasi dan LAG yang berbeda.

¹⁴ *Ibid*, hal: 83.

¹⁵ Wei, A. ; Leuthold, R. M., *op.cit.*, hal: 27.

Tabel 4.2 Nilai Estimasi Correlation Dimension*

Series	LAG = 0 no filt	LAG = η_{\min}			LAG < η_{\min}	LAG > η_{\min}
		filt 1 %	5 %	10 %		
MA1	0,88	1,53	1,51	1,51	1,20	1,80
WA1	1,00	1,76	1,79	1,82	1,32	1,83
DA1	0,98	1,96	1,71	1,86	1,00	2,50

* Nilai estimasi adalah nilai tertinggi (*up-bond*) di daerah saturasi.

Dengan memperhatikan hal-hal di atas maka nilai estimasi *correlation dimension* yang dianggap mewakili adalah nilai pada saat $LAG = \eta_{\min}$.

Dari tabel juga terlihat bahwa tingkat filtrasi tidak mempengaruhi nilai estimasi *correlation dimension* pada MA1, tetapi semakin tinggi frekwensi *time series*, semakin besar pengaruhnya. Hal ini disebabkan karena data bulanan lebih kecil *noise*-nya dibandingkan dengan data harian.

Dari tabel juga terlihat semakin tinggi frekwensi data, semakin besar nilai estimasi *correlation dimension*. Tetapi belum bisa diklaim bahwa data harian lebih tinggi *correlation dimension*-nya dibandingkan dengan data mingguan atau bulanan. Menurut Wei (1998), jika frekwensi data turun, semakin mudah mendeteksi *correlation dimension*. Hal ini berhubungan dengan *noise* yang ada dalam data. Data bulanan mengandung *noise* yang lebih kecil dibandingkan dengan data harian. Wei meneliti *agricultural futures prices* di CBOT (Chicago Board of Trade) untuk komoditi jagung, gandum, dan kacang kedelai ; dan CSCE (Coffee, Sugar and Cocoa Exchange – New York) untuk komoditi kopi dan gula. Usahanya untuk mengukur *correlation dimension* pada *time series* harian gagal karena faktor *noise*.¹⁶ Wei juga tidak menghilangkan pengaruh *temporal correlation*.

¹⁶ *Ibid*, hal: 28.

Dalam penelitian ini ditemukan *correlation dimension* komoditi CPO di COMMEMX-Malaysia merupakan bilangan noninteger yang terletak antara 1 dan 2, yang mengindikasikan *low dimension chaos*.

Tetapi eksistensi *low dimension attractor* bukan merupakan kondisi cukup untuk eksistensi *chaos*. Diperlukan suatu tambahan bukti lain, yaitu maximum Lyapunov exponent.

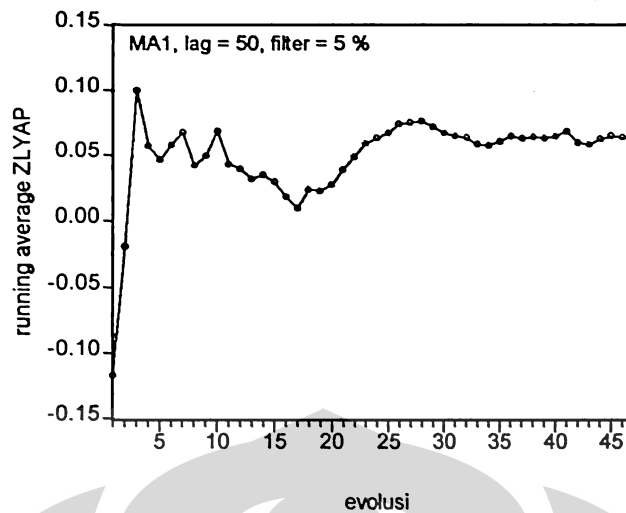
4.7 ESTIMASI MAXIMUM LYAPUNOV EXPONENT

4.7.1 Estimasi Maximum Lyapunov Pada Time Series MA1.

Menurut algoritma Wolf, maximum Lyapunov exponent hanya dapat terdeteksi jika plot *running average* Lyapunov exponent mengalami saturasi. Nilai saturasi *running average* Lyapunov exponent tersebut adalah maximum Lyapunov exponent λ . Jika tidak terjadi saturasi, maka tidak ditemukan bukti adanya *chaos*. Pada saat yang sama *chaos* juga mensyaratkan adanya λ yang bertanda positif.

Tetapi *random noise* juga dapat menghasilkan λ yang positif. Walaupun begitu λ tetap dapat mengungkapkan *chaos* jika besaran λ^{-1} nilainya dekat dengan *decorrelation time* T_d (saat pertama kali pola autokorelasi menyentuh nol), oleh karena itu akan diamati pola autokorelasi MA1 sebagai petunjuk.

Tabel L7.1 pada Lampiran 7 memperlihatkan data berkas keluaran estimasi maximum Lyapunov exponent pada *time series* MA1 yang difilter sebesar 5 % dari *range* data *time series* dan parameter LAG = 50.



Gambar 4.24 Grafik Running Average ZLYAP vs Evolusi , MA1

Gambar 4.24 memperlihatkan plot *running average* Lyapunov exponent vs evolusi berdasarkan data pada tabel tersebut, terlihat kurva mengalami saturasi.

Dari Tabel L7.1 dapat dilihat nilai saturasi *running average* Lyapunov exponent adalah sekitar 0,0638.

Pada Lampiran 8 juga dapat dilihat pola autokorelasi MA1 yang pertama kali mencapai batas insignifikan pada *lag* ke 21 , dan mencapai titik nol (*decorrelation time* T_d) pada *lag* ke 25.

Diperoleh nilai $\lambda^{-1} = 0,063^{-1} \approx 16$

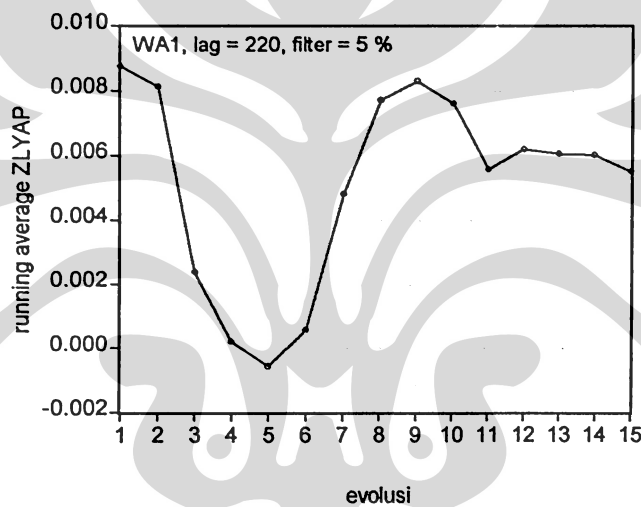
Mengingat pekanya algoritma Wolf terhadap *noise* dan adanya keterbatasan jumlah titik data, maka nilai tersebut cukup bagus karena memberikan gambaran bahwa λ bukanlah suatu nilai positif sembarang yang terlalu besar.

4.7.2 Estimasi Maximum Lyapunov Pada Time Series WA1.

Tabel L7.2 pada Lampiran 7 memperlihatkan data berkas keluaran estimasi maximum Lyapunov exponent pada *time series* WA1 yang difilter sebesar 5 % dari *range* data *time series* dan parameter LAG = 220

Gambar 4.25 memperlihatkan plot *running average* Lyapunov exponent vs (waktu evolusi x jumlah iterasi) berdasarkan data pada tabel tersebut, terlihat kurva mengalami saturasi.

Dari Tabel L7.2 dapat dilihat nilai saturasi *running average* Lyapunov exponent adalah sekitar 0,006



Gambar 4.25 Grafik Running Average ZLYAP vs Evolusi , WA1

Pada Lampiran 8 juga dapat dilihat pola autokorelasi WA1 yang pertama kali mencapai batas insignifikan pada *lag* ke 99, dan mencapai titik nol (*decorrelation time* T_d) pada *lag* ke 110.

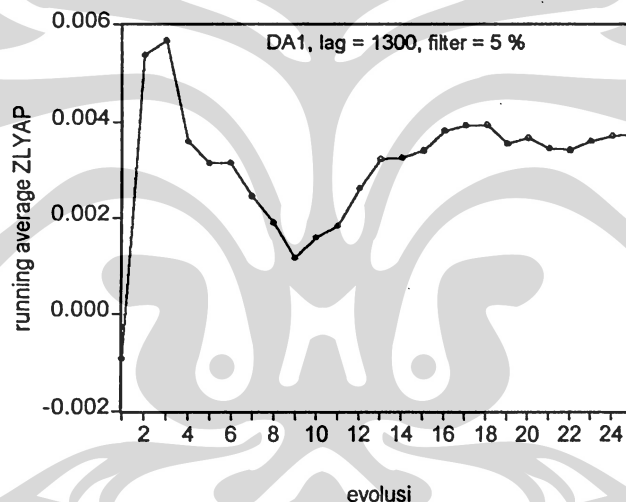
Diperoleh nilai $\lambda^{-1} = 0,006^{-1} \approx 167$. Dengan pertimbangan yang sama seperti pada MA1, diperoleh kepercayaan bahwa nilai λ bukanlah nilai sembarang.

4.7.3 Estimasi Maximum Lyapunov Pada Time Series DA1.

Tabel L7.3 pada Lampiran 7 memperlihatkan data berkas keluaran estimasi maximum Lyapunov exponent pada *time series* DA1 yang difilter sebesar 5 % dari *range* data *time series* dan parameter LAG = 1300.

Gambar 4.26 memperlihatkan plot *running average* Lyapunov exponent vs (waktu evolusi x jumlah iterasi) berdasarkan data pada tabel tersebut, terlihat kurva mengalami saturasi.

Dari Tabel L7.3 dapat dilihat nilai saturasi *running average* Lyapunov exponent adalah sekitar 0,0037



Gambar 4.26 Grafik Running Average ZLYAP vs Evolusi , DA1

Decorrelation time T_d untuk *time series* DA1 tidak teramati karena sangat panjang sehingga tidak bisa dijadikan petunjuk.

Kesimpulan yang didapatkan dari estimasi maximum Lyapunov exponent :

Hal yang harus diperhatikan pada waktu mengestimasi maximum Lyapunov exponent pada suatu *time series* adalah melihat *running average* Lyapunov exponent mengalami saturasi saat berevolusi. Hanya jika terjadi saturasi maka nilai *running average* Lyapunov exponent tersebut merupakan estimasi dari maximum Lyapunov exponent. Hal lainnya adalah mengamati tanda nilai saturasi tersebut. Hanya tanda positif yang mencirikan *chaotic attractor* (atau *random noise*, jika nilainya terlalu besar)

Tabel 4.3 mencantumkan hasil estimasi maximum Lyapunov exponent pada 3 macam *time series* yang berbeda frekwensinya : *prices series* bulanan MA1, *prices series* mingguan WA1, dan *prices series* harian DA1. Semuanya bertanda positif dan nilainya mendekati *decorrelation time* T_d (kecuali DA1, karena *decorrelation time* tak terukur).

Tabel 4.3 Nilai Aproksimasi Maximum Lyapunov Exponent

Series	T_d	λ	λ^{-1}
MA1	25	0,0638	16
WA1	110	0,006	167
DA1	*	0,0037	270

* *decorrelation time* tak teramati pada Correlogram EViews

4.8 ANALISIS AKHIR UNTUK PEMBUKTIAN CHAOS

Pengujian ARCH standar dengan LM Test menunjukkan adanya efek ARCH pada *futures prices series* komoditi CPO di COMDEX Malaysia. Tetapi pola autokorelasi residual kuadrat dari semua *time series* yang diteliti meluruh dengan sangat lambat dan tidak teratur, dan keadaan ini bukanlah perilaku dari proses ARCH. Selain itu *unconditional moment* dapat menunjukkan apakah model ARCH cocok dengan *time series* tersebut atau tidak. Proses ARCH umumnya memiliki *unconditional third moment* sama dengan nol,

yaitu simetri. Tetapi semua *time series* dalam penelitian ini menunjukkan *skewness* yang positif (*positively skewed*). Model GARCH(1,1) mencirikan bahwa *unconditional second moment* pada *time series* adalah tidak terhingga.¹⁷ Tetapi Dickey – Fuller Test dan Phillips – Perron Test semuanya menyimpulkan bahwa *time series* adalah stasioner dengan rata-rata dan variansi yang terhingga. Sehingga model GARCH(1,1) juga tidak cocok merepresentasikan *price series* CPO COMMEMX Malaysia.

R/S analysis menemukan bukti bahwa *time series* tersebut bersifat persistens, bukan proses yang random. R/S analysis juga menemukan siklus nonperiodik sepanjang 42 bulan. Karena *price series* bulanan (MA1) dibentuk dari *settlement price* di hari terakhir *trading day* tiap bulan kalender, maka siklus nonperiodik sepanjang 42 bulan tersebut identik dengan 42 bulan kalender. Bilangan tersebut tampaknya ada hubungannya dengan suatu siklus bisnis yang disebut siklus Kitchin (3 – 5 tahun).

Siklus nonperiodik yang diperoleh dari R/S analysis digunakan sebagai parameter perioda orbital rata-rata Q pada waktu pembentukan *phase space*, yang kemudian dipergunakan pada perhitungan *correlation integral* dan perhitungan *running average maximum Lyapunov exponent*.

Estimasi *correlation dimension* menyimpulkan bahwa *time series* tersebut memiliki suatu *strange attractor* berdimensi rendah.

Estimasi maximum Lyapunov exponent menghasilkan bilangan kecil yang bertanda positif.

Hasil yang diperoleh dari estimasi *correlation dimension* dan maximum Lyapunov exponent adalah komplementer. *Correlation dimension* yang rendah dan noninteger memberikan suatu *bounded set*, sehingga *time series* yang tampak seperti random dalam

¹⁷ Wei, A. ; Leuthold, R.M., *op.cit.*, hal: 36.

evolusinya dibatasi / ditarik ke dalam suatu *attractor*. Maximum Lyapunov exponent yang bertanda positif menjamin bahwa walaupun *time series* diperangkap dalam suatu *strange attractor*, tapi ia tidak akan berkonvergensi. Dengan demikian *time series* akan berfluktuasi secara kontinu dalam *attractor*-nya.¹⁸ (bayangkan seperti bumi yang mengorbit matahari, walaupun dalam hal ini siklusnya periodik, bumi tidak akan tertarik ke dalam matahari ataupun terlontar ke luar dari orbitnya).

4.9 IMPLIKASI DARI TEMUAN CHAOS

Chaos berdimensi rendah secara eksplisit menyatakan bahwa hanya ada sedikit faktor deterministik yang membentuk pergerakan harga dalam pasar, walaupun begitu harga tidak atau hampir tidak bisa diprediksikan.¹⁹

Karena *futures prices* CPO COMMEMX Malaysia adalah *chaotic structure* berdimensi rendah, maka dinamikanya ditentukan oleh sedikit faktor deterministik. Hal ini memungkinkan dibuatnya model yang terdiri dari beberapa variabel dengan persamaan gerak yang sederhana. Tetapi sifat sistem nonlinier dinamis seperti adanya nilai kritis pada nilai koefisien dan *sensitive dependence on initial condition* dapat mengakibatkan timbulnya perilaku *erratic*. Dengan demikian harus dihindari pencarian variabel-variabel yang meragukan, pencarian variabel harus difokuskan pada beberapa kekuatan-kekuatan fundamental (*fundamental forces*). Untuk *futures prices* CPO COMMEMX Malaysia, pergerakan harga dalam perioda jangka panjang ini boleh jadi disebabkan oleh beberapa

¹⁸ *Ibid*, hal: 32.

¹⁹ *Ibid*, hal: 33.

basic forces, seperti perubahan dalam elastisitas pasokan – permintaan, dan peran pemerintah Malaysia. Peristiwa-peristiwa random seperti cuaca atau musim mungkin juga berperan.²⁰

Walaupun konsep pasokan – permintaan tampaknya sederhana sehingga dijadikan dasar bagi analisis fundamental, hal ini bukan berarti tanpa komplikasi. Secara sederhana segala sesuatu yang menurunkan pasokan akan menaikkan harga, dan segala sesuatu yang menaikkan pasokan akan menurunkan harga. Sedangkan dari sisi permintaan, kenaikan permintaan akan menaikkan harga dan penurunan permintaan akan menurunkan harga.

Secara normal ada korelasi antara harga dan konsumsi, jika harga naik maka konsumsi turun, dan sebaliknya. Tetapi ada faktor lain yang mesti dipertimbangkan dalam mengukur permintaan, misalnya kondisi ekonomi dan selera konsumen. Misalnya dengan semakin meningkatnya kesadaran masyarakat akan kesehatan, maka permintaan akan minyak goreng yang berbahan baku CPO – yang dianggap membahayakan kesehatan karena kandungan kolesterolnya yang tinggi – akan turun tidak peduli berapapun harganya.

Faktor lain yang perlu dipertimbangkan adalah adanya produk substitusi, kecenderungan untuk pindah ke produk substitusi diukur dengan elastisitas permintaan. CPO merupakan substitusi dekat dari beberapa minyak nabati lainnya, sehingga harganya cenderung mengikuti pergerakan harga dunia minyak-minyak nabati tersebut.

Pasokan suatu komoditi agrikultural juga tidak mudah dihitung. Secara sederhana pasokan adalah stok perioda sebelumnya ditambah dengan yang diproduksi sekarang ditambah oleh impor. Pasokan juga ditentukan oleh sifat komoditi tersebut, apakah dapat disimpan atau tidak. Juga terdapat elastisitas pasokan terhadap harga, jika harga komoditi naik maka akan terjadi perluasan areal perkebunan, sebaliknya jika harganya turun akan

²⁰ *Ibid*, hal: 39.

banyak perkebunan yang ditelantarkan. Sebagai konsekwensinya pasokan yang ada juga berkorelasi dengan harga.

Jadi walaupun pasokan – permintaan tampak seperti konsep yang sederhana, tetapi kombinasi faktor-faktornya memperumit proses analisis pasar komoditi.

Program pemerintah mempunyai pengaruh yang berarti – dalam beberapa kasus merupakan pengaruh terbesar – dalam menentukan harga komoditi. Melalui bantuan kepada petani, pemberian lahan, insentif, dan bentuk-bentuk intervensi lainnya.

Keputusan politis juga dapat mempengaruhi harga komoditi terlebih-lebih jika komoditi tersebut merupakan penghasil utama devisa negara. Pemerintah akan berusaha memproteksi atau mendirikan hambatan dagang untuk melindungi produser lokal terhadap pesaing dari luar negeri.

Faktor-faktor lain seperti cuaca, peristiwa-peristiwa penting dunia seperti ketegangan internasional dan perang, dan fluktuasi mata uang US Dollar merupakan hal-hal yang perlu dipertimbangkan.²¹

4.10 PREDIKTABILITAS FUTURES PRICES

Walaupun telah diketahui bahwa *futures prices* CPO COMMEEX Malaysia merupakan proses *deterministic chaos* berdimensi rendah yang artinya memiliki sedikit *explanatory variable*, prediksi *prices series* tetap tidak akan bisa dilakukan dengan baik. Hal ini disebabkan adanya sifat *sensitive dependence on initial condition* pada proses *chaotic*. Savitt(1988) dan Baumol dan Benhabib (1989) mengemukakan, jika pasar adalah atau mendekati *chaotic* maka mungkin dilakukan prediksi jangka pendek, tetapi tidak

²¹ Bernstein, J., "How The Futures Markets Work", New York Institute of Finance, 1989., hal: 144.

mungkin dilakukan prediksi jangka panjang.²² Tetapi mengingat sulitnya mengukur besaran faktor-faktor fundamental seperti yang dikemukakan di atas dan membangun model peramalan yang baik dari data empiris, maka prediksi untuk jangka waktu yang pendek pun menjadi tidak mungkin.

Kesulitan lain akan dijumpai pada saat menentukan koefisien untuk variabel fundamental yang sudah dipilih. Adanya beberapa nilai kritis – dimana lebih dari satu keadaan kesetimbangan eksis – membatasi *range* parameter tersebut, dimana dalam *range* tersebut perilaku model masih sesuai dengan perilaku sistem empiris yang dimodelkan.

4.11 MANFAAT TEMUAN CHAOS DALAM FUTURES MARKET CPO

Jika *futures market* CPO COMMEMX Malaysia adalah proses *chaotic* dan tidak dapat diprediksikan, lalu apa manfaat temuan tersebut ?

Chaos ditemukan dari *time series* yang melingkup periode waktu yang sangat panjang. Hanya dalam periode yang sangat panjang, dampak suatu peristiwa random dapat diisolasi sehingga diperoleh beberapa faktor determinan yang mendominasi pasar yang menghasilkan pergerakan harga yang *chaotic*. *Chaos* adalah fenomena jangka panjang, karena hanya dalam jangka panjang struktur *fractal* dapat diidentifikasi. Struktur *fractal* merupakan objek kompleks, kita hanya dapat mengenali aspek kualitatif dari suatu objek kompleks sedangkan pengukuran yang akurat tidak dapat dilakukan. Struktur *fractal* menunjukkan perbedaan dalam detail tetapi persamaan dalam konsep keseluruhan (*locally random and globally deterministic*).

²² Wei, A. ; Leuthold, R.M., op.cit., hal: 40.

Sesuai dengan sifatnya, *chaos theory* tidak membantu kita dalam memprediksi pasar, tetapi *chaos theory* membantu kita untuk memahami pasar dengan lebih mendalam. *Chaos theory* banyak digunakan sebagai dasar untuk pemahaman pasar, selanjutnya teknik-teknik yang digunakan untuk memprediksi pasar adalah kombinasi dari metoda-metoda linier standar, *fuzzy logic*, *neural networks*, atau *genetic algorithms* ; yang dapat menghasilkan model-model dinamis/*adaptable*.

Karena tidak mungkin membangun model peramalan statis yang baik dari data empiris, temuan ini menganjurkan agar tidak terlalu mengandalkan model peramalan statis. Tetapi bahwa pasar adalah struktur *chaotic* membuka peluang lain. *Chaos* adalah struktur *fractal* yang memiliki sifat *self similarity*. Berarti pergerakan harga dalam jangka waktu pendek adalah bagian dari pergerakan jangka panjang, pergerakan yang seolah-olah tampak tidak beraturan sebenarnya berhubungan dengan keseluruhan dalam bentuknya. Suatu gelombang dari pergerakan harga bisa jadi terdiri dari sub gelombang yang lebih kecil yang berkorespondensi dalam dimensi dan karakter terhadap gelombang yang lebih besar.²³

Tantangan bagi para investor adalah menemukan titik pengambilan keputusan yang dapat digunakan sebagai *break-out points* atau *stop-loss levels* jika pergerakan harga di pasar membalik terhadap apa yang diekspektasikan semula. Menurut Bernstein (1989), mengetahui siklus pergerakan harga suatu komoditi adalah penting. Tetapi siklus harga dapat berubah-ubah periodenya, sehingga sulit atau bahkan tidak mungkin membuat prediksi yang akurat mengenai perilaku siklus-siklus berikutnya. Suatu saat mungkin

²³ *Ibid*, hal: 41.

terjadi pembalikan fasa. Keadaan ini sering terjadi saat pasar berada dalam titik balik yang besar (*major turning point*).²⁴

Kemungkinan pasar komoditi yang diteliti oleh Bernstein merupakan sistem nonlinier dinamis atau bahkan *chaos*. Dalam *chaotic system* terdapat siklus nonperiodik, siklus tersebut mempunyai durasi rata-rata tetapi berapa persisnya durasi siklus selanjutnya tidak diketahui. Pembalikan fasa terjadi pada saat pasar berada dalam *major turning point*, ada kemungkinan bahwa yang dimaksud dengan *major turning point* itu sebenarnya adalah *bifurcation point* dalam sistem *chaotic*.

Chaotic system memiliki jumlah solusi yang tidak terhingga tetapi terletak dalam *finite space*. Sistem tertarik (*attracted*) ke suatu *region of space* (daerah dimana solusi-solusi terletak). Dengan demikian sistem *chaotic* adalah *bounded set*.

Sifat ini menjustifikasi pemakaian analisis garis *support* dan *resistance* pada *futures prices* suatu komoditi. Garis *support* adalah garis yang menghubungkan titik-titik terendah dari *futures prices*, sedangkan garis *resistance* adalah garis yang menghubungkan titik-titik tertinggi dari *futures prices*. Pengamatan dilakukan pada *futures prices* yang terjadi sekarang, jika mendekati garis *support* biasanya *futures prices* akan beranjak naik, sebaliknya jika mendekati garis *resistance* biasanya *futures prices* akan bergerak turun.

Futures prices series komoditi CPO di COMMEMEX Malaysia memiliki Hurst exponent $0,5 < H < 1$ yang dinamakan *persistent series* atau *trend-reinforcing series*. Kecenderungan (*trend*) jelas terlihat, jika *series* naik (turun) di periode sebelumnya maka besar kemungkinannya untuk tetap naik (turun) di periode berikutnya. Walaupun begitu arah dan *magnitude* perubahan sulit diperkirakan, karena seringkali suatu perubahan *futures*

²⁴ Bernstein, J., *op.cit.*, hal: 139.

prices yang besar diikuti oleh perubahan yang lebih besar, secara tiba-tiba proses berubah ke perubahan kecil diikuti oleh perubahan yang lebih kecil, dan tampak seperti siklus tetapi durasinya nonperiodik.

Sifat ini menganjurkan agar investor mengambil sikap tunggu dan lihat jika tidak terjadi pergerakan *futures prices* yang signifikan. Tetapi jika pergerakan cukup fluktuatif dan bergerak ke arah yang berlawanan dengan perkiraan, maka investor harus segera mengambil posisi. Jika *floating loss* (kerugian yang belum direalisasi) sudah mencapai persentase tertentu dari dana yang ditransaksikan maka harus segera dilakukan *cut loss*, jangan mengharapkan kerugian membalik menjadi keuntungan.

Sebaliknya jika *floating profit* (keuntungan yang belum direalisasi) sudah mendekati titik "optimum" sebaiknya segera dieksekusi, jangan terlalu serakah, karena pembalikan bisa terjadi dengan tiba-tiba.

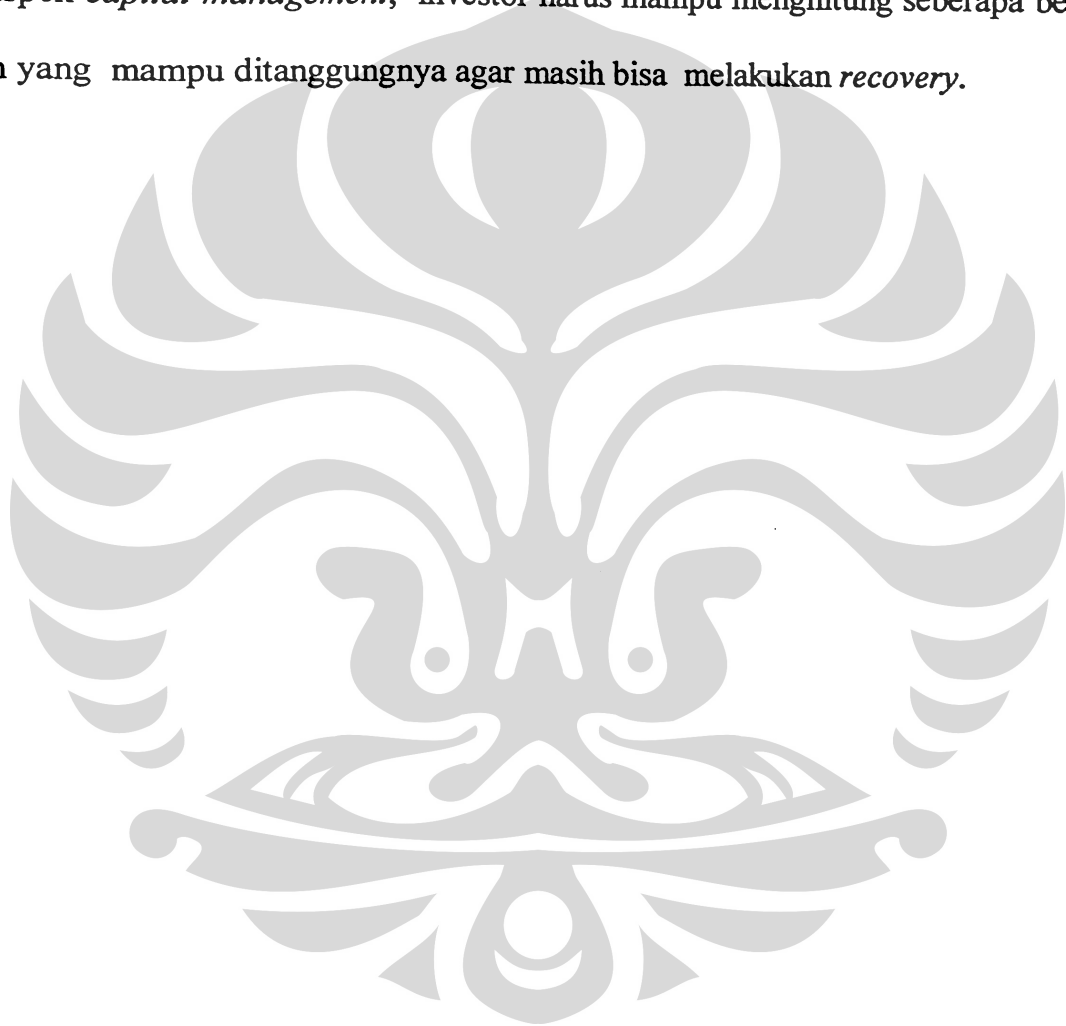
Sebagai proses dinamis, sistem *chaotic* merupakan mekanisme umpan balik, apa yang terjadi sekarang dipengaruhi oleh keadaan-keadaan sebelumnya. Jika diamati pada suatu titik waktu tertentu, maka pasar akan tampak seperti suatu sistem yang hidup yang terdiri dari perilaku psikologis manusia-manusia di dalamnya. Pada mekanisme umpan balik yang demikian peristiwa-peristiwa yang saling bergantung akan diperkuat dengan sendirinya (*self-reinforce interdependent events*) dan menyebabkan perilaku tak beraturan. Dengan adanya sifat ini, dianjurkan investor memasukkan aspek psikologis, analisis pasar, dan *capital management* dalam pengambilan keputusan.

Aspek psikologis menganjurkan investor agar segera keluar dari pasar jika ragu terhadap transaksi yang dilakukan, tetapi juga jangan keluar pasar tanpa alasan yang jelas. Walaupun

mendapatkan keuntungan besar jangan tergiur untuk buru-buru menambah investasi pada komoditi yang sama bila belum benar-benar “menguasai” pasar.

Yang harus dipertimbangkan dalam analisis pasar adalah jangan melawan pasar, artinya jangan mengambil posisi jual atau beli jika tidak tahu pasti bagaimana *trend* pasar yang tengah terjadi.

Dalam aspek *capital management*, investor harus mampu menghitung seberapa besar resiko kerugian yang mampu ditanggungnya agar masih bisa melakukan *recovery*.



BAB V KESIMPULAN DAN SARAN

5.1 KESIMPULAN

1. Nonlinieritas pada semua frekwensi data (bulanan, mingguan, dan harian) *time series* dari *futures prices* CPO pada Commodity and Monetary Exchange of Malaysia (COMDEX Malaysia) sepanjang 20 tahun (23 Okt 1980 – 31 Mar 2000) tidak dapat direpresentasikan dengan memuaskan oleh pemodelan nonlinier stokastik ARCH maupun GARCH.
2. Rescaled Range (R/S) analysis yang diterapkan pada *time series* bulanan, mingguan, dan harian masing-masing menghasilkan Hurst exponent H 0,6970 , 0,6276 , dan 0,6305. Masing-masing signifikan pada $0,77\sigma$, $0,75\sigma$, dan $3,80\sigma$. Hanya satu *time series*, yaitu data harian yang cukup signifikan menolak hipotesis nol bahwa *time series* adalah random. Walaupun begitu ada kemungkinan perilaku *time series* harian itu bukan berasal dari *long-term memory* melainkan merupakan simptom dari *short-term memory*, akibat metoda residual AR(1) tidak cukup mengeliminir *short-range dependence* pada *time series*.
3. Rescaled Range (R/S) analysis berhasil menghitung siklus nonperiodik pada semua frekwensi data *time series*. Durasi siklus nonperiodik *time series* bulanan adalah 42 bulan, durasi siklus nonperiodik *time series* mingguan adalah 200 minggu, dan durasi siklus nonperiodik *time series* harian adalah 1012 hari. Perbandingan panjang durasi konsisten dengan perbandingan frekwensi sampling ketiga *time series* tersebut. Jika *time series* adalah *Gaussian random walk*, *white noise* akan tampak sama di semua frekwensi, sehingga tidak akan ada siklus tertentu. Sehingga penampakan siklus yang

konsisten pada ketiga frekwensi data dapat membuktikan bahwa ketiga *time series* tersebut bukanlah random.

4. Dalam penelitian ini dapat diestimasi *correlation dimension* pada semua frekwensi data *time series*. *Correlation dimension* merupakan bilangan noninteger (*fractal*) yang terletak antara 1 dan 2, yang mengindikasikan adanya struktur *low dimension chaos*.

Temuan *noninteger correlation dimension* bukan merupakan kondisi cukup untuk membuktikan adanya struktur *chaotic*, diperlukan adanya maximum Lyapunov exponent yang bertanda positif.

5. Dalam penelitian ini dapat diestimasi maximum Lyapunov exponent pada semua frekwensi data *time series*. Nilai maximum Lyapunov exponent masing-masing adalah 0,0638 untuk data bulanan, 0,006 untuk data mingguan, dan 0,0037 untuk data harian.

Semua nilai maximum Lyapunov exponent ini mendekati nilai T_d^{-1} dimana T_d adalah *decorrelation time* masing-masing *time series*, kecuali data harian yang tidak bisa diperoleh plot *correlogram*-nya.

6. Hasil yang diperoleh dari estimasi *correlation dimension* dan maximum Lyapunov exponent adalah komplementer. *Correlation dimension* yang rendah dan noninteger memberikan suatu *bounded set*, sehingga *time series* yang walaupun gerakannya seperti random evolusinya dibatasi oleh suatu *attractor*. Maximum Lyapunov exponent yang bertanda positif menjamin *time series* dalam perjalanan evolusinya tidak akan berkonvergensi. Dengan demikian *time series* akan berfluktuasi secara kontinu dalam *attractor*-nya.

5.2 SARAN

1. Kualitas hasil temuan pembuktian adanya chaos dalam suatu *time series* data empiris sangat dipengaruhi oleh ketepatan penerapan metoda / teknik yang dipakai, kualitas serta kuantitas data yang dipakai, dan *data treatment* sebelum pemrosesan.
Algoritma Grassberger & Procaccia yang dipakai untuk menghitung *correlation integral* yang selanjutnya digunakan untuk mengestimasi *correlation dimension* dan algoritma Wolf untuk menghitung *running average* maximum Lyapunov exponent cukup sederhana, tetapi membutuhkan komputasi yang cukup banyak memakan waktu. Penulis mencantumkan kode program dalam bahasa Basic untuk mengeksekusi kedua algoritma tersebut di Lampiran 8. Tetapi jika jumlah titik datanya melebihi 5000 disarankan untuk mengubah kode program tersebut ke dalam bahasa Pascal atau C, penulis memakai Pascal dari Borland Delpi dengan hasil yang memuaskan.
2. Kedua algoritma tersebut juga peka terhadap *noise* dan efek *temporal correlation* dalam *time series*. Beberapa peneliti sebelumnya gagal mengestimasi *correlation dimension* pada *time series* yang *noisy* seperti data harian karena tidak menerapkan *noise filtering* maupun menghilangkan efek *temporal correlation*.
3. R/S analysis memiliki kelemahan yaitu peka terhadap *short-range dependence*. Peters (1994) menggunakan metoda residual AR(1) untuk menghilangkan atau mengurangi ketergantungan linier, sesuai dengan yang dilakukan oleh Brock, Dechert, dan Sheinkman (1987) yang menyatakan bahwa metoda itu cukup dapat menghilangkan ketergantungan untuk mereduksi efek sampai ke tingkat yang insignifikan.¹ Tetapi

¹ Peters, E. E., "Fractal Market Analysis", John Wiley & Sons Inc., 1994, hal: 108.

terbukti metoda ini tidak dapat menghilangkan seluruh efek *short-term memory*.
Disarankan untuk mencoba metoda Modified R/S analysis dari Lo dan Mac Kinlay.

4. *Chaos theory* terus berkembang dengan pesat, algoritma-algoritma baru yang lebih baik terus ditemukan. Untuk menghitung Lyapunov exponent misalnya ada algoritma dari Rosenstein yang lebih baik daripada algoritma Wolf. Disarankan untuk terus mencoba-coba beberapa algoritma yang sesuai dengan *time series* yang akan dianalisis.
5. Struktur *chaotic* berdimensi rendah pada *futures prices* CPO pada Commodity and Monetary Exchange of Malaysia (COMMEX Malaysia) mengindikasikan bahwa dinamika sistem ditentukan oleh sedikit faktor deterministik. Oleh karena itu saran penulis untuk *fundamental analyst* adalah menghindarkan pencarian variabel-variabel yang meragukan, pencarian harus difokuskan pada beberapa *fundamental forces* dan mengamati interdependensi faktot-faktornya.
6. Perilaku sistem *chaotic* menjustifikasi beberapa praktek yang sering dilakukan oleh *technical analyst*. Praktek analisis garis *support* dan *resistance* didukung oleh adanya sifat *bounded set* pada *attractor* sistem-sistem *chaotic*.

Mekanisme umpan balik pada pasar juga menganjurkan investor mempertimbangkan aspek-aspek psikologis, analisis pasar, dan *capital management*.

Usaha mencari-cari suatu siklus periodik pada pergerakan harga pasar adalah sia-sia karena pada sistem-sistem nonlinier dan *chaos* sulit atau mustahil menjumpai suatu siklus periodik, yang ada adalah siklus nonperiodik yang tidak bisa diramalkan perilakunya.

Pembalikan fasa bisa terjadi kapan saja, saat pasar berada dalam *major turning point* dimana pada saat itu sebenarnya sistem memasuki *bifurcation point*.

Mengetahui adanya perilaku pasar seperti ini ini, penulis menganjurkan agar investor berespons sesuai dengan arah, *magnitude*, dan kecepatan pergerakan pasar. Investor harus bertindak cepat, melakukan *cut loss* jika *floating loss* sudah mencapai titik tertentu. Jangan mengharapkan adanya pembalikan arah yang merubah kerugian menjadi keuntungan. Sebaliknya jika *floating profit* sudah mendekati titik “optimum” sebaiknya segera dieksekusi karena bisa saja terjadi perubahan arah dengan tiba-tiba.



DAFTAR PUSTAKA

1. Bask, M., **“Deterministic Chaos in Swedish Exchange Rates ?”**, Departement of Economics, Umea University.
2. Bernstein, J., **“How The Futures Markets Work”**, New York Institute of Finance, 1989.
3. Blank, S. C. ; Carter, C. A. ; Schmiesing, B. H., **“Futures and Options Markets : Trading in Financials and Commodities”**, Prentice-Hall , 1991.
4. Chatfield, C., **“ The Analysis of Time series : An Introduction”**, Fourth Edition, Chapman & Hall, London, 1989.
5. Chen, P., **“Searching for Economic Chaos : A Challenge to Econometric Practice and Nonlinear Tests”**, dalam Day, R.H. & Chen, P. , eds., **“Nonlinear Dynamics & Evolutionary Economics”** , Oxford University Press, 1993.
6. DeCoster, G. P.; Labys, W.C.; Mitchell, D. W., **“Evidence of Chaos in Commodities Futures Prices”** , in Peters, C. ; Warwick, B., eds, **“The Handbook of Managed Futures”**, Irwin, 1997.
7. Gaynor, P. E. ; Kirkpatrick, R. C., **“Introduction to Time-Series Modeling and Forecasting in Business and Economics”**, McGraw-Hill Inc., Singapore, 1994.
8. Gleick, J., **“Chaos: Making a New Science”**, Penguin Books, 1987.
9. Greene, W. H., **“Econometrics Analysis”**, Fourth Edition, Prentice Hall International, Inc., 2000
10. Gujarati, D. N., **“Basic Econometrics”** , Third Edition, McGraw-Hill Inc., Singapore, 1995.




11. Gujarati, D. N., **“Essentials of Econometrics”** , Second Edition, Irwin/McGraw Hill Inc., Singapore, 1999.
12. Hanke, J. E., Reitsch, A. G., **“ Business Forecasting”**, Third Edition, Allyn and Bacon, Boston, 1989.
13. Hull, J. C., **“Options, Futures, & Other Derivatives”** , Fourth Edition, Prentice Hall , 2000.
14. Jarrett, J., **“Business Forecasting Methods”**, Second Edition, Basil Blackwell Inc., Cambridge-Massachusetts, 1991.
15. Kantz, Holger ; Schreiber, Thomas , **“Nonlinear Time Series Analysis”** , Cambridge University Press, 2000.
16. Le Baron, B., **“Chaos and Nonlinear Forecastability in Economics and Finance”**, Departement of Economics University of Wisconsin - Madison, February 1994.
17. Lo, A.W. ; MacKinlay, A.C., **“A Non-Random Walk Down Wall Street”**, Princeton University Press, Princeton, New Jersey, 1999.
18. Makridakis, Spyros ; Wheelright, S.C., **“Forecasting : Methods and Applications”**, Second Edition, John Wiley & Sons, New York, 1983.
19. Newbold, P. ; Bos, T., **“Introductory Business & Economic Forecasting”**, Second Edition, South-Western Publishing Co., Cincinnati-Ohio, 1994.
20. Peters, E. E., **“Chaos and Order in The Capital Markets”**, John Wiley & Sons Inc. , 1991.
21. Peters, E. E., **“Fractal Market Analysis”**, John Wiley & Sons Inc. , 1994.
22. Shinnars, S. M., **“Modern Control System Theory and Application”**, Second Edition, Addison-Wesley Publishing Company, 1980,

23. **Studi Tentang Pemasaran CPO dan Perkebunan Kelapa Sawit di Indonesia,** 1999, Prepared by PT. CAPRICORN Indonesia Consult Inc., hal : 50.
24. **Wei, A. ; Leuthold, R. M., “Long Agricultural Futures Prices: ARCH, Long Memory, or Chaos Process ?”,** OFOR Paper Number 98-03, May 1998.





LAMPIRAN 1 : *PRICES SERIES* SEBELUM DAN SETELAH ADJUSTMENT



LAMPIRAN 2 : HASIL UJI NORMALITAS

Tabel L2.1. Uji Normalitas Pada *Prices Series* Sebelum dan Sesudah *Adjustment*

SERIES	MEAN	ST. DEV	SKEWNESS	KURTOSIS	JARQUE-BERA
D	1.092,576	426,5031	1,517406	5,270581	3.034,738
DA	2.643,705	957,0837	0,335643	2,542674	139,3767
W	1.092,268	427,8455	1,525475	5,301558	617,6892
WA	2.644,112	959,1722	0,333184	2,538457	27,78854
M	1.092,051	424,0750	1,490473	5,229090	135,0851
MA	2.643,615	961,3792	0,320727	2,518811	6,269298

Tabel L2.2 Uji Normalitas Pada *Logaritmik Prices Differences*

SERIES	MEAN	ST. DEV	SKEWNESS	KURTOSIS	JARQUE-BERA
DAL	0,000132	0,003791	1,092689	28,32514	136.496,7
WAL	0,000667	0,008463	1,383367	17,87399	9.670,624
MAL	0,002836	0,022419	1,640849	12,42082	966,1862

Tabel L2.3 Uji Normalitas Pada *Log-Linear Detrending*

SERIES	MEAN	ST. DEV	SKEWNESS	KURTOSIS	JARQUE-BERA
DA1	0,000534	0,203767	0,698101	3,420196	449,1947
WA1	0,000151	0,204633	0,715279	3,486218	96,54787
MA1	2,62 E-5	0,204888	0,708213	3,479398	21,80181

LAMPIRAN 3 : HASIL UJI STASIONARITAS

Tabel L3.1 Uji Stasionaritas Pada *Time Series* Data Harian

	Augmented Dickey - Fuller	Phillips - Perron
D	-2,244265	-2,337170
DA	-1,322316	-1,350642
DAL	-29,48499	-67,74353
DA1	-2,371359	-2,459671
Critical value :	1 % -3,4348	-3,4348
	5 % -2,8626	-2,8626
	10% -2,5674	-2,5674

Tabel L3.2 Uji Stasionaritas Pada *Time Series* Data Mingguan

	Augmented Dickey - Fuller	Phillips - Perron
W	-2,992879	-2,659760
WA	-1,489914	-1,487914
WAL	-12,38841	-25,51084
WA1	-2,655531	-2,761252
Critical value :	1 % -3,4396	-3,4395
	5 % -2,8648	-2,8648
	10% -2,5685	-2,5685

Tabel L3.3 Uji Stasionaritas Pada *Time Series* Data Bulanan

	Augmented Dickey - Fuller	Phillips - Perron
M	-2,829992	-2,581631
MA	-1,598681	-1,472377
MAL	-5,060175	-12,82078
MA1	-3,065093	-2,750197
Critical value :	1 % -3,4604	-3,4599
	5 % -2,8742	-2,8740
	10% -2,5735	-2,5734

LAMPIRAN 4 : PEMODELAN ARIMA DAN ARCH / GARCH

Tabel L4.1 Model ARCH(1) dan GARCH(1) Untuk Time Series MAL

Dependent Variable: MAL
 Method: ML - ARCH
 Date: 05/25/01 Time: 08:32
 Sample(adjusted): 2 233
 Included observations: 232 after adjusting endpoints
 Convergence achieved after 21 iterations
 Backcast: 1

	Coefficient	Std. Error	z-Statistic	Prob.
AR(1)	-0.504	0.131742	-3.825651	0.0001
MA(1)	0.709023	0.105859	6.697791	0
Variance Equation				
C	1.50E-05	6.98E-06	2.146728	0.0318
ARCH(1)	0.28188	0.069867	4.034534	0.0001
GARCH(1)	0.714385	0.06069	11.77113	0
R-squared	0.056935	Mean dependent var		0.00257
Adjusted R-squared	0.040317	S.D. dependent var		0.022098
S.E. of regression	0.021648	Akaike info criterion		-5.23264
Sum squared resid	0.10638	Schwarz criterion		-5.15836
Log likelihood	611.9861	F-statistic		3.426122
Durbin-Watson stat	1.90733	Prob(F-statistic)		0.009624
Inverted AR Roots	-0.5			
Inverted MA Roots	-0.71			

Tabel L4.2 Model ARIMA(1,1) Untuk Time Series WAL

Dependent Variable: WAL
 Method: Least Squares
 Date: 05/25/01 Time: 08:12
 Sample(adjusted): 2 1014
 Included observations: 1013 after adjusting endpoints
 Convergence achieved after 15 iterations
 Backcast: 1

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.693428	0.066348	10.45136	0
MA(1)	-0.48519	0.081139	-5.979671	0
R-squared	0.081384	Mean dependent var		0.000652

(lanjutan Tabel L4.2)

Adjusted R-squared	0.080476	S.D. dependent var	0.008453
S.E. of regression	0.008106	Akaike info criterion	-6.79041
Sum squared resid	0.066433	Schwarz criterion	-6.78069
Log likelihood	3441.341	F-statistic	89.56884
Durbin-Watson stat	2.007456	Prob(F-statistic)	0

Inverted AR Roots	0.69
Inverted MA Roots	0.49

Tabel L4.3 Model ARCH(2) Untuk Time Series WAL

Dependent Variable: WAL
 Method: ML - ARCH
 Date: 05/25/01 Time: 08:13
 Sample(adjusted): 2 1014
 Included observations: 1013 after adjusting endpoints
 Convergence achieved after 23 iterations
 Backcast: 1

	Coefficient	Std. Error	z-Statistic	Prob.
AR(1)	0.70424	0.036351	19.37345	0
MA(1)	-0.49752	0.062174	-8.002062	0
Variance Equation				
C	2.19E-05	1.10E-06	19.83335	0
ARCH(1)	0.37702	0.048994	7.695148	0
ARCH(2)	0.325812	0.044894	7.257437	0
R-squared	0.081345	Mean dependent var	0.000652	
Adjusted R-squared	0.0777	S.D. dependent var	0.008453	
S.E. of regression	0.008118	Akaike info criterion	-7.18179	
Sum squared resid	0.066436	Schwarz criterion	-7.1575	
Log likelihood	3642.574	F-statistic	22.31417	
Durbin-Watson stat	2.004215	Prob(F-statistic)	0	
Inverted AR Roots	0.7			
Inverted MA Roots	0.5			

Tabel L4.4 Model ARIMA(1,1) Untuk Time Series DAL

Dependent Variable: DAL
 Method: Least Squares
 Date: 05/25/01 Time: 07:52
 Sample(adjusted): 2 5070
 Included observations: 5069 after adjusting endpoints

(lanjutan Tabel L4.4)

Convergence achieved after 9 iterations

Backcast: 1

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	-0.68034	0.104796	-6.492031	0
MA(1)	0.723226	0.098864	7.315396	0
R-squared	0.003218	Mean dependent var		0.000133
Adjusted R-squared	0.003021	S.D. dependent var		0.00379
S.E. of regression	0.003784	Akaike info criterion		-8.31547
Sum squared resid	0.072568	Schwarz criterion		-8.31289
Log likelihood	21077.55	F-statistic		16.35885
Durbin-Watson stat	1.971654	Prob(F-statistic)		0.000053

Tabel L4.5 Model ARCH(2) Untuk Time Series DAL

Dependent Variable: DAL

Method: ML - ARCH

Date: 05/25/01 Time: 07:57

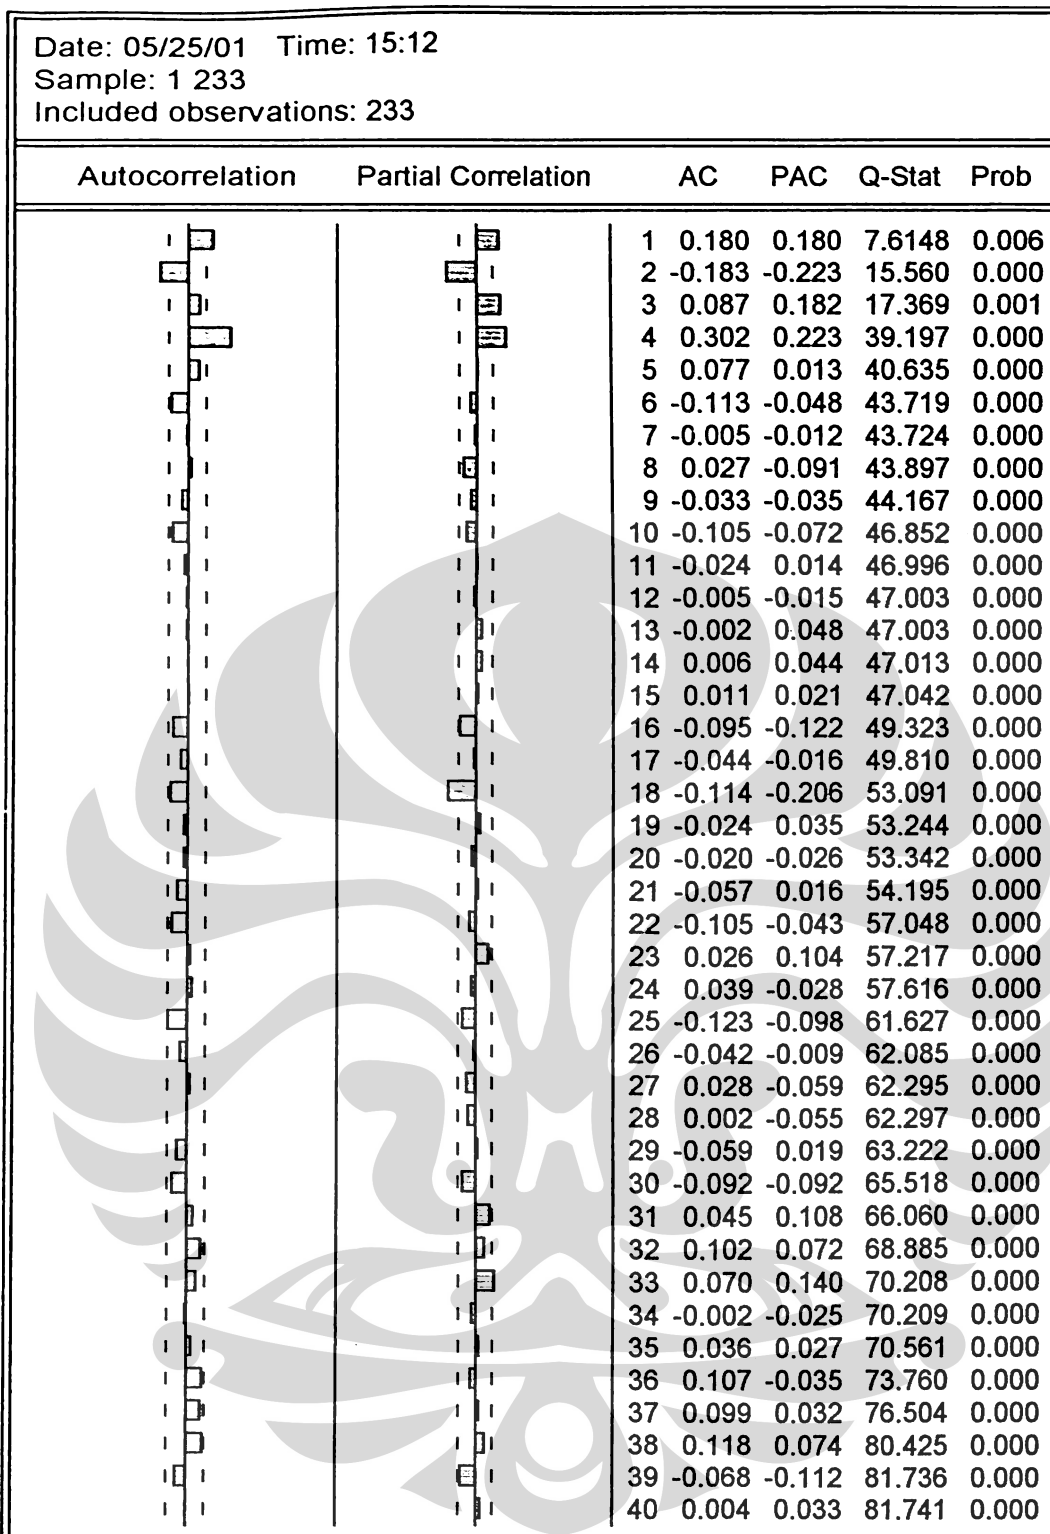
Sample(adjusted): 2 5070

Included observations: 5069 after adjusting endpoints

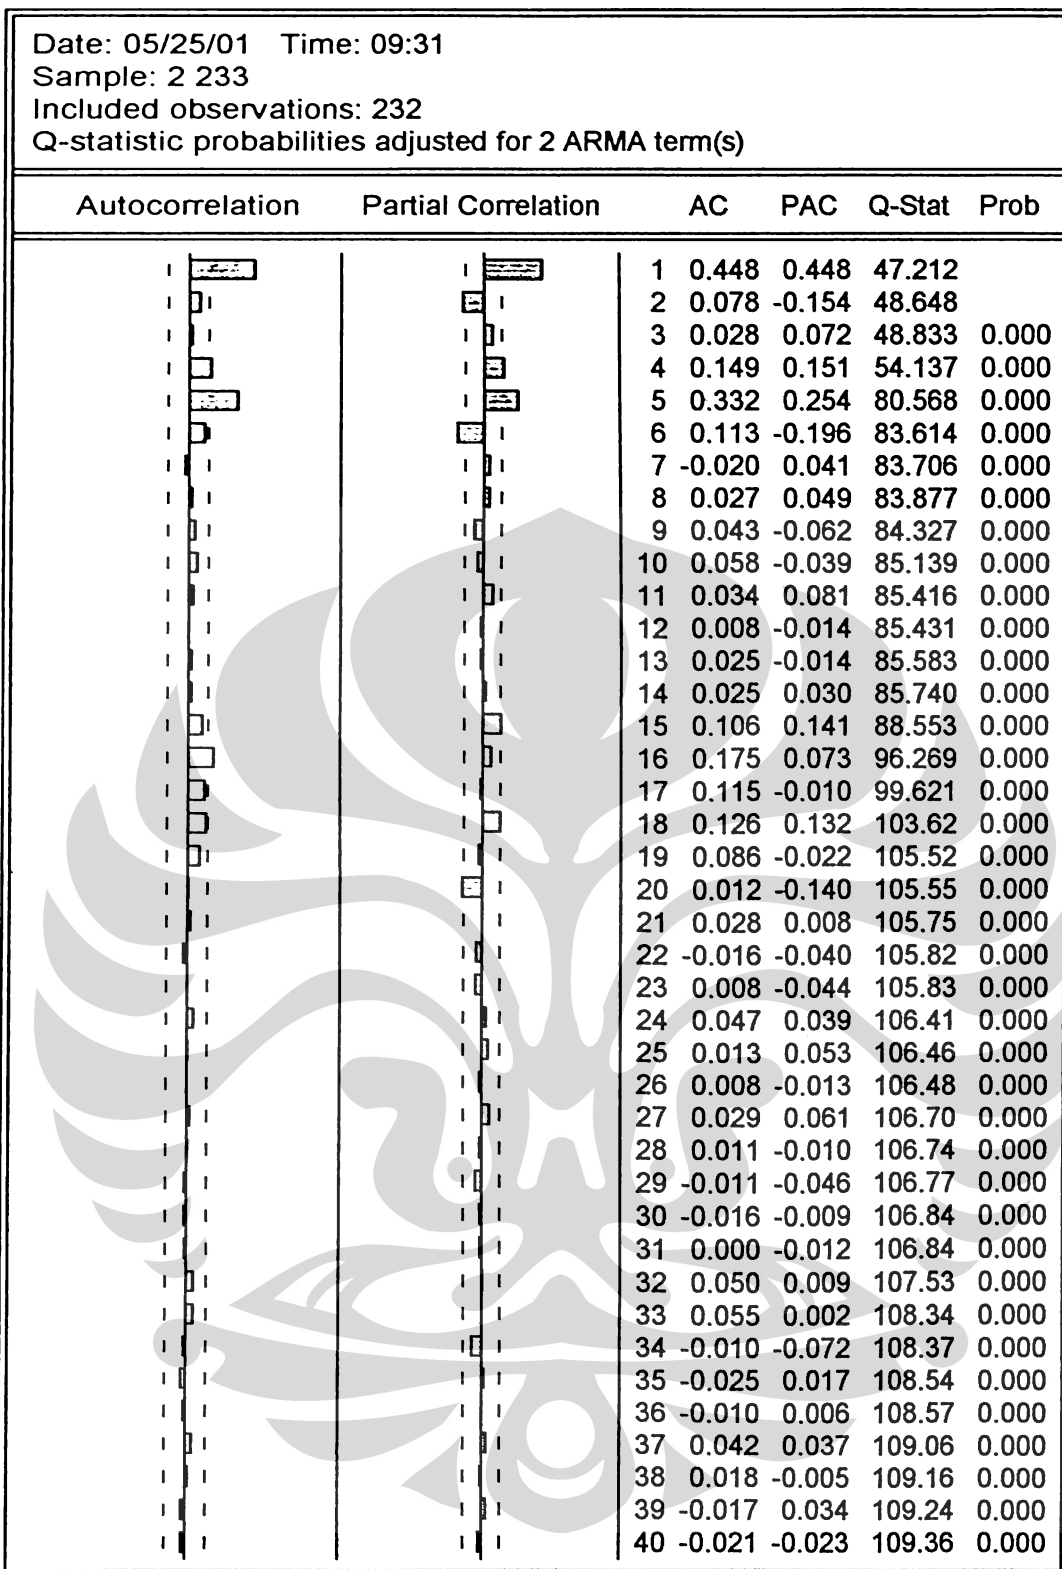
Convergence achieved after 40 iterations

Backcast: 1

	Coefficient	Std. Error	z-Statistic	Prob.
AR(1)	0.962309	0.003156	304.9088	0
MA(1)	-0.83106	0.00272	-305.561	0
Variance Equation				
C	3.95E-06	5.08E-08	77.82418	0
ARCH(1)	0.440599	0.016806	26.2167	0
ARCH(2)	0.332454	0.016502	20.14646	0
R-squared	-0.02908	Mean dependent var		0.000133
Adjusted R-squared	-0.02989	S.D. dependent var		0.00379
S.E. of regression	0.003846	Akaike info criterion		-8.90356
Sum squared resid	0.074919	Schwarz criterion		-8.89712
Log likelihood	22571.07	Durbin-Watson stat		2.096499



Gambar L4.1 : Correlogram Dari Logaritmik Prices Differences Bulanan MAL

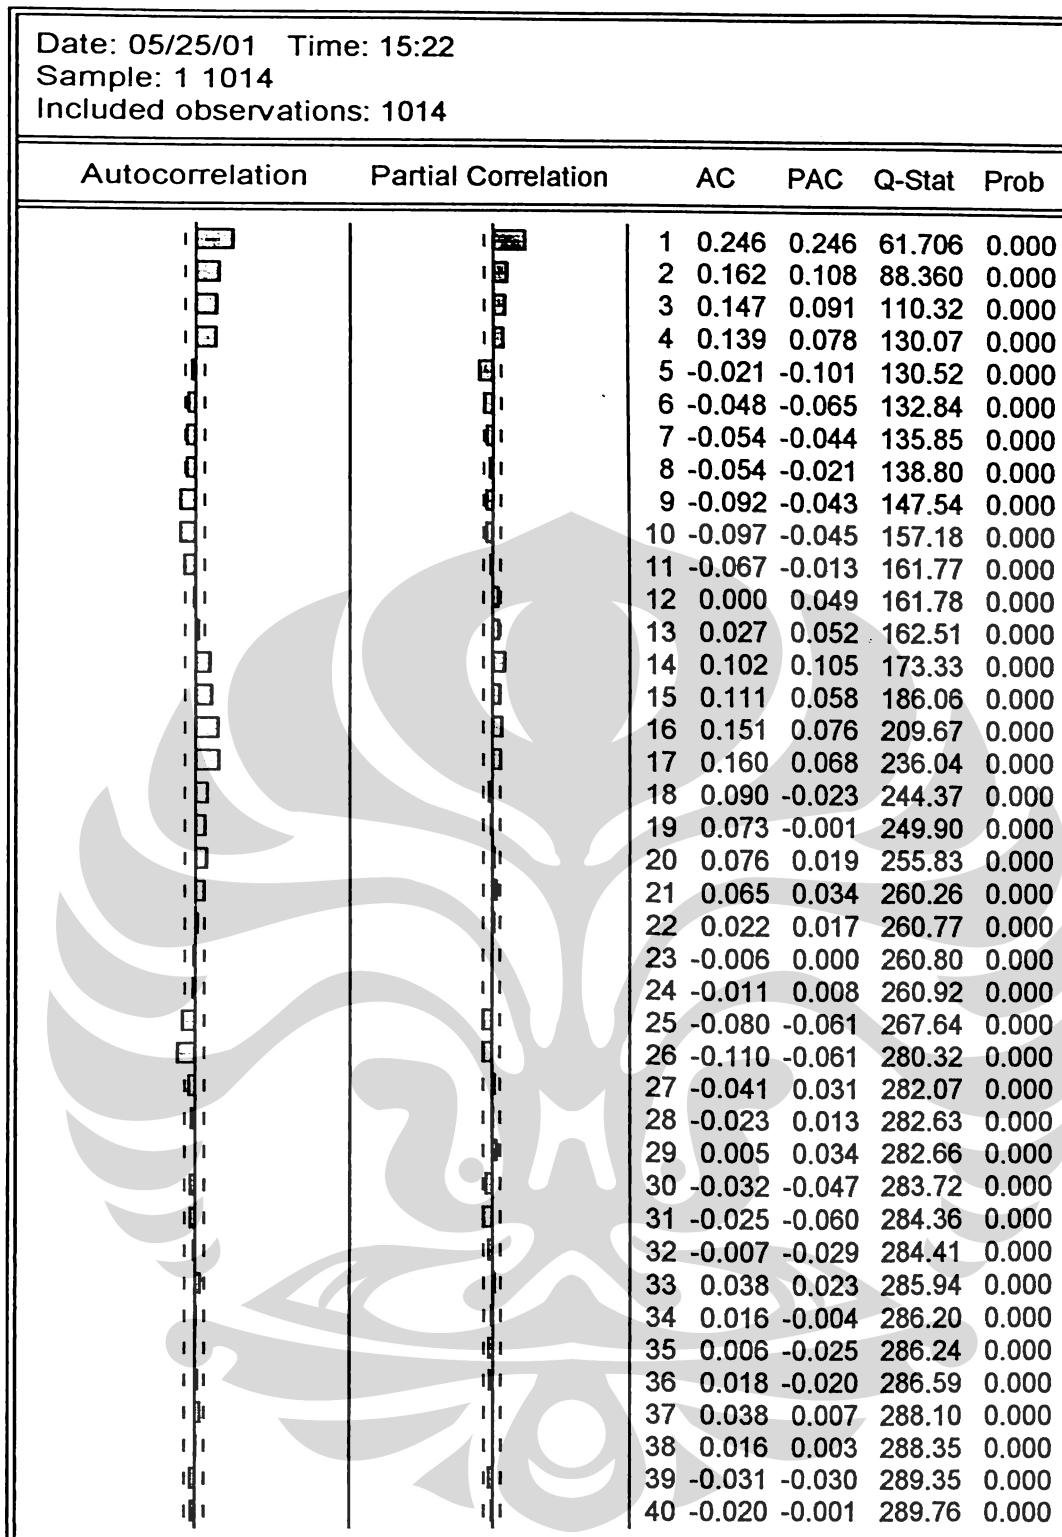


Gambar L4.2 : Correlogram Residual Kuadrat ARIMA(1,1) MAL

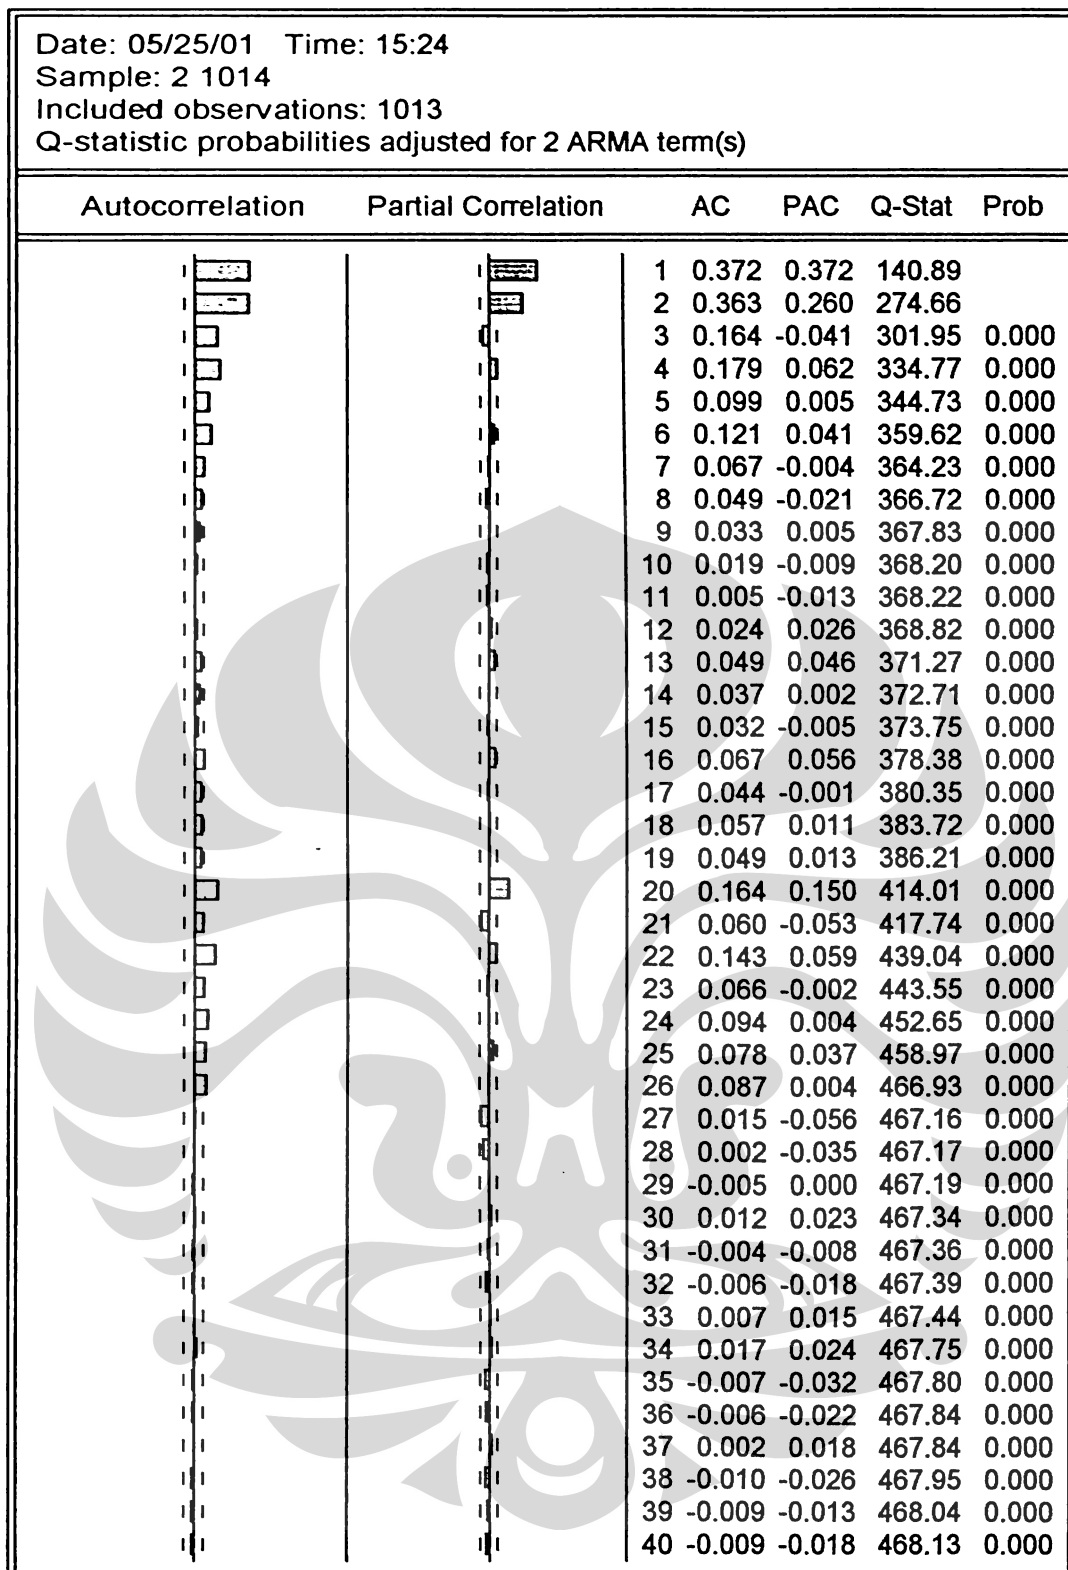
Date: 05/25/01 Time: 15:18
Sample: 2 233
Included observations: 232
Q-statistic probabilities adjusted for 2 ARMA term(s)

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.059	0.059	0.8231	
		2	-0.120	-0.124	4.1998	
		3	-0.033	-0.018	4.4626	0.035
		4	0.087	0.077	6.2526	0.044
		5	0.069	0.053	7.3779	0.061
		6	-0.091	-0.083	9.3728	0.052
		7	0.002	0.032	9.3742	0.095
		8	-0.039	-0.066	9.7465	0.136
		9	-0.024	-0.028	9.8825	0.195
		10	-0.047	-0.046	10.418	0.237
		11	-0.068	-0.064	11.553	0.240
		12	-0.029	-0.037	11.766	0.301
		13	-0.015	-0.015	11.824	0.377
		14	-0.015	-0.025	11.878	0.456
		15	-0.022	-0.013	11.995	0.528
		16	0.037	0.039	12.341	0.579
		17	0.028	0.012	12.534	0.638
		18	0.054	0.058	13.281	0.652
		19	0.056	0.053	14.090	0.661
		20	0.023	0.017	14.225	0.714
		21	0.106	0.107	17.132	0.581
		22	-0.064	-0.086	18.177	0.576
		23	0.032	0.049	18.442	0.621
		24	-0.022	-0.044	18.565	0.672
		25	-0.009	-0.013	18.588	0.725
		26	-0.059	-0.065	19.516	0.724
		27	-0.028	0.010	19.730	0.761
		28	0.001	-0.022	19.730	0.804
		29	-0.029	0.008	19.950	0.833
		30	-0.093	-0.086	22.270	0.769
		31	-0.048	-0.013	22.881	0.782
		32	0.067	0.058	24.117	0.767
		33	0.132	0.128	28.837	0.578
		34	0.035	0.043	29.166	0.611
		35	-0.055	-0.019	30.015	0.617
		36	-0.050	-0.068	30.704	0.630
		37	0.055	0.004	31.548	0.636
		38	0.042	-0.009	32.045	0.657
		39	-0.052	-0.066	32.820	0.665
		40	-0.064	-0.062	33.981	0.656

Gambar L4.3 : Correlogram Residual Kuadrat ARCH(1) dan GARCH(1) MAL



Gambar L4.4 : Correlogram Dari Logaritmic Prices Differences Mingguan WAL



Gambar L4.5 : Correlogram Residual Kuadrat ARIMA(1,1) WAL

Date: 05/25/01 Time: 15:38
Sample: 2 1014
Included observations: 1013
Q-statistic probabilities adjusted for 2 ARMA term(s)

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.010	-0.010	0.1018	
		2 -0.038	-0.038	1.5682	
		3 0.027	0.026	2.2918	0.130
		4 0.080	0.079	8.8127	0.012
		5 0.034	0.038	9.9847	0.019
		6 -0.028	-0.022	10.793	0.029
		7 0.084	0.083	18.076	0.003
		8 0.011	0.003	18.207	0.006
		9 0.021	0.023	18.651	0.009
		10 0.039	0.039	20.204	0.010
		11 0.027	0.019	20.980	0.013
		12 -0.009	-0.015	21.067	0.021
		13 0.076	0.078	27.022	0.005
		14 0.006	-0.008	27.062	0.008
		15 -0.001	-0.001	27.062	0.012
		16 0.011	0.006	27.178	0.018
		17 0.051	0.036	29.818	0.013
		18 -0.012	-0.022	29.978	0.018
		19 0.000	0.008	29.978	0.027
		20 0.036	0.017	31.290	0.027
		21 0.013	0.005	31.456	0.036
		22 0.008	0.007	31.517	0.049
		23 0.007	0.004	31.568	0.065
		24 0.063	0.049	35.707	0.033
		25 0.035	0.038	36.949	0.033
		26 0.040	0.038	38.595	0.030
		27 0.015	0.009	38.815	0.038
		28 -0.020	-0.029	39.247	0.046
		29 0.005	-0.007	39.276	0.060
		30 0.024	0.008	39.881	0.068
		31 0.039	0.031	41.469	0.063
		32 -0.020	-0.021	41.895	0.073
		33 0.006	-0.003	41.936	0.091
		34 0.098	0.085	52.101	0.014
		35 -0.037	-0.044	53.577	0.013
		36 -0.015	-0.012	53.800	0.017
		37 0.032	0.017	54.868	0.017
		38 -0.002	-0.025	54.872	0.023
		39 0.003	0.002	54.882	0.029
		40 -0.017	-0.014	55.200	0.035

Gambar L4.6 : Correlogram Residual Kuadrat ARCH(2) WAL

Date: 05/25/01 Time: 15:40
Sample: 1 5070
Included observations: 5070

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.053	0.053	14.207	0.000
		2	-0.018	-0.020	15.786	0.000
		3	-0.014	-0.012	16.796	0.001
		4	0.009	0.010	17.242	0.002
		5	0.073	0.072	44.445	0.000
		6	0.010	0.003	45.000	0.000
		7	0.050	0.053	57.832	0.000
		8	0.038	0.035	65.260	0.000
		9	0.055	0.053	80.514	0.000
		10	0.093	0.087	124.71	0.000
		11	0.038	0.032	132.10	0.000
		12	0.041	0.037	140.61	0.000
		13	0.045	0.041	150.77	0.000
		14	-0.026	-0.038	154.30	0.000
		15	0.016	0.006	155.57	0.000
		16	0.022	0.008	157.94	0.000
		17	0.024	0.003	160.78	0.000
		18	0.031	0.013	165.67	0.000
		19	0.033	0.022	171.35	0.000
		20	0.072	0.053	197.40	0.000
		21	-0.021	-0.036	199.70	0.000
		22	0.044	0.039	209.42	0.000
		23	-0.001	-0.016	209.43	0.000
		24	-0.020	-0.024	211.37	0.000
		25	0.007	-0.006	211.59	0.000
		26	-0.027	-0.034	215.24	0.000
		27	-0.046	-0.063	226.00	0.000
		28	-0.034	-0.044	231.83	0.000
		29	0.031	0.017	236.84	0.000
		30	0.076	0.058	266.65	0.000
		31	-0.036	-0.043	273.43	0.000
		32	0.004	0.013	273.53	0.000
		33	-0.019	-0.012	275.29	0.000
		34	-0.046	-0.038	286.22	0.000
		35	0.015	0.014	287.40	0.000
		36	-0.010	0.003	287.88	0.000
		37	-0.006	-0.002	288.07	0.000
		38	-0.034	-0.029	293.81	0.000
		39	-0.003	0.002	293.86	0.000
		40	-0.010	-0.020	294.37	0.000

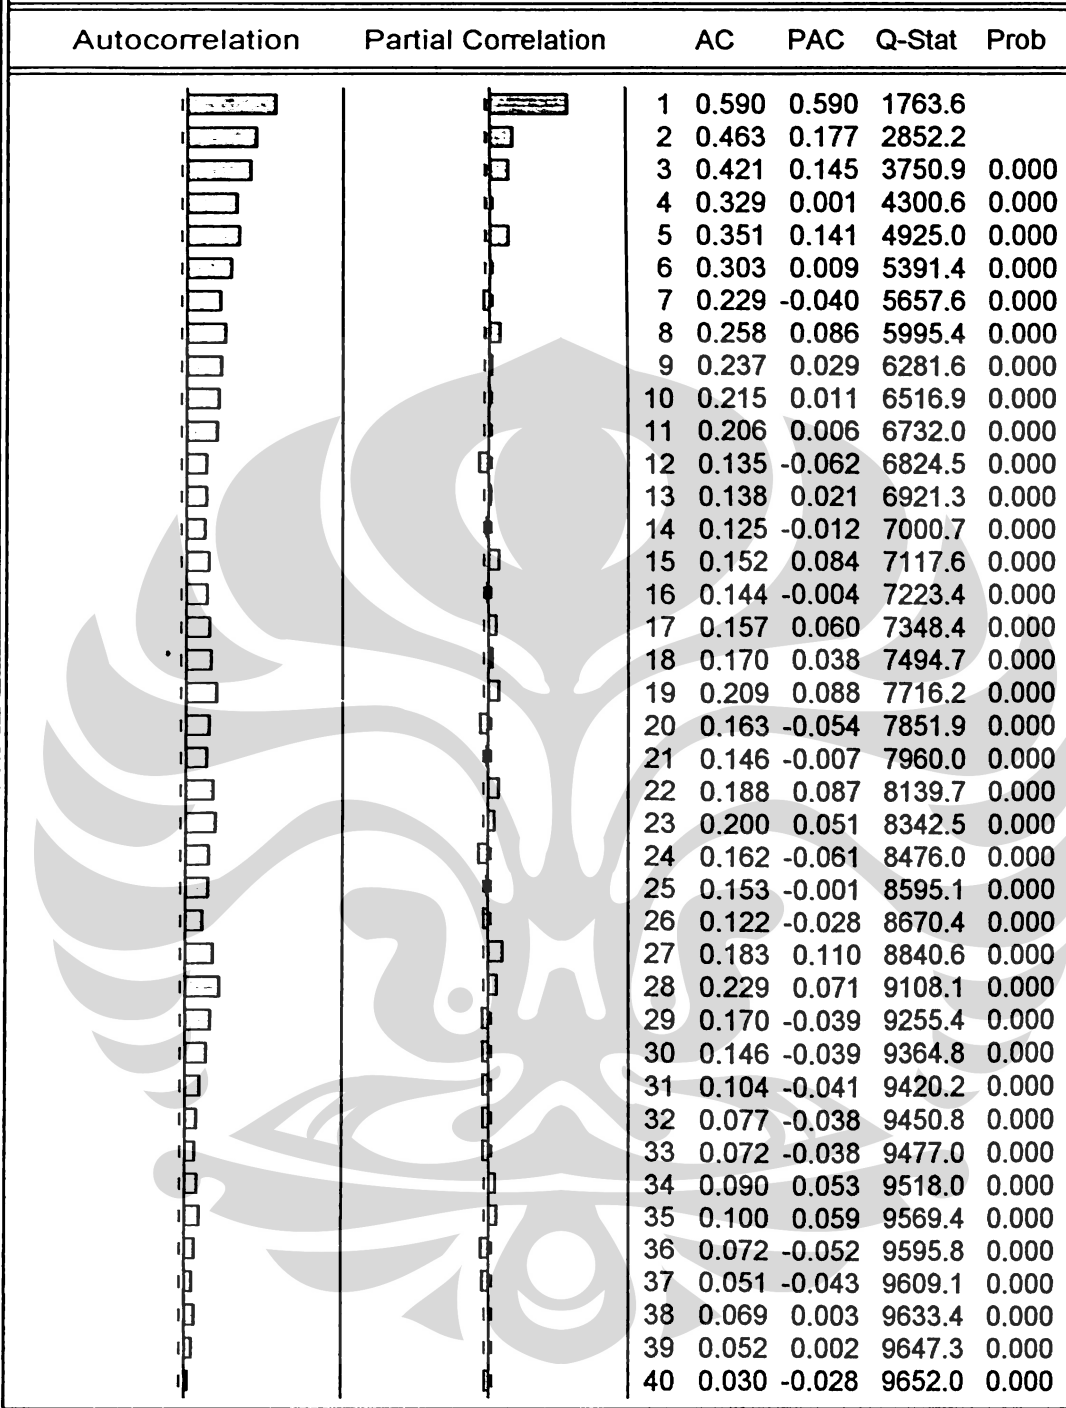
Gambar L4.7 : Correlogram Dari Logaritmic Prices Differences Harian DAL

Date: 05/25/01 Time: 15:43

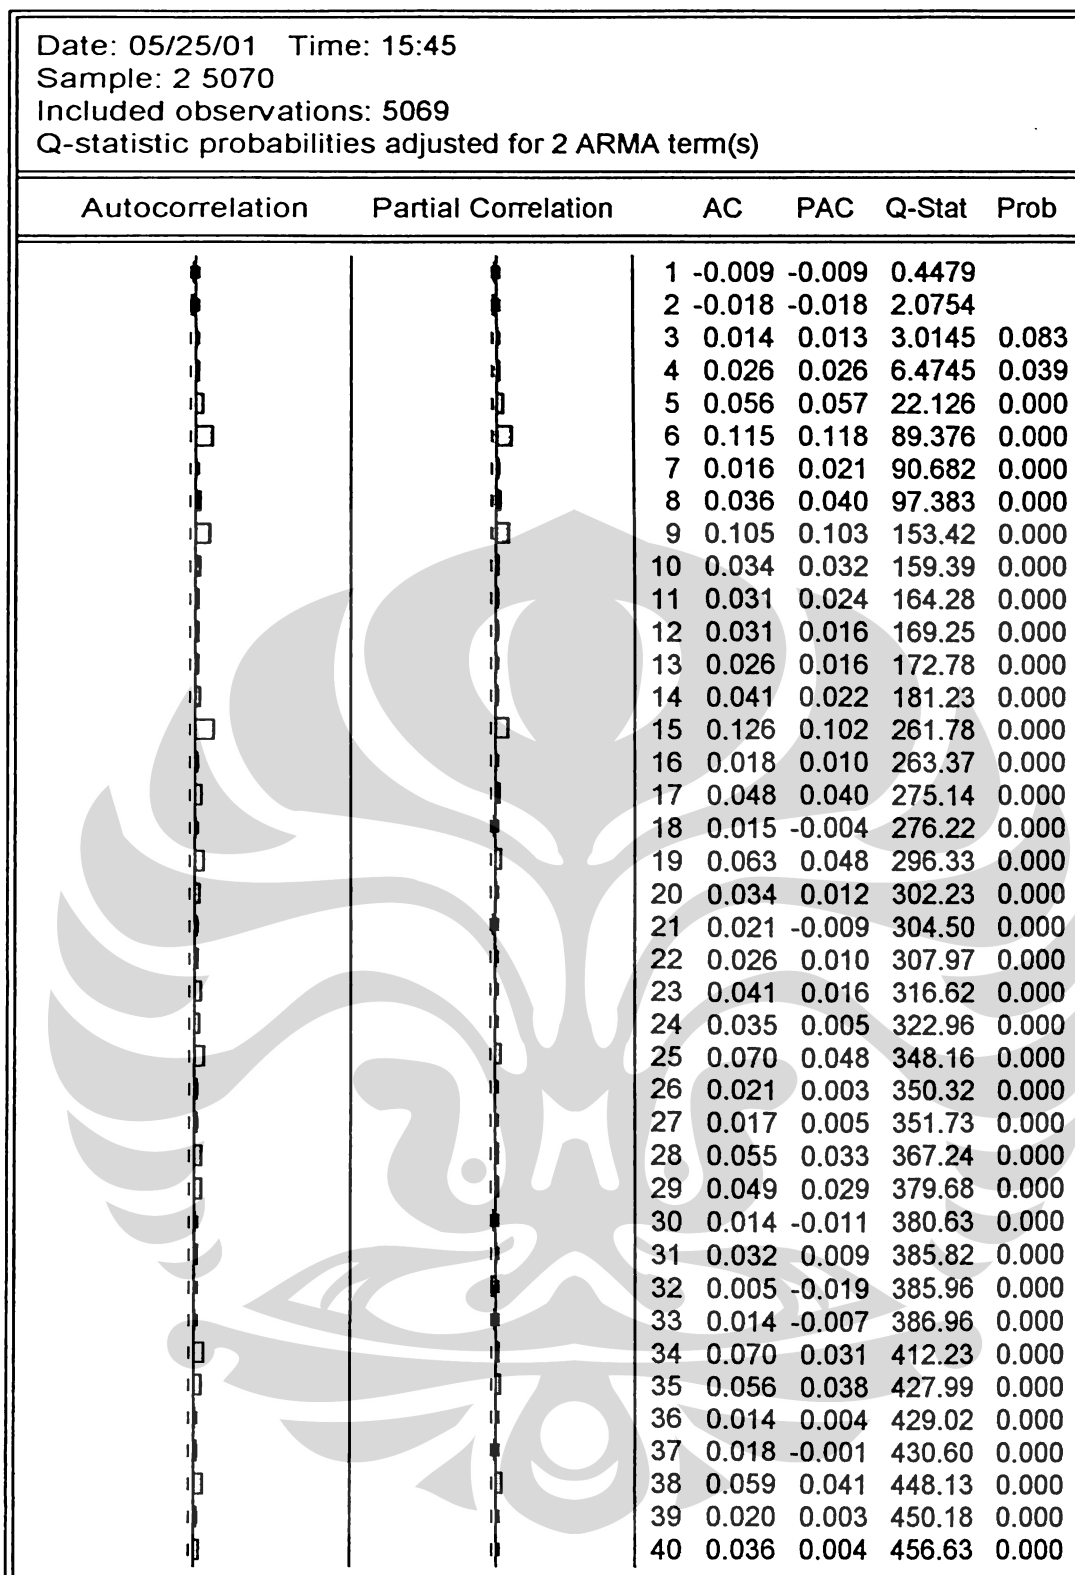
Sample: 2 5070

Included observations: 5069

Q-statistic probabilities adjusted for 2 ARMA term(s)



Gambar L4.8 : Correlogram Residual Kuadrat ARIMA(1,1) DAL



Gambar L4.9 : Correlogram Residual Kuadrat ARCH(2) DAL

LAMPIRAN 5 : R/S ANALYSIS

Tabel L5.1 R/S Analysis dan V Statistic : Residual AR(1) Data Bulanan MAL

log(n)	log(R/S)	log E(R/S)	(R/S)/sq.n	E(R/S)/sq.n
1	0.470364	0.423291	0.934037	0.838091
1.146128	0.550802	0.530541	0.950032	0.906727
1.176091	0.572231	0.551515	0.964241	0.919325
1.322219	0.672311	0.649854	1.026128	0.974416
1.477121	0.782984	0.748325	1.107703	1.022739
1.544068	0.802485	0.789432	1.072633	1.040874
1.623249	0.900187	0.83711	1.226202	1.060439
1.845098	0.987207	0.966284	1.160536	1.105949
2.021189	1.092649	1.065246	1.207966	1.134099

Tabel L5.2 Hasil Regresi : Residual AR(1) Data Bulanan MAL

	$(R/S)_n$ $14 \leq n \leq 42$	$E(R/S)_n$ $14 \leq n \leq 42$	$(R/S)_n$ $42 \leq n \leq 210$
Regression output :			
Constant	-0,2494	-0,2052	0,1155
S.E. of regression	0,0153	0,0029	0,0165
R squared (adjusted)	0,9878	0,9995	0,9706
Number of observations	6	6	3
Hurst exponent	0,6970	0,6440	0,4798
S.E. of coefficient	0,0483	0,0091	0,1076
Significance	0,77	-	-

Tabel L5.3 R/S Analysis dan V Statistic : Residual AR(1) Data Mingguan WAL

log(n)	log(R/S)	log E(R/S)	(R/S)/sq.n	E(R/S)/sq.n
1	0.465326	0.423291	0.923265	0.838091
1.30103	0.684529	0.63596	1.081469	0.967041
1.39794	0.740673	0.69863	1.100786	0.999217
1.60206	0.846835	0.824444	1.111233	1.055393
1.69897	0.900815	0.881867	1.125459	1.077413
2	1.106891	1.053473	1.279059	1.131028
2.09691	1.109725	1.107048	1.151516	1.14444
2.30103	1.334209	1.217945	1.52649	1.167966
2.39794	1.352244	1.269835	1.423226	1.177241
2.69897	1.502213	1.428665	1.421439	1.199996

Tabel L5.4 Hasil Regresi : Residual AR(1) Data Mingguan WAL

	$(R/S)_n$ $10 \leq n \leq 200$	$E(R/S)_n$ $10 \leq n \leq 200$	$(R/S)_n$ $200 \leq n \leq 1000$
Regression output :			
Constant	-0,1525	-0,1562	0,3106
S.E. of regression	0,0308	0,0148	0,0179
R squared (adjusted)	0,9877	0,9969	0,9623
Number of observations	8	8	3
Hurst exponent	0,6276	0,6040	0,4403
S.E. of coefficient	0,0457	0,0220	0,1509
Significance	0,75	-	-

Tabel L5.5 R/S Analysis dan V Statistic : Residual AR(1) Data Harian DAL

log(n)	log(R/S)	log E(R/S)	(R/S)/sqr.n	E(R/S)/sqr.n
1	0.482649	0.423291	0.960834	0.838091
1.041393	0.508866	0.454592	0.973127	0.858807
1.30103	0.681616	0.63596	1.07424	0.967041
1.342423	0.696375	0.662998	1.059652	0.981267
1.361728	0.713332	0.675468	1.077626	0.987652
1.643453	0.884575	0.849128	1.155711	1.065127
1.662758	0.899747	0.860558	1.170492	1.069497
1.740363	0.957225	0.906024	1.221923	1.086032
1.963788	1.108656	1.033274	1.338942	1.125589
2.041393	1.155321	1.076439	1.363403	1.136954
2.060698	1.157159	1.087107	1.339092	1.139615
2.342423	1.325009	1.240162	1.424945	1.172061
2.361728	1.319228	1.250496	1.375195	1.173902
2.403121	1.364026	1.272597	1.453671	1.177706
2.662758	1.526417	1.409718	1.566888	1.197675
2.704151	1.557917	1.431372	1.606357	1.20032
3.005181	1.763911	1.587553	1.825242	1.216083
3.102091	1.815702	1.63743	1.839319	1.220069
3.403121	1.95089	1.791432	1.775537	1.229905

Tabel L5.6 Hasil Regresi : Residual AR(1) Data Harian DAL

	(R/S) _n 10 ≤ n ≤ 1012	E(R/S) _n 10 ≤ n ≤ 1012	(R/S) _n 1012 ≤ n ≤ 5060
Regression output :			
Constant	-0,1457	-0,1164	0,3696
S.E. of regression	0,0101	0,0186	0,0049
R squared (adjusted)	0,9993	0,9971	0,9974
Number of observations	17	17	3
Hurst exponent	0,6305	0,5771	0,4649
S.E. of coefficient	0,0084	0,0155	0,0530
Significance	3,80	-	-

LAMPIRAN 6 : ESTIMASI CORRELATION DIMENSION

Tabel L6.1 Log C(m,ε) vs log ε . MA1, No Lag, No Filter

m5	m6	m7	m8	m9	m10	log e
-1.540740	-1.656923	-1.744791	-1.795208	-1.807228	-1.973476	-0.958607
-1.055372	-1.140761	-1.201099	-1.239308	-1.246739	-1.321478	-0.657577
-0.718689	-0.813981	-0.878056	-0.923635	-0.943553	-1.034534	-0.481486
-0.447098	-0.549730	-0.625615	-0.668211	-0.689564	-0.773605	-0.356547
-0.276518	-0.330172	-0.387491	-0.468804	-0.515001	-0.580364	-0.259637
-0.198684	-0.236526	-0.271326	-0.299571	-0.331060	-0.379956	-0.180456
-0.140710	-0.181130	-0.211458	-0.230345	-0.248077	-0.277660	-0.113509
-0.092375	-0.128427	-0.160083	-0.180100	-0.195037	-0.223615	-0.055517
-0.050758	-0.079096	-0.107969	-0.134026	-0.150695	-0.178592	-0.004365
-0.021543	-0.042857	-0.068568	-0.090771	-0.112190	-0.136433	0.041393
-0.006121	-0.018212	-0.037634	-0.059290	-0.076504	-0.096643	0.082785
-0.000952	-0.004476	-0.011593	-0.032679	-0.052809	-0.065692	0.120574
-0.000116	-0.000972	-0.003400	-0.013285	-0.032927	-0.042852	0.155336
0.000000	-4.74E-05	-0.000427	-0.003728	-0.013686	-0.019355	0.187521

Tabel L6.2 Local Slopes vs log ε , MA1, No Lag, No Filter

m5	m6	m7	m8	m9	m10	log e
1.612359	1.714654	1.806105	1.846660	1.861903	2.165892	-0.958607
1.911981	1.855746	1.834520	1.792666	1.721757	1.629516	-0.657577
2.173793	2.115040	2.020519	2.044392	2.032906	2.088455	-0.481486
1.760182	2.265589	2.457162	2.057655	1.801292	1.994026	-0.356547
0.982991	1.182673	1.467082	2.137282	2.323036	2.531001	-0.259637
0.865966	0.827470	0.894263	1.034051	1.239530	1.528021	-0.180456
0.833479	0.908803	0.885902	0.866409	0.914623	0.931933	-0.113509
0.813586	0.964382	1.018797	0.900707	0.866860	0.880175	-0.055517
0.638477	0.791989	0.861067	0.945311	0.841495	0.921353	-0.004365
0.372586	0.595393	0.747348	0.760559	0.862132	0.961285	0.041393
0.136780	0.363491	0.689102	0.704192	0.627039	0.819065	0.082785
0.024054	0.100789	0.235691	0.557915	0.571947	0.657039	0.120574
0.003604	0.028735	0.092396	0.296951	0.597845	0.730076	0.155336

Tabel L6.3 Local Slopes vs log ε , MA1, Lag = 50, Filter = 1 %

m5	m6	m7	m8	m9	m10	log e
3.330247	4.088801	4.810043	4.697799	4.158460	5.655309	-0.638272
2.888987	3.071945	2.966670	3.407538	3.536324	4.351161	-0.468521
2.813454	3.366967	3.605752	2.628842	2.185991	2.619477	-0.346787
1.553279	2.065716	2.536777	3.574660	3.316370	3.608677	-0.251812
1.466172	1.408718	1.477762	1.653007	2.044179	2.629407	-0.173925
1.352264	1.595047	1.623394	1.499628	1.492586	1.520008	-0.107905
1.233844	1.568556	1.685197	1.531031	1.396017	1.553728	-0.050610
0.837568	1.139503	1.302989	1.514280	1.345286	1.530160	0.000000
0.348303	0.786189	1.147925	1.172557	1.312200	1.552802	0.045323
0.033339	0.340790	0.906692	1.057075	0.929704	1.276458	0.086360
0.001204	0.014883	0.105798	0.628369	0.827470	1.004599	0.123852
0.000000	0.000000	0.000000	0.249631	0.741945	1.044533	0.158362
0.000000	0.000000	0.000000	0.006986	0.250853	0.408719	0.190332

Tabel L6.4 Local Slopes vs $\log \varepsilon$, MA1, Lag = 50, Filter = 5 %

m5	m6	m7	m8	m9	m10	log e
3.293949	3.943607	4.697341	4.758182	4.075931	5.689135	-0.638272
2.927954	2.905824	3.060725	3.253260	3.374324	4.024325	-0.468521
2.567517	3.324278	3.628569	2.872020	2.130001	2.520928	-0.346787
1.484738	1.910556	2.168180	3.094502	3.525532	3.790752	-0.251812
1.411444	1.406634	1.434141	1.553622	1.596787	2.212735	-0.173925
1.421283	1.559898	1.641336	1.520186	1.489805	1.451669	-0.107905
1.189672	1.559719	1.699733	1.538558	1.378928	1.551738	-0.050610
0.786258	1.060121	1.285223	1.535196	1.354238	1.513864	0.000000
0.364310	0.786849	1.134514	1.116611	1.287699	1.561914	0.045323
0.007771	0.342869	0.836160	1.060656	0.938385	1.276472	0.086360
0.001204	0.004959	0.108299	0.565864	0.811846	0.987863	0.123852
0.000000	0.000000	0.000000	0.240235	0.691140	0.972689	0.158362
0.000000	0.000000	0.000000	0.000000	0.238745	0.409679	0.190332

Tabel L6.5 Local Slopes vs $\log \varepsilon$, MA1, Lag = 50, Filter = 10 %

m5	m6	m7	m8	m9	m10	log e
3.206171	4.169899	4.676202	5.022115	4.295327	5.412013	-0.638272
2.929275	2.885535	2.599632	2.594509	2.934982	3.578312	-0.468521
2.154691	3.048234	3.792110	3.350983	2.033499	2.458499	-0.346787
1.368254	1.517600	1.797953	2.347099	3.421222	3.962490	-0.251812
1.416247	1.445546	1.303911	1.396584	1.403238	1.669255	-0.173925
1.354087	1.548304	1.563497	1.456978	1.409688	1.314007	-0.107905
1.182318	1.587385	1.756393	1.569460	1.320541	1.490266	-0.050610
0.791027	0.967489	1.220888	1.561891	1.378186	1.513755	0.000000
0.180876	0.753961	1.114537	1.014411	1.206828	1.519451	0.045323
0.060071	0.271267	0.811754	1.070554	0.890876	1.164325	0.086360
0.000000	0.000000	0.002479	0.494199	0.885441	0.998372	0.123852
0.000000	0.000000	0.000000	0.171538	0.512791	0.934782	0.158362
0.000000	0.000000	0.000000	0.000000	0.232003	0.320691	0.190332

Tabel L6.6 Local Slopes vs $\log \varepsilon$, MA1, Lag = 25, Filter = 5 %

m5	m6	m7	m8	m9	m10	log e
3.408916	4.246287	5.088511	4.964081	4.154623	6.538250	-0.638272
3.417331	3.357122	3.295133	3.256862	3.191730	3.885652	-0.468521
2.263474	3.423175	4.054137	3.401387	2.376179	2.784495	-0.346787
1.253634	1.601788	1.815813	2.708791	3.591147	4.117319	-0.251812
1.137919	1.120915	1.193729	1.387817	1.452087	1.871426	-0.173925
1.118137	1.218797	1.265123	1.207339	1.257367	1.268062	-0.107905
0.937371	1.212871	1.355822	1.235744	1.115443	1.229475	-0.050610
0.677728	0.842247	0.994224	1.189252	1.120785	1.198700	0.000000
0.380252	0.695415	0.904073	0.873853	1.016667	1.247444	0.045323
0.088428	0.340958	0.702205	0.854122	0.737354	0.969869	0.086360
0.024560	0.091149	0.200435	0.516384	0.677801	0.790645	0.123852
0.003784	0.030058	0.085592	0.303255	0.610111	0.808941	0.158362
0.000000	0.002081	0.017687	0.068324	0.268477	0.405330	0.190332

Tabel L6.7 Local Slopes vs $\log \varepsilon$, MA1, Lag = 64, Filter = 5 %

m5	m6	m7	m8	m9	m10	log e
3.293949	3.943607	4.697341	4.758182	4.075931	5.689135	-0.638272
2.604196	2.838001	3.060725	3.253260	3.374324	4.024325	-0.468521
1.921379	2.506342	2.998446	2.553772	2.095542	2.511371	-0.346787
1.568347	1.593966	1.488153	2.232686	2.561007	2.988880	-0.251812
1.552000	1.647323	1.541685	1.390572	1.284721	1.596001	-0.173925
1.361319	1.689714	1.922607	1.771386	1.579350	1.402579	-0.107905
1.134465	1.480906	1.746111	1.738860	1.585812	1.799469	-0.050610
0.800813	1.014206	1.169228	1.441966	1.377322	1.748421	0.000000
0.415970	0.828763	1.108806	1.003112	1.187254	1.476459	0.045323
0.006804	0.392513	0.925540	1.078973	0.855840	1.162011	0.086360
0.000000	0.003049	0.119458	0.623196	0.793853	0.935900	0.123852
0.000000	0.000000	0.000000	0.280474	0.778557	1.053025	0.158362
0.000000	0.000000	0.000000	0.000000	0.286600	0.484418	0.190332

Tabel L6.8 Log C(m,e) vs $\log \varepsilon$ WA1, No Lag, No Filter

m5	m6	m7	m8	m9	m10	log e
-1.448318	-1.546624	-1.604519	-1.675902	-1.736344	-1.812416	-0.920819
-1.014707	-1.096078	-1.146809	-1.202104	-1.235439	-1.265890	-0.619789
-0.671099	-0.764038	-0.829289	-0.900543	-0.947117	-0.995435	-0.443697
-0.369723	-0.453262	-0.546238	-0.623587	-0.683989	-0.734789	-0.318759
-0.243592	-0.283923	-0.326499	-0.372903	-0.423581	-0.488827	-0.221849
-0.176694	-0.208705	-0.242240	-0.266276	-0.291969	-0.321546	-0.142668
-0.114802	-0.151426	-0.183600	-0.208410	-0.228200	-0.246670	-0.075721
-0.058234	-0.094202	-0.125463	-0.153804	-0.176768	-0.198696	-0.017729
-0.019550	-0.045386	-0.075043	-0.100775	-0.124564	-0.148794	0.033424
-0.004872	-0.015940	-0.036593	-0.058825	-0.081011	-0.102809	0.079181
-0.000949	-0.004346	-0.008870	-0.021717	-0.044688	-0.064309	0.120574
-6.55E-05	-0.000773	-0.002436	-0.005932	-0.014995	-0.030030	0.158362
0.000000	-0.000103	-0.000202	-0.001013	-0.004949	-0.009855	0.193125
0.000000	-2.61E-06	-1.82E-05	-7.46E-05	-0.000854	-0.002400	0.225309

Tabel L6.9 Local Slopes vs $\log \varepsilon$, WA1, No Lag, No Filter

m5	m6	m7	m8	m9	m10	log e
1.440425	1.496680	1.520478	1.573922	1.663970	1.815521	-0.920819
1.951306	1.885612	1.803156	1.712529	1.637342	1.535879	-0.619789
2.412196	2.487429	2.265520	2.216735	2.106058	2.086191	-0.443697
1.301520	1.747383	2.267458	2.586774	2.687107	2.538048	-0.318759
0.844875	0.949948	1.064121	1.346609	1.662173	2.112637	-0.221849
0.924502	0.855586	0.875916	0.864371	0.952527	1.118428	-0.142668
0.975433	0.986771	1.002503	0.941598	0.886882	0.872258	-0.075721
0.756247	0.954312	0.985683	1.036697	1.020562	0.975550	-0.017729
0.320794	0.643518	0.840296	0.916796	0.951811	1.004980	0.033424
0.094766	0.280110	0.669764	0.896478	0.877524	0.930125	0.079181
0.023379	0.094542	0.170249	0.417713	0.785762	0.907124	0.120574
0.001884	0.019284	0.064271	0.141500	0.289001	0.580374	0.158362
0.000000	0.003117	0.005720	0.029165	0.127229	0.231621	0.193125

Tabel L6.10 Local Slopes vs $\log \varepsilon$, WA1, Lag = 220, Filter = 1 %

m5	m6	m7	m8	m9	m10	log e
3.846736	4.716359	5.831578	9.037126	13.53487	11.62503	-0.602060
3.614408	3.685823	3.412975	3.732636	4.230921	5.183160	-0.431798
2.323344	3.053268	3.719927	4.102089	4.024554	3.784296	-0.309804
1.474309	1.686212	1.800229	2.354450	2.898419	3.615636	-0.214670
1.600568	1.522440	1.640376	1.588299	1.730259	1.986590	-0.136677
1.596455	1.747868	1.820434	1.753338	1.619346	1.533484	-0.070581
1.119900	1.481587	1.613428	1.727842	1.783137	1.757900	-0.013228
0.279533	0.850185	1.273315	1.535732	1.614606	1.711955	0.037426
0.014026	0.242365	0.904777	1.374559	1.431331	1.553914	0.082785
0.000000	0.044053	0.040462	0.413381	1.092434	1.456987	0.123852
0.000000	0.000000	0.000350	0.018171	0.231198	0.725130	0.161368
0.000000	0.000000	0.000000	0.000000	0.035338	0.101225	0.195900
0.000000	0.000000	0.000000	0.000000	0.000000	0.000247	0.227887

Tabel L6.11 Local Slopes vs $\log \varepsilon$, WA1, Lag = 220, Filter = 5 %

m5	m6	m7	m8	m9	m10	log e
3.611062	4.400072	5.368596	8.553770	14.81457	12.00252	-0.585027
3.394882	3.685761	3.327387	3.473139	3.610183	4.430526	-0.420216
2.074046	2.646129	3.354165	3.900485	4.059920	4.008697	-0.301030
1.418224	1.510290	1.519786	1.938485	2.432218	2.987157	-0.207608
1.616983	1.521808	1.685764	1.553125	1.573543	1.712886	-0.130768
1.517350	1.758211	1.846077	1.830435	1.642353	1.502930	-0.065502
0.965367	1.392685	1.538107	1.680288	1.743818	1.784916	-0.008774
0.220567	0.682674	1.241129	1.484644	1.589871	1.666026	0.041393
0.006554	0.227367	0.699960	1.267170	1.451084	1.537492	0.086360
0.000000	0.010456	0.009866	0.256351	0.848597	1.332855	0.127105
0.000000	0.000000	0.000000	0.002856	0.177282	0.582849	0.164353
0.000000	0.000000	0.000000	0.000000	0.006583	0.039426	0.198657
0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.230449

Tabel L6.12 Local Slopes vs $\log \varepsilon$, WA1, Lag = 220, Filter = 10 %

m5	m6	m7	m8	m9	m10	log e
3.699045	4.037341	4.814387	8.375812	12.43923	11.99326	-0.585027
3.035380	3.587259	3.638658	3.729608	3.374096	3.653642	-0.420216
1.589603	2.038340	2.468729	3.045269	3.773320	3.988062	-0.301030
1.507500	1.434455	1.271265	1.499961	1.811906	2.246272	-0.207608
1.596956	1.673438	1.674222	1.494401	1.403373	1.296532	-0.130768
1.547265	1.721123	1.888210	1.880289	1.719670	1.607950	-0.065502
0.558080	1.154675	1.407208	1.628755	1.733954	1.815985	-0.008774
0.072444	0.407211	1.243802	1.488097	1.450935	1.641818	0.041393
0.000000	0.091152	0.149936	0.777833	1.415071	1.524324	0.086360
0.000000	0.000000	0.000519	0.054707	0.406452	0.964401	0.127105
0.000000	0.000000	0.000000	0.000000	0.040279	0.220622	0.164353
0.000000	0.000000	0.000000	0.000000	0.000000	0.000616	0.198657
0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.230449

Tabel L6.13 Local Slopes vs $\log \varepsilon$, WA1, Lag = 100, Filter = 5 %

m5	m6	m7	m8	m9	m10	log e
4.277545	5.012335	6.141352	9.021250	10.73103	14.70225	-0.602060
3.917851	4.518481	4.229009	4.306291	4.290909	4.975830	-0.431798
1.712930	2.257823	3.186843	4.103392	4.700213	4.835385	-0.309804
1.105464	1.204450	1.298765	1.697538	2.122040	2.679616	-0.214670
1.219447	1.155291	1.237646	1.188552	1.248445	1.426925	-0.136677
1.166150	1.289024	1.368659	1.340413	1.225824	1.154499	-0.070581
0.825384	1.101659	1.169543	1.274666	1.319215	1.315527	-0.013228
0.295255	0.657496	0.974923	1.110856	1.187127	1.271019	0.037426
0.076360	0.276250	0.673731	1.045004	1.090445	1.126713	0.082785
0.021142	0.077420	0.135281	0.338256	0.782110	1.076481	0.123852
0.001523	0.017703	0.059683	0.130443	0.280177	0.545079	0.161368
0.000000	0.002532	0.004564	0.024902	0.096966	0.183345	0.195900
0.000000	5.66E-05	0.000000	0.001652	0.020745	0.066096	0.227887

Tabel L6.14 Local Slopes vs $\log \varepsilon$, WA1, Lag = 280, Filter = 5 %

m5	m6	m7	m8	m9	m10	log e
3.550112	4.400072	5.368596	2.874808	14.81457	12.00252	-0.585027
2.813861	3.283992	3.154558	2.530166	3.609544	4.430526	-0.420216
1.703716	1.894292	2.477679	2.964581	3.519010	3.698344	-0.301030
1.655890	1.676253	1.327233	3.262418	1.553804	2.020924	-0.207608
1.678171	1.749698	1.985282	1.633699	1.616904	1.414637	-0.130768
1.470741	1.723230	2.033049	1.020082	2.020687	1.826851	-0.065502
0.988648	1.363477	1.422560	1.088475	1.893543	2.099904	-0.008774
0.239397	0.708775	1.203237	1.179298	1.436170	1.639316	0.041393
0.007065	0.246883	0.778520	1.029582	1.409078	1.397187	0.086360
0.000000	0.012033	0.005209	0.996230	0.905420	1.352410	0.127105
0.000000	0.000000	0.000000	0.460141	0.201805	0.647587	0.164353
0.000000	0.000000	0.000000	0.154720	0.008135	0.047338	0.198657
0.000000	0.000000	0.000000	0.031687	0.000000	0.000000	0.230449

Tabel L6.15 Log C(m,e) vs $\log \varepsilon$, DA1, No Lag, No Filter

m5	m6	m7	m8	m9	m10	log e
-1.431706	-1.528954	-1.589781	-1.647224	-1.708733	-1.772246	-0.920819
-1.008332	-1.091630	-1.141380	-1.190743	-1.226185	-1.255929	-0.619789
-0.668051	-0.763017	-0.832649	-0.895182	-0.946398	-0.990657	-0.443697
-0.368869	-0.452225	-0.543609	-0.621238	-0.683309	-0.731289	-0.318759
-0.242103	-0.283792	-0.325332	-0.371510	-0.421869	-0.487878	-0.221849
-0.174422	-0.207527	-0.239835	-0.264776	-0.291482	-0.320384	-0.142668
-0.112656	-0.150137	-0.180661	-0.206030	-0.226986	-0.244904	-0.075721
-0.056200	-0.092215	-0.122705	-0.151352	-0.174673	-0.196335	-0.017729
-0.018042	-0.043163	-0.071938	-0.098717	-0.122705	-0.146125	0.033424
-0.004212	-0.014238	-0.033961	-0.057205	-0.079665	-0.100774	0.079181
-0.000602	-0.003278	-0.007965	-0.020184	-0.042164	-0.062571	0.120574
0.000169	-0.000415	-0.001636	-0.005116	-0.013581	-0.028135	0.158362
0.000213	0.000156	9.04E-05	-0.000637	-0.003716	-0.008830	0.193125

Tabel L6.16 Local Slopes vs log ε , DA1, No Lag, No Filter

m5	m6	m7	m8	m9	m10	log e
1.406420	1.452759	1.489556	1.516396	1.602992	1.715168	-0.920819
1.932409	1.866152	1.753244	1.678452	1.588871	1.506449	-0.619789
2.394634	2.487555	2.313450	2.192628	2.105749	2.075954	-0.443697
1.308081	1.738028	2.252375	2.576909	2.697757	2.511730	-0.318759
0.854756	0.963182	1.079757	1.347962	1.646690	2.115314	-0.221849
0.922617	0.857234	0.883894	0.877514	0.963392	1.127465	-0.142668
0.973514	0.998795	0.999379	0.942847	0.902068	0.837511	-0.075721
0.745971	0.958952	0.992481	1.028995	1.015955	0.981584	-0.017729
0.302242	0.632123	0.829953	0.907213	0.940608	0.991123	0.033424
0.087207	0.264777	0.628040	0.894378	0.905977	0.922927	0.079181
0.020396	0.075768	0.167478	0.398746	0.756394	0.911285	0.120574
0.001283	0.016421	0.049662	0.128846	0.283772	0.555356	0.158362
0.000000	0.001786	0.003298	0.025128	0.102202	0.214159	0.193125

Tabel L6.17 Local Slopes vs log ε , DA1, Lag = 1300, Filter = 1 %

m5	m6	m7	m8	m9	m10	log e
3.854995	4.971116	6.440233	9.039469	18.05776	11.72905	-0.602060
3.272664	3.552511	3.563993	3.747969	4.434286	5.199310	-0.431798
2.044629	2.537316	3.174747	3.718048	3.887471	3.699319	-0.309804
1.615567	1.731431	1.582071	1.843344	2.277778	3.053360	-0.214670
1.628394	1.689499	1.842106	1.719551	1.680531	1.616740	-0.136677
1.568960	1.727455	1.907634	1.976891	1.872714	1.743189	-0.070581
1.161271	1.502353	1.564506	1.673190	1.876378	1.960107	-0.013228
0.259887	0.881309	1.277380	1.444820	1.481296	1.673883	0.037426
0.010667	0.233454	0.893769	1.447022	1.471723	1.419336	0.082785
0.000000	0.021054	0.040388	0.424616	1.127061	1.532289	0.123852
0.000000	0.000000	0.000000	0.007050	0.250036	0.754654	0.161368
0.000000	0.000000	0.000000	0.000000	0.007364	0.088320	0.195900
0.000000	0.000000	0.000000	0.000000	0.000000	6.83E-05	0.227887

Tabel L6.18 Local Slopes vs log ε , DA1, Lag = 1300, Filter = 5 %

m5	m6	m7	m8	m9	m10	log e
3.633786	4.889096	6.556886	9.569149	22.31868	13.21451	-0.602060
3.080377	3.502179	3.403428	3.506350	3.875695	4.639058	-0.431798
1.923427	2.226696	2.866897	3.464354	3.765213	3.735466	-0.309804
1.582204	1.679465	1.502139	1.658426	1.944925	2.525321	-0.214670
1.624050	1.677296	1.867051	1.717831	1.650313	1.567586	-0.136677
1.526661	1.729574	1.889081	2.002273	1.886228	1.714382	-0.070581
1.055358	1.437013	1.495560	1.621588	1.848882	1.968680	-0.013228
0.205947	0.779262	1.289954	1.402122	1.439900	1.600883	0.037426
0.005400	0.196926	0.728517	1.380478	1.515895	1.419242	0.082785
0.000000	0.006699	0.009473	0.293887	0.948202	1.463319	0.123852
0.000000	0.000000	0.000000	0.002387	0.165017	0.629424	0.161368
0.000000	0.000000	0.000000	0.000000	0.000784	0.036142	0.195900
0.000000	0.000000	0.000000	0.000000	0.000000	7.59E-06	0.227887

Tabel L6.19 Local Slopes vs $\log \varepsilon$, DA1, Lag = 1300, Filter = 10 %

m5	m6	m7	m8	m9	m10	log e
3.604926	4.372307	5.790727	8.970304	15.90895	12.34317	-0.602060
2.617114	3.263501	3.457742	3.614959	3.539371	3.785807	-0.431798
1.608696	1.775017	1.996356	2.519903	3.258354	3.579373	-0.309804
1.673391	1.615695	1.442757	1.393684	1.496514	1.720793	-0.214670
1.525430	1.721484	1.865279	1.765864	1.609683	1.446928	-0.136677
1.555904	1.723720	1.839822	1.974879	1.943515	1.859311	-0.070581
0.637288	1.193741	1.366542	1.492174	1.680712	1.896720	-0.013228
0.061741	0.457066	1.290161	1.522755	1.370777	1.495042	0.037426
0.000000	0.057670	0.160271	0.834847	1.557134	1.518789	0.082785
0.000000	0.000000	0.000000	0.040965	0.397245	1.048291	0.123852
0.000000	0.000000	0.000000	0.000000	0.018971	0.209637	0.161368
0.000000	0.000000	0.000000	0.000000	0.000000	0.000230	0.195900
0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.227887

Tabel L6.20 Local Slopes vs $\log \varepsilon$, DA1, Lag = 300, Filter = 5 %

m5	m6	m7	m8	m9	m10	log e
3.250873	3.040628	2.704680	2.610474	2.551536	2.697424	-0.920819
4.009464	4.416081	4.705335	4.749285	4.606050	4.399407	-0.619789
3.541795	4.182231	4.145220	4.235745	4.404781	4.646777	-0.443697
1.542588	2.023937	2.918584	3.689783	4.228330	4.346481	-0.318759
0.983033	1.085410	1.209375	1.542305	1.890170	2.455251	-0.221849
1.096801	1.026372	1.076109	1.038738	1.112953	1.281351	-0.142668
1.104120	1.192592	1.192506	1.162889	1.071491	1.003033	-0.075721
0.803148	1.039614	1.097003	1.154450	1.195924	1.164659	-0.017729
0.303088	0.679111	0.953643	1.015203	1.072864	1.129883	0.033424
0.092679	0.280094	0.650164	1.020343	1.054009	1.048949	0.079181
0.016104	0.071992	0.169188	0.381672	0.783288	1.031146	0.120574
0.000752	0.014186	0.040617	0.135093	0.286286	0.567712	0.158362
0.000000	0.000875	0.002075	0.021274	0.099177	0.209100	0.193125

Tabel L6.21 Local Slopes vs $\log \varepsilon$, DA1, Lag = 1800, Filter = 5 %

m5	m6	m7	m8	m9	m10	log e
3.311757	4.651293	6.397332	9.313219	22.10801	13.04365	-0.602060
2.252008	2.771887	2.814048	2.971828	3.440264	4.292137	-0.431798
1.856944	1.547231	1.885077	2.472158	2.906551	3.050845	-0.309804
2.197325	2.208021	1.554341	1.207901	1.070983	1.307253	-0.214670
1.901090	2.300981	2.685715	2.470060	2.055917	1.611091	-0.136677
1.412289	1.923414	2.402468	2.723328	2.748338	2.497836	-0.070581
0.665413	1.055238	1.395552	1.863822	2.356182	2.702357	-0.013228
0.098922	0.466796	0.992978	1.227369	1.400568	1.849994	0.037426
0.000000	0.112324	0.309369	0.844237	1.236721	1.296661	0.082785
0.000000	0.000107	0.000000	0.085842	0.445219	0.920475	0.123852
0.000000	0.000000	0.000000	0.000000	0.057752	0.310970	0.161368
0.000000	0.000000	0.000000	0.000000	0.000000	0.000653	0.195900
0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.227887

LAMPIRAN 7 : ESTIMASI MAXIMUM LYAPUNOV EXPONENT

Tabel 7.1 Running Average Lyapunov Exponent Untuk MA1

zlyap	evolusi	zlyap	evolusi	zlyap	evolusi	zlyap	evolusi	zlyap	evolusi
-0.11713	4	4.31E-02	44	3.89E-02	84	6.54E-02	124	6.90E-02	164
-1.91E-02	8	3.96E-02	48	4.87E-02	88	6.42E-02	128	6.03E-02	168
0.100275	12	3.16E-02	52	5.95E-02	92	5.91E-02	132	5.88E-02	172
5.74E-02	16	3.51E-02	56	6.36E-02	96	5.83E-02	136	6.32E-02	176
4.69E-02	20	2.96E-02	60	6.77E-02	100	6.12E-02	140	6.57E-02	180
5.83E-02	24	1.85E-02	64	0.074658	104	6.52E-02	144	6.46E-02	184
6.81E-02	28	9.77E-03	68	7.55E-02	108	6.36E-02	148	6.38E-02	188
4.25E-02	32	2.38E-02	72	7.67E-02	112	6.50E-02	152		
4.98E-02	36	2.26E-02	76	7.27E-02	116	0.063997	156		
6.91E-02	40	2.73E-02	80	6.76E-02	120	6.52E-02	160		

Keterangan : evolusi = parameter EVOLV x ITS dalam program LyapExp, untuk MA1 EVOLV = 4

Tabel 7.2 Running Average Lyapunov Exponent Untuk WA1

zlyap	evolusi	zlyap	evolusi	zlyap	evolusi	zlyap	evolusi
8.75E-03	54	5.57E-03	594				
8.12E-03	108	6.18E-03	648				
2.39E-03	162	6.04E-03	702				
2.10E-04	216	6.00E-03	756				
-5.59E-04	270	5.49E-03	810				
5.84E-04	324						
4.83E-03	378						
7.72E-03	432						
8.31E-03	486						
0.007613	540						

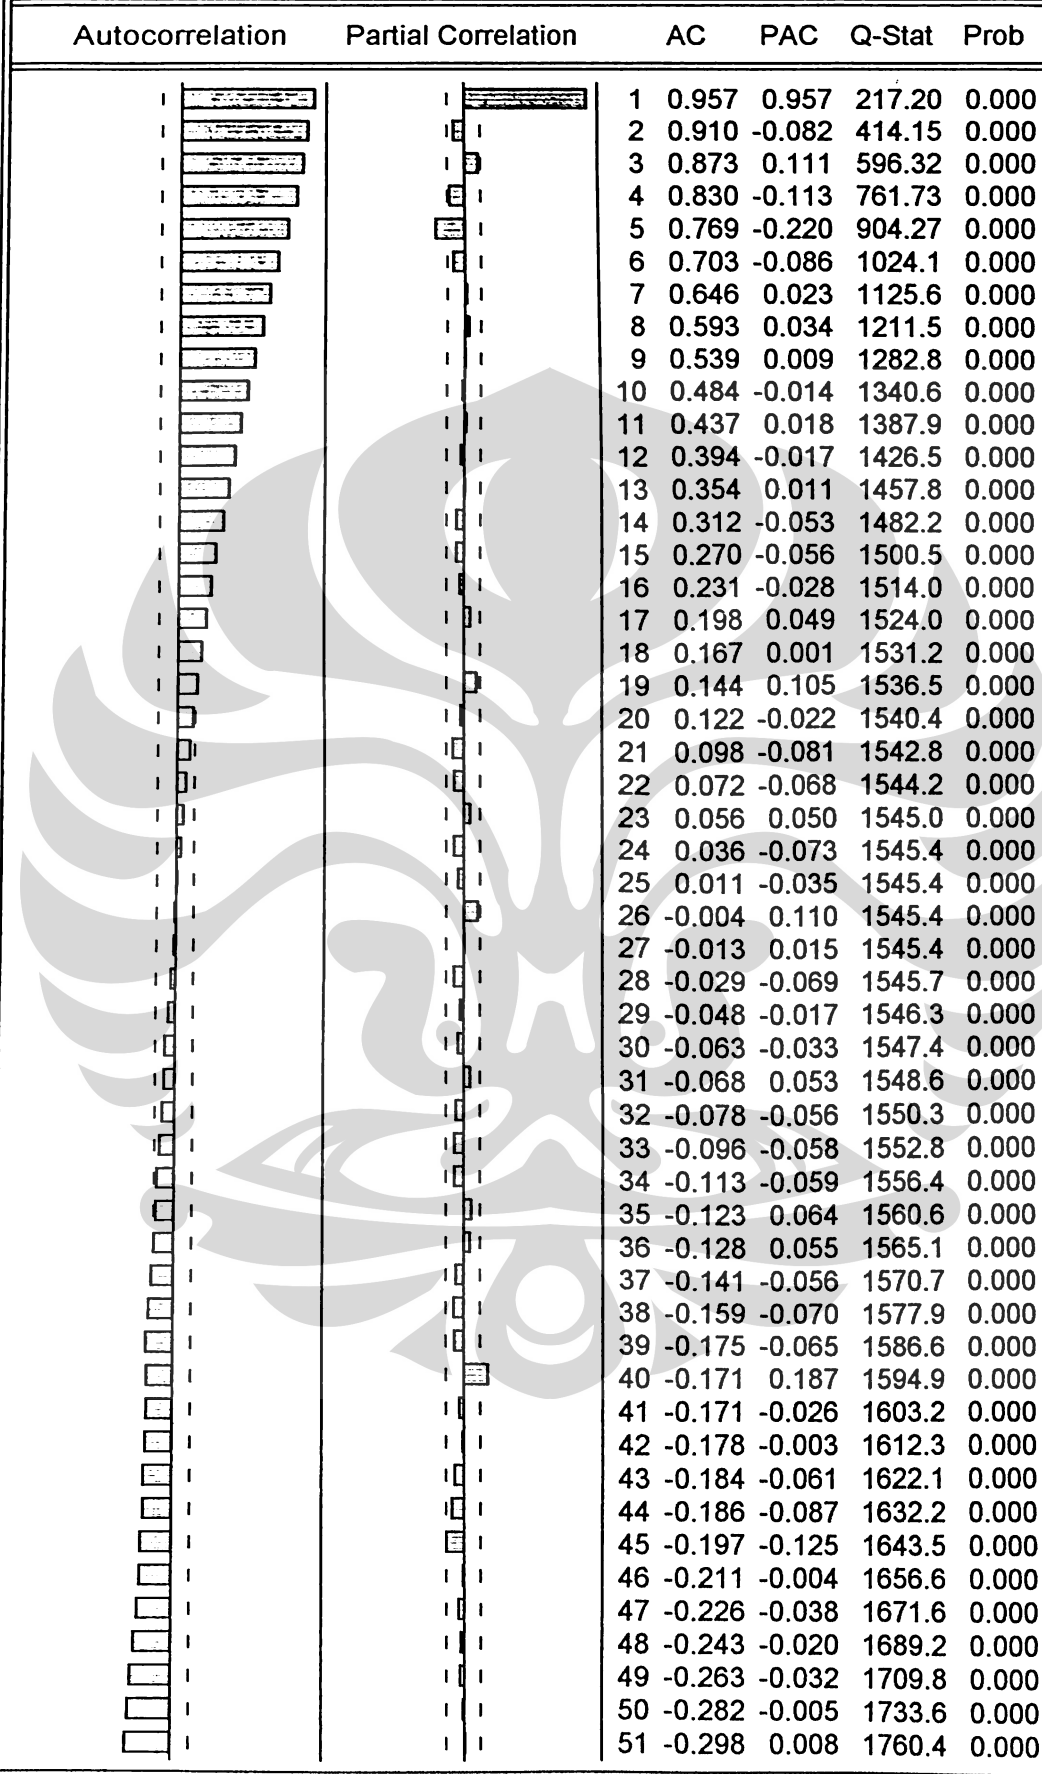
Keterangan : evolusi = parameter EVOLV x ITS dalam program LyapExp, untuk WA1 EVOLV = 54

Tabel 7.3 Running Average Lyapunov Exponent Untuk DA1

zlyap	evolusi	zlyap	evolusi	zlyap	evolusi	zlyap	evolusi
-9.24E-04	158	1.83E-03	1738	3.45E-03	3318		
5.38E-03	316	2.62E-03	1896	3.42E-03	3476		
5.67E-03	474	3.23E-03	2054	3.60E-03	3634		
3.60E-03	632	3.26E-03	2212	3.73E-03	3792		
3.13E-03	790	3.41E-03	2370	3.76E-03	3950		
3.13E-03	948	3.82E-03	2528				
2.44E-03	1106	3.93E-03	2686				
0.001896	1264	3.95E-03	2844				
1.16E-03	1422	0.003551	3002				
1.59E-03	1580	3.67E-03	3160				

Keterangan : evolusi = parameter EVOLV x ITS dalam program LyapExp, untuk DA1 EVOLV = 158

Date: 05/23/01 Time: 18:56
 Sample: 1 234
 Included observations: 234

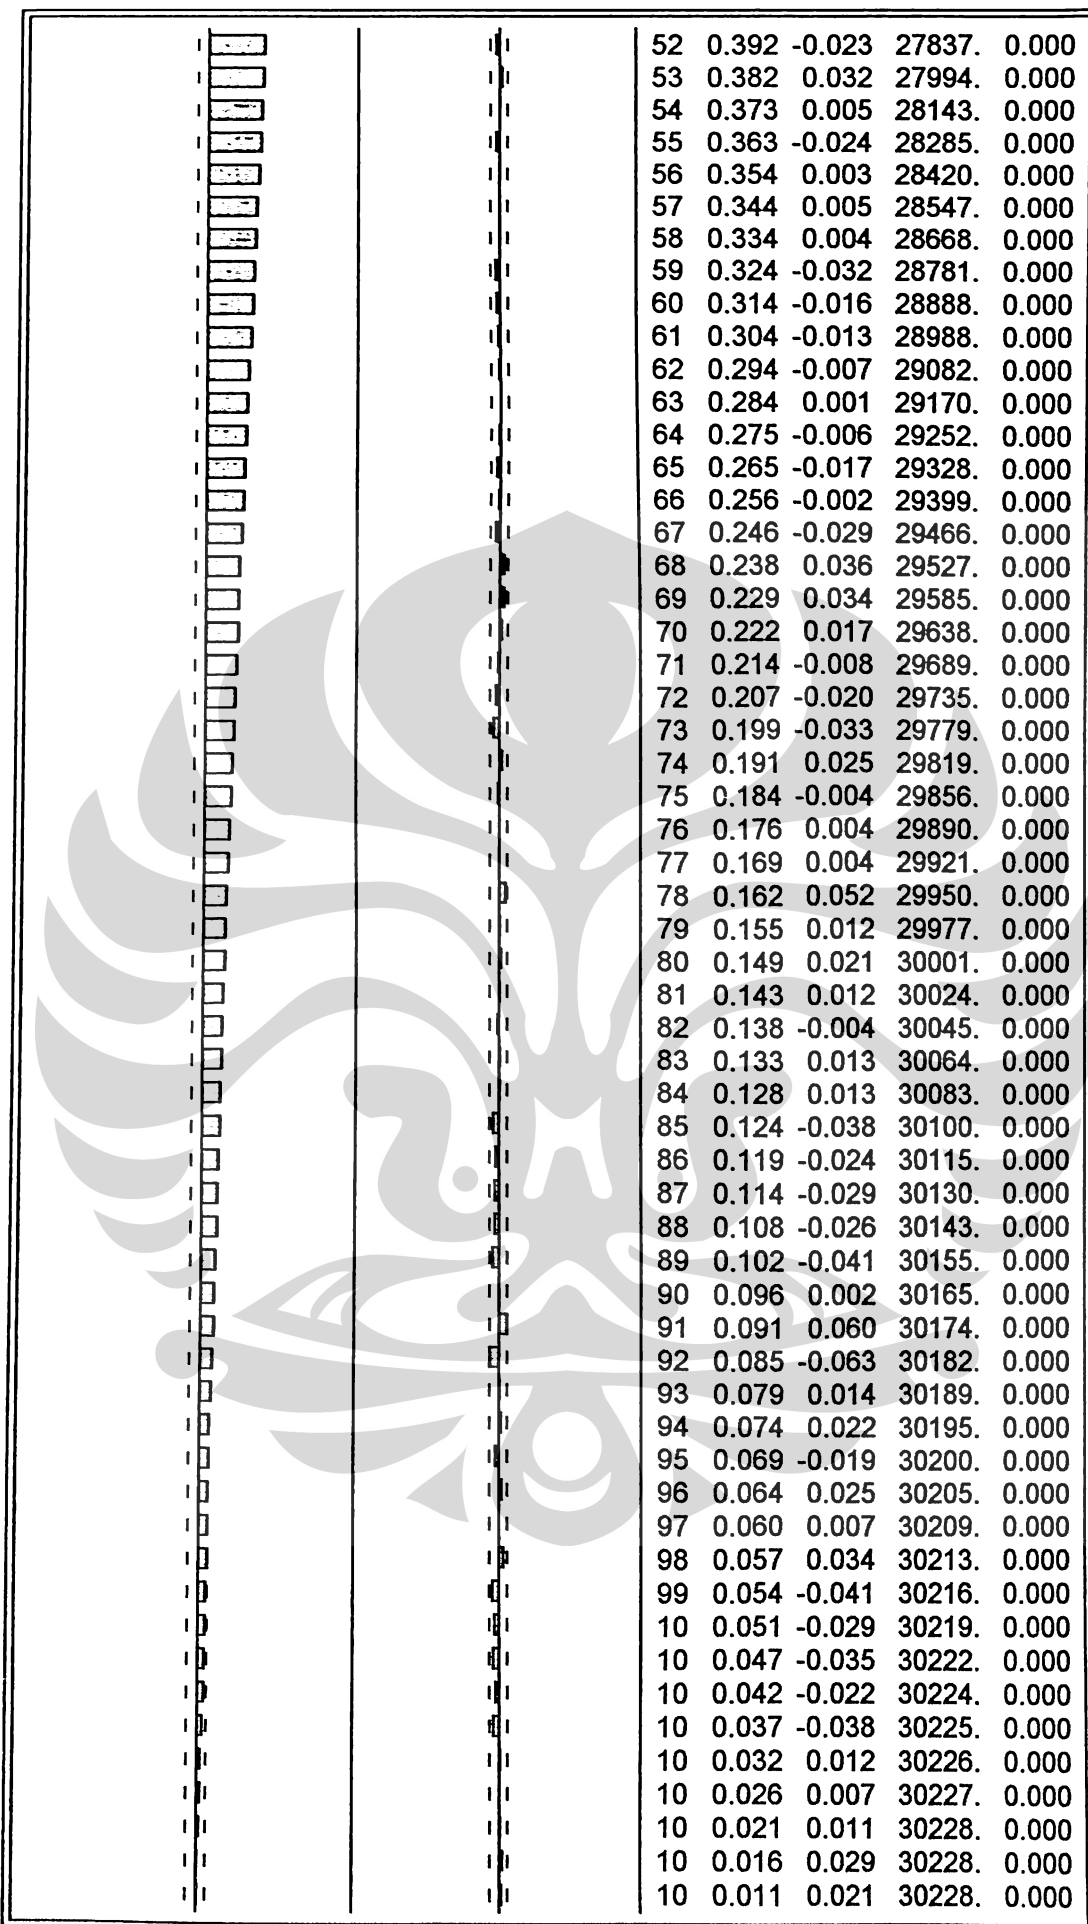


Gambar L6.1 : Correlogram Log-Linear Detrending MA1

Date: 05/25/01 Time: 10:22 Sample: 1 1015 Included observations: 1015						
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.993	0.993	1002.8	0.000
		2	0.983	-0.128	1987.7	0.000
		3	0.973	-0.045	2953.4	0.000
		4	0.962	-0.066	3897.8	0.000
		5	0.950	-0.031	4819.9	0.000
		6	0.938	0.025	5720.6	0.000
		7	0.927	0.014	6600.5	0.000
		8	0.915	-0.058	7458.5	0.000
		9	0.904	0.091	8297.3	0.000
		10	0.895	0.060	9119.4	0.000
		11	0.886	0.040	9926.7	0.000
		12	0.878	-0.005	10720.	0.000
		13	0.870	-0.027	11499.	0.000
		14	0.861	-0.029	12264.	0.000
		15	0.852	-0.064	13014.	0.000
		16	0.842	-0.050	13746.	0.000
		17	0.830	-0.077	14459.	0.000
		18	0.818	-0.058	15152.	0.000
		19	0.804	-0.039	15821.	0.000
		20	0.789	-0.021	16468.	0.000
		21	0.774	-0.011	17091.	0.000
		22	0.759	-0.033	17689.	0.000
		23	0.743	-0.025	18264.	0.000
		24	0.727	-0.004	18815.	0.000
		25	0.712	-0.013	19343.	0.000
		26	0.697	0.024	19851.	0.000
		27	0.684	0.037	20339.	0.000
		28	0.670	-0.021	20809.	0.000
		29	0.657	0.002	21261.	0.000
		30	0.644	-0.013	21696.	0.000
		31	0.632	0.035	22115.	0.000
		32	0.620	0.048	22519.	0.000
		33	0.609	0.007	22909.	0.000
		34	0.598	0.013	23285.	0.000
		35	0.586	-0.023	23647.	0.000
		36	0.574	-0.009	23995.	0.000
		37	0.562	0.019	24329.	0.000
		38	0.550	-0.020	24649.	0.000
		39	0.537	-0.036	24954.	0.000
		40	0.525	0.017	25246.	0.000
		41	0.512	-0.012	25524.	0.000
		42	0.499	-0.003	25788.	0.000
		43	0.487	0.009	26039.	0.000
		44	0.475	-0.014	26279.	0.000
		45	0.463	-0.001	26507.	0.000
		46	0.451	0.009	26724.	0.000
		47	0.441	0.000	26931.	0.000
		48	0.431	0.030	27129.	0.000
		49	0.421	-0.033	27319.	0.000
		50	0.411	-0.020	27500.	0.000
		51	0.402	-0.003	27672.	0.000

Gambar L6.2 : Correlogram Log-Linear Detrending WA1

Correlogram of WA1



LAMPIRAN 8 : PROGRAM KOMPUTER

A. R/Sanalysis : program untuk R/S analysis

```
Dim buff1(6000)
Dim buff2(6000)
Dim buff3(6000)
Dim lbuff, dbuff, ymax, ymin, n, n1
Dim tot, mea, sjum, sjum1, vari, sdev
Dim rs, logrs, logn, range, rkum, versn, rs2n, depar, depar1
Dim rssub, rsrata, vstat, logersn, ersn, ersn1, ersn2, pi
Dim npoint, segm, conti, r As Integer
Dim j, cntx, cnt, cnt1, cnt2, cnt3, cnt4 As Integer

' --- parameter ---
npoint = 210
Open "c:\month\ma1.prn" For Input As 1
Open "c:\month\rsma1.prn" For Output As 2

' jumlah titik file input
' nama file input
' nama file output

' --- baca data input ---
For j = 1 To npoint
    Input #1, buff1(j)
Next j
Close #1

ersn = 0
pi = 3.141592654
For cntx = (npoint \ 2) To 2 Step -1

n = npoint \ cntx
n1 = npoint Mod cntx

If n1 = 0 Then
    segm = n
    conti = cntx

If segm >= 10 Then
    rkum = 0
    For r = 1 To (segm - 1)
        rkum = rkum + Sqr((segm - r) / r)
    Next r
    ersn1 = (segm - 0.5) / segm
    ersn2 = (segm * (pi / 2)) ^ -0.5
    ersn = ersn1 * ersn2 * rkum
    versn = ersn / Sqr(segm)
    logersn = Log(ersn) / Log(10)
    rssub = 0

For cnt = 1 To conti

' --- subperiod mean ---
tot = 0
mea = 0
For cnt1 = ((cnt - 1) * segm) + 1 To (cnt * segm)
    tot = tot + buff1(cnt1)
Next cnt1
mea = tot / segm

' --- subperiod standard deviation ---
sjum = 0
For cnt2 = ((cnt - 1) * segm) + 1 To (cnt * segm)
    sjum1 = (buff1(cnt2) - mea) ^ 2
    sjum = sjum + sjum1
```

```

Next cnt2
vari = sjum / (segm - 1)
sdev = Sqr(vari)

' --- superiod maximum - minimum ---
depar = 0
For cnt3 = ((cnt - 1) * segm) + 1 To (cnt * segm)
  buff2(cnt3) = buff1(cnt3) - mea
  depar = depar + buff2(cnt3)
  buff3(cnt3) = depar
Next cnt3
ymax = buff3((cnt - 1) * segm + 1)
ymin = buff3((cnt - 1) * segm + 1)
For cnt4 = ((cnt - 1) * segm) + 1 To (cnt * segm)
  If (buff3(cnt4) >= ymax) Then ymax = buff3(cnt4)
  If (buff3(cnt4) <= ymin) Then ymin = buff3(cnt4)
  range = ymax - ymin
Next cnt4

' --- subperiod log r/s ---
rs = range / sdev
rsub = rsub + rs

Next cnt

logn = Log(segm) / Log(10)
rsrata = rsub / conti
logrs = Log(rsrata) / Log(10)
rs2n = rsrata / Sqr(segm)
Print #2, logn; logrs; logersn; rs2n; versn

End If
End If

Next cntx
Close #2
End Sub

```

B. CorrDim : menghitung correlation integral

```

Dim buff1(1200)
Dim buff2(1200, 10)
Dim buff5(15, 10)
Dim buff6(15, 10)
Dim dt, r, logr
Dim theta, theta2, cr, logcr, d, slop
Dim i, j, k, l, m, npointfix, npointvar, dimen, dimen1, Q, lag, lag1
Dim x, y, tau

npointfix = 1015
Q = 200
lag = 0
Open "c:\input\ma1.prn" For Input As 1
Open "c:\output\dwa1.prn" For Output As 2
Open "c:\output\swa1.prn" For Output As 3

' jumlah titik file input
' perioda orbit
' temporal correlation minimal lag = 0
' file input
' file output log C(m,r) vs log r
' file output slope vs r

' --- baca data input ---
For i = 1 To npointfix
  Input #1, buff1(i)
Next i

Close #1

For dimen = 2 To 10
  dt = 0.11
  ' = 10% x (datamax - datamin)

```

```

r = 0.23
tau = Q \ dimen
theta = 0
theta2 = 0
cr = 0

' = 10% x (datamax - datamin)

' --- rekonstruksi phase space ---
For i = 1 To npointfix
  For j = 1 To dimen
    buff2(i, j) = buff1(i + (j - 1) * tau)
  Next j
Next i

npointvar = npointfix - dimen * tau
For l = 1 To 14

For k = 1 To (npointvar - lag)
  For i = k + lag To npointvar
    d = 0
    For j = 1 To dimen
      d = d + (buff2(k, j) - buff2(i, j)) ^ 2
    Next j
    d = Sqr(d)
    If d > r Then theta2 = 0 Else theta2 = 1
    theta = theta + theta2
  Next i
Next k

' --- test jumlah neighbour points ---
If theta < 10 Then GoTo 100
End If

If lag = 0 Then lag1 = 0 Else lag1 = lag
cr = (2 / ((npointvar - lag1) * (npointvar - lag1 - 1))) * theta
logcr = Log(cr) / Log(10)
logr = Log(r) / Log(10)
r = r + dt
cr = 0
theta = 0
theta2 = 0
buff5(l, (dimen - 1)) = logcr
buff5(l, 10) = logcr
buff6(l, 10) = logr

Next l

Next dimen

For x = 1 To 9
  For y = 1 To 13
    buff6(y, x) = (buff5(y + 1, x) - buff5(y, x)) / (buff5(y + 1, 10) - buff5(y, 10))
  Next y
Next x

For m = 1 To 14
Print #2, buff5(m, 1); buff5(m, 2); buff5(m, 3); buff5(m, 4); buff5(m, 5); buff5(m, 6); buff5(m, 7); buff5(m, 8);
buff5(m, 9); buff5(m, 10)
Next m

For m = 1 To 14
Print #3, buff6(m, 1); buff6(m, 2); buff6(m, 3); buff6(m, 4); buff6(m, 5); buff6(m, 6); buff6(m, 7); buff6(m, 8);
buff6(m, 9); buff5(m, 10)
Next m

100
Close #2
Close #3

```

End Sub

C. LyapExp : estimasi maximum Lyapunov exponent

Dim x(6000), pt1(12), pt2(12)

Dim z(6000, 5)

Dim ind, ind2, lag, sum, its, di, dii, iii

Dim d, df, zmult, zlyap, indold, thmin, dold, dnew

Dim dot, cth, th, anglmx, scalmax, scalmin

Dim i, j, npt, Q, dimen, tau, dt, evolv As Integer

' --- parameter ---

Open "c:\input\ma1.prn" For Input As 1

Open "c:\output\lyap.prn" For Output As 2

npt = 234

Q = 42

lag = 50

evolv = 5

dimen = 3

tau = Q \ dimen

dt = 1

ind = 1

sum = 0

its = 0

' file input

' file output

' jumlah titik file input

' nonperiodic cycle

' time lag between neighbor

' propagation time between replacement attempts

' dimension of phase space reconstruction

' reconstruction time delay

' time between data samples

' --- baca data input ---

For i = 1 To npt

Input #1, x(i)

Next i

Close #1

' --- data range

xmax = x(1)

xmin = x(1)

For i = 2 To npt

If x(i) > xmax Then xmax = x(i)

If x(i) < xmin Then xmin = x(i)

Next i

scalmax = 0.1 * (xmax - xmin)

scalmin = 0.1 * scalmax

' --- reconstructing phase space ---

For i = 1 To npt - (dimen - 1) * tau

For j = 1 To dimen

z(i, j) = x(i + (j - 1) * tau)

Next j

Next i

' --- initial point ---

npt = npt - dimen * tau - evolv

di = 1000000000

For i = (lag + 1) To npt

d = 0

For j = 1 To dimen

d = d + (z(ind, j) - z(i, j)) ^ 2

Next j

d = Sqr(d)

If (d > di) Or (d < scalmin) Then GoTo label1

di = d

ind2 = i

label1:

Next i

' --- coordinates of evolved points ---

label2:

```

    For j = 1 To dimen
    pt1(j) = z(ind + evolv, j)
    pt2(j) = z(ind2 + evolv, j)
    Next j

' --- compute final divergence ---
df = 0
    For j = 1 To dimen
    df = df + (pt2(j) - pt1(j)) ^ 2
    Next j
df = Sqr(df)
its = its + 1
sum = sum + (Log(df / di) / (evolv * dt * Log(2)))
zlyap = sum / its

Print #2, zlyap; evolv * its '; di; df

indold = ind2
zmult = 1
anglmx = 0.3

label3:
thmin = 3.14

' --- look for replacement points ---
For i = 1 To npt
iii = Abs(Int(i - (ind + evolv)))
If iii < lag Then GoTo label4

dnew = 0
    For j = 1 To dimen
    dnew = dnew + (pt1(j) - z(i, j)) ^ 2
    Next j
dnew = Sqr(dnew)
If (dnew > zmult * scalmax) Or (dnew < scalmin) Then GoTo label4
dot = 0
    For j = 1 To dimen
    dot = dot + (pt1(j) - z(i, j)) * (pt1(j) - pt2(j))
    Next j
cth = Abs(dot / (dnew * df))
If cth > 1 Then cth = 1
th = Cos(cth)
If (th > thmin) Then GoTo label4
thmin = th
dii = dnew
ind2 = i

label4:
Next i

If thmin < anglmx Then GoTo label5
zmult = zmult + 1
If (zmult < 5) Then GoTo label3
zmult = 1

anglmx = 2 * anglmx
If (anglmx < 3.14) Then GoTo label3
ind2 = indold + evolv
dii = df

label5:
ind = ind + evolv
If (ind >= npt) Then GoTo label6
di = dii
GoTo label2
Close #2

```

```
label6:  
End Sub
```

D. NoiseFilt : simple noise reduction

```
Dim y(6000)  
Dim yc(6000)  
Dim jh(10000)  
Dim jpntr(6000)  
Dim nlist(6000)  
Dim nmax, m, eps  
Dim i, n, nn, nfound, nfound1, av  
Dim indeks, a, b, im, ii, id  
Dim nlast  
Dim jj, kk, j, k, jk, ip, np  
  
nmax = 1015          ' jumlah titik file input  
eps = 0.12          ' persentase terhadap range file input  
id = 1              ' time delay  
m = 3               ' embedding dimension  
nlast = nmax  
  
Open "c:\input\wa1.prm" For Input As 1      ' file input  
Open "c:\output\wa1fil.prm" For Output As 2 ' file output  
  
' --- baca data input ---  
For i = 0 To (nmax - 1)  
Input #1, y(i)  
Next i  
Close #1  
  
' --- base ---  
im = 100  
ii = 100000000  
  
For i = 0 To (im * im)  
jh(i) = 0  
Next i  
  
For n = (m - 1) * id To (nmax - 1)  
a = Int(y(n) / eps)  
b = Int(y(n - (m - 1) * id) / eps)  
indeks = (im * ((a + ii) Mod im)) + (b + ii) Mod im  
jh(indeks) = jh(indeks) + 1  
Next n  
  
For i = 1 To (im * im)  
jh(i) = jh(i) + jh(i - 1)  
Next i  
  
For n = (m - 1) * id To (nmax - 1)  
a = Int(y(n) / eps)  
b = Int(y(n - (m - 1) * id) / eps)  
indeks = (im * ((a + ii) Mod im)) + (b + ii) Mod im  
i = indeks  
jpntr(jh(i)) = n  
jh(i) = jh(i) - 1  
Next n  
  
' --- nlazy---  
For n = 0 To (nmax - 1)  
yc(n) = y(n)  
Next n
```

```

For n = (m - 1) * id To (nmax - 1)
' --- neighbours ---
jj = Int(y(n) / eps)
kk = Int(y(n - (m - 1) * id) / eps)
nfound = 0
For j = jj - 1 To (jj + 1)

For k = kk - 1 To (kk + 1)

jk = (im * ((j + ii) Mod im)) + ((k + ii) Mod im)

For ip = jh(jk + 1) To (jh(jk) + 1) Step -1
np = jpntr(ip)

If (np >= nlast) Then GoTo 20

For i = 0 To (m - 1)
If Abs(y(n - i * id) - y(np - i * id)) >= eps Then GoTo 30
Next i

If i = m Then nlist(nfound) = np
nfound = nfound + 1

30 Next ip

20 Next k

10 Next j

nfound1 = nfound
av = 0
For nn = 0 To nfound1 - 1
av = av + y(nlist(nn) - (m - 1) / 2)
Next nn
yc(n - (m - 1) / 2) = av / nfound1

Next n
For i = 0 To (nmax - 1)
Print #2, yc(i)
Next i

Close #2
End Sub

```

D. StPlot : space-time separation plot

```

Dim y(5100)
Dim stp(5100, 20)
Dim ihist(1000)
Dim mfrac, meps, nmax, m, id, epsmax, idt, mdt
Dim it, iep, n, ifrac, need, ist, i, dis
Dim ih, ihist1, itrow, j, k

```

```

mfrac = 20      ' jumlah kontur
meps = 1000    ' time delay
id = 1         ' embedding dimension

nmax = 5071    ' jumlah titik file input
epsmax = 1.2  ' range file input
mdt = 5000    ' jumlah pengamatan
idt = 1        ' jarak antar titik time series

```

```

Open "c:\input\da1.prn" For Input As 1      ' file input
Open "c:\output\stpda1.prn" For Output As 2  ' file output

    For i = 0 To (nmax - 1)
        Input #1, y(i)
    Next i
Close #1

For it = 0 To (mdt - 1)

    For ieps = 0 To (meps - 1)
        ihist(ieps) = 0
    Next ieps

For n = it * idt + (m - 1) * id To (nmax - 1)

dis = 0
    For i = 0 To (m - 1)
        If Abs(y(n - i * id) - y(n - i * id - it * idt)) > dis Then dis = Abs(y(n - i * id) - y(n - i * id - it * idt))
        ih = meps - 1
        If Int(meps * dis / epsmax) < ih Then ih = Int(meps * dis / epsmax)
        ihist(ih) = ihist(ih) + 1
    Next i
Next n

    For ifrac = 0 To (mfrac - 1)
        need = (nmax - it * idt - (m - 1) * id) * (ifrac + 1) / mfrac
        ist = 0
        For ieps = 0 To (meps - 1)
            ist = ist + ihist(ieps)
            If ist >= need Then Exit For
        Next ieps
        stp(it, ifrac) = (ieps * epsmax) / meps
    Next ifrac

Next it

itrow = it

    For j = 0 To (itrow - 1)
        Print #2, stp(j, 0); stp(j, 5); stp(j, 10); stp(j, 15); stp(j, 19)
    Next j

Close #2
End Sub

```

E. Shuffle : program untuk mengacak time series

```

Dim buff1(6000)
Dim s1, s2
Dim npt, i, j, k, l As Integer
Dim a, c, t, e1, e2, e3, e, delta, r1, r2

npt = 1014
Open "c:\week\wal.prn" For Input As 1      ' file input
Open "c:\shuffle\sfwal.prn" For Output As 2  ' file output

    For i = 1 To npt
        Input #1, buff1(i)
    Next i
Close #1

For l = 1 To 100
    For i = 1 To (npt - 1)
        Randomize
        r1 = Rnd()

```



```
j = Abs(Int(r1 * npt) + 1)
Randomize
r2 = Rnd()
k = Abs(Int(r2 * npt) + 1)
Print , j; k
s1 = buff1(j)
s2 = buff1(k)
buff1(j) = s2
buff1(k) = s1
Next i
```

Next I

```
For i = 1 To npt
Print #2, buff1(i)
Next i
```

Close #2
End Sub

