

Chaos, Sebuah Studi Empiris dari BEJ: Pengamatan pada Indeks Portfolio Pasar



Bambang Hermanto Minarnita
Yanti Verawati Bakara

Abstract

We try to detect chaos structure on the capital market by searching for low dimensional chaos at the market portfolio index: IHSG. We apply BDS statistic, R/S Analysis, Correlation Dimension and Lyapunov Exponent for nonlinearity and chaos testing. We observe IHSG data from January 1988 until November 2003. We find nonlinearity, persistence and low dimensional chaos in IHSG data,

Keywords: Attractor, BDS statistic, Chaos, Correlation Dimension, Correlation Integral, Embedding Dimension, Fractal, Hurst Exponent, Lyapunov Exponent, Phase Space, Phase Space Reconstruction, Rescaled Range (R/S) Analysis.



Chaos (*deterministic nonlinear dynamics*) dapat memberikan hasil yang tampak *random* dari yang *deterministic*. Meski tampak *random* tapi pergerakan harga dan *return* saham bukan *random walk* (Lo & MacKinlay, 1999)¹. Bagi teori keuangan dan ekonomi, kemungkinan struktur chaos dan temuan empiris adanya *nonlinearity* dan *chaos* menjadi penting dan menarik. Gagasan penelitian ini berawal dari dugaan adanya struktur *chaos* dalam pasar modal Indonesia. *Chaos theory* diharapkan membantu melengkapi teori ekonomi dan keuangan dari sudut pandang lain, sebagai titik awal pemahaman perilaku sistem. Masih terjadi kontroversi pro dan kontra relevansi penerapan hasil penelitian *chaos* dan *nonlinear* di bidang ekonomi dan keuangan secara empiris dan teoritis.

Bambang Hermanto, PhD, Ketua
Departemen Manajemen FEUI Minarnita
Yanti Verawati Bakara, SE, MSI

Penelitian ini merupakan studi empiris yang melengkapi penelitian lainnya dalam area sistem *chaos*, sistem dinamik dan sistem nonlinier baik pro maupun kontra. Masalah yang diteliti berhubungan dengan pencarian struktur *chaos* dan *fractal*. Pemodelan untuk *forecasting* atau prediksi tidak dilakukan. Penelitian ini mendeteksi adanya karakteristik proses *deterministic nonlinear dynamic* yaitu *chaos* pada IHSG.

Berbeda dari istilah sehari-hari sesuai kamus bahwa *chaos* adalah keadaan atau situasi tidak menentu, kacau dan membingungkan yang mirip dengan keacakantapanapolaspesifik. Makachaos yang dimaksud disini yaitu *chaos* dalam arti matematik: *deterministic nonlinear dynamic system* atau *chaos theory*. *Chaos* ditunjukkan melalui fungsi pergerakan dari hubungan nonlinier yang pasti antar variabel yang saling mempengaruhi dimana terjadi iterasi, yang tergambar dalam bentuk geometri *strange attractor* pada *phase space*.

Bila sistem keuangan memenuhi

chaos theory maka akan memiliki karakteristik atau ciri-ciri berikut, dimana *forecasting* kurang dapat diandalkan karena *erratic system*:

1. Sensitif terhadap perubahan kondisi awal (*sensitive dependence on initial condition*)
2. Mempunyai lebih dari satu titik kritis (*critical levels* atau *critical points*) dimana ada lebih dari satu titik kesetimbangan yang berarti tidak stabil (*far from equilibrium*)
3. Mempunyai karakteristik statistik yang mirip: mengalami perulangan pola atau struktur dengan skaladan ukuran yang berbeda (*self-similarity* atau *fractal structure/dimension*)
4. Memiliki *trend* artinya siklus atau pattern, dan ketergantungan jangka panjang/ *long term correlations* (*feedback effect* atau *persistent/long memory*)

Struktur *chaos* merupakan struktur geometri yang tidak teramati melalui dimensi waktu. Data *series* tampak acak dalam dimensi waktu, sehingga sering dikategorikan *random* daripada *chaos*. Adanya *chaos* dalam kumpulan data *time series* dapat dibuktikan melalui pengamatan pada *phase space*. Bila diketahui fungsi gerak dari hubungan saling mempengaruhi (*interdependent*) secara simultan variabel-variabel dalam sistem maka pengamatan di *phase space* mudah. Namun persamaan pergerakan yang membentuk data *time series* tidak diketahui sehingga pola pergerakan dalam *phase space* tidak dapat dibentuk dengan pemetaan solusi persamaan pergerakan menjadi *phase portrait*.

¹ Lo & MacKinlay (1999), "A Non-Random Walk Down Wall Street", Princeton University Press, New Jersey, 3-146

Dalam studi kasus pengamatan phase space sangat penting untuk mengetahui dinamika sistem terutama sistem yang memiliki properti deterministik (tertentu dan pasti). Dinamika sistem teramati melalui dinamika titik-titik solusi dalam phase space. Sehingga data *time series* yang tidak diketahui persamaannya perlu diubah ke bentuk phase space yang menggambarkan interaksi *interdependent* variabel-variabel yang membentuk *time series* tersebut, yaitu melalui *phase space reconstruction* dengan mengkonvert data *time series* ke *vector state space* menggunakan metode *time delay*.

Dasar rekonstruksi ini adalah merekonstruksi vector space R^m berdimensi tertentu yang ekuivalen dengan *state space* sistem aslinya dari data *time series*. Meski dengan pengetahuan yang akurat tentang proses pengukuran namun tidak mungkin untuk merekonstruksi *state space* sistem aslinya dari data, sehingga cukup merekonstruksi ruang sehingga attractor dalam ruang tersebut ekuivalen dengan aslinya. Algoritma berikut (Kantz & Schreiber, 1997) adalah dasar perhitungan *correlation dimension* dan *Lyapunov exponent* serta prediksi di phase space untuk pengolahan data. Fungsi pemetaan F yang membentuk *time series* tidak diketahui:

$$x_{t+1} = f(x_t)$$

Dengan asumsi fungsi pemetaan F kontinu, untuk memprediksi x_{N+1} dari x_N maka dicari semua x_n , $n < N$ yang mendekati x_N . Jika saat n_n mirip dengan x_N dan berdekatan di phase space maka akan menjamin bahwa x_{n+1} akan dekat dengan x_{N+1} . Untuk waktu observasi yang panjang akan ditemui keadaan di masa lampau yang dekat dengan keadaan sekarang sehingga prediksi $x_{t+v+1} = f^v(x_t)$ akan mendekati kebenaran. Ini merupakan algoritma prediksi dari sistem chaos. Biasanya tidak diukur x_n yang sebenarnya tapi hanya beberapa yang secara fungsional tergantung pada x_n . Dalam pengukuran skalar:

$$s =$$

(1.2)

dimana $n=1, \dots, N$ dan r_n adalah n -se, dan fungsi pengukuran skalar s tidak diketahui. Pengukuran skalar merupakan proyeksi dari variabel dalam sistem yang tidak teramati ke interval pada sumbu asli. Sehingga digunakan *delay reconstruction* dalam dimensi m menggunakan vector s_n yang ekuivalen dengan aslinya:

$$S =$$

(1.3)

Perbedaan waktu v (dalam unit *sampling*) atau $\tau = vA$ (dalam unit waktu) antar komponen dalam *delay vector* merupakan *lag* atau *delay time*. Ada 2 parameter yang dapat disesuaikan untuk metode prediksi yaitu *delay time* v dan *embedding dimension* m . Untuk semua pengukuran s_1, \dots, s_N dibentuk *delay vector* untuk memprediksi pengukuran mendatang $S_{(m-1)v+1} \dots S_N$. Untuk memprediksi pengukuran mendatang $s_{N+1} \dots s_{N+H}$ dicari *embedding vector* S_n yang dekat dengan S_N dan digunakan sebagai *predictor*. Attractor yang dibentuk oleh S_n setara atau ekuivalen dengan attractor dalam ruang yang tidak diketahui dimana sistem berada bila dimensi m dari ruang koordinat *delay* cukup besar. Inti terpenting adalah menunjukkan dalam kondisi mana proyeksi dengan pengukuran skalar dan rekonstruksi dengan *delay vector* membentuk suatu *embedding*.

Teorema *embedding* dijelaskan sebagai berikut. Objek geometrik yang dibentuk oleh vector S_i ekuivalen dengan lintasan aslinya x_n . Evolusi waktu dari suatu lintasan dalam ruang yang direkonstruksi (*reconstructed space*) seharusnya hanya tergantung pada posisi terbaru dalam ruang dan tidak pada yang lain. Ini adalah karakteristik dinamika sistem yaitu keunikan dalam ruang rekonstruksi. Untuk menjamin bahwa perhitungan untuk attractor yang direkonstruksi identik dengan yang di *state space* aslinya maka struktur *tangent space* (linierisasi) dari dinamika pada tiap titik dalam *state space* dipertahankan oleh proses rekonstruksi. Teorema *embedding* menjamin bahwa untuk data bebas n -se maka ada dimensi m dimana vector s_n ekuivalen dengan *vector phase space*.

Taken (1981) memberikan teorema *embedding* menggunakan *delay*. Dengan

time delay embedding maka attractor A merupakan sekumpulan *state space* dari sistem yang menjamin bahwa pemetaan F dari *state vector* pada waktu tertentu ke posisinya kemudian dalam interval satu *sampling* adalah unik. Sehingga *time delay embedding* adalah pemetaan yang tidak tergantung pada waktu dari A ke R^m . Jika x_n adalah *state vector* saat n , s adalah fungsi pengukuran dan F adalah pemetaan yang menunjukkan dinamika $x_{t+1} = F(x_t)$ maka $(x_n, s(F(x_n)))$ atau $(x_n, s(F(x_n)))$ pada waktu n_i ekuivalen dengan mengetahui sekumpulan koordinat berbeda pada saat tertentu bila pemetaan F membentuk derajat kebebasan (*degrees of freedom*) berbeda sehingga komponen *delay vector* tidak tergantung (*independent*). Taken membuktikan bahwa *delay map* dari dimensi $m=2D+1$ adalah *embedding* dengan dimensi D .

Parameter *embedding* terpenting adalah m dari *delay time* dan *embedding dimension*, merupakan *time span* yang ditunjukkan dengan *embedding vector*. Cara mengestimasi nilai m yang optimal dengan melihat *false neighbours* dalam *phase space* pada nilai m tertentu. Saat m meningkat dimulai dengan nilai yang kecil dapat dideteksi dimensi *embedding* minimal, dengan mengamati tidak ada lagi *false neighbours*. Tetapi ketidakstabilan sistem chaos membuat sulit untuk menentukan mana *neighbours* yang *false* atau *true*. Untuk estimasi $\tau - v/\tau$. Jika τ terlalu kecil dibandingkan skala waktu sistem maka elemen-elemen dari *delay vector* akan sangat berkorelasi sehingga semua vector akan terkumpul di sekitar diagonal kecuali m sangat besar. Jika τ terlalu besar elemen-elemen tersebut hampir *independent*.

Beberapa penelitian yang dilakukan dalam area chaos dan *nonlinear* pada indeks portfolio pasar, antara lain: Abhyankar, Copeland dan Wong (1997) meneliti kemungkinan adanya struktur *nonlinear dependence* pada indeks data transaksi *real time* S&P 500, FTSE-100, DAX, Nikkei, S&P 500 Futures dan FTSE-100 Futures menggunakan pengujian metode standar *non parametric* BDS (Brock-Dechert-Scheinkman) dan LWG (Lee, White dan Granger) *neural network* based untuk *nonlinearity*, mengestimasi

Lyapunov Exponent dengan metode estimasi pendekatan *Neural Network* (Nychka, Ellner, Gallant dan McCaffrey) dan algoritma *nearest neighbour* (Zeng, Pielke dan Eyckholt) untuk *sensitive dependence*; Hoque (1995) mencoba menemukan *low dimensional chaos* dalam indeks penutupan harian pasar saham London, Tokyo, Hong Kong, Singapore, New York menggunakan *correlation dimension* dengan diagnosa Grassberger-Procaccia, diagnosa *Residual*, diagnosa *shuffle*, dan diagnosa BDS; Pandey, Kohers T. dan Kohers G (1998) mendeteksi *low-dimensional deterministic chaos* pada data mingguan pasar saham Eropa (United Kingdom, Jerman, Prancis, Switzerland dan Itali) dan Amerika menggunakan BDS *statistic* untuk menguji hipotesa IID, R/S Analysis untuk menguji non IID disebabkan *nonlinear dynamics* dan *three moments test* untuk *chaotic determinism*; Olmeda dan Perez (1995) meneliti pasar modal Spanyol menggunakan Scheinkman dan Hshieh *third order moment* dan uji BDS; Kyrtsov dan Terraza (2000) mempelajari adanya perilaku *chaotic* pada return pasar modal Paris dengan uji BDS, uji *fractional integration*, metode *correlation dimension* dan Lyapunov exponent Penelitian di Indonesia tentang *chaos* dilakukan oleh Ki Eeng Tjun, MM dan Dr. Bambang Hermanto (2001) pada *Future Market Malaysia* dimana *Future Market* merupakan sistem *chaos*.

Metodologi

2.1A/on/7near/ly Test: BDS (Brock, Dechert & Scheinkman) *Statistic Diagnostic*

BDS *statistic* yang terdistribusi normal untuk *time series* sepanjang T didefinisikan:

$$mm, e, T \quad (2.1.1)$$

$$(2.1.2)$$

$$(2.1.3)$$

$$(2.1.4)$$

dimana:
 T = jumlah/ukuran observasi
 e = jarak pengukuran sebagai *proximity* parameter yang dipilih m = jumlah *embedding dimensions* C = *Correlation integral*, dan a^2 = estimasi varian dari $C(c(m, \epsilon, T) - C(l, e, T))^m$ a(m,e,T) ~ standar deviasi dari *correlation integral* yang bervariasi dengan dimensi

Menggunakan pasangan *m-histories* dalam jarak spesifik e, BDS test mampu menunjukkan pola tersembunyi yang seharusnya tidak terjadi dalam data yang benar-benar didistribusi secara acak. *Correlation Function* C(m,e,T) adalah estimasi probabilitas bahwa jarak antara 2 *m-histories* X_t dan X_{t+s} dari series {x(t)} lebih kecil dari e. Bilaseries{x(t)}independent makauntukt¹ s, probabilitas kejadian bersama (*joint probability*) ini sama dengan hasil probabilitas individual. Brock et al. (1987) memperoleh *estimator variance*, sebagai dasar pengujian hipotesa nol IID (*random*). Bila {x(t)} *identically distributed* maka semua probabilitas m akan sama. Brock, Dechert dan Scheinkman (1987)² menunjukkan bahwa saat e tertentu, untuk tiap m sebagaimana T->∞, C(m,e,T) mempunyai limit G(m,e) sedemikian sehingga jika data {x(t)} adalah IID, maka:

$$C(m,e) = C(1,E)^m \quad (2.1.5)$$

Persamaan ini adalah hipotesa nol yang diuji BDS *statistic* yang ekuivalen dengan hipotesa nol *whiteness* yaitu jenis penskalaan proses *random* dimana *correlation integral* mengisi space dimensi tempatnya. Dari percobaan Monte Carlo, Brock et al (1991)³ merekomendasikan e/ s antara 0.5 dan 1.5 standar deviasi data untuk optimasi pengujian.

2.2 R/S (*Rescaled Range or Range over Standard deviation*) Analysis R/S *statistic* adalah range bagian penjumlahan deviasi *time series* dari nilai meannya, diskala ulang dengan standar deviasinya, dinyatakan dengan:

$$(2.2.1)$$

dimana (R/S) adalah range yang distandarisasi dengan deviasi kumulatif untuk semua subperiode panjang N, t adalah peningkatan waktu *integer* yang berada di dalam N, r, adalah observasi ke t dalam series yang dianalisa, dan S adalah standar deviasi series awal:

$$S^{-1} \sum_{t=1}^N (x_t - \bar{x})^2 \quad (2.2.2)$$

Adjusted range (R/S) adalah jarak sistem bergerak untuk *time index* n, dan selalu non negatif. Karena (R/S) range yang distandarisasi untuk deviasi kumulatif dari rata-rata (mean), maka range meningkat dengan N. Estimasi R/S (Hurst, 1951):

$$(R/S) = a * (N)^H \quad (2.2.3)$$

dimana a adalah konstanta dan H Hurst exponent. Log persamaan di atas:

$\log(R/S) = H \times \log(N) + \log(a)$ (2.2.4) H diestimasi dengan regresi OLS antara log (R/S) dan log (N) untuk berbagai nilai N. H=0.5 jika series merupakan *random walk*: range deviasi kumulatif meningkat dengan akar kuadrat waktu. H<0.5 menunjukkan perilaku *anti-persistent trend* positif dalam subperiode sepanjang N lebih diikuti *trend* negatif dalam subperiode berikutnya. H>0.5 menunjukkan perilaku *persistent trend* positif cenderung diikuti *trend* positif.

Beberapa sistem mungkin mempunyai siklus memori yang pendek, sehingga estimasi R/S persistensi/anti-persistensi hanya untuk subperiode N yang pendek. Observasi dahulu plot dari log (R/S) dengan log (N) kemudian estimasi H hanya untuk porsi linier dari plot. Untuk N sangat panjang series konvergen ke H=0.5 karena *memory effect* berkurang ke nilai yang tak terukur. Artinya observasi dengan N yang panjang akan menghasilkan pola mirip Brownian *motion* atau *random walk* murni, dengan hilangnya pengaruh memori. R/S *analysis* tidak mengasumsikan suatu distribusi adalah Gaussian. H=0,5 tidak

2 dalam Barnett, W. A. & He, Y. (1998), "Center Manifold, Stability, and Bifurcation in Continuous-Time Macroeconometrics Systems", *Washington University-St. Louis, Manuscript*, 1-24.

3 dalam Gwilym, O. AP., Brooks, C., Clare, A., Thomas, S. (1999) "Tests of Non-Linearity Using Life futures Transactions Price Data", *The Manchester School*, 67/2, 175

membuktikan *random walk*, tapi hanya tidak adanya proses *long memory*. Berarti *independent system*, Gaussian dan lainnya akan menghasilkan $H=0,5$. Untuk *random walk* (Hurst, 1951):

$$(R/S) \gg (n \cdot j r / 2)^{-5} \quad (2.2.5)$$

Anis & Lloyd (1976)⁴ mengembangkan deviasi R/S staf/c untuk n yang kecil:

(2.2.6)

Menggunakan Sterling's Function, persamaan tersebut disederhanakan menjadi:

$$E(R/S) \sim (n \cdot j r / 2)^{-5} \quad (2.2.7)$$

Peters (1994) mengoreksi formula tersebut menjadi:

(2.2.8)

Ini adalah *expected R/S* dengan hipotesa *random* untuk memperoleh signifikansi statistik.

2.3. Correlation dimension

Grassberger dan Procaccia (1983)⁵ menyarankan algoritma dengan konsep *correlation dimension* / *correlation exponent* menggunakan *correlation integral* yang merupakan pendekatan dimensi *attractor* fraktal Hausdorff untuk menguji hubungan *subset sequential series* aslinya dengan prosedur berdasarkan *spatial correlation*. Perhitungan *correlation* memerlukan pengetahuan bentuk *phase space* tapi jumlah faktor-faktor yang mempengaruhi sistem tidak diketahui pasti. Takens (1981)⁶ menyatakan teorema bahwa *phase space* dapat direkonstruksi dengan *lagging* untuk tiap dimensi yang diduga ada.

dalam Peters E. E. (1994), "Fractal Market Analysis: Applying Chaos Theory to Investment and Economics", John Wiley & Sons, 69
 Grassberger, P. & Procaccia, I. (1983), "Measuring the Strangeness of Strange Attractors", *Physica*, 9D, 189-208 & Grassberger, P. & Procaccia, I. (1983a), "Characterization of Strange Attractors", *Physical Review Letters*, 50, 346-349 dalam Peters (1991 & 1994); Kantz & Schreiber (1997); Atchison & White (1996); Barnett & Choi (1989); Barnett, W. A. & He, Y. (1998); Olmeda, I. & Perez, J. (1995); Bask, Mikael (1998); Campbell, J. Y., Lo, A. W., MacKinlay, A. C. (1997)
 Takens, F. (1981), "Detecting Strange Attractors in Turbulence", *Lecture Notes in Mathematics*, 898 dalam Peters (1991 & 1994); Kantz & Schreiber (1997); Atchison & White (1996); Barnett & Choi (1989); Barnett, W. A. & He, Y. (1998); Olmeda, I. & Perez, J. (1995); Bask, Mikael (1998); Campbell, J. Y., Lo, A. W., MacKinlay, A. C. (1997)

$\{x_t\}$ ialah *scalar time series* yang diobservasi dengan asumsi *unidimensional* dan dibangkitkan secara acak berdasarkan fungsi kerapatan f . Anggap X_t dalam *time series* X dengan T observasi tidak saling tergantung. Bentuklah *vector* dimensi m (disebut *m-histories*): *series* tersebut di-tag ke "*m histories*" menggunakan metode *time delay* Takens untuk membuat *phase space* dimensi m dari *time series* X , lalu hitung *correlation integral*, Rekonstruksi ulang *time series* ke dalam *phase space* dimulai *embedding dimension* terendah $m=2$ yang menunjukkan panjang tiap subseri dengan jarak yang kecil. Pembentukan *vector* berbagai dimensi dari series awal disebut *embedding*.

J adalah titik-titik dalam *attractor* berdimensi satu yang ditaruh dalam *series vector* berdimensi m : $X_t = (x_t, x_{t-1}, \dots, x_{t-m+1})$ yang

menghasilkan *series* $\{f_m, m\}$ *m-histories* dari *series* tersebut

$x_t = (x_t, x_{t-1}, \dots, x_{t-m+1})$ dihitung untuk waktu $t=1, \dots, T-m$, *embedding dimension* m dan *time delay* τ . Derajat kemiripan antara *subsequens m histories* didefinisikan sebagai e . Dimulai dengan jarak kecil tertentu dihitung *correlation integral* untuk jarak ini. *Correlation integral* menghitung probabilitas tiap 2 titik yang terpisah pada lintasan berbeda dalam *phase space* berada dalam jarak tertentu sejauh e unit bagian:

$$C(\epsilon) = \lim_{\epsilon \rightarrow 0} C(\epsilon) \quad (2.3.1)$$

Rumus dasar *correlation integral* yaitu *correlation sum* sekelompok titik-titik di *vector space* sebagai fraksi semua kemungkinan pasangan titik-titik yang berdekatan dari jarak e :

$$C(\epsilon) = \frac{1}{N(N-1)} \sum_{i \neq j} I_{ij}(\epsilon) \quad (2-3.2)$$

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

menunjukkan *supremum* yaitu jarak, dan

I_{ij} jumlah elemen. I adalah fungsi indikator dari kejadian *Heaviside function* berikut:

$$I_{ij}(\epsilon) = \begin{cases} 1 & \text{if } \|X_i - X_j\| \leq \epsilon \\ 0 & \text{otherwise} \end{cases} \quad (2.3.3)$$

sama dengan satu bila $\|X_i - X_j\| \leq \epsilon$ dan nol lainnya. *Correlation integral* mengukur fraksi pasangan yang berada antara jarak

toleransi kurang dari e untuk *embedding dimension* m . Fungsi Z menghitung jumlah titik dengan jarak e satu dengan lainnya. Jika $C(N, m, \epsilon]$ besar/mendekati nol untuk ϵ yang kecil maka data amat ter Korelasi.

Dengan meningkatnya e , maka skala probabilitas tergantung pada dimensi fraktal *phase space*. Jika E bertambah, $C^m(f, r)$ akan naik pada tingkat, sehingga diperoleh:

$$C^m(\epsilon) \sim \epsilon^D \quad (2.3.4)$$

$$\log(C^m(f, r)) = m \log \epsilon + \text{konstanta} \quad (2.3.5)$$

Bilakenaikan $C^m(f, r)$ lambat dengan naiknya E maka kebanyakan data cukup dekat satu dengan lainnya dan ter Korelasi dengan baik. Di sistem stokastik, makin tinggi *correlation dimension*: makin cepat kenaikan *correlation integral* dengan pertambahan jarak, data kurang ter Korelasi. Pada sistem *deterministic*, makin rendah *correlation dimension*: kenaikan *correlation integral* lambat dengan bertambahnya jarak, data lebih ber Korelasi.

Hitung *log correlation integral* dibagi log jarak E dan ambil *limit* dengan e dibuat secara progresif lebih kecil. Membagi *correlation integral* dengan E dan mengambil log naturalnya menghasilkan *series* dari *correlation dimension*. Pilihan nilai e dan m saling berhubungan dan dipengaruhi panjang *series* T . Secara teknis, D^m adalah batasan ganda, dalam hal $T \gg m$ dan $e \ll 1$. Dalam praktek T biasanya tertentu dan tidak mungkin meningkat hingga tak terhingga. Jadi hanya diperhatikan batasan $E \rightarrow 0$. Karena itu C diskala seperti *power law*, $C(\epsilon) \sim \epsilon^{-D}$ sehingga *correlation dimension* D :

$$D = \lim_{\epsilon \rightarrow 0} \frac{\log C(\epsilon)}{\log \epsilon} \quad (2.3.6)$$

$$D(N, m, \epsilon) =$$

$$= \lim_{\epsilon \rightarrow 0} \lim_{m \rightarrow \infty} D(N, m, \epsilon) \quad (2.3.7)$$

Untuk data set terbatas, *power law* hanya mempunyai range ϵ terbatas, untuk ϵ yang besar semua titik-titik akan berada dalam jarak ϵ tetapi untuk ϵ yang sangat kecil tidak ada pasangan titik-titik dalam jarak ϵ . Untuk *series* terhingga, *correlation dimension* menjadi:

$$D^m(r) = \lim(\ln C^m(f, r) / \ln f) \quad (2.3.8)$$

Berbagai $\ln C^m(e, T)$ diregresi linier dengan $\ln g$ dan *slope* yang dihasilkan adalah estimasi $D^m(r)$ untuk *embedding dimension* m . $C(\epsilon)$ dan estimasi sampelnya $C(\epsilon)$ proporsional dengan ϵ^D dimana D *correlation dimension* yang merupakan estimasi/ope. Daripofberikut diestimasikan nilai *correlation dimension* saat kurva saturasi/konvergensi:

- *Plot* $\ln C^m(e, T)$ vs $\ln e$
- *Plot slope* $D^m(r)$ yang merupakan hasil regresi $\ln C^m(f, r)$ dan $\ln e$ vs $\ln s$
- *Plot slope* $D^m(r)$ vs *embedding dimension* m

Jika dengan naiknya m , *correlation dimension* terus meningkat maka sistem adalah stokastik. Jika data dibangkitkan oleh proses *deterministic* sesuai dengan perilaku *chaotic* maka *correlation dimension* akan saturasi terbatas pada beberapa nilai m yang cukup kecil. Sehingga *correlation dimension* digunakan untuk membedakan proses stokastik dari proses *deterministic chaos* yang berdimensi rendah maupun tinggi (Barnett & He, 2001).

Estimasi $D^m(T)$ *Correlation dimension* banyak digunakan sebagai dasar mendeteksi *chaos*, yaitu: Grassberger-Procaccia diagnostic, *Residual diagnostic*, dan *Shuffle diagnostic* (Hoque, 1995). Pada Grassberger-Procaccia *diagnostic*, jika estimasi $D^m(j)$ konvergen dengan berubahnya m dan/atau ϵ maka *series* tersebut *chaotic* tapi jika melonjak *random*.

2.4 Lyapunov Exponents

Sebuah sistem *chaotic* menunjukkan sensitivitas ketergantungan terhadap kondisi awal (SDIC = *Sensitive Dependence on Initial Condition*). SDIC dinyatakan dengan adanya paling sedikit sebuah Lyapunov *Exponent* yang positif, sehingga pengujian berdasarkan Lyapunov *exponent* merupakan pengujian langsung untuk *chaos*. Konsep SDIC merupakan karakteristik dasar sistem *chaotic*, yaitu jika perubahan tak terhingga $\delta x(0)$ dibuat pada *initial condition* maka perubahan terkait $\delta x(t)$ diiterasi melalui sistem hingga waktu t , akan bertumbuh secara eksponensial dengan t (Ruelle, 1990):⁷

$$\delta x(t) \sim \delta x(0) \exp(\lambda t) \quad (2.4.1)$$

Lyapunov *exponent* diukur oleh evolusi tingkat perubahan bentuk suatu bidang yang tak terbatas kecilnya pada radius ϵ dengan berkembangnya sistem sejalan dengan waktu:

$$L = \lambda = \lim_{t \rightarrow \infty} \frac{1}{t} \log \frac{\delta x(t)}{\delta x(0)} \quad (2.4.2)$$

dimana $\epsilon(t)$ adalah panjang dari *principal axis* ke *ellips* pada saat t .

Disini akan dibatasi pada yang terpenting yaitu *maximal Lyapunov exponent* $L_1(X)$. Anggap s_n dan s^A adalah 2 titik yang berada pada *state space* dalam *phase space* dengan jarak $|s_n - s_m| = \epsilon_0 \ll 1$. Maka $\delta_{n,m}$ merupakan jarak pada waktu n antara 2 lintasan yang berkembang dari titik-titik itu $A = V^n$; $|W_i - W_j|$. Sehingga $L_1(A)$ ditentukan dengan:

$$L_1 = \lim_{n \rightarrow \infty} \frac{1}{n} \ln \frac{\delta_{n,m}}{\epsilon_0} \quad (2.4.3)$$

Wolf et al (1985)⁸ mengembangkan metode untuk menghitung Lyapunov *Exponent* terbesar dalam dasar 2 merupakan hilangnya informasi dalam bits per iterasi

yang menunjukkan keandalan peramalan karena ketidakpastian. Peramalan jangka panjang akan mustahil karena semua informasi yang berguna hilang hanya dalam beberapa iterasi. Makin besar bit informasi maka makin tinggi ketidakpastian.

Brock (1986) dan lainnya menunjukkan bahwa jika Lyapunov *Exponent* terbesar positif maka sistem itu *chaotic* (Atchison & White, 1996). Bila L , positif, lintasan yang berdekatan divergen secara eksponensial. Dua lintasan tidak dapat terpisah lebih jauh dari ukuran *attractor*-nya. Ketentuan L , di atas hanya berlaku selama waktu D_n dimana d_{0n} tetap kecil. Persamaan *largest lyapunov exponent* bagi sejumlah data tak terhingga tanpa *noise*:

$$L = \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n \ln |f'(x_i)| \quad (2A4)$$

Sedangkan bagi sejumlah data diskrit tertentu yang mengandung *noise* menjadi:

$$(2.4.5)$$

Data untuk algoritma Wolf bervariasi tergantung kompleksitas, minimum 10D titik data dan 10(D-1) periode orbit sehingga perlu menentukan dimensi sebelum estimasi lyapunov *exponent*. Algoritma Wolf et al. (1985) ialah metode pertama estimasi Lyapunov *exponent* pada *time series* hanya dengan *delay reconstruction* dalam *phase space*. Asumsinya ada *exponential divergence* yang menghasilkan nilai *exponent* terhingga untuk data stokastik yang sebenarnya tak terhingga. Hasil estimasi sangat sensitif terhadap *noise*.⁹

Hasil Penelitian, Analisa Dan Implikasi

Hasil penelitian dan pembahasan yang lebih lengkap dapat dilihat pada Bakara (2004) dan juga dapat diberikan berdasarkan permintaan ke penulis. Data *time series* bersumber dari *database* di Bursa Efek Jakarta berupa data penutupan harian IHSG. Data mingguan diambil akhir minggu. Data bulanan pada akhir bulan. Jangka waktu dan jumlah titik data ada pada label 1. Perlakuan terhadap data yang "hilang" karena hari libur dalam hari perdagangan menggunakan metode interpolasi¹⁰:

$$P = \frac{A_j - A_{j-1}}{S_j - S_{j-1}} \quad (3.1)$$

7 dalam Gwilym, O. AP., Brooks, C., Clare, A., Thomas, S. (1999), "Tests of Non-Linearity Using Liffe Futures Transactions Price Data", *The Manchester School*, 67/2, 175
 8 Wolf, A., Swift, J. B., Swinney, H. L. and Vastano, J. a. (1985), "Determining Lyapunov Exponents from a Time Series", *Physica D*, 16, 285-317 dalam Peters (1991 & 1994); Kantz & Schreiber (1997); Bask, Mikael (1998); Gwilym, O. AP., Brooks, C., Clare, A., Thomas, S. (1999)
 9 dalam Gwilym, O. AP., Brooks, C., Clare, A., Thomas, S. (1999), "Tests of Non-Linearity Using Liffe Futures Transactions Price Data", *The Manchester School*, 67/2, 176
 10 dalam Ekaputra, I. A. (2003), "Studi Tentang Dinamika Intrahari Saham di Bursa Efek Jakarta", Disertasi, Program Pascasarjana, Fakultas Ekonomi, Universitas Indonesia

Tabel 2. Hasil Uji BDS Statistic

dimana D_t adalah interval pengamatan, dan adalah indeks sebelum. *Return series* diukur menggunakan *return* berbentuk logaritma natural yang dikenal dengan *continuously compounded return* (Campbell, Lo dan McKinlay, 1997):

$$R_t = 1n(P/P_M) \quad (3.2)$$

dimana R_t adalah log *return* pada observasi ke- i , P_t adalah indeks pada observasi ke- i dan P_M adalah indeks pada observasi ke- $i-1$.

Pengujian *chaotic* dengan metodologi *RS Analysis*, *Correlation dimension* dan *Lyapunov Exponent* menggunakan *listing program* dari Ki Eng Tjun (2001). Pengujian nonlinieritas menggunakan *BDS statistic* yang software *programnya* dari Kocenda (2001) dan berasal dari Dechert *etal.* (1996). Dalam artikel kali ini belum diterapkan pemfiteran.

3.1 Pengujian Nonlinieritas - BDS Statistic

Pengujian *BDS Statistic* diterapkan untuk melihat adanya *nonlinear dependence*. Hipotesa nol *BDS statistic* adalah *random* atau *IID (Identically Independent Distribution)*. *BDS Statistic* sensitif terhadap *short term dependence* karena dapat menangkap adanya proses *dependence* baik linier maupun nonlinier. Uji *BDS* tidak langsung menunjukkan *chaotic* affracfortapi mempunyai kemampuan terhadap hipotesa *dependence*, karena *linear dependence*, *nonstationarity* dan proses *nonlinear stochastic (Hsieh, 1991)*.

Hasil uji *BDS statistic* disajikan pada Tabel 2. Seluruh *series IHSG* harian, mingguan dan bulanan menolak hipotesa nol bahwa data *series* tersebut *IID (random)*. Hal ini dapat terjadi bila suatu *series*

JN													
		Harian	Mingguan	Bulanan	Harian	Mingguan	Bulanan	Harian	Mingguan	Bulanan	Harian	Mingguan	Bulanan
2	0.5	2.56E+01	7.93E+00	1.19E+00	4.61 E+02	1.94E+02	5.71E+01	-1.03E-01	-9.81 E-01	9.32E-02	1.30E+00	-4.81 E-01	-8.15E-01
3	0.5	3.35E+01	1.02E+01	1.12E+00	8.81E+02	3.65E+02	854E+01	-2.95E-01	-1.25E+00	1.14E-01	1.87E+00	-2.33 E-01	-8.02E-01
4	0.5	4.08E+01	1.16E+01	1.28E+00	1.85E+03	7.04E+02	1.36E+02	-4.28E-01	-7.26E-01	-2.80E-01	157E+00	-3.53E-01	-1.14E+00
5	0.5	4.96E+01	1.32E+01	1.75E+00	4.25E+03	1.52E+03	2.37E+02	7.98E-03	-3.64E-01	-4.60E-01	1.19E+00	-2.53E-01	-1.30E+00
6	0.5	6.09E+01	1.48E+01	1.45E+00	1.04E+04	3.49E+03	4.38E+02	1.83E-01	-1.97E-01	-3.95E-01	1.12E+00	-1.45E-01	-1.78E+00
7	0.5	7.74E+01	1.67E+01	1.52E+00	2.87E+04	8.40E+03	8.50E+02	4.07E-01	-2.90E-01	-2.65E-01	1.36E+00	-4.82E-01	-2.01 E+00
a	0.5	1.01 E+02	1.89E+01	2.32E+00	7.10E+04	2.10E+04	1.75E+03	4.59E-01	-1.96E-01	-1.31 E-01	1.12E+00	-6.63E-01	-2.28E+00
9	05	1.33E+02	2.25E+01	2.81 E+00	1.94E+05	5.38E+04	3.65E+03	4.85E-01	-1.06E-02	-1.29E-01	1.03 E+00	-5.84E-01	-2.10E+00
10	05	1.81 E+02	2.78E+01	1.85E+00	5.42E+05	1.41E.05	6.00E+03	5.64E-01	3.51 E-01	-1.83E-01	6.75E-01	-4.29E-01	-1.71E+00
2	0.75	2.47E+01	7.95E+00	1.75E+00	2.91 E+02	1.55E+02	4.09E+01	-6.32E-02	-1.01 E+00	-1.71 E-01	1.09E+00	-3.06E-01	-2.72E-02
3	0.75	3.01 E+01	9.83E+00	1.37E+00	4.29E+02	1.80E+02	523E+01	-3.91 E-01	-9.22E-01	-1.12E-02	1.61 E+00	-2.41 E-01	-8.14E-01
4	0.75	3.43E+01	1.08E+01	1.26E+00	6.68E+02	2.72E+02	6.84E+01	-5.53E-01	-4.45E-01	-5.62E-02	1.34E+00	-7.30E-01	-1.74E+00
5	0.75	3.86E+01	1.14E+01	1.71 E+00	1.11E+03	4.36E+02	9.42E+01	+6.96E-02	-3.92E-02	-1.33E-01	8.72 E-01	-9.27 E-01	-2.18E+00
6	0.75	4.33E+01	1.20E+01	2.01 E+00	1.93E+03	7.32E+02	1.35E+02	2.25E-01	8.51E-02	-6.48E-02	1.07E+00	-1.28E+00	-3.39E+00
7	0.75	4.95E+01	1.27E+01	2.36E+00	3.49E+03	1.78E+03	1.99E+02	4.45E-01	-4.89E-02	1.22E-01	1.21 E+00	-1.60E+00	-3.51 E+00
a	0.75	5.73E+01	1.36E+01	2.91 E+00	5.53E+03	2.99E+03	3.05E+02	6.16E-01	1.71E-01	2.95E-01	1.62E+00	-2.56E+00	-4.07E+00
9	0.75	6.89E+01	1.48E+01	3.45E+00	1.25E+04	4.23E+03	4.75E+02	6.14E-01	4.98E-01	2.72E-B1	1.67E+00	-3.18 E+00	-3.84E+00
10	0.75	7.94E+01	1.65E+01	4.21 E+00	3.46E+04	1.93E+03	7.81 E+02	7.23E-01	9.42E-01	2.21 E-01	1.36E+00	-3.45E+00	-3.04E+00
2	1.00	2.36E+01	8.74E+00	1.60E+00	2.20E+02	9.40E+01	3.45E+01	-8.90E-01	-5.86E-01	3.20E-01	6.08E-01	4.41 E-01	-2.73E-01

3	1.00	2.78 E+01	1.00E+01	1.18E+00	2.76E+02	1.17E+02	3.99E+01	-1.20E+00	-1.98E-01	2.27E-01	5.25E-01	3.03E-01	-1.59E+00
4	1.00	3.04E+01	1.08E+01	1.21 E+00	3.56E+02	1.49E+02	4.68E+01	-1.16E+00	2.71 E-01	1.48E-01	3.76E-01	6.79E-02	-2.30E+00
5	1.00	3.27E+01	1.12E+01	1.51 E+00	4.80E+02	1.97E+02	5.63E+01	-5.94E-01	3.78E-01	-8.93E-02	3.02E-01	3.53E-02	-3.04E+00
6	1.00	3.48E+01	1.15E+D1	1.73E+00	6.71 E+02	2.69E+02	6.97E+01	-8.00E-02	4.08E-01	-2.07E-01	6.17E-01	1.36E-02	-3.71 E+00
7	1.00	3.74E+01	1.19E+01	1.97 E+00	9.67E+02	3.80E+02	8.84E+01	3.65E-01	2.66E-01	1.50E-02	9.21E-01	-4.40E-01	-4.61 E+00
8	1.00	4.05E+01	1.24E+01	2.05E+00	1.43E+03	5.48 E+02	1.14E+02	5.91 E-01	4.10E-01	3.14E-03	1.05E+M	-1.70E+00	-5.37E+00
9	1.00	4.40E+D1	1.30E+01	2.24E+00	2.16E+03	8.08E+02	1.50E+02	6.13E-01	6.69E-01	-1.66E-01	1.54E+00	-2.93E+00	-5.18E+00
10	1.00	4.84E.01	1.37E+01	2.56E+00	3.33E+03	1.21E+03	2.04E+02	7.48E-01	9.80E-01	-3.27E-01	1.79E+00	-3.88E+01	-5.51 E+00

BDS Statistic tabulated value (Brock et al. 1987):

250 observations: m:	Significance Level 5%	
	EJSD=0,5	EISD=1
2	2.350	1.860
3	2.590	1.910
4	3.020	1.980
5	3.880	2.100

Significance Level 1%

E0-0,5	BSD=1
4.040	2.920
4.850	2.960
6.440	3.060

berstruktur *nonrandom*. Tapi belum tentu menunjukkan bahwa data benar-benar *random* karena jumlah observasi kurang memadai yaitu kurang dari 200 sehingga *nonstationary*. Dari uji stasioneritas series tidak dapat diharapkan bahwa BDS stambulan IHSJ serta series mingguan IHSJ *istic* data IID mendekati distribusi standar nonstasioner sedangkan series harian normal (Brock *et al.*, 1987). Series yang stasioner sehingga pada IHSJ bulanan dan diacak tiga kali dengan program *Shuffle* mingguan tidak menunjukkan bukti adanya dari Ki Eeng Tjun (2001) tidak dapat struktur nonlinier. Dari uji struktur korelasi menolak hipotesa nol IID. 3.2 R/S dengan diference d=1 meskipun stasioner tapi (*Rescaled range*) *Analysis overdifferencing* (Greene, 2000). Artinya ada R/S *analysis* merupakan pengamatan struktur nonlinier atau *long memory* pada persistensi. R/S *analysis* memungkinkan indeks karena memerlukan $0 < d < 1$. Maka pengukuran panjang siklus rata-rata *time* sebaiknya pada series indeks bulanan dan *series*. Dalam sistem nonlinier dinamis, mingguan dicoba pengujian BDS *statistic* panjang periode siklus rata-rata adalah dengan diferensiasi pada tingkat *fractional* panjang waktu yang diperlukan untuk artinya penggunaan proses ARFIMA. melupakan kondisi semula (*memory process*). Data harian dan mingguan series *return* menunjukkan struktur non IID dengan nonperiodik maka panjang siklus yang *significance level* 1% sehingga menolak hipotesa nol IID. Karena *series return* stasioner rata-

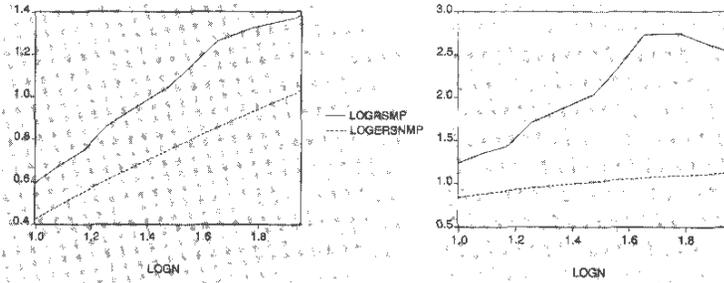
berarti terdapat struktur *dependence* dalam Untuk memperoleh nilai Hurst *Exponential* *return* harian dan mingguan. Series *return* H makadilakukan regresi OLS antara log n sebagai variabel bebas dan log R/S sebagai variabel terikat. Kemiringan $\log R/S - \log c + H \log n$ an nilai Hurst $F(3,3)$ nent H berdasarkan persamaan:

Bila *time series* tidak *random* maka pada nilai n tertentu *time series* akan

Tabel 1. Range Observasi *Series*

Indeks			Return								
Harian	Mingguan	Bulanan	Marian	Mingguan	Bulanan	Marian	Mingguan	Bulanan			
Range	Truk	Tri	Range	Tri	Range	Tri	Range	Tri			
4 Jan 88-21 Nop 03	414 5	8 Jan 88-21 Nop 03	82 9	29 Jan 88-21 Nop 03	19 1	5 Jan 88-21 Nop 03	414 4	15 Jan 88-21 Nop 03	82 8	29 Feb 88-21 Nop 03	19 0

konvergen ke nilai $H=0.5$ karena *memory effect* melemah ke suatu titik yang tidak terukur. Dengan kata lain, observasi saat ini diharapkan timbul sifat yang sama seperti reguler *Brownian motion* atau *random walk* pada saat *memory effect* ter-disipasi. Beberapa sistem mungkin mempunyai siklus memori yang pendek sehingga estimasi R/S akan menunjukkan persisten atau antipersisten hanya untuk subperiode n yang pendek. Observasi dahulu *plot log R/S* terhadap $\log n$ kemudian mengestimasi H hanya untuk porsi inier dari *plot* tersebut (Pandey *et. al.*, 1998). Regresi harus dilakukan pada area ini yaitu sebelum mencapai konvergensi pada $H=0.5$ label 3 merupakan hasil uji *R/S Analysis*. Gambar 1 *plot log R/S vs log n* dan *plot log V Statistic (log ers) vs log n* untuk data bulanan. Untuk series IHSG bulanan pada kurva *log R/S* terlihat patahan pada $n = 60$ (antilog $1.77815 = 60$) dimana patahan tersebut menjadi paralel dan sejajar dengan kurva *log ers* yang merupakan kurva *random*. Artinya setelah $n = 60$ kurva *log R/S* menjadi *random*. Ini menunjukkan bahwa *memory process* bekerja untuk nilai n kurang dari 60 bulan (5 tahun) karena range berhenti bertumbuh setelah mencapai titik $n = 60$. Pada titik $n = 60$ *memory process* terdisipasi dimana data yang terpisah lebih dari 60 bulan memiliki korelasi yang hampir tak terukur sehingga R/S mulai berperilaku *erratic* dan *random*. Patahan tampak jelas pada kurva *V statistic* (yaitu kurva $\log(R/S)^2$ dan $\log(E(R/S)_n)$ terhadap $\log n$). Pada gambar 1 tersebut *V statistic* berhenti naik setelah $n=60$, sehingga regresi harus dilakukan



Gambar 1. Indeks IHSG, *plot log R/S vs log n* dan *plot log V Statistic (log ers) vs log n*

pada $10 \times \ln 60$. label 4 menunjukkan hasil regresi $\log rs$ dan $\log ers$ terhadap $\log n$. $\log ers$ maupun $\log v$ merupakan *expected value* uji statistik untuk hipotesa *random*. Hurst *exponent H* terukur = 0.974397 dengan signifikansi sebesar 4.402 standar deviasi diatas nilai ekspektasinya dihitung dari:

$$\text{Signifikansi } H = \frac{E(H) - (H)}{SD} \quad (3.4)$$

dimana $SD = \sqrt{\text{jumlah titik data pengamatan}}$. Sehingga hipotesa nol bahwa series IHSG bulanan adalah *random* ditolak secara signifikan. Karena $H > 0.5$ dengan signifikansi lebih dari 1 (satu) maka *time series* ini tidak *random* tapi bersifat persisten. Dengan cara yang sama diperoleh bahwa hipotesa nol series IHSG mingguan adalah *random* ditolak secara signifikan dan series IHSG harian juga bukan *random*.

Jika series menunjukkan persistensi ($H > 0.5$) maka rasio R/S akan naik tapi saat melewati *random walk* ($H=0.5$) akan paralel dengan kurva $E(R/S)$ maka saat peralihan tersebut akan tampak patahan. Patahan juga terjadi ketika se-

ries yang semula persisten menjadi antipersisten. Jika series antipersisten ($H < 0.5$) maka rasio R/S akan menurun atau terletak dibawah kurva $E(R/S)$ dengan slope yang lebih rendah dari $E(R/S)$.

Dengan makin rendahnya frekuensi *sampling* (data bulanan) Hurst *exponent* diharap naik karena frekuensi *sampling* rendah mengurangi dampak *noise* dan menghilangkan dampak *fractional noise* yang ada pada frekuensi *sampling* tinggi. Hurst *exponent* yang tinggi pada data dengan frekuensi *sampling* lebih tinggi menunjukkan adanya *long range dependence*.

Periode siklus rata-rata untuk frekuensi *sampling* yang berbeda yaitu bulanan, mingguan dan harian menunjukkan konsistensi dimana diperoleh periode sekitar 5 tahun. Siklus yang konsisten pada ketiga frekuensi *sampling* ini dapat membuktikan bahwa series tersebut bukan *random*. Bila periode siklus rata-rata yang diperoleh untuk frekuensi *sampling* yang berbeda ini tidak konsisten maka berarti hasil bentuk patahan yang terlihat bukan menunjukkan periode siklus rata-rata sesungguhnya tetapi merupakan *artefact*.

Ketidakkonsistenan periode siklus rata-rata dapat terjadi karena *under-sampling* (Peters, 1991). Tidak ditemukannya periode siklus rata-rata karena jumlah titik data sampel tidak memadai disebut *undersampling* tipe 1 (satu). Bila jumlah titik data dianggap telah mencukupi maka 3 kemungkinan penyebab tidak ditemukannya periode siklus rata-rata: series tersebut *random*, antipersisten atau *true (pure) hurst process*.

Tabel 3. Hasil pengujian *R/S Analysis*

	Hurst Exponent (H)	E(H)	Standard Deviasi (s)	SIGNIFICANT	Fractional Differencing Parameter (d)	PERIOD, SUB-PERIOD & AVERAGE PERIOD
Marian						
Indeks	0.99659	0.56924	0.01566	27.29706	0.49659	10 - 1360 days / 5.23 years (antilog 3.133539 = 1360)
Return	0.66390	0.57277	0.01566	5.82105	0.16390	10 - 1020 days / 3.92 years (antilog 3.0086 = 1020)
Shuffle Indeks	0.49174	0.56532	0.01566	-4.70011	-0.00826	No average cycle length
Shuffle Return	0.55043	0.56532	0.01566	-0.95142	0.05043	No average cycle length
Mingguan						
Indeks	0.99613	0.60156	0.03581	11.01966	0.49613	10 - 260 weeks / 5 years (antilog 2.414973 = 260)
Return	0.65056	0.60828	0.03727	1.13444	0.15056	10 - 180 weeks / 3.46 years (antilog 2.255273 = 180)
Shuffle Indeks	0.56974	0.59406	0.03581	-0.67919	0.06974	No average cycle length
Shuffle Return	0.64836	0.59440	0.03727	1.44785	0.14836	No average cycle length
Bulanan						
Indeks	0.97440	0.64630	0.07454	4.40195	0.47440	10 - 60 months / 5 years (antilog 1.778151 = 60)
Return	0.64337	0.65790	0.07454	-0.19497	0.14337	10 - 45 months / 3.75 years (antilog 1.653213 = 45)
Shuffle Indeks	0.55133	0.63237	0.07454	-1.08714	0.05133	No average cycle length
Shuffle Return	0.54142	0.63237	0.07454	-1.22013	0.04142	No average cycle length

Siklus nonperiodik yang diperoleh dari R/S analysis dapat digunakan sebagai parameter perioda orbital rata-rata Q pada waktu pembentukan phase space untuk perhitungan correlation integral dan running average maximum Lyapunov Exponent. Karena Q adalah perioda rata-rata dari siklus aperiodic maka nilai yang mendekati Q dapat digunakan juga dan akan menghasilkan nilai yang serupa

dengan periode sebesar Q.

Pasar keuangan merupakan fractional noise untuk jangka pendek tetapi noisy chaos pada jangka panjang (Peters, 1994). Menurut Peters (1994) sistem yang mempunyai periode siklus konsistent tanpa tergantung pada periode sampling yang berbeda atau peningkatan waktu pengamatan/ukuran sampel maka sistem itu merupakan noisy chaos tapi jika

sebaliknya maka fractional noise. Series indeks IHSG merupakan noisy chaos.

Dengan Hurst Exponent dapat diperkirakan resiko. Nilai H (Hurst Exponent) yang tinggi menunjukkan noise yang lebih rendah, lebih persisten dan trend lebih jelas daripada nilai H yang rendah. Nilai H yang lebih tinggi berarti resiko lebih kecil karena noise lebih sedikit (Peters, 1994). Tapi nilai H yang tinggi beresiko tinggi atas perubahan mendadak. 3.3Estimasi Correlation dimension

Konsep correlation dimension yang digunakan di sini berdasarkan algoritma Grassberger dan Procaccia. Hasil pengukuran correlation dimension akan mengindikasikan derajat kebebasan sistem non linier (non linear degrees of freedom). Correlation dimension merupakan konsep kunci untuk menentukan bahwa sistem bekerja sebagai proses chaotic yaitu bila dimensinya (correlation dimension) tidak meningkat dengan peningkatan dimensi space (embedding dimension) dimana ia berada. Semakin rendah correlation dimension maka semakin tinggi kemungkinan chaos.

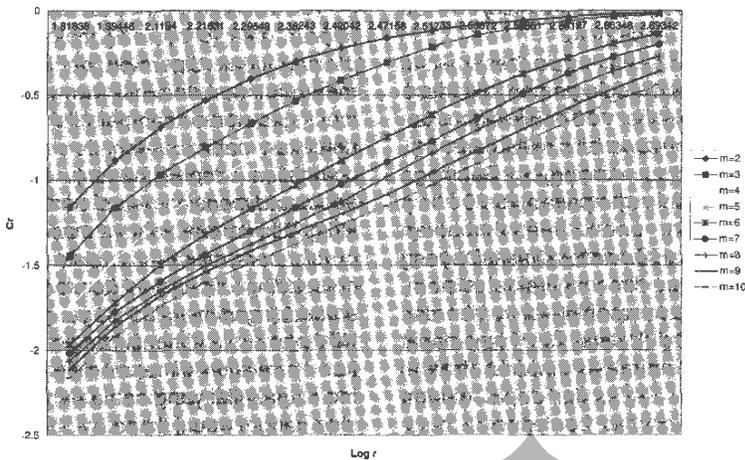
Dependent Variable: LOGERSNMP Met nod: Sample: 1 9 Least Squares				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.211926	0.013213		-16.03899
LOGN	0.646295	0.009526		67.84465
R-squared	Adjusted R-squared	S.E. of regression	Sum squared resid	Log likelihood
	0.998482	0.998265	0.00719	0.000362
Durbin-Watson stat	32.77619	0.564B7	Mean dependent var	S.D. dependent var
			0.669647	0.172593
			Akaike info criterion	Schwarz criterion
			6.839153	-6.795326
			F-statistic	Prob(F-statistic)
			4.602	897 0
Dependent Variable: LOGP.SMP Method: Sam Die: 1 9 Least Squares				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.378824	0.035489		-10.67455
LOGN	0.974397	0.023586		38.08369
R-squared	Adjusted R-squared	S.E. of regression	Sum squared resid	Log likelihood
	0.995197	0.994511	0.019311	0.00261
Durbin-Watson stat	23.88422	2.445013	Mean dependent var	S.D. dependent var
			0.950293	0.280541
			Akaike info criterion	Schwarz criterion
			4.819332	1,450.367 0
			F-statistic	Prob(F-statistic)
Dependent Variable: LOGERSNWP Method: Sample: 1 16 Least Squares				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.153494	0.013057		11.755760
LOGN	0.601562	0.007657		78.56406
R-squared	Adjusted R-squared	S.E. of regression	Sum squared resid	Log likelihood
	0.997737	0.997575	0.013441	0.002529
Durbin-Watson stat	47.31598	0.213947	Mean dependent var	S.D. dependent var
			0.837754	0.272968
			Akaike info criterion	Schwarz criterion
			5.664497	-5.567923
			F-statistic	Prob(F-statistic)
			6,172.312 0	
Dependent Variable: LOGRSWP Method: Sample: 1 16 Least Squares				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.400155	0.015297		-26.15904
LOGN	0.996129	0.008971		111.04330
R-squared	Adjusted R-squared	S.E. of regression	Sum squared resid	Log likelihood
	0.998866	0.998765	0.015747	0.003472
Durbin-Watson stat	44.78251	2.213007	Mean dependent var	S.D. dependent var
			1.241257	0.451754
			Akaike info criterion	Schwarz criterion
			5.347814	-525124
			F-statistic	Prob(F-statistic)
				12330.62 0
Dependent Variable: LOGERSNDP Method: Sample: 1 31 Least Squares				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.10088	0.010542		-9.569263
LOGN	0.569236	0.005083		111.986000
H-squared	Adjusted R-squared	S.E. of regression	Sum squared resid	Log likelihood
	0.997693	0.997613	0.017013	0.008394
Durbin-Watson stat	83.33356	0.088752	Mean dependent var	S.D. dependent var
			1.029007	0.348247
			Akaike info criterion	Schwarz criterion
			5.247327	*5154811
			F-statistic	Prob(F-statistic)
				12540.87 0
Dependent Variable: LOGRSDP Method: Sample: 1 31 Least Squares				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.396537	0.010627		-37.31459
LOGN	0.99658	0.005124		194.4951
R-squared	Adjusted R-squared	S.E. of regression	Sum squared resid	Log likelihood
	0.99923	0.999208	0.01715	0.008529
Durbin-Watson stat	83.08526	0.696455	Mean dependent var	S.D. dependent var
			1.58161	0.609223
			Akaike info criterion	Schwarz criterion
			5.138792	37828.36 0
			F-statistic	Prob(F-statistic)

			D
MONIH.Y	IH3G	255-2,62	3,471100%
	FBIFN	-0,06-0,03	0,02±20%
WGBO.Y	IHSG	2,456	
	RETJURJ		0,0004±20%
M.Y	IHSG	2,52-256	
	FEUFN	•OIS-00 2-7	0,0001±20%

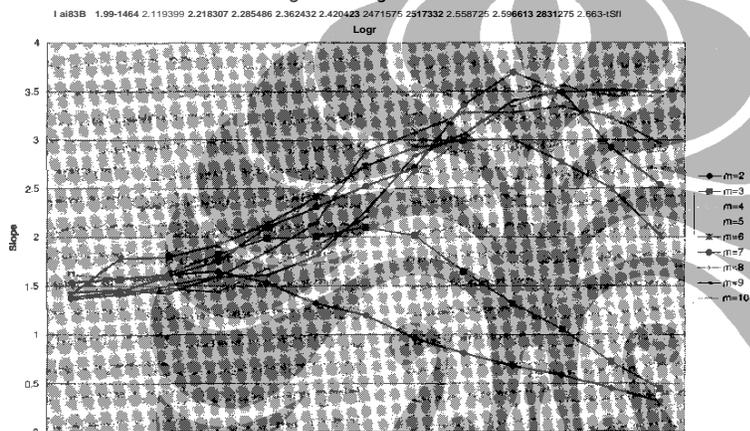
Dalam estimasi correlation dimension digunakan teknik diagnosa berikut (Hoque, 1995):

1. Grassberger Procaccia diagnostic Jika estimasi correlation dimension suatu series konvergen dengan perubahan embedding dimension dan jarak makseri tersebut chaotic.
2. Shuffle Diagnostic

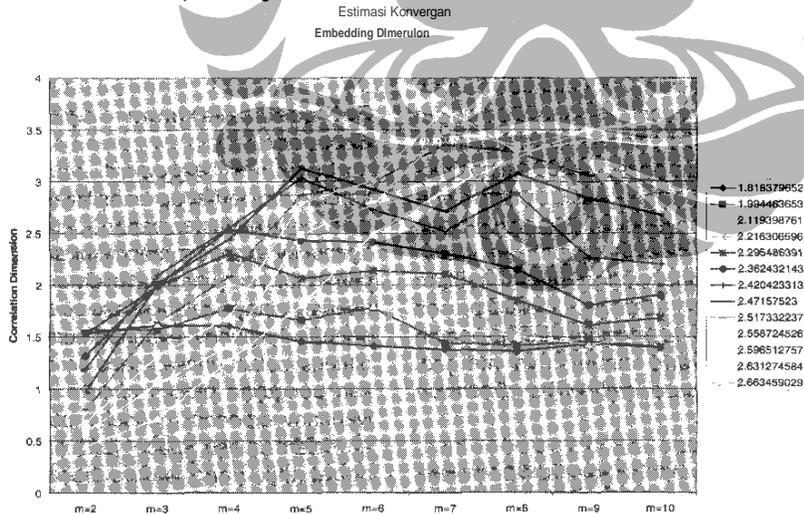
Metode ini diterapkan oleh Scheinkman dan LeBaron. Jika correlation dimension dari data series yang telah diacak lebih besar daripada sebelum diacak maka series tersebut chaotic. Pengacakan bertujuan untuk merusak setiap ketergantungan linier maupun "fionlinier.



Gambar 2. Correlation integral vs Log r: series IHSB harian



Gambar 3. Slope vs Log r: series IHSB harian



Gambar 4. Estimasi Konvergen Dimensi Fraktal: IHSB harian

label 5 menunjukkan hasil estimasi correlation dimension. Grafik plot correlation integral $\log C(m,r)$ vs $\log r$ untuk data harian IHSB dengan periode orbit sebesar 1300 (sekitar 5 tahun) terlihat pada gambar 2. Dari grafik tersebut tidak tampak jelas area yang merupakan garis-garis lurus dan paralel sebagai indikator *self-similarity* yang menunjukkan adanya struktur fraktal/perilaku *power law* pada $C(m,r)$. Pencarian garis-garis lurus (*straight lines*) dan paralel pada *plot correlation integral* sangat meragukan karena bisa terjadi kesalahan/kekeliruan pengamatan dengan mata. Maka lebih mudah melakukan *plot slope* dan mencari area *plateau* dimana kurva *slope convergence* dan konstan/stabil yang berarti ada garis lurus dan paralel. Gambar 3 merupakan *plot slope vs log r*. Area *plateau* pada *plot slope* berkorespondensi dengan daerah linier pada *plot correlation integral*.

Grafik *plot slope vs log r* dapat dibagi ke dalam

4 daerah berbeda tergantung jangkauan r dimulai dari skala r yang besar sampai skala r kecil:

1. Dalam daerah r yang besar (*Macroscopic regime*) yaitu daerah grafik paling kanan, *correlation integral* tidak memperlihatkan suatu *scaling* karena struktur makroskopis *attractor* menentukan nilainya, sehingga *local scaling exponent* bergantung pada *embedding dimension* dan r . Pada daerah ini skala *self similarity* dirusak oleh *cutoff* yang dihasilkan oleh ukuran tertentu *attractor*.
2. Dalam daerah r yang lebih kecil, *scaling range* yang baik dapat ditemukan. Pada sebuah *self similar object*, *local scaling exponent* akan konstan untuk semua *embedding dimension* $m > D$ (*correlation dimension object*). Jika tampak *plateau* yang meyakinkan maka *scaling exponent* dapat digunakan sebagai estimasi untuk *correlation dimension*.
3. Pada skala r yang lebih kecil lagi terletak daerah *noise*. Jika data mengandung *noise* maka pada skala r yang lebih kecil dari beberapa lipatan *noise level*, algoritma mendeteksi bahwa titik-titik data tidak dapat diinterpretasikan sebagai struktur fraktal, tetapi akan menyebarkan seluruh ruang fase.

Jika *local scaling exponent* naik sehingga r mencapai *noise level* maka *correlation integral* akan mencapai nilai *embedding dimension* (seperti gas yang memenuhi seluruh ruang tempatnya).

4. Dengan semakin mengecilnya r (daerah pal ing kiri grafik) maka ditemui masalah *lack of neighbours*, karena dengan r yang sangat kecil maka makin sedikit jumlah pasangan titik-titik yang dihitung. Kesalahan statistik menjadi efek dominan dan kurva amat berfluktuasi. Pada penelitian ini minimal jumlah pasangan titik-titik /neighbours ditetapkan 10. Lebih baik lagi bila digunakan nilai minimal lebih besar tapi karena keterbatasan jumlah titik data maka ini tidak dapat dilakukan.

Pada *plot slope* tidak ditemukan area *plateau* yang meyakinkan (hasilnya meragukan untuk menentukan dengan tepat adanya area *plateau*). Area *plateau* yaitu area dimana kurva *slop* konvergen ke arah *slop* yang konstan atau area dimana kurva *slop* mendatardankonstan/ stabil. Tetapi estimasi *areaplateau* (meski tidak tepat sebagai area *p/afeau*) ditunjukkan dengan nilai *slop* yang tidak banyak bervariasi/berubah meskipun berfluktuasi pada daerah estimasi *plateau* yaitu sekitar $\log r = 2.5173-2.5587$ dan *embedding dimension* $m = 8$. Dari estimasi area *plateau* diperoleh nilai *slop* kira-kira $3.28 \pm 10\%$ yang menunjukkan dimensi atraktor.

Biasanya konvergen terjadi saat *embedding dimension* *sebesar* atau lebih level *integer* di atas dimensi fraktal (Peters, 1991). Dimensi 3,28 didapat pada $m=3+3.28e^*6.28$. Menurut Whitney (1936)¹¹ *embedding* m terendah untuk memperoleh *correlation dimension* yang meyakinkan dimulai pada $m=2D+1$ tetapi D bukan dimensi fraktal melainkan *integer*, sehingga $m=(2*3)+1=7$. Sedangkan menurut Sauer et al (1993)¹² *embedding dimension* terendah yang meyakinkan dalam *phase space reconstruction* dimulai pada $m>2D_i$ dimana D_i adalah dimensi fraktal/non/nteger, sehinggam $>2*3.28>6.56$ yaitu dimulai pada $m=7$. Sementara Takens (1981)¹³ dengan *time delay embedding theorem* membuktikan bahwa $m=2D+1$ akan mulai *embedding* untuk

dimensi D , sehingga $m=(2*3.28)+1=7.56$ yaitu dimulai pada $m=8$.

Untuk m yang terlalu besar akan menyebabkan kebingungan algoritma (Kantz & Schreiber, 1997). Bila diteruskan ke *embedding dimension* mulai dari $m=11$ plot akan tidak konvergen. Sehingga perolehan konvergen pada $m=8-10$ cukup meyakinkan untuk menyimpulkan estimasi besar *correlation dimension* yang menunjukkan dimensi fraktal sistem. Dengan melakukan plot konvergen dari dimensi fraktal (Peters, 1991) juga dapat diperoleh estimasi dimensi fraktal (gambar 4). *Series* ini dapat diduga merupakan *chaotic* berdasarkan diagnosa Grasberger Procaccia yang diterapkan Hoque (1995).

Nilai estimasi *correlation dimension* untuk *return* tampak terlalu kecil (*underestimated*) dan estimasi kurang meyakinkan karena kemungkinan pemilihan skala kurang tepat, *noise* dan efek *temporal correlation* (Kantz & Schreiber 1997). Pemilihan skala dengan pembesaran atau pengecilan skala dapat merusak ataupun memperbaiki tampilan pembagian area pengamatan. Cara lainnya untuk memperbaiki estimasi: *noise iiltering/reduction* untuk menghilangkan *noise* pada daerah no/seditengah-tengah grafik yang ditunjukkan oleh kurva yang mencuat ke atas, dan menghilangkan *temporal correlation* yaitu korelasi yang terjadi antara titik-titik yang berdekatan dalam *phase space* (area dalam *phase space* dengan jarak lebih kecil dari r yang dipilih).

Tidak ditemukannya nilai *correlation dimension* yang meyakinkan bukan berarti sistem yang bersangkutan bukan *chaotic*. Jumlah titik data yang tidak cukup menyebabkan *phase space reconstruction* tidak dapat menghasilkan *phase portrait* yang meyakinkan. Ketidakcukupan jumlah titik data menyebabkan *phase space reconstruction* menghasilkan *phase portrait* dihasilkan melalui proses peregangan (*stretching*) dan pelipatan (*folding*) yang dimensinya menjadi konvergen pada *embedding dimension* lebih besar.

11 dalam Kantz, H. & Schreiber, T. (1997), "Nonlinear Time Series Analysis", Cambridge University Press, 126-127

12 ibid, 127

13 ibid, 127-130

Ketika dilakukan *shuffle* / pengacakan data (gambar 5) maka daerah *plateau* tidak diperoleh bahkan *slop* menunjukkan dimensi yang tinggi / meningkat terus (sampai nilai *slop*=6). Lonjakan pada daerah *noise* 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). Nilai *plot* kurva dimensi yang menunjukkan *correlation dimension* seharusnya mencapai nilai yang sama dengan nilai *slop* yang menunjukkan *embedding dimension* tapi tampaknya tidak demikian karena data masih kurang diacak (pengacakan hanya 3 kali). Maka seolah-olah pada objek masih ditemukan struktur *chaos* atau fraktal karena proses pengacakan komputer sebenarnya tidak sepenuhnya *random* tetapi *pseudo random* (*chaos*).

Shuffled merusak struktur korelasi antar titik-titik data tetapi besaran statistik seperti rata-rata, standardeviasi, kurtosis, *skewness*, dan Jarque-Bera tetap sama. Menurut Peters (1991) jika *time series* bukan *chaotic attractor*, maka *correlation dimension* harus tidak berubah. Bila merupakan *strange attractor* maka *scrambling* merusak struktur *attractor* dan *correlation dimension* akan meningkat lebih besar. Dari diagnosa *shuffle*, bila dimensi *attractor* sesudah *shuffle* lebih besar dahpada sebelumnya berarti ada *chaotic attractor*.

Estimasi Maximum Lyapunov Exponent

Lyapunov exponent mengukur kerentanan terhadap sensitifitas ketergantungan pada perubahan kondisi awal. *Lyapunov exponent* mengukur seberapa cepatorbrtyang berdekatan divergen satu dengan lainnya dalam *phase space*. Ada sebuah *lyapunov exponent* untuk tiap dimensi dalam *phase space*. Ini merupakan pengujian proses *chaotic*. *Positive* *lyapunov exponent* mengukur peregangan dalam *phase space* yaitu seberapa cepat titik yang sating berdekatan berdivergensi satu dengan lainnya. Sedangkan *negative* *lyapunov exponent* *mengukur kontraksi yaitu berapa lama

dibutuhkan untuk membentuk kembali setelah mengalami gangguan. Dengan kata lain *negative* lyapunov exponent mengukur jumlah orbit atau waktu yang dibutuhkan dalam plot phase space untuk kembali ke bentuk affractornya. Dalam pasar modal, peregangan pada phase spacedisebabkansentimenfaktorteknikal tap! nilai fundamental mendorong kembali ke range yang pantas.

Tapi pengujian lyapunov exponent adalah metode yang kurang potensial untuk mendeteksi adanya chaos dalam *time series financial*. Frank *etal.* (1988), Dechert dan Gencay (1992), Blank (1991),¹⁴ Abhyankar, Copeland, dan Wong (1997), Gwilym, Brooks, Clare dan Thomas (1999), dan Peters (1991) dengan algoritma yang berbeda-beda melakukan penghitungan estimasi *maximum* lyapunov exponent terhadap berbagai *time series financial* dan *macroeconomic*. Hanya Blank dan Peter yang berhasil menemukan *positive* lyapunov exponent dengan algoritma Wolf. Perhitungan estimasi *maximum* lyapunov exponent yang digunakan dalam penelitian ini memakai algoritma Wolf.

Menurut algoritma Wolf, *maximum* lyapunov exponent hanya dapat terdeteksi jika plot *running average* lyapunov exponent mengalami saturasi. Nilai saturasi *running average* lyapunov exponent adalah *maximum* lyapunov exponent. Namun chaos mensyaratkan nilai saturasi *running average* lyapunov exponent harus positif (Brock, 1986)¹⁵. Tapi *random noise* juga menghasilkan *maximum* lyapunov exponent yang positif dengan menggunakan algoritma Wolf yang sangat sensitif terhadap *noise*. Maka bila nilai *positive maximum* lyapunov exponent cukup besar berarti nilai tersebut tidak cukup bagus karena adanya *noise*. Disamping itu nilai *positive maximum* lyapunov exponent yang meyakinkan diperoleh bila mendekati seper rata-rata periode siklus (Peters, 1991).

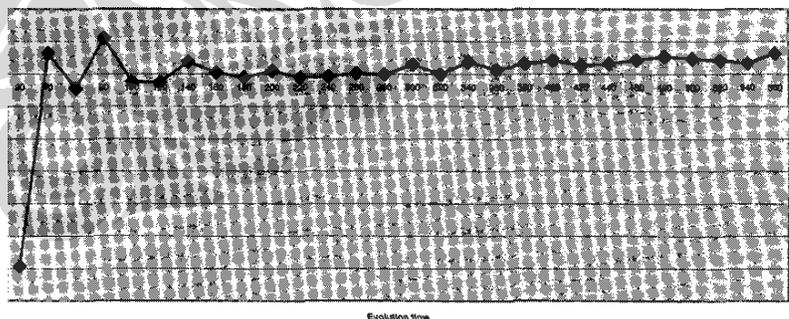
dalam Gwilym, O.AP., Brooks, C., Clare, A., dan Thomas S. (1999), "Tests of Non-Linearity Using Liffe Futures Transactions Price Data", *The Manchester School*, 67/2, 180 dalam Atchison, M. D. & White, M. A. (1996), "Disappearing Evidence of Chaos in Security Returns: A Simulation", *QJBE*, 35/2, 23

Gambar 6 memperlihatkan plot *running average* lyapunov exponent vs evolusi dengan menyesuaikan perubahan parameter-parameter *embedding dimension* dan *delay time*. Dari gambar dapat dilihat nilai saturasi *running average* lyapunov exponent pada IHSG mingguan sekitar 0.000758. Nilai lyapu-nov exponent yang positif menunjukkan series IHSGc/iaotfc. Hasil ini setara dengan seperperiode rata-rata siklus yang didapat dari pengujian RS *Analysis*. Dari RS *Analysis* didapat periode siklus rata-rata IHSG mingguan adalah 260 minggu (5 tahun). Nilai *positive maximum* lyapunov exponent 0.00385 setara dengan 1/260 dimana 260 minggu ialah rata-rata periode siklus nonperiodik mingguan.

Arti nilai 0.00385 yaitu sistem kehilangan 0.00385 *predictive power* untuk tiap iterasi atau orbit dalam hal ini tiap minggu. Ini disebut *bits of accuracy* yang mengukur seberapa besar diketahui tentang kondisi sistem saat ini. Konsep tersebut diambil dari konsep *entropy* *thermodynamic* yang mengukur *entropy* dalam *tats*. Semakin besar jumlah *bits* informasi yang masuk ke dalam sistem maka semakin tinggi *entropy* atau

semakin tidak pasti. Tabel 6. Hasil Estimasi Lyapunov Exponent
Nilai *positive*
Converganci LargHI Lyapunov Exponent (L1) WmKly pfict IHSG

Indeks IHSG			Return		
Monthly	Weekly	Daily	Monthly	Weekly	Daily
0.0166	0.00385	0.000758	0.0283	0.00445	0.000968



lyapunov expo-

Gambar 6. Lyapunov Exponent Estimation: sen'es IHSG mingguan

ment sebesar 0.00385 bits per minggu berarti tiap minggu ke depan kehilangan

saat ini akan diukur ke dalam satu bit *exponent* juga karena sistem tersebut presisi maka informasi menjadi tidak bukan *chaotic/nonlinear dynamic*.

0.00385 *bit predictive power*. Bila kondisi

berguna setelah 1/0.00385 (260 minggu). Jika diketahui pasti berapa nilai IHSG hari ini maka akan tetap mempunyai 0 persen akurasi untuk meramalkan nilai IHSG 260 minggu ke depan. Artinya pengaruh 1 bit informasi akan habis setelah 260 minggu dan sistem tidak akan mengingatnya lagi. Dengan mengetahui *maximum* lyapunov exponent akan menunjukkan seberapa andal peramalan untuk periode waktu mendatang. Mengingat pekanya algoritma Wolf terhadap *noise* dan keterbatasan jumlah titik data maka nilai ini cukup bagus karena memberikan gambaran bahwa lyapunov exponent bukan nilai positif sembarang yang terlalu besar.

Tabel 6 merupakan hasil estimasi LE. Bila nilai *positive maximum* lyapunov exponent lebih besar dari seperperiode rata-rata siklus berarti ada *noise*. Ketidakcukupan jumlah titik data sehingga tidak dapat diperoleh panjang periode rata-rata siklus merupakan salah satu penyebab estimasi nilai *maximum* lyapunov exponent menjadi negatif. Tidak diperolehnya estimasi *positive maximum* lyapunov exponent karena pemilihan nilai parameter-parameter untuk perhitungan tidak tepat,

yang merupakan kelemahan lyapunov exponent dengan algoritma wolf. Tidak

diperolehnya *positive maximum* lyapunov

3.5. Analisa Lanjutan

Dari BDS *statistic* hipotesa *random* ditolak untuk IHSG. Kemungkinan struktur *nonlinear* atau *long memory* untuk IHSG mingguan dan bulanan. Pada IHSG harian serta *return* harian dan mingguan terdapat struktur *dependence*. Untuk memastikan struktur *dependence* itu adalah *nonlinear long dependence* maka perlu difilter. Berdasarkan R/S *analysis*, IHSG dan *return* adalah persisten tapi menyarankan proses *random* untuk *return* bulanan. IHSG mempunyai periode rata-rata siklus yang konsisten sekitar 5 tahun.

Meski tidak diperoleh estimasi yang sangat meyakinkan tentang nilai *correlation dimension* karena kemungkinan masalah *noise* untuk IHSG dan masalah *temporal correlation* untuk estimasi *return* yang *underestimated* namun sementara dapat dikategorikan bahwa IHSG dan *return-nya* sebagai sistem chaos/c-sampai diterapkan pemfilteran dan penghilangan *temporal correlation*. Diperolehnya nilai estimasi *correlation dimension* yang bukan *integer* dan *low dimensional* menunjukkan adanya *self similarity* atau *fractal structure* yang merupakan karakteristik *chaos*. Ruelle (1991) berargumen bahwa data *chaotic* bila mempunyai *correlation dimension* dibawah $2\log_{10}N$ dimana N adalah jumlah titik observasi. Adanya karakteristik *sensitive dependence on initial condition* menunjukkan bahwa IHSG dan *returnnya* adalah *chaos*, tampak dari perolehan nilai *running average* estimasi *maximum lyapunov exponent* yang positif dan tidak terlalu besar dimana nilai itu konsisten dengan periode rata-rata siklus.

Implikasi

Hasil penelitian menunjukkan bahwa IHSG & *return-nya* lebih berstruktur *deterministic* (tertentu dan pasti) meskipun tampak *random* tapi bukan *random* melainkan *chaos*. Karena itu maka pemodelan *chaos* atau *nonlinear (long memory)* lebih tepat untuk prediksi atau analisa pemahaman sistem dan pemecahan masalah dibanding pemodelan lainnya karena menghasilkan *prediction error* lebih kecil (Kantz & Schreiber, 1997). Faktanya

memberikan keuntungan dari beda pendekatan *random* dan *chaos* untuk pengelolaan manajemen resiko serta untuk *trading* bagi *trader* dan *short investment horizon investor*.

Struktur *chaos* menunjukkan bahwa IHSG dapat diprediksi meski sulit dan hanya untuk prediksi jangka pendek, karena karakteristik/sifat fraktal yang dihasilkan sistem *chaos* membuat prediksi jangka panjang tidak memungkinkan. Berdasarkan hasil estimasi *correlation dimension* disimpulkan bahwa IHSG adalah *chaos* karena memiliki *strange attractor* berdimensi rendah sekitar 3,28. *Low dimensional chaos* menunjukkan bahwa ada sedikit faktor *deterministic* atau *explanatory variable* yang membentuk pergerakan IHSG, sehingga memungkinkan untuk membuat persamaan gerak sederhana yang terdiri dari beberapa variabel *deterministic* sebagai pemodelan untuk peramalan dan prediksi.

Dari nilai ini dapat dikatakan bahwa pola pergerakan IHSG dipengaruhi oleh paling sedikit 4 faktor atau 4 *degrees of freedom* yang berarti hanya dapat ditempatkan pada *embedding dimension* minimum 4. Artinya minimum ada 4 variabel faktor *deterministic* yang membentuk pergerakan indeks sehingga dapat dilakukan pemodelan dinamika fungsi pergerakan IHSG dengan 4 variabel. Pencarian variabel-variabel yang meragukan harus dihindari tapi harus fokus pada kekuatan-kekuatan *fundamental (fundamental forces)* yang berasal dari dalam sistem. Tidak perlu mencari variabel lainnya yang mempengaruhi sistem sebab variabel lainnya sudah embedded/terwakili dalam 4 variabel/dimensi tersebut. Dimensi lainnya telah dinyatakan dalam *embedding dimension* terendah tersebut.

Chaos theory menyatakan bahwa perilaku *chaotic* pergerakan IHSG dibangun melalui interaksi *interdependent* variabel-variabel yang berasal dari dalam sistem pasar modal (*endogen*). Gangguan dari luar (*eksogen*) sampai pada tingkat tertentu (*critical points*) menyebabkan perilaku *chaotic*. Mengingat sulitnya mengukur

besaran faktor *fundamental* dan membangun model peramalan yang baik dari data empiris maka prediksi jangka pendekpun tidak mudah. Penentuan nilai koefisien yang tepat untuk variabel *fundamental* yang telah dipilih tidak mudah. Range parameter untuk koefisien itu harus dibatasi sehingga perilaku model sesuai dengan perilaku sistem empiris yang dimodelkan.

Karena sifat dari sistem *chaos (feedback effect, critical points, fractal structure dan sensitive dependence on initial condition)* maka *chaos theory* membantu pemahaman lebih mendalam tentang pasar modal dan perilakunya. Pemahaman ini membantu pelaku pasar dan regulator mengambil tindakan dan keputusan, terutama dalam kaitannya dengan krisis. Pemahaman karakteristik sistem *chaos* dan periode siklus yang tidak periodik dengan perulangan yang meskipun serupat tetapi tidak sama karena berbeda skala dan besarnya akan membantu *regulator* dalam mengatasi, mengelola dan menghadapi krisis.

Dalam penciptaan struktur *chaos* faktor makro dan mikro saling tarik menarik/membuat *frange* yang menyebabkan *trajectory* meregang dan melipat sehingga membentuk pola *phase portrait* tertentu yang tetap dan berdimensi tetap karena *self organizing*. Meskipun bentuk *phase portrait* tetap namun pergerakan titik-titik yang membentuk lintasan (*trajectory*) dalam *phase space* tidak pernah terulang atau kembali pada lintasan yang sama. Pergerakan IHSG tidak pernah terulang lagi prosesnya tepat sama dengan yang pernah terjadi. Tidak ada dua peristiwa sebab akibat yang tepat sama tapi hanya mirip (*self similarity*) yaitu hampir sama polanya dengan ukuran skala berbeda.

KESIMPULAN

Karena belum diterapkan pemfilteran, penghilangan *temporal correlation* maupun penerapan skala yang berbeda maka untuk sementara hasil penelitian ini menunjukkan adanya kemungkinan *nonlinearity, chaos dan fractal yang persistent* pada indeks IHSG dan *return*, artinya bukan *random*

(menolak hipotesa *random*) meskipun tampak *random*.

Uji *BDS statistic* menunjukkan bahwa *IHSG* dan *return* nonlinier kecuali *IHSG* bulanan. Dari uji *R/S analysis* untuk melihat *persistensi*, indeks dan *return IHSG* adalah *noisy chaotic* yaitu *random* pada jangka pendek dan persisten pada jangka panjang. *Correlation dimension* untuk *series return* terlalu rendah karena masalah *temporal correlation*. Pengujian *correlation dimension* menolak hipotesa *random* dan diperoleh dimensi fraktal yang rendah yaitu 3.4 untuk *IHSG*. Penemuan dimensi fraktal yang *low dimensional* menunjukkan *adany a self similarity* yang adalah karakteristik *chaos*. Pengujian *lyapunov exponent* memperoleh nilai *running average* yang positif dan tidak terlalu besar artinya ada *sensitive dependence on initial condition* yaitu karakteristik *chaos*, H

DaftarPustaka

- Abhyankar, A., Copeland, L. S. & Wong, W. (1997). Uncovering Nonlinear Structure in Real-Time Stock-Market Indexes: The S&P 500, the DX, the Nikkei 225, and the FTSE-100. *Journal of Business & Economic Statistics*, 15, 1-14.
- Amilon, Henrik & Bystrom, Hans, N. E. (1998). The Search for Chaos and Nonlinearities in Swedish Stock Index Returns. *Working Paper, Department of Economics, Lund University*, 006, 1-24.
- Atchison, Michael, D. & White, Mark A. (1996). Disappearing Evidence of Chaos in Security Returns: A Simulation. *QJBE*, 35, 21-37.
- Bakara, Minamita, Y.V. (2004). *Chaos in Emerging Capital Market: Sebuah Studi Empiris dari Bursa Efek Jakarta*, Tesis, Program Pascasarjana, Fakultas Ekonomi, Universitas Indonesia.
- Barnett, William, A. & Choi, Seungmook, S. (1989). A Comparison between the Conventional Econometric Approach to Structural Inference and the Nonparametric chaotic Attractor Approach. In Barnett, W. A., Geweke, J. & Shell, K., eds. *Economic Complexity, Chaos, Sunspots, Bubbles and Nonlinearity* (141 -212). Cambridge University Press.
- Barnett, William, A., Gallant, Ronald, A., Hinich, Melvin, J., Jungeilges, Jochen, A., Kaplan, Daniel, T. & Jensen, Mark J. (1997). A single-blind controlled competition among tests for nonlinearity and chaos. *Journal of Econometrics*, 82, 157-192.
- Campbell, John, Y., Lo, Andrew, W. & MacKinlay, A., Craig (1997). *The Econometrics of Financial Markets*, Princeton University Press, New Jersey.
- Ekaputra, Irwan, A. (2003) *Studitentang Dinamika Intrahari Saham di Bursa Efek Jakarta*, Disertasi, Program Pascasarjana, Fakultas Ekonomi, Universitas Indonesia.
- Greene, William, H. (2000). *Econometric Analysis* (4th ed.). Prentice Hall, Inc.
- Gwilym, O., AP., Brooks, C., Clare, A. & Thomas, S. (1999). Tests of Non-Linearity Using Life Futures Transactions Price Data. *The Manchester School*, 67, 167-186.
- Hoque, Monzurul (1995). Impetus for Future Growth in the Globalization of Stock Investments: Evidence from Joint Time Series and Chaos Analyses. *Managerial Finance*, 21, 62-75.
- Kantz, Holger & Schreiber, Thomas (1997) *Nonlinear Time Series Analysis*. Cambridge University Press.
- Ki, E. Tj. (2001). *Chaos dalam Future Prices CPO: Study empiris pada commodity and monetary exchange of Malaysia*. Tesis. Magister Manajemen, Fakultas Ekonomi, Universitas Indonesia.
- Kocenda, Evzen (2001). An alternative to the BDS test: Integration across the correlation integral. *Econometric reviews*, 20, 337-351.
- Kyrtsou, Catherine & Terraza, Michel (2000). Is it possible to study jointly chaotic and ARCH behaviour? Application of a noisy Mackey-Glass equation with heteroskedastic errors to the Paris Stock Exchange returns series. *CNRS UPRES-A*, 5474,1 -16.
- Lo, Andrew, W. & MacKinlay, A. Craig (1999). *A Non-Random Walk Down Wall Street*, Princeton University Press.
- Olmeda, Ignacio & Perez Joaquin (1995). Non-Linear Dynamics & Chaos in the Spanish Stock Market. *Investigaciones Economicas*, 79, 217-248
- Pandey, Vivek, Kohers, Theodor & Kohers, Gerald (1998). Deterministic nonlinearity in the Stock Returns of Major European Equity Markets and the United States. *The Financial Review*, 33, 45-64.
- Peters, Edgar E. (1991). *Chaos and order in the Capital Markets: A new view of cycles, prices, and market volatility*. John Wiley & Sons, Inc.
- Peters, Edgar E. (1994). *Fractal Market Analysis: Applying chaos theory to investment and economics*, John Wiley & Sons, Inc.

Pimpinan, Staf dan Karyawan Lembaga Management FEUI dan Majalah USAHAWAN Mengucapkan :



Lembaga Management

FAKULTAS EKONOMI UNIVERSITAS INDONESIA



SELAMAT
IDUL FITRI
1 Syawal 1426 H

maaf lahir bathin