

Monika Miśkiewicz-Nawrocka

Uniwersytet Ekonomiczny w Katowicach
Katedra Matematyki
monika.miskiewicz@ue.katowice.pl

WPŁYW OPTYMALNYCH PARAMETRÓW REDUKCJI SZUMU LOSOWEGO NA IDENTYFIKACJĘ CHAOSU W EKONOMICZNYCH SZEREGACH CZASOWYCH

Wprowadzenie

Rzeczywiste szeregi czasowe (s_t) składają się z części deterministycznej (y_t) oraz części stochastycznej (ε_t), która wyraża poziom szumu losowego. Redukcja szumu losowego pozwala poznać własności szeregu (y_t) na podstawie analizy szeregu obserwacji (s_t). Jedną z metod redukcji poziomu szumu losowego jest metoda najbliższych sąsiadów.

Celem artykułu było zbadanie wpływu procesu redukcji szumu losowego metodą najbliższych sąsiadów na identyfikację chaosu w szeregach czasowych. Badania empiryczne przeprowadzono na podstawie rzeczywistych danych natury ekonomicznej – szeregi finansowe utworzone z logarytmów dziennych stóp zwrotu cen zamknięcia wybranych indeksów giełd światowych. Dane obejmują okres od 3.01.2000 do 26.08.2013. Do przeprowadzenia niezbędnych obliczeń wykorzystano program napisany przez autora w języku Delhi, arkusz kalkulacyjny Excel oraz program TISEAN.

1. Redukcja szumu losowego metodą najbliższych sąsiadów

Rzeczywisty szereg czasowy można opisać za pomocą układu równań:

$$x_{t+1} = f(x_t + \eta_t), \quad (1)$$

$$s_{t+1} = h(x_{t+1}) + \xi_t, \quad t = 0, 1, 2, \dots \quad (2)$$

gdzie:

- $f : X \rightarrow X$ – funkcja opisująca rzeczywistą dynamikę układu,
 $h : X \rightarrow R$ – funkcja pomiarowa generująca szereg czasowy obserwacji s_t układu dynamicznego, $X \subset R^m$,
 X – przestrzeń stanów, $x_t, x_{t+1} \in X$ – stan nieznanego, pierwotnego układu wielowymiarowego odpowiednio w chwilach t , $t+1$, s_{t+1} – obserwacja szeregu czasowego w chwili $t+1$,
 η_t – szum dynamiczny wewnątrz układu,
 ξ_t – szum pomiarowy.

W skrócie, szereg czasowy opisany równaniami (1) – (2) można zapisać jako:

$$s_t = y_t + \varepsilon_t, \quad (3)$$

gdzie:

- s_t – obserwacja szeregu czasowego w momencie t ,
 y_t – część deterministyczna szeregu czasowego,
 ε_t – część stochastyczna szeregu czasowego (szum losowy).

Podstawą metody najbliższych sąsiadów służącej do redukcji szumu losowego jest rekonstrukcja przestrzeni stanów [10], która pozwala na podstawie jednowymiarowego szeregu czasowego obserwacji odtworzyć przestrzeń stanów układu dynamicznego. Elementami zrekonstruowanej przestrzeni stanów są wektory opóźnień tzw. d -historie postaci:

$$s_t^d = (s_t, s_{t-\tau}, \dots, s_{t-(d-1)\tau}), \quad (4)$$

gdzie:

- s_t – obserwacja szeregu czasowego w momencie t ,
 d – wymiar zanurzenia,
 τ – opóźnienie czasowe, $(d-1)\tau + 1 \leq t \leq N$.

Szacowanie wartości części deterministycznej y_n , $1 < n < N$ szeregu czasowego (s_1, s_2, \dots, s_N) metodą najbliższych sąsiadów odbywa się według następującej procedury [3]:

1. Dla oszacowanego wymiaru zanurzenia d oraz opóźnienia czasowego $\tau = 1$ tworzy się wektor opóźnień postaci:

$$s_t^d = (s_t, s_{t-1}, \dots, s_{t-(d-1)}), \quad (5)$$

tak aby filtrowana obserwacja s_n była jedną ze środkowych współrzędnych wektora s_t^d .

2. Wyznacza się k najbliższych sąsiadów (w sensie odległości euklidesowej) wektora s_t^d :

$$s_{l(1)}^d, s_{l(2)}^d, \dots, s_{l(k)}^d. \quad (6)$$

3. Na podstawie pierwszych współrzędnych najbliższych sąsiadów wektora s_t^d , oblicza się wartość y_n według wzoru:

$$y_n = \frac{1}{k} \sum_{i=1}^k s_{l(i)}, \quad (7)$$

gdzie:

$s_{l(i)}$ – pierwsza współrzędna wektora $s_{l(i)}^d$.

Do oceny skuteczności stosowanej metody filtracji można zastosować współczynnik poziomu redukcji szumu *NRL*, który bada zależność pomiędzy siłą szumu dodawanego do układu a strukturą geometryczną jego atraktora. Współczynnik *NRL* dany jest wzorem [7]:

$$NRL(d) = \frac{\sum_{i=1}^T d_i}{\sum_{i=1}^T D_i}, \quad (8)$$

gdzie:

d_i i D_i – odległości i -tego wektora opóźnień (d -historii) odpowiednio od jego najbliższego i najdalszego sąsiada.

2. Identyfikacja dynamiki chaotycznej w szeregach czasowych

Do podstawowych narzędzi teorii nieliniowych układów dynamicznych, służących do identyfikacji deterministycznego chaosu należą największy wykładnik Lapunowa oraz wymiar korelacyjny układu¹. Wartość największego

¹ Metody identyfikacji chaosu pozwalają na wykrycie jedynie pojedynczego atrybutu dynamiki chaotycznej. Zatem przeprowadzenie pełnej analizy danych wymaga uwzględnienia uzupełniających się metod (testu BDS, analizy przeskalowanego zakresu R/S, wymiaru fraktalnego szeregu, testu Kaplana, analizy bispektrum lub testu White'a za pomocą sieci neuronowych).

wykładnika Lapunowa mierzy wrażliwość układu dynamicznego na zmianę warunków początkowych, która jest podstawowym atrybutem dynamiki chaotycznej. Natomiast szacowanie wartości wymiaru korelacyjnego pozwala zmierzyć złożoność układu i określić liczbę zmiennych układu.

2.1. Największy wykładnik Lapunowa

Dla układu dynamicznego (X, f) wykładniki Lapunowa definiuje się jako granice [11]:

$$\lambda_i(x_0) = \lim_{n \rightarrow \infty} \frac{1}{n} \ln |\mu_i(n, x_0)|, \quad i = 1, \dots, m, \quad \text{dla } m \geq 1, \quad (9)$$

gdzie:

- $\mu_i(n, x_0)$ – wartości własne macierzy Jacobiego odwzorowania f^n ,
- f^n – n -krotne złożenie funkcji f, X ,
- f – j.w.

W praktyce, dla rzeczywistych szeregów czasowych, gdy nie jest znana funkcja generująca f , największy wykładnik Lapunowa szacuje się na podstawie zależności:

$$\Delta_n \approx \Delta_0 \cdot e^{n\lambda_{\max}}, \quad (10)$$

jako współczynnik kierunkowy równania regresji:

$$\ln \Delta_n = \ln \Delta_0 + \lambda_{\max} n, \quad (11)$$

gdzie:

- Δ_0 – początkowa odległość pomiędzy dwoma początkowo bliskimi (w sensie metryki euklidesowej) wektorami zrekonstruowanej przestrzeni stanów,
- Δ_n – odległość pomiędzy tymi wektorami po n iteracjach,
- λ_{\max} – największy wykładnik Lapunowa [3;11].

Dodatnia wartość największego wykładnika Lapunowa jest bardzo często uznawana jako warunek konieczny i wystarczający obecności chaosu w układzie dynamicznym.

2.2. Wymiar korelacyjny

Wymiar korelacyjny atraktora układu dynamicznego jest nazywany granicą [3;8]:

$$D_C = \lim_{\varepsilon \rightarrow 0} \frac{\ln C(d, \varepsilon, t)}{\ln \varepsilon}, \quad (12)$$

gdzie:

$C(d, \varepsilon, t) = \lim_{n \rightarrow \infty} C(d, n, \varepsilon, t)$ – całką korelacyjną daną wzorem:

$$C(d, n, \varepsilon, \tau) = \frac{2}{n(n-1)} \sum_{j=1}^n \sum_{i=j+1}^n I(\varepsilon - \|x_i^d - x_j^d\|), \quad \varepsilon > 0, \quad (13)$$

$$I(a) = \begin{cases} 0, & a < 0 \\ 1, & a \geq 0 \end{cases},$$

x_i^d – wektor d -wymiarowej zrekonstruowanej przestrzeni stanów,

τ – opóźnienie czasowe.

Dla rzeczywistych szeregów czasowych wartość wymiaru korelacyjnego szacuje się jako współczynnik kierunkowy równania regresji [7;11]:

$$\ln C(\varepsilon) = D_C \cdot \ln \varepsilon + a, \quad (14)$$

gdzie:

a – stała.

Wartość wymiaru korelacyjnego D_C wyznacza się dla kolejnych wartości wymiaru zanurzenia d . Dla szeregów deterministycznych wartość wymiaru D_C powinna stabilizować się na pewnym poziomie równym szacowanemu wymiarowi korelacyjnemu. Dla szeregów losowych wymiar D_C powinien w przybliżeniu być równy wymiarowi zanurzenia d [5].

3. Badania empiryczne

Przedmiotem badania były logarytmy dziennych stóp zwrotu indeksów giełd światowych: CAC40 – indeks na Giełdzie Papierów Wartościowych w Paryżu (CAC), HANGSENG – indeks na Giełdzie Papierów Wartościowych w Hongkongu (HSI), NIKKEI225 – indeks na Giełdzie Papierów Wartościowych w Tokio (NKX), SENSEX 30 – indeks na Giełdzie Papierów Wartościowych w Bombaju (SNX), S&P500 – indeks giełdy w Nowym Jorku (SPX), WIG – indeks na Giełdzie Papierów Wartościowych w Warszawie (WIG) oraz XU100 – indeks na Giełdzie Papierów Wartościowych w Stambule (XU); postaci:

$$x_t = \ln s_t - \ln s_{t-1}, \quad (15)$$

gdzie:

s_t – obserwacja szeregu, notowane w okresie 3.01.2000-26.08.2013².

² Dane pochodzą z archiwum plików strony internetowej stooq.com.

W pierwszym etapie badania, wybrane szeregi czasowe poddano procesowi redukcji poziomu szumu losowego metodą najbliższych sąsiadów dla opóźnienia czasowego $\tau = 1$. Redukcję szumu losowego w szeregach czasowych przeprowadza się dla ustalonego wymiaru zanurzenia d i ustalonej liczby najbliższych sąsiadów wektora x_t^d . W celu ustalenia optymalnych parametrów, tj. parametrów, dla których poziom szumu losowego jest najniższy, pod uwagę wzięto następujące wartości wymiaru zanurzenia $d = 2, 3, 4, 5, 6, 7, 8, 9, 10, 15, 20$, natomiast jako najbliższych sąsiadów wektora x_t^d ustalono wektory z jego otoczenia o promieniu otoczenia $\rho = 0,001; 0,01; 0,1^3$. Do oceny poziomu szumu w przefiltrowanych szeregach zastosowano współczynnik *NRL*.

W tabeli 1 zamieszczono optymalne parametry redukcji szumu losowego: wartość wymiaru zanurzenia d i promień otoczenia ρ , oraz odpowiadającą im najniższą wartość współczynnika *NRL* dla analizowanych szeregów. Tak przefiltrowane szeregi oznaczono symbolem *NazwaSzeregu_red*.

Tabela 1

Współczynnik *NRL* dla szeregów przefiltrowanych metodą najbliższych sąsiadów

Szereg	d	ρ	<i>NRL</i>
CAC_red	2	0,1	0,0005687
HSI_red	2	0,1	0,0008235
NKX_red	9	0,1	0,0008070
SNX_red	2	0,1	0,0006529
SPX_red	2	0,1	0,0005776
WIG_red	2	0,1	0,0003023
XU_red	3	0,1	0,0011119

Następnie dla analizowanych szeregów oszacowano parametry rekonstrukcji przestrzeni stanów metodą opóźnień: stosując funkcję autokorelacji – *ACF* [1;9] wyznaczono czas opóźnień τ , natomiast za pomocą metody najbliższego pozornego sąsiada – *FNN* [1;4] obliczono wymiar zanurzenia d . Tabela 2 zawiera parametry rekonstrukcji d i τ dla szeregów czasowych przed i po filtracji.

Tabela 2

Wartości parametrów rekonstrukcji przestrzeni stanów dla analizowanych szeregów

Szereg	Opóźnienie czasowe	Wymiar zanurzenia	Szereg	Opóźnienie czasowe	Wymiar zanurzenia
CAC	20	8	CAC_red	17	10
HSI	2	6	HSI_red	21	9
NKX	6	6	NKX_red	19	10
SNX	15	7	SNX_red	4	4
SPX	4	6	SPX_red	14	5
WIG	16	7	WIG_red	23	6
XU	4	6	XU_red	12	4

³ Redukcję szumu przeprowadzono przy wykorzystaniu darmowego programu TISEAN autorstwa H. Kantza i T. Schreiber.

Kolejny etap badań, polegał na identyfikacji chaosu w analizowanych szeregach czasowych. W tabeli 3 przedstawiono wyniki szacowania największego wykładnika Lapunowa dla badanych szeregów. Obok wartości największego wykładnika Lapunowa podano również równanie regresji oraz współczynnik determinacji R^2 , na podstawie których wyznaczono λ_{\max} . Znakiem „-” oznaczono sytuację, w której oszacowany współczynnik kierunkowy równania regresji nie może być traktowany jako wartość największego wykładnika Lapunowa, ponieważ $R^2 < 0,3$.

Tabela 3

Wartości największego wykładnika Lapunowa dla analizowanych szeregów

Szereg	Równanie regresji	λ_{\max}	Szereg	Równanie regresji	λ_{\max}
CAC	$y = 0,0003x - 4,2329$ $R^2 = 0,2395$	-	CAC_red	$y = 0,0061x - 9,1894$ $R^2 = 0,3317$	0,0061
HSI	$y = 0,0009x - 4,1869$ $R^2 = 0,2953$	-	HSI_red	$y = 0,011x - 8,6463$ $R^2 = 0,3728$	0,0110
NKX	$y = 0,0018x - 4,1765$ $R^2 = 0,3630$	0,0018	NKX_red	$y = 0,038x - 8,5717$ $R^2 = 0,4348$	0,0380
SNX	$y = 0,0021x - 4,1885$ $R^2 = 0,3596$	0,0021	SNX_red	$y = 0,0321x - 8,8706$ $R^2 = 0,3376$	0,0321
SPX	$y = 0,0011x - 4,3929$ $R^2 = 0,3309$	0,0011	SPX_red	$y = 0,0094x - 9,4164$ $R^2 = 0,6639$	0,0094
WIG	$y = 0,0029x - 4,3491$ $R^2 = 0,3495$	0,0029	WIG_red	$y = 0,0251x - 11,376$ $R^2 = 0,6013$	0,0251
XU	$y = 0,0018x - 3,8043$ $R^2 = 0,0823$	-	XU_red	$y = 0,0217x - 6,8222$ $R^2 = 0,1907$	-

Obliczone wartości największego wykładnika Lapunowa λ_{\max} dla wszystkich analizowanych szeregów czasowych są dodatnie, jednak są one niewielkie. Świadczy to o wrażliwości tych szeregów na zmianę warunków początkowych, a zatem o obecności chaosu, lecz jego poziom jest nieznaczny. Analizując dane zawarte w tabeli 3, można stwierdzić, że po zastosowaniu procedury redukcji szumu losowego wartości największego wykładnika Lapunowa są znacznie większe niż w szeregach przed filtracją. Największym poziomem chaosu wykazały się serie NKX, SNX oraz WIG, dla których zastosowano procedurę redukcji szumu metodą najbliższych sąsiadów. Ponadto, szacowane równania regresji charakteryzują silniejszym dopasowaniem do danych dla szeregów przefiltrowanych.

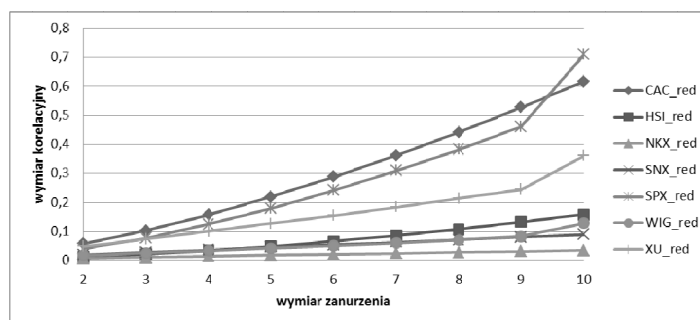
W tabeli 4 zamieszczono oszacowane wartości wymiaru korelacyjnego dla wszystkich analizowanych szeregów dla wymiaru zanurzenia $d = 2, 3, \dots, 10$.

Tabela 4

Wymiar korelacyjny dla analizowanych szeregów

Szereg	Wymiar zanurzenia									
	2	3	4	5	6	7	8	9	10	
CAC	1,4114	2,1801	2,9678	3,7592	4,6051	5,7329	5,6573	6,4719	6,4726	
CAC red	0,0574	0,1028	0,1574	0,219	0,2876	0,3617	0,4418	0,527	0,6157	
HSI	1,3781	2,1238	2,8646	3,6136	4,3226	5,1482	5,8571	5,8252	6,4214	
HSI red	0,0127	0,0218	0,0337	0,0484	0,0658	0,0857	0,1078	0,1325	0,1587	
NKX	1,4757	2,2844	3,1125	3,9523	4,7868	5,5165	5,8772	6,5436	7,2646	
NKX red	0,0073	0,0107	0,0141	0,0173	0,0206	0,024	0,0274	0,0309	0,0345	
SNX	1,4103	2,1882	2,9967	3,8393	4,6899	5,511	5,9237	6,9005	7,8878	
SNX red	0,0185	0,0273	0,0364	0,0453	0,0542	0,0627	0,0714	0,0805	0,0896	
SPX	1,3154	2,0061	2,711	3,4417	4,2256	5,2432	5,8473	5,8024	6,5743	
SPX red	0,0393	0,0766	0,1242	0,1792	0,2413	0,3093	0,3822	0,4604	0,7092	
WIG	1,457	2,2582	3,0832	3,9134	4,7525	5,6239	5,9755	6,8416	7,7154	
WIG red	0,0172	0,0252	0,0334	0,0416	0,0506	0,0604	0,0714	0,0835	0,1277	
XU	1,3981	2,1406	2,9119	3,7108	4,5049	5,4173	5,4467	6,227	7,3079	
XU red	0,0477	0,0731	0,0997	0,1266	0,1545	0,1836	0,2137	0,2438	0,3608	

Obliczone wartości wymiaru korelacyjnego dla szeregów przefiltrowanych są znacznie niższe od wartości D_c otrzymanych dla szeregów nieprzefiltrowanych. Jednak zarówno dla szeregów przefiltrowanych jak i nieprzefiltrowanych brak jest wyraźnego poziomu stabilizowania się wartości wymiaru korelacyjnego. Dla przefiltrowanych szeregów XU_red, SNX_red, WIG_red oraz HSI_red można zaobserwować wolniejsze tempo wzrostu wartości wymiaru korelacyjnego (rys. 1). Fakt ten może potwierdzać istnienie pewnych zależności deterministycznych w badanych szeregach.



Rys. 1. Wartości wymiaru korelacyjnego dla przefiltrowanych szeregów

Wobec faktu, że dla szeregów chaotycznych (tj. szeregów wygenerowanych na podstawie odwzorowania logistycznego, odwzorowania Henon), wyniki krótko-okresowego prognozowania potwierdzają wykładnicze tempo wzrostu błędu prognozy wraz ze wzrostem jej horyzontu [6], [8], w kolejnym etapie badania wyznaczono prognozy analizowanych szeregów dla horyzontu prognozy $T = 1, 2, \dots, 10$. Do wyznaczenia prognoz wykorzystano metodę opartą na wartości największego wykładnika Lapunowa LEM. W metodzie LEM prognozę obserwacji s_{N+1} wyznacza się na podstawie zależności [3], [4]:

$$\Delta_1 \approx \Delta_{\min} \cdot e^{\lambda_{\max}}, \quad (15)$$

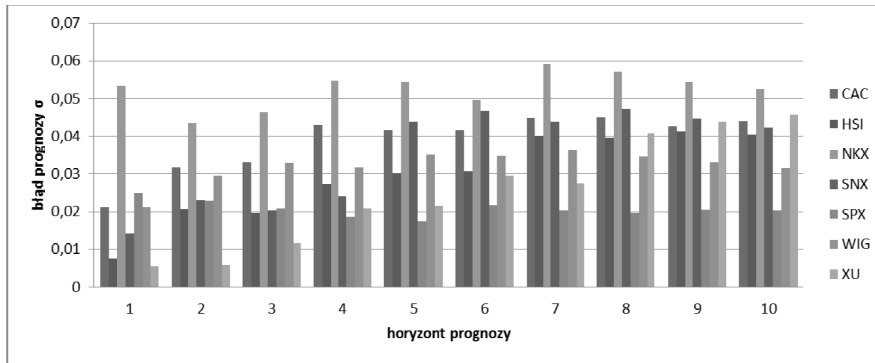
gdzie:

λ_{\max} – wykładnik Lapunowa,


Δ_{\min} – odległość pomiędzy wektorem s_N^d oraz jego najbliższym sąsiadem oznaczonym jako s_{\min}^d ,

Δ_1 – odległość pomiędzy wektorami s_{N+1}^d oraz $s_{\min+1}^d$ [8].

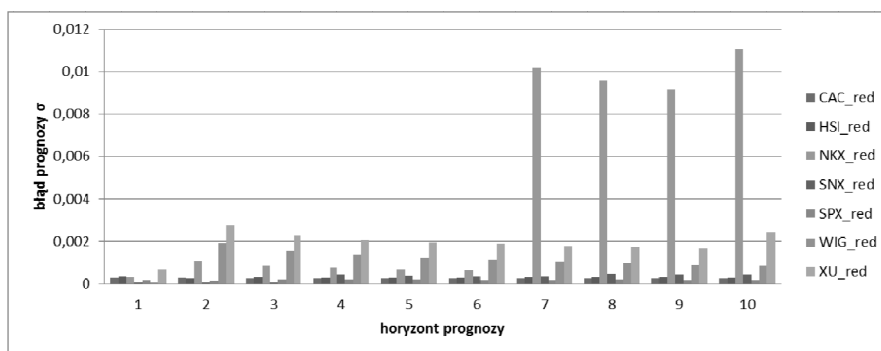
W związku z tym, że odległości pomiędzy wektorami są mierzone metryką euklidesową, prognoza \hat{s}_{N+1} może przyjmować dwie wartości: \hat{s}_{N+1}^+ oraz \hat{s}_{N+1}^- , będące odpowiednio przeszacowaną i niedoszacowaną wartością rzeczywistego s_{N+1} [8]. W celu oszacowania dokładności wyznaczonych prognoz wykorzystano pierwiastek błędu średniokwadratowego *RMSE*. Rysunki 2-5 przedstawiają błędy prognoz wyznaczonych metodą LEM w zależności od horyzontu prognozy.




Rys. 2. Wartości błędu RMSE przeszacowanych prognoz szeregów



Rys. 3. Wartości błędu RMSE niedoszacowanych prognoz szeregów



Rys. 4. Wartości błędu RMSE przeszacowanych prognoz szeregów



Rys. 5. Wartości błędu RMSE niedoszacowanych prognoz szeregów

Na podstawie powyższych wykresów (rys. 2-5) można zauważyć, że w większości badanych szeregów błędy prognoz zwiększają się wraz ze wzrostem horyzontu prognozy, jednak tempo wzrostu tych błędów jest wolniejsze niż tempo wykładnicze. Można więc wnioskować, że badane szeregi finansowe nie są generowane przez układy chaotyczne. Dodatkowo można zauważyć, że w wyniku redukcji szumu losowego błędy prognoz analizowanych szeregów w całym przedziale weryfikacji są znacznie mniejsze niż błędy prognoz nieprzefiltrowanych szeregów.

Podsumowanie

W artykule zbadano wpływ redukcji szumu losowego metodą najbliższych sąsiadów na identyfikację chaosu w wybranych szeregach finansowych. Na podstawie przeprowadzonych badań można stwierdzić, że przefiltrowane szeregi wykazały cechy chaotyczne w większym stopniu niż szeregi nieprzefiltrowane. Świadczą o tym znacznie większe wartości największego wykładnika Lapunowa dla szeregów poddanych procedurze redukcji niż dla szeregów nieprzefiltrowa-

nych. Istnienie pewnych zależności deterministycznych w czterech z badanych szeregów, wydaje się potwierdzać wolniejsze tempo wzrostu wartości wymiaru korelacyjnego po zastosowaniu metody redukcji szumu losowego.

Dodatkowo przeprowadzone badania wykazały, że szeregi poddane procesowi redukcji szumu charakteryzowały się znacznie mniejszymi błędami prognozy w całym przedziale weryfikacji.

Literatura

- [1] Cao L., *Method of False Nearest Neighbors*, [w:] *Modeling and Forecasting Financial Data*, ed. A.S. Soofi, L. Cao, Kluwer, Boston 2001.
- [2] Guégan D., Leroux J., *Forecasting Chaotic Systems: The Role of Local Lyapunov Exponents*, „Chaos, Solitons & Fractals” 2009, Vol. 41.
- [3] Kantz H., Schreiber T., *Nonlinear Time Series Analysis*, Cambridge University Press, Cambridge 2004.
- [4] Kennel M.B., Brown R., Abarbanel H.D.I., *Detecting Embedding Dimension for Phase Space Reconstruction Using a Geometrical Construction*, „Physical Review A” 1992, Vol. 45.
- [5] Kyrtsov C., Terraza M., *Stochastic Chaos or ARCH Effects in Stock Series? A Comparative Study*, „International Review of Financial Analysis” 2002, Vol. 11.
- [6] Miśkiewicz-Nawrocka M., *Zastosowanie wykładników Lapunowa do analizy ekonomicznych szeregów czasowych*, Wydawnictwo Uniwersytetu Ekonomicznego, Katowice 2012.
- [7] Orzeszko W., *Identyfikacja i prognozowanie chaosu deterministycznego w ekonomicznych szeregach czasowych*, Polskie Towarzystwo Ekonomiczne, Warszawa 2005.
- [8] Ott E., *Chaos w układach dynamicznych*, Wydawnictwa Naukowo-Techniczne, Warszawa 1997.
- [9] Ramsey J.B., Sayers C.L., Rothman P., *The Statistical Properties of Dimension Calculations Using Small Data Sets: Some Economic Applications*, „International Economic Review” 1990, Vol. 31, No. 4.
- [10] Takens F., *Detecting Strange Attractors in Turbulence*, [w:] *Lecture Notes in Mathematics*, ed. D.A. Rand and L.S. Young, Springer, Berlin 1981.
- [11] Zawadzki H., *Chaotyczne systemy dynamiczne*, Wydawnictwo Akademii Ekonomicznej, Katowice 1996.
- [12] Zhang J., Lam K.C., Yan W.J., Gao H., Li Y., *Time Series Prediction Using Lyapunov Exponents in Embedding Phase Space*, „Computers and Electrical Engineering” 2004, Vol. 30.

EFFECT OF OPTIMUM PARAMETERS OF RANDOM NOISE REDUCTION ON THE IDENTIFICATION OF CHAOS IN ECONOMIC TIME SERIES

Summary

Real time series are usually disturbed by random noise and the presence of noise in the data can significantly affect the characteristics of dynamic system. The aim of the article will be to research the effect of reduction of random noise by the nearest neighbor method on the identification of chaos in time series. The test will be conducted on the basis of selected financial time series.