

**Joanna BOBKOWSKA**

WEST POMERANIAN UNIVERSITY OF TECHNOLOGY OF SZCZECIN, FACULTY OF SOFTWARE ENGINEERING,  
ul. Żołnierska 49, 71-210 Szczecin

## Wady i zalety metody prognozowania zachowania złożonych procesów opartej na metodzie GMDH z funkcjami wrażliwości

Mgr Joanna BOBKOWSKA

Doktorantka Wydziału Informatyki ZUT w Szczecinie. Studiowała na Wydziale Matematyki i Informatyki Uniwersytetu im. A. Mickiewicza w Poznaniu. Praca magisterska dotyczyła matematycznych podstaw informatyki, problemów nierozstrzygalnych w teorii algorytmów w kontekście maszyn Turinga. Obecnie zajmuje się analizą szeregów czasowych i symulacją zachowania procesów złożonych. Interesuje się również zagadnieniami psychologii.



e-mail: jbobkowska@wi.zut.edu.pl

### Streszczenie

W artykule przedstawiono zalety i ograniczenia metody predykcji procesów złożonych reprezentowanych przez szeregi czasowe, opartej na metodzie GMDH i korzystającej z właściwości funkcji wrażliwości. Użycie funkcji wrażliwości ma zapewnić zwiększenie precyzji predykcji w stosunku do metody podstawowej, dzięki informacjom o kierunku i szybkości zmian wartości zmiennych szeregu, zawartych w funkcjach wrażliwości. Na wejściu potrzebna jest niewielka ilość danych (siedem). Metoda wykazuje zwiększenie skuteczności w stosunku do GMDH nawet przy wykorzystaniu wielomianów Kołmogorowa-Gabóra jedynie drugiego stopnia.

**Słowa kluczowe:** procesy złożone, prognoza, małowielomienne zbiory próbek, funkcje wrażliwości, metoda GMDH, regresja.

### The advantages and limitations of the complex processes behavior prediction method with sensitivity functions based on GMDH

#### Abstract

In this paper, there are presented the advantages and limitations of the prediction method of complex processes (presented in the form of the time series) which is based on the Russian researcher A. G. Ivakhnenko-GMDH method and uses the properties of the first and second-order sensitivity functions. Sensitivity function is used to ensure an increase of the precision of the prediction in relation to the basic method, thanks to the information about direction and changes in the values of the time series variables and the speed of these changes included in them. We need only small amount of input data (seven) opposed to the other regression methods using large amounts of information in order to study the statistical relationship between time series variables. On the basis of several alternative (partial) models we receive several outputs for every time-series variable, from which we choose the best (terms previously fixed criteria) [1]. Figures 1, 4, 6 and 7 show the results of the prediction of the best partial models for one or two steps forward. Others show values of the sensitivity functions indicating an influence on the studied variables. Results of the prediction without using the sensitivity function differ significantly from the expected values, therefore, are not shown in the drawings. The method shows an increase in efficacy in comparison with GMDH even for second degree Kolmogorov-Gabor polynomials.

**Keywords:** complex processes, prognosis, short sample of data, sensitivity functions, GMDH method, regression.

## 1. Wstęp

Termin „złożoność systemu” oznacza w pracy, że składa się on z wielu elementów oraz, że obiekty (podsystemy) wchodzące w skład całego systemu są ze sobą połączone i wzajemnie na siebie oddziałują, a ich rozdzielenie jest zasadniczo niemożliwe, niebezpieczne, lub zbyt kosztowne. Mogą również wystąpić ograniczenia w dostępności do informacji o sygnałach dochodzących z zewnątrz do systemu. Dlatego też do systemów o strukturze

złożonej nie da się w bezpośredni sposób zastosować algorytmów identyfikacji stosowanych dla pojedynczego obiektu.

Należy podkreślić, że nie ma ścisłej definicji systemu złożonego i określenie to może mieć różne znaczenie dla różnych zastosowań. Za system złożony może być uważany taki układ, do opisu którego niezbędna jest duża liczba i złożoność równań. Wówczas granica podziału systemów złożonych i prostych jest nieformalna i bardzo płynna.

Fenomen złożoności w terminach kategorii analizy systemowej określić można jak w [2], [3]. Obiekt (system, proces) jest uważany za złożony, jeśli posiada następujące cechy:

1. Działanie systemu ma charakter stochastyczny.
2. Użyteczny system działa w taki sposób, że jego działania skierowane są na stopniowe zmniejszenie entropii informacyjnej (właściwość tzw. nieentropijności).
3. Właściwości systemu nie są pochodnymi właściwościami jego podsystemów.
4. System jest emergentny (ang. *emergent*), czyli ma właściwości, których wstępnie nie da się przewidzieć.
5. Cele użytecznego systemu polegają na znalezieniu zadowalających, ale niekoniecznie najlepszych rozwiązań spośród wszystkich hipotetycznie możliwych.

Największym problemem w modelowaniu złożonych systemów, takich, z jakimi mamy do czynienia w ekonomii, ekologii, socjologii czy innych jest uwzględnienie w modelu własnych uprzedzeń. Gdy proces jest bardzo skomplikowany, podstawowe założenia dotyczące jego przebiegu pochodzą z zewnątrz, od badacza, tak naprawdę są przez niego odgadywane.

Współczesne sposoby rozwiązywania opisanego zagadnienia symulacji systemów złożonych opierają się na idei tworzenia modeli na bieżąco, podczas dokonywania procesu symulacji. Takie podejście do symulacji niektórzy badacze określają jako samoorganizację modeli, lub symulację ewolucyjną (ze względu na to, że proces tworzenia modeli przypomina proces ewolucji naturalnej) [4], inni – jako adaptację modeli (ze względu na to, że modele są adaptowane do ciągle zmieniających się stanów obiektów podlegających symulacji) [5, 6]. Proces adaptacyjnej budowy modeli obiektów złożonych realizowany jest poprzez proces obejmujący: 1) szczegółowe zbieranie danych o obiekcie z dostępnych źródeł; 2) inteligentną analizę zebranych informacji w celu wyboru istotnych dla rozwiązania danego problemu wiadomości i faktów oraz wyrzucania nieistotnych; 3) formułowanie wiedzy o obiekcie badań; 4) tworzenie i dopracowywanie modelu zachowania się obiektu, który coraz bardziej precyzyjnie odzwierciedla rzeczywiste zachowanie obiektu; 5) predykcja zachowania się obiektu w przyszłości.

## 2. Metoda GMDH

Jako przykład metody samoorganizacji może służyć GMDH. W tym roku mija 46 lat od jej powstania. Zakłada ona działanie na danych, złożonych procesach i przewidywanie ich przyszłych wartości bez wykorzystywania dodatkowych założeń i informacji o systemie z zewnątrz, oraz ich wewnętrznych związkach, korelacjach.

Wykorzystana w tej pracy do celów budowy modeli predykcji metoda GMDH to metoda maszyn uczących ze stopniowo komplikującymi się modelami aż do znalezienia optymalnej jego złożoności. Tworzy się wielowarstwowe modele podobne do sieci neuronowych. Zbyt skomplikowane modele stają się jednak ostatecznie niestabilne i tracą swoje predykcyjne właściwości. To typowa metoda indukcyjnego modelowania, jedna z efektywniejszych metod identyfikacji strukturalno-parametrycznej obiektów

i procesów (systemów) złożonych z danych, w warunkach niekompletnej informacji. GMDH posiada wielką różnorodność możliwości w porównaniu z innymi metodami o podobnej konstrukcji. Dotyczy to przede wszystkim sposobów generowania modeli i kryteriów oceny ich jakości.

Metoda GMDH jest podstawowym narzędziem teorii indukcyjnego modelowania należącej do najnowocześniejszych metod Obliczeń Inteligentnych i tzw. Soft Computing. Dostateczność modeli prognozy tworzonych na podstawie GMDH dla przewidywania wszystkich możliwych stanów badanych systemów wynika z faktu, że modele GMDH bazują na wykorzystaniu dyskretnych analogów szeregów Volterra w postaci szeregów Kołmogorowa-Gabora, czyli wielomianów, a te ostatnie, według twierdzenia Stone'a-Weierstrassa, pokrywają wszystkie ewentualne stany obiektów podlegających symulacji.

Idea metody GMDH polega na zastąpieniu jednego złożonego modelu strukturą składającą się z modeli cząstkowych. Struktura ta ewoluje podczas syntezy powstałej w ten sposób sieci. Modele cząstkowe sieci GMDH można podzielić na liniowe, nieliniowe i dynamiczne. Tworzone modele regresyjne uwzględniają tylko część spośród wielu argumentów (zmiennych wejściowych). Oznacza to w wielu przypadkach rozpatrywanie tysięcy kolejnych modeli regresyjnych. Każdy taki model posiada inną konfigurację tworzących go danych wejściowych. Zadanie polega na wyborze tylko najlepszych spośród dostępnych modeli. Stąd uznawana jest za metodę samoorganizującą. Modele regresyjne różnią się nie tylko współczynnikami liczbowymi przy poszczególnych wyrazach wykorzystywanego do budowy równania Kołmogorowa-Gabora, ale także różną strukturą tego równania (różne stopnie wyrazów równania). Wybór kilku (czasem większej ilości) najlepszych, a nie jednego najlepszego modelu na danym kroku złożoności Ivakhnenko uzasadnia koniecznością pozostawienia swobody w procesie decyzyjnym.

Skuteczność metody, jej efektywność była potwierdzana rozwiązywaniem wielu problemów świata rzeczywistego z zakresu ekologii, ekonomii, meteorologii i innych, np.: [7].

### 3. GMDH z funkcjami wrażliwości

Metoda GMDH posiada oczywiście pewne słabości. Niektóre z cech metody wymagają dodatkowych badań, ulepszeń. Realizacja jednowarstwowych (kombinatorycznych) algorytmów GMDH dla rozwiązania problemów prognozy na dużych zbiorach danych jest związana z olbrzymią ilością obliczeń. Jak twierdzą autorzy metody GMDH [4], mimo, że zaproponowano szereg skutecznych sposobów, zmniejszających objętość obliczeń, szybko osiągamy praktyczne granice obliczalności i podatności na ocenę przez ludzi tak olbrzymiej ilości informacji. Z tego powodu algorytmy jednowarstwowe ograniczone są do wykorzystania jedynie wielomianów niskiego rzędu na stosunkowo niedużych zbiorach danych wejściowych. W przypadku, gdy stopnie wielomianów przekraczają granice obliczalności, pomocne jest zastosowanie indukcji niezupełnej, w której dzięki rozsądnemu wyborowi nośnika funkcji często udaje się utrzymać ilość modeli w rozsądnych granicach. Dla zmniejszenia objętości obliczeń używane są różne techniki redukcji modeli. Przyjęte w praktyce podejście do tej redukcji polega na odrzucaniu na każdym etapie tworzenia modeli nieudanych wersji. Zasada ta wychodzi z założenia, że „słabi rodzice nie mogą reprodukcować silnego potomstwa”, która, jak udowodniono w teorii algorytmów genetycznych, jest błędna.

Uwzględniona w pracy metoda ogranicza się do wykorzystania wielomianów Kołmogorowa-Gabora co najwyżej drugiego stopnia, co znacznie upraszcza obliczenia. Tworzy się modele cząstkowe zawierające wszystkie możliwe pary argumentów złożonego procesu przedstawianych za pomocą szeregów czasowych.

W celu znalezienia przyszłych wartości wszystkich argumentów, bierze się próbkę zawierającą jedynie po siedem kolejnych wartości każdego z argumentów analizowanego procesu, a w wyniku otrzymuje się przyszłą prognozowaną wartość każdego argumentu szeregu. Ze względu na niewielką ilość danych

wejściowych, horyzont predykcji obejmuje jeden (ewentualnie dwa) kroki wprzód dla danej próbki, następnie przesuwa się próbkę o jeden punkt czasowy i próbuje się dalej.

Przyszłą wartość każdej ze zmiennych oblicza się z wykorzystaniem kilku modeli cząstkowych (wszystkich możliwych kombinacji zmiennych wchodzących w skład procesu), metodą uproszczoną (zawierającą funkcje wrażliwości pierwszego rzędu) (1), i rozszerzoną (pierwszego i drugiego rzędu) (2) [1]. Spośród wszystkich modeli cząstkowych używanych do predykcji wartości rozpatrywanego argumentu, wybiera się jeden z najkorzystniejszych, ale nie dyskwalifikuje się pozostałych. Być może wykażą one zadowalającą dokładność w kolejnej próbce.

Metoda uproszczona wymaga obliczenia przyrostów cząstkowych przez rozwiązanie układu równań liniowych, a metoda rozszerzona – układu równań nieliniowych o dwóch niewiadomych.

Przyszłą wartość argumentu  $x$  w modelu uproszczonym ze zmienną  $y$  oblicza się ze wzoru:

$$X_{i+1}(x_i, y_i) = x_i + S_{x_i}^{X(x,y)} \cdot dx_i + S_{y_i}^{X(x,y)} \cdot dy_i, \quad (1)$$

a w modelu rozszerzonym z użyciem wzoru:

$$\begin{aligned} X_{i+1}(x_i, y_i) = & x_i + S_{x_i}^{X(x,y)} \cdot dx_i + S_{y_i}^{X(x,y)} \cdot dy_i + \\ & + 0.5 \cdot S_{x_i^2}^{X(x,y)} \cdot (dx_i)^2 + 0.5 \cdot S_{y_i^2}^{X(x,y)} \cdot (dy_i)^2 + \\ & + S_{x_i y_i}^{X(x,y)} \cdot dx_i \cdot dy_i, \end{aligned} \quad (2)$$

gdzie  $dx_i$  oraz  $dy_i$  są przyrostami cząstkowymi, a  $S^{X(x,y)}$  oznacza funkcję wrażliwości (zawierającą pochodne pierwszego i drugiego rzędu wielomianu Kołmogorowa-Gabora drugiego stopnia).

Dzięki informacjom niesionym przez funkcje wrażliwości uzyskuje się większą dokładność prognozy w porównaniu z podstawową metodą GMDH. Wartości funkcji wrażliwości (względne, lub półwzględne), zawierające pochodne wykorzystywanej w modelu funkcji Kołmogorowa-Gabora informują o kierunku i szybkości zmian wartości poszczególnych zmiennych.

Metoda podstawowa GMDH wymaga większej ilości danych wejściowych niż zmodyfikowana. Natomiast użycie w niej szeregów czasowych o ilości argumentów przekraczających 30 okazuje się zbyt wymagające obliczeniowo, mimo ogromnego postępu w dziedzinie technologii komputerowej. W wielu przypadkach uzyskiwane prognozy mają niewielki horyzont, modele znacznie się komplikują i wzrasta stopień używanych równań Kołmogorowa-Gabora. W przypadku metody z funkcjami wrażliwości ogranicza się do równań stopnia drugiego, a komplikacje w obliczeniach mogą pojawić się w momencie konieczności obliczenia układów równań nieliniowych w celu znalezienia przyrostów cząstkowych. Błędne ustalenie punktu początkowego obliczeń może prowadzić do znacznie odbiegających od oczekiwanych rezultatów. Ze względu na niewielką ilość danych wejściowych i konieczność znalezienia współczynników wielomianu Kołmogorowa-Gabora poprzez obliczenie układu sześciu równań o sześciu zmiennych można też napotykać na przypadki macierzy źle uwarunkowanych. Metoda nie nadaje się więc dla każdego typu danych. Nie można też wykorzystać informacji statystycznych ukazujących związki pomiędzy wartościami poszczególnych zmiennych szeregu czasowego, gdyż danych wejściowych jest niewiele.

Dla metody GMDH, spośród wszystkich modeli cząstkowych wybiera się ten, który daje największą regularność, dopasowanie na próbce (najmniejsze kwadraty na próbce testowej). Możliwości przewidywania danego modelu są w znacznej części zależne od liczby obserwacji dla zbioru zewnętrznego.

Metoda GMDH daje jedną wartość wyjściową, najlepszą uzyskaną spośród wszystkich modeli cząstkowych. W metodzie z funkcjami wrażliwości otrzymuje się kilka wyjść. Na podstawie obranych kryteriów decyduje się, która jest optymalna.

Indukcyjne podejście w metodzie GMDH nie eliminuje wkładu ekspertów w rezultaty działań metody a raczej daje im pewną specyficzną rolę, funkcję. Eksperti wskazują kryterium selekcji

modeli i interpretują wybrane modele. Mogą oni wpływać na rezultaty poprzez formułowanie nowego kryterium. Komputer staje się wtedy obiektywnym sędzią naukowych wątpliwości, podczas gdy ostateczne kryterium ustalane jest między ekspertami biorącymi udział w sporze.

W metodzie zmodyfikowanej, obserwując wcześniejszy przebieg wartości danego argumentu w szeregu, wartości funkcji wrażliwości oraz przyrostów cząstkowych obliczanych w każdym punkcie czasowym próbki danych wejściowych, decyduje się, który z modeli cząstkowych ma szansę dać oczekiwane rezultaty predykcji na danym etapie. Dopiero uzgodnienie wszystkich dostępnych informacji, czynników, daje pełniejszy obraz obserwowanego procesu. Nie zawsze model o najmniejszej wartości sumy kwadratów okazuje się najkorzystniejszy. Co pokazano analizując wyniki badań.

### 4. Wyniki predykcji uzyskiwanej metodą zmodyfikowaną

Badania przeprowadzane były na benchmarkach w postaci szeregów czasowych dostępnych w zasobach internetowych. Do celów tej pracy wykorzystano szereg z pięcioma argumentami, co daje 20 modeli cząstkowych (po 4 modele na prognozowanie wartości każdej ze zmiennych szeregu).

Tab. 1. Wartości poszczególnych zmiennych rozpatrywanego szeregu  
Fig. 1. The values of every concerned variables of the time series

Punkty czasowe	$x$	$y$	$z$	$q$	$r$
P(0)	161	344	567	429	404
P(1)	110	390	421	453	579
P(2)	135	184	405	427	198
P(3)	203	432	554	482	428
P(4)	106	319	402	538	559
P(5)	85	469	534	454	559
P(6)	102	257	322	313	464
P(7)	70	247	660	234	152
P(8)	14	178	567	162	420


Na początkowym etapie badań wydawało się, że metoda z funkcjami wrażliwości wykazuje skuteczność dla szczególnych szeregów czasowych o znacznej regularności [1], jednak po dokonaniu usprawnień na etapie przewidywania wartości funkcji wrażliwości oraz przyrostów cząstkowych okazało się, że daje zadowalające rezultaty również w przypadkach bardziej zróżnicowanych wartości.

Na pierwszym etapie obliczeń, na podstawie danych wejściowych P(0) – P(6), dla każdej pary zmiennych wyznaczono współczynniki wielomianu Kołmogorowa-Gabora stopnia drugiego (modele cząstkowe), obliczając układ sześciu równań z sześcioma niewiadomymi [1]. Mogą tutaj wystąpić problemy z uzyskiwaniem źle uwarunkowanych macierzy. Przesuwa się wtedy zakres obserwowanych danych o jeden punkt czasowy. Oblicza się wartości funkcji wrażliwości oraz przyrostów cząstkowych, następnie dokonuje się predykcji wartości każdego z argumentów szeregu czasowego wykorzystując wzory (1) i (2) i wyznaczone wcześniej wartości.

W rezultacie otrzymuje się szesnaście modeli (rozwiązań) dla każdej zmiennej. Tzn. cztery modele uproszczone, cztery rozszerzone, cztery takie, dla których przyrostów cząstkowych szukano metodą Newtona-Ralphsona i cztery w klasycznym modelu GMDH bez funkcji wrażliwości – dla porównania rezultatów.

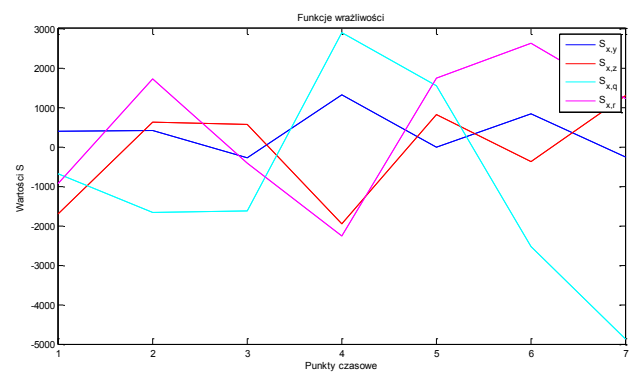
Na rysunkach przedstawiono jedynie modele, które uzyskiwały najlepszą skuteczność predykcji na jeden, dwa kroki wprzód. Na rys. 1 pokazano rezultaty obliczeń dla modelu uproszczonego  $X(x, r)$  oraz rozszerzonego  $X(x, q)$ , przewidującego wartości zmiennej  $x$  w punkcie czasowym  $t_7$  oraz  $t_8$ . Jak można zauważyć na rys. 1, dla punktu czasowego  $t_4$ , z powodu trudności w znalezieniu dokładnego rozwiązania układu równań nieliniowych uży-

skano nieprecyzyjne dopasowanie, jednak nie wpływa to na dokładność predykcji ze względu na charakter i sposoby dalszych obliczeń (pominięto znacznie odstające od rzeczywistych wartości przyrostów czy funkcji wrażliwości).




Rys. 1. Prognoza wartości zmiennej  $x$  w modelu uproszczonym  $X(x, r)$  oraz w modelu rozszerzonym  $X(x, q)$   
Fig. 1. The prognosis of the  $x$  variable value using simple model  $X(x, r)$  and extended model  $X(x, q)$

Przyglądając się wartościom funkcji wrażliwości, które przechowują informacje o szybkości zmian wartości argumentów szeregu oraz informują o wpływie poszczególnych zmiennych na wartość danego argumentu zauważa się, że im wyższa wartość bezwzględna funkcji wrażliwości, tym większy ma na nią wpływ zmienna z danego modelu cząstkowego. Rys. 2 przedstawia wartości funkcji wrażliwości pierwszego rzędu zawierające wartości pochodnych cząstkowych względem drugiej (nieposzukiwanej) zmiennej  $v$  (gdzie  $v$  oznacza kolejno zmienne  $y, z, q$  i  $r$ ).



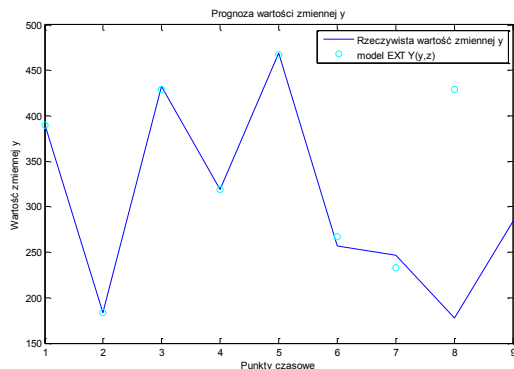
Rys. 2. Wartości funkcji wrażliwości  $S_v^{X(x,v)}$  stopnia pierwszego  
Fig. 2. The values of the first order sensitivity functions  $S_v^{X(x,v)}$



Rys. 3. Wartości funkcji wrażliwości  $S_{v^2}^{X(x,v)}$  stopnia drugiego  
Fig. 3. The values of the second order sensitivity functions  $S_{v^2}^{X(x,v)}$

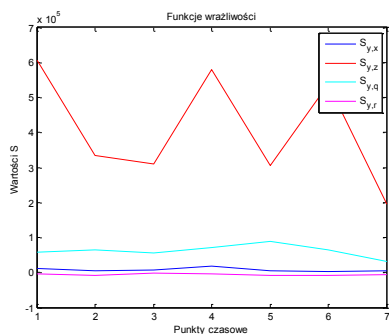
Na rys. 3 przedstawiono wartości funkcji wrażliwości rzędu drugiego zawierające wartości pochodnych cząstkowych ponownie względem drugiej (nieposzukiwanej) zmiennej  $v$ . Wartości te używane są w modelu rozszerzonym. Wartości funkcji wrażliwości modelu  $X(x, q)$  są wyraźnie wyższe od pozostałych.

Podobne rezultaty uzyskano dla pozostałych argumentów szeregu.




Rys. 4. Prognoza wartości zmiennej  $y$  w modelu rozszerzonym  $Y(y, z)$   
Fig. 4. The prognosis of the  $y$  variable value using extended model  $Y(y, z)$

W przypadku zmiennej  $y$  (rys. 4) jedynie przewidywania o jeden punkt czasowy wprzód wypadły zadowalająco. W celu próby znalezienia dokładniejszej wartości predykcji dla punktu P(8) przeprowadzono te same obliczenia, dla wartości uzyskanych na pierwszym etapie obliczeń w punktach czasowych P(1) – P(7). Wartości uzyskiwane z użyciem metody podstawowej (GMDH) znacznie odbiegają od rzeczywistych dla każdej ze zmiennych.



Rys. 5. Wartości funkcji wrażliwości  $S_{y,v}^{(2)}$  stopnia drugiego  
Fig. 5. The values of the second order sensitivity functions  $S_{y,v}^{(2)}$


Wartości funkcji wrażliwości względem zmiennej  $z$  wykazują największą czułość (wrażliwość) na wahania wartości zmiennej  $y$ . Model  $Y(y, z)$  wykazał największą dokładność.



Rys. 6. Prognoza wartości zmiennej  $q$  w modelach uproszczonych  $Q(q, y)$  oraz  $Q(q, z)$   
Fig. 6. The prognosis of the  $q$  variable value using simple model  $Q(q, y)$  and  $Q(q, z)$

Wyniki predykcji wartości zmiennej  $z$ , okazały się korzystniejsze od uzyskanych za pomocą GMDH, ale nadal niewystarczająco dokładne. Predykcja wartości zmiennej  $q$  przedstawiona została na rysunku rys. 6, natomiast zmiennej  $r$  na rys. 7.

Dla zmiennej  $q$ , funkcje wrażliwości ze zmienną  $z$  przyjmowały najwyższe wartości bezwzględne. Dla zmiennej  $r$  – funkcje ze zmienną  $q$  oraz  $z$ .



Rys. 7. Prognoza wartości zmiennej  $r$  w modelach uproszczonych  $R(r, y)$  oraz  $R(r, q)$   
Fig. 7. The prognosis of the  $r$  variable value using simple model  $R(r, y)$  and  $R(r, q)$

## 5. Wnioski

Porównując wyniki predykcji otrzymane metodą podstawową GMDH oraz zmodyfikowaną z funkcjami wrażliwości obserwuje się znaczną poprawę dokładności predykcji na korzyść przedstawionej metody, mimo niewielkiej próbki danych wejściowych. Udało się zmniejszyć stopień skomplikowania poszczególnych modeli cząstkowych zarówno w sferze obliczeń, jak i ich budowy, względem modeli metody podstawowej, co ułatwia ich analizę przez ekspertów – ludzi. Wydaje się, że dzięki zastosowaniu funkcji wrażliwości uda się przełamać pewne słabości metody GMDH. Przedstawiona metoda, mimo konieczności znajdowania rozwiązania układów równań liniowych (niebezpieczeństwo uzyskania źle uwarunkowanych macierzy), nieliniowych (problem ustalenia właściwego punktu początkowego) na jednym z etapów predykcji, wydaje się być rozwojowa.

## 6. Literatura

- [1] Rogoza V., Bobkowska J.: Using sensitivity functions to simulation of complex processes – Przegląd Elektrotechniczny, nr 10b, 2012, s. 188-191.
- [2] Fryer P.: A brief description of Complex Adaptive Systems and Complexity Theory, [Online]. Available: <http://www.trojanmice.com/articles/complexadaptivesystems.htm>. [Accessed 24 1 2010].
- [3] Ahmed E., Elgazzar A. and Hegazi A.: An overview of complex adaptive systems [Online]. Available: <http://arxiv.org/abs/nlin/0506059>. [Accessed 15 6 2005].
- [4] Ivakhnenko A. and Müller J.: Selbstorganisation von vorhersagemodellen, Berlin: Verlag Technik, 1984.
- [5] Tsytkin Z. Y.: Adaptation and Learning in Automatic Systems, New York: Academic Press, 1971.
- [6] Holland H.: Adaptation in Natural and Artificial Systems, London: A Bradford Book, The MIT Press Cambridge, Massachusetts, 1992.
- [7] Wiliński A.: GMDH - metoda grupowania argumentów w zadaniach zautomatyzowanej predykcji zachowań rynków finansowych, Warszawa: Instytut Badań Systemowych PAN, 2009.