

ZASTOSOWANIE TEORII SZARYCH SYSTEMÓW DO MODELOWANIA I PROGNOZOWANIA W DIAGNOSTYCE MASZYN

Czesław CEMPEL, Maciej TABASZEWSKI

Instytut Mechaniki Stosowanej, Politechnika Poznańska,

czeslaw.cempel@put.poznan.pl, maciej.tabaszewski@put.poznan.pl

Streszczenie

Praca przedstawia metodologię budowy szarego modelu pierwszego rzędu przydatnego w prognozowaniu stanu za pomocą symptomów drganiowych. Pokazano na przykładach, że szare modele mogą mieć zastosowanie w diagnostyce maszyn prostych, dla których wystarcza podejście jedno symptomowe, jak też w diagnostyce wielu uszkodzeniowej obiektów złożonych. Zastosowano tu metodę szarych systemów Deng'a z odcinkowym prognozowaniem tzw. ślizgającym okienkiem, zaczerpniętą z najnowszej literatury przedmiotu.

Słowa kluczowe: diagnostyka maszyn, symptomy drganiowe, szare modele, prognozowanie.

APPLICATION OF GREY SYSTEM THEORY TO MODELING AND FORECASTING IN MACHINE CONDITION MONITORING

Summary

The paper presents methodology of grey system theory and the first order grey model GM(1,1), which can be applied for the machine condition forecasting using vibration symptoms, and rolling forecasting window. Basing on real data taken from vibration condition monitoring, it was shown successfully one step forecasting with the grey model applied to condition observation by one symptom only. It was shown also, that in case of multidimensional condition monitoring one can apply the same methodology to the generalized symptom of condition, obtained from singular value decomposition of symptom observation matrix.

Keywords: machines, condition monitoring, vibration symptoms, grey system theory, condition forecasting.

1. WSTĘP

Liczba znaczących obserwacji w diagnostyce, nawet przy zastosowaniu systemów monitorujących, nie jest duża – zwykle jest ich kilkadziesiąt. Do tego, decyzyjnie istotne są zwykle obserwacje końcowe o niewielkiej liczbie. Zatem prognozowanie przyszłych wartości symptomów stanu technicznego maszyn jest zagadnieniem niezwyklej wagi i poświęcono mu w literaturze przedmiotu dużo miejsca, jak na przykład: [2], [3], [9], [1], [16], [14], [15]. Stosowane metody do prognozowania (*ponad 300*, [18]) rozciągają się tu od wyrównywania wykładniczego Browna aż do sieci neuronowych z automatycznym nadzorem poprawności modelu.

Jak się obecnie okazuje z przeglądu dostępnej literatury światowej możliwe jest użycie znacznie prostszych metod wynikających z **teorii szarych systemów** (*grey systems theory-GST lub w skrócie GS*) opracowanej i opisanej po raz pierwszy przez uczonego chińskiego J-L. Deng'a w roku 1982, [4]. Odkrycie tej niezwykle efektywnej metody modelowania i prognozowania krótkookresowych szeregów czasowych długo pozostawało w cieniu, jako że pierwsze książki opublikowano w języku chińskim. Pierwszą publikacją angielską pokazującą możliwe aplikacje ukazała się dopiero w roku 1990, [6]. Mimo tego naukowy świat chińsko języczny szybko

rozpoznał szeroką możliwość zastosowań tkwiących w metodzie i teorii szarych systemów zaczęto stosować we wszystkich dziedzinach bazujących na kwantyfikowalnych modelach z **niewielką** liczbą (*nawet kilka*) niepełnych i **niepewnych** danych; od nauk społecznych, przez ekonomię i gospodarkę do nauk technicznych. Pojawił się już nawet w języku chińskim specjalny **Toolbox** do systemu **Matlab®** [18], do modelowania i prognozowania zachowania się systemów ewolucyjnych. Pojawiły się również różne odmiany metody grey systems (**GS**), np. w powiązaniu ze zbiorami rozmytymi (*grey-fuzzy*) [21], czy też z metodą Taguchi [19]. Okazało się też w prognozowaniu, że metoda GS jest najbardziej efektywna, jeśli **zapomina** przeszłe dane, czyli modeluje i prognozuje w **okienku** danych o małej szerokości, co z angielska nazwano rolling forecast.

Celem niniejszej pracy jest zasygnalizowanie możliwości metodologii **GS** i pokazanie szczegółowego zastosowania w prognozowaniu diagnostycznym dla pojedynczych symptomów oraz dla diagnostyki wielowymiarowej.

2. SZARE SYSTEMY DYNAMICZNE I ICH ZASTOSOWANIA (W PROGNOZOWANIU STANU)

Od czasów monografii J-L. Deng'a pojawiło się wiele wykładni metodologii szarych systemów, czyli w skrócie szarych modeli (*grey models-GM*). Generalnie **szary model** opisujący zachowanie się systemu za pomocą obserwowanego symptomu $x^{(0)}(k)$, $k=1, \dots, n$, może być przedstawiony równaniem różniczkowym zwyczajnym l -tego rzędu i mieć wymuszenie m -tego rzędu, co zapisuje się jako **GM(l,m)**. Oznacza to, że po prawej stronie modelu mamy m – zmiennych niezależnych wymuszających zachowanie systemu opisane równaniem różniczkowym (*lub równoważnym różnicowym*) l – tego rzędu, jak niżej:

$$\sum_{i=0}^l a_i \frac{d^{n-i} \mathbf{x}^{(1)}}{dt^{n-i}} = \sum_{j=1}^{m-1} b_j \mathbf{y}_j^{(1)}, \quad (1)$$

gdzie $x^{(1)}(k) = \sum_{i=1}^k x^{(0)}(i)$ – zmienna stanu modelu,

a \mathbf{y}_j niezależne wymuszenia przyjęte dla poprawnego odwzorowania zachowania identyfikowanego modelu, natomiast współczynniki wielomianów; a_i oraz b_j wyznacza się z obserwowanego szeregu czasowego $x^{(0)}(k)$, $k=1, \dots, n$.

Startując z ogólnego modelu (1) możemy wyróżnić trzy dziedziny zastosowań modeli GS. Pierwsza obszar jest łatwy do uchwycenia w (1) dla $l=0$, czyli dla zerowego rzędu równania różniczkowego. Bowiem, możemy taki model GS użyć do poszukiwania siły związku między zmienną zależną \mathbf{x} , a zmiennymi niezależnymi \mathbf{y}_j daje to wtedy tzw *grey relational analysis*. Z podobnych przesłanek można wychodzić przy formułowaniu decyzji o rozmytych związkach przyczynowo skutkowych danego zbioru sytuacji z możliwymi ich efektami (*grey decision making*) [12]. Wreszcie trzeci obszar, dla $l \neq 0$, to budowa modelu prognostycznego obiektu dla obserwowanego szeregu czasowego (*symptomu*), $x^{(0)}(k)$, $k=1, \dots, n$.

Jak do tej pory większość prac w prognozowaniu, niezależnie czy to analiza rynku [17], czy zużycia silnika Diesla [20], przyjmuje za punkt wyjścia uproszczone równanie **GM(1,1)**, czyli równanie pierwszego rzędu ($l=1$) z jednym rodzajem wymuszenia. Posługując się przyjętą terminologią i oznaczeniami można, np. [20], to zagadnienie dobrze zapisać w postaci kilku, jak się wydaje łatwo zrozumiałych kroków.

Krok 1.

Zdefiniujemy wierszowy wektor obserwacji;

$$\mathbf{x}^{(0)} = \{x^{(0)}(1), x^{(0)}(2), \dots, x^{(0)}(n)\}, \quad (2)$$

gdzie $n \geq 4$ jest liczbą obserwacji.

Krok 2.

Tworzymy wektor sum cząstkowych AGO, $\mathbf{x}^{(1)}$ (*accumulating generating operation*)

$$x^{(1)}(k) = \sum_{i=1}^k x^{(0)}(i), \quad k=1, 2, \dots, n. \quad (3)$$

W ten sposób wierszowy wektor **AGO** jest sformułowany, jako monotonicznie rosnący

$\mathbf{x}^{(1)} = \{x^{(1)}(1), x^{(1)}(2), \dots, x^{(1)}(n)\}$, przy warunku; $x^{(1)}(1) = x^{(0)}(1)$,

Krok 3.

Dla szeregu **AGO** definiujemy szary model pierwszego rzędu (*patrz (1)*), **GM(1,1)**

$$\frac{d\mathbf{x}^{(1)}(t)}{dt} + a\mathbf{x}^{(1)}(t) = u \quad (5)$$

gdzie

t oznacza zmienną niezależną (*tutaj miarę eksploatacji np.: czas / lub nr kolejny odczytu*),

a oznacza eksponent wzrostu, zaś u jest zmienną kontrolną szeregu modelu.

Krok 4.

Rozwiązujemy równanie różniczkowe (5) z jedynekowym krokiem zmiennej t i zadany warunek początkowy (4), otrzymując:

$$\hat{x}^{(1)}(k+1) = [x^{(0)}(1) - u/a] \exp(-ak) + u/a \quad (6)$$

gdzie $\hat{x}^{(1)}$ oznacza prognozę rozwiązania **AGO**.

Krok 5.

Zamieniając w (5) różniczkę przyrostem skończonym dla jednostkowego kroku $t=1$, możemy napisać równania różnicowe wsteczne i progresywne, otrzymując:

$$\begin{aligned} x^{(1)}(k+1) - x^{(1)}(k) + a x^{(1)}(k) &= u, \\ x^{(1)}(k+1) - x^{(1)}(k) + a x^{(1)}(k+1) &= u. \end{aligned} \quad (7)$$

Kombinując oba powyższe równania znajdziemy

$$x^{(1)}(k+1) - x^{(1)}(k) = -a/2 [x^{(1)}(k) + x^{(1)}(k+1)] + u, \quad k=1, \dots, n. \quad (8)$$

Krok6;

Rozpisując powyższe równanie dla kolejnych k i posługując się pierwotnym wektorem obserwacji $\mathbf{x}^{(0)}$ mamy możliwość wyznaczenia niewiadomych współczynników szeregu modelu a i u . Wykonując to za pomocą metody najmniejszych kwadratów uzyskamy macierzowe rozwiązanie w postaci:

$$[a, u]^T = (\mathbf{B}^T \mathbf{B})^{-1} \mathbf{B}^T \mathbf{Y}, \quad (9)$$

gdzie: $Y = [x^{(0)}(2), x^{(0)}(3), \dots, x^{(0)}(n)]^T$,
natomiast macierz:

$$B = \begin{bmatrix} -[x^{(1)}(1) + x^{(1)}(2)] & 1 \\ -[x^{(1)}(2) + x^{(1)}(3)] & 1 \\ \dots & \dots \\ -[x^{(1)}(n-1) + x^{(1)}(n)] & 1 \end{bmatrix}$$

Krok 7.

Definiując przekształcenie odwrotne (*inverse*) AGO, czyli IAGO do wyliczenia prognozowanej obserwacji z wektora prognoz sum cząstkowych (AGO) w postaci:

$$\hat{x}^{(0)}(k+1) = \hat{x}^{(1)}(k+1) - \hat{x}^{(1)}(k), \quad (10)$$

zatem z użyciem rozwiązania (8) możemy znaleźć końcową wartość prognozy wg. modelu

GM(1,1), jak niżej:

$$\hat{x}^{(0)}(k+1) = \left[x^{(0)}(1) - u/a \right] (e^{-ak} - e^{-a(k-1)}), \quad k=2,3,\dots,n. \quad (11)$$

I to jest cała tajemnica prognozowania z wykorzystaniem szarego modelu Deng'a rzędu pierwszego GM(1,1). Jak można zauważyć z drugiego kroku procedury szukanemu modelowi trendu nadaje się charakter monotoniczny, który w kroku trzecim zdobywa legitymację równania różniczkowego/różnicowego o rozwiązaniu eksponencjalnym. Zatem do tego typu modeli i prognozowania nadają się obserwacje nieujemne i z założenia rosnące, tak jak symptomy stanu podczas zużywania się maszyn. Dlatego też w wielu przypadkach dobrą prognozę można uzyskać już po kilku obserwacjach, natomiast większa liczba obserwacji daje większe błędy prognozy. Rozwiązaniem jest tutaj prognozowanie w małym okienku ślizgającym się po większej liczbie danych. W najnowszej literaturze teorii i aplikacji szarych systemów nosi to nazwę 'rolling window' [19] i staje się popularne przy większej liczbie danych, jak np. przy prognozowaniu kursu dolara [17]. Zobaczymy

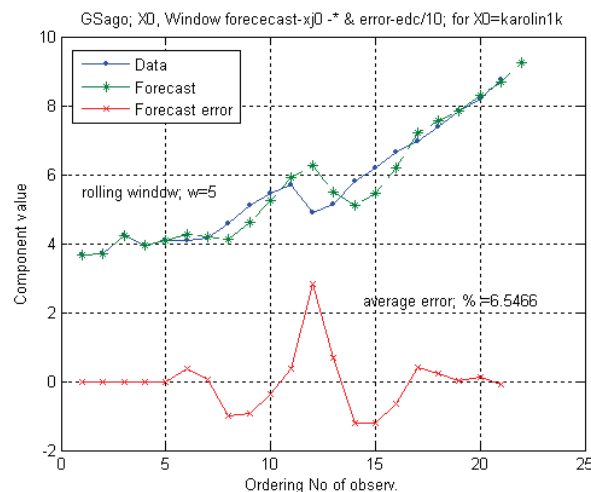
w następnych punktach jak to wygląda w zastosowaniu do prognozowania w diagnostyce maszyn.

3. PROGNOZOWANIE

JEDNOWYMIAROWE – PRZYKŁADY

W ogóle niewiele jest zastosowań teorii szarych systemów w diagnostyce. Po bardzo wczesnych dwu pracach z Australii [10] opublikowanych w biuletynie wewnętrznym Monash University w Melbourne, mamy prawie dziesięcioletnią przerwę w literaturze zachodniej anglojęzycznej. Mimo powstania czasopisma **Journal of Grey System Theory** w Chinach, idea ta z oporem przebija się do zachodniej metodologii, o czym świadczy wielka liczba takich badań na konferencjach międzynarodowych w Chinach, [8] widziana ostatnio przez pierwszego z autorów tej pracy. Autorzy zainspirowani tymi osiągnięciami i dalszymi z przytoczonej częściowo literatury postanowili przenieść metodę GS na grunt wibroakustycznej diagnostyki maszyn. Zaimplementowano, zatem przytoczone wyżej kroki budowy modelu prognostycznego w systemie symulacyjnym Matlab®, dodając procedurę ruchomego okienka prognostycznego – *rolling window*. Kolejne rysunki przedstawiają efekty działania programu **GSago.m** w zastosowaniu do prognozowania w diagnostyce jedno i wielowymiarowej.

Weźmy wpieryw pod uwagę ewolucję skutecznej prędkości drgań (*mm/s*) na łożysku młyna wentylatorowego do przemiału węgla w elektrociepłowni. Na rys. 1 przedstawiono uśrednioną w przedziałach (21 obserwacji) ewolucję symptomu pokazując jako oddzielne krzywe; zaobserwowany symptom X_0 , jego prognozę x_{j0} oraz bieżący błąd prognozy edc zmniejszony dziesięciokrotnie celem umieszczenia go na jednym rysunku.




Rys. 1. Początkowy fragment ewolucji prędkości drgań łożyska młyna wentylatorowego X_0 , jej prognoza x_{j0} o jeden krok w przód i bieżący błąd prognozy edc , wraz z informacją o szerokości okna w i średnim błędzie prognozy


Jak widać z rysunku gwałtowne skoki symptomu są korygowane w prognozie w jej następnym kroku (*krzywa z gwiazdkami**), błąd prognozy jest w tym miejscu ($k=12$) maksymalny (*ponad 20%*) przy średnim błędzie w całym zakresie ($k=1,2 \dots 21$) równym 6,55%. Nie jest to duży błąd, tym bardziej, że końcowy fragment krzywej prognozy ma błąd znacznie mniejszy. Według ogólnie przyjętych zasad **prognozę na poziomie 5%** uważa się za dobrą. Uzyskiwane wartości są bliskie tej granicy.

A jak wygląda prognoza dla tych samych obserwacji w świetle możliwości zmiany szerokości ślizgającego okna prognozy w ? Sytuację tą dla tego samego obiektu przedstawia kolejny rysunek (rys. 2) dla w w zakresie (2-20). Jak widać z rysunku krzywa błędu średniego prognozy **aeW** w funkcji szerokość okna ma szereg minimów dla $w = 4; 10; 13$, a minimalny błąd średni **aeW** = **4.0%** można uzyskać dla szerszego okna $w = 13$, większego niż połowa

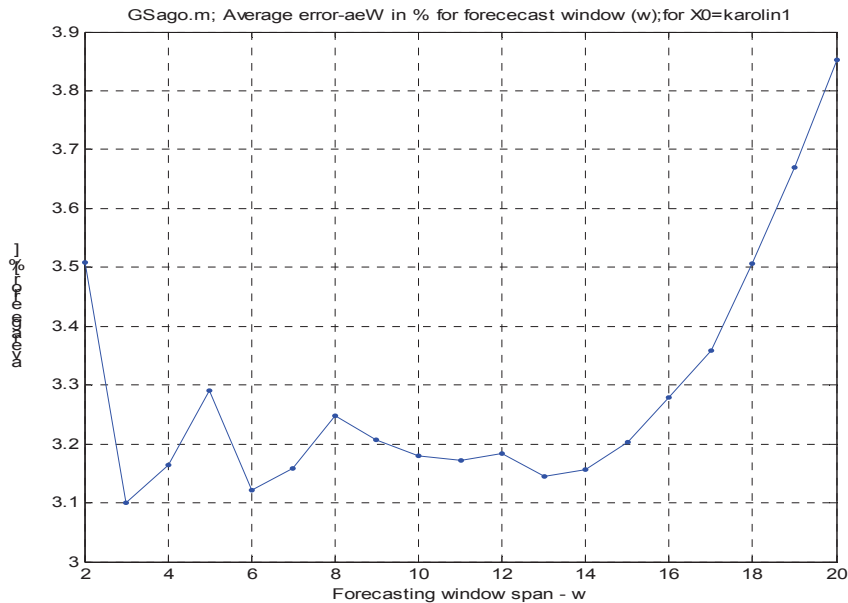
liczby obserwacji. Weźmy teraz ten sam młyn wentylatorowy wraz z jego całkowitą krzywą życia prędkości drgań łożyska bez uśredniania w wartościach w przedziałach ($n=69$). Sytuację tą w tej samej konwencji prezentacji jak na rys. 1 przedstawia rys. 3. Widać tu, że przy tym samym oknie prognozy $w = 5$ mamy nieco mniejszy średni błąd prognozy równy około **3,3%**. Ponadto krzywa bieżącego błędu zachowuje się podobnie mając lokalne maksima w miejscach skoku prognozowanego symptomu. Natomiast inaczej zachowuje się średni błąd prognozy **aeW** w funkcji szerokości okna w . Mamy tu kilka minimów dla $w = 3; 6; 13$ z minimum globalnym dla $w = 3$, z błędem **aeW(3) = 3,1%**. Następnie dla wzrastających wartości $w > 13$ błąd prognozy rośnie monotonicznie uzyskując dla $w > 20$ wartości rzędu kilkunastu procent.



Rys. 2. Średni błąd prognozy w funkcji okna prognozy w dla danych symptomowych z rys. 1



Rys. 3. Krzywa życia prędkości drgań łożyska młyna wentylatorowego, jej prognoza wg szarego modelu diagnostycznego i bieżący błąd prognozy



Rys. 4. Średni błąd prognozy szarego modelu symptomu z rys. 3 w funkcji szerokości okna prognozy w

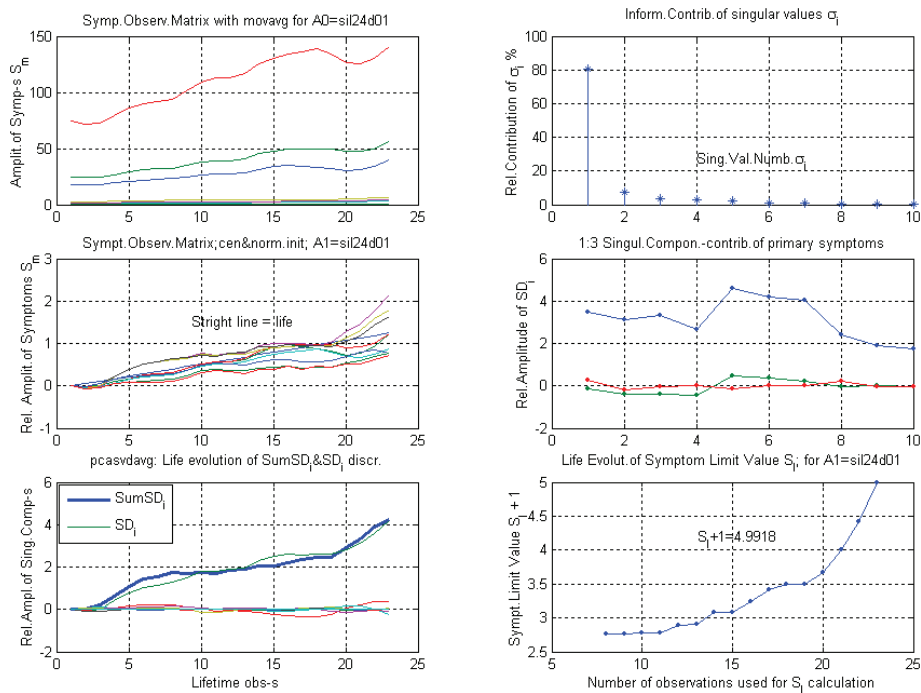
Podsumowując oba pokazane przypadki zastosowania szarego modelu **GM(1,1)** do prognozowania wartości krzywych symptomowych drgań można powiedzieć, że w zależności od monotoniczności krzywej symptomowej uzyskane średnie błędy prognozy są rzędu kilku do kilkunastu procent. Natomiast błędy lokalne, chwilowe mogą osiągać nawet rząd 20% i wyżej, zależnie od ostrości skoku na krzywej symptomowej. Wynika stąd, że opisywana metoda prognozowania nadaje się w szczególności dla symptomowych krzywych życia charakteryzujących się monotonicznym wzrostem bez istotnych fluktuacji wartości. W przypadku zmiennych parametrów sterowania obiektu, które wpływają na wartości mierzonego symptomu, należy grupować obserwacje dotyczące poszczególnych wartości tychże parametrów i tak otrzymane krzywe życia rozpatrywać osobno. Istotnym problemem jest także konieczność zachowania stałego kroku pomiarowego. Aby go zapewnić można jednak zastosować tutaj technikę interpolacji, bądź też zastosować metodę ulepszenia kroku proponowaną przez Guo, [7]. Prezentowana zaś wyżej metoda nadaje się do prognoz krótkookresowych w przedstawionych przykładach jest to zawsze jeden krok w przód.

Tyle na temat prognozowania jednego symptomu w diagnostyce prostych maszyn, takich np. jak młyn

wentylatorowy. Zobaczmy niżej jak wygląda podobna sytuacja dla diagnostyki wielowymiarowej.

4. PROGNOZOWANIE W DIAGNOSTYCE WIELOWYMIAROWEJ

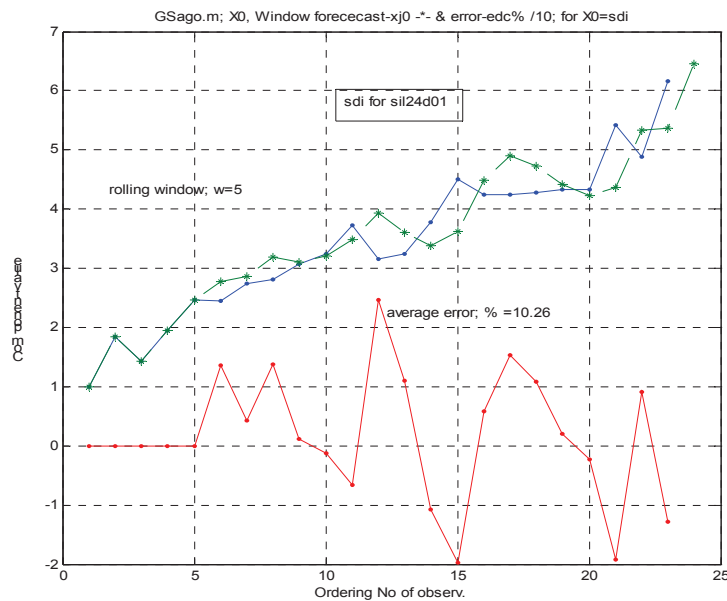
Wielo uszkodzeniowa diagnostyka maszyn jest na początku swego rozwoju, nie ma więc tu jeszcze ustalonych metod. Generalnie do przetwarzania sygnałów i/lub symptomów używa się tu sieci neuronowych [15], jedną z metod tzw. data fusion [11], oraz rozkład względem wartości szczególnych – **SVD** uprawiany przez autorów tej pracy. Posłużymy się dalej tą ostatnią metoda do ekstrakcji informacji o uszkodzeniach i to w przypadku najprostszym jednego dominującego uszkodzenia. Rys. 5 przedstawia wynik jednoczesnego przetwarzania dziewięciu krzywych symptomowych drgań rejestrowanych na silniku diesla stosowanym do napędu lokomotyw. Pomiary wszystkich wielkości drganiowych wykonywano na głowicy jednego z cylindrów, co 10 tysięcy kilometrów przebiegu.



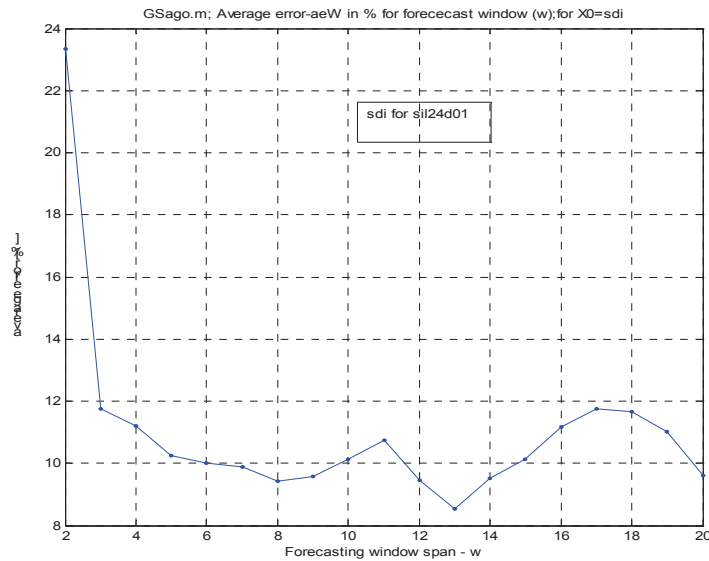
Rys. 5. Efekty przetworzenia 9 drganiowych krzywych symptomowych w diagnostyce silnika lokomotywy spalinowej (pomiary co 10 tys. km)

Obrazek lewy górny rys. 5 przedstawia 9 krzywych symptomowych pokazanych w ich jednostkach i wartościach pomiarowych, natomiast obrazek poniżej przedstawia to samo po unormowaniu do wartości początkowych każdego symptomu. Dolny obrazek z lewej strony przedstawia efekt działania algorytmu SVD i daje uogólnione krzywe życia uszkodzeń. A ponieważ w pierwszym podejściu

interesuje nas ogólne zaawansowanie uszkodzeń to do naszych celów weźmiemy krzywą **SumSD_i** (niebieska), traktując ją dalej jako wejście do modelu GM(1,1). Efekt przetworzenia tych danych naszym programem **GSago** pokazuje rys. 6 przedstawiony w tej samej konwencji co poprzednie rys. 1 i 5.



Rys. 6. Uogólniona krzywa zaawansowania uszkodzeń silnika trakcyjnego, jej prognoza wg szarego modelu (gwiazdki *) wraz błędem prognozy



Rys. 7. Średni błąd prognozy uogólnionego symptomu stanu silnika trakcyjnego w zależności od szerokości okna obliczeniowego w

Jak widać z rys. 6 prognoza jest opóźniona w stosunku do obserwacji o jeden krok i w punktach skoku obserwowanej wartości uzyskujemy maksimum błędu chwilowego dochodzącego czasami do 20%, przy średnim błędzie prognozy rzędu 10%. Jest to niezły wynik, a jak popatrzymy na następny rys. 7 to widzimy, że dla naszej szerokości okna $w=5$ średni błąd nie jest minimalny, może on być mniejszy dla $w=8$, a zwłaszcza $w=13$. Widać więc z powyższego, że dla zagadnień diagnostyki wielowymiarowej szare modele symptomowe mogą być tak samo przydatne jak i dla diagnostyki jednowymiarowej.

W ramach badań tej pracy przeanalizowano jeszcze wiele przypadków prognoz jednowymiarowych i wielowymiarowych badając problem optymalnej prognozy przy warunku minimalnego błędu średniego aeW . Okazuje się z tych badań, niepokazanych tu z braku miejsca, że optymalna szerokość ślizgającego okna dla $GM(1,1)$ jest rzędu $w = 4 - 8$, mimo że np. błąd prognozy nie jest jeszcze minimalny. Bowiern powyżej tej szerokości przedziału w pogarsza się jakość prognozy i wielkości prognozowane mogą być równe lub nawet mniejsze od obserwowanych, co może być w diagnostyce całkowicie nieprzydatne.

5. PODSUMOWANIE

Przedstawiona wyżej metodologia prognozowania krótkoterminowego wg koncepcji teorii szarych systemów GS nadaje się także do zastosowań w dziedzinie drganiowej diagnostyki maszyn. Wniosek ten jest słuszny zarówno dla diagnostyki jedno uszkodzeniowej jak i wielu uszkodzeniowej. Zastosowano tu metodę ślizgającego się okienka prognozy, co daje mniejszy błąd, a jak wynika

z przedstawionych danych zawsze można znaleźć szerokość okna o minimalnej wielkości błędzie prognozy. Wydaje się, iż można się pokusić o bieżące szacowanie optymalnej szerokości okna wychodząc z oszacowania nieciągłości prognozowanej krzywej życia. Będzie to ewentualnie przedmiotem dalszych badań.

6. Literatura

- [1] Batko W.: *Metody syntezy diagnoz predykcyjnych w diagnostyce technicznej*. Rozprawa habilitacyjna, AGH, Kraków 1984. str. 134.
- [2] Cempel C.: *Diagnostyka Wibroakustyczna Maszyn*. Wyd. Politechniki Poznańskiej, 1984, wydanie II poprawione, PWN, Warszawa 1990.
- [3] Cempel C.: *Simple condition forecasting techniques in vibroacoustical diagnostics*. Mechanical Systems and Signal Processing, 1987, pp 75 – 82.
- [4] Deng J-L.: *Control Problems of Grey Systems*. Systems and Control Letters, Vol. 1, No 5, North Holland, Amsterdam, 1982.
- [5] Deng J-L.: *Introduction to grey system theory*. The Journal of Grey System, 1989, Vol. 1, No 1, pp 1-24.
- [6] Deng J-L.: *The Course on Grey Systems Theory*. Publishing House, Huazhong University of Technology, Wuhan, (in Chinese), 1990.
- [7] Guo R.: *Modeling imperfectly repaired system data via grey differential equations with unequal-gapped time*. Reliability

- Engineering & System Safety, Vol. 92, No 3, March 2007, pp378 -391.
- [8] ICME06, Proceedings of the First International Conference on Maintenance Engineering, Cheng Du, China, October 2006, p1300.
- [9] Kaźmierczak J.: *Zastosowanie liniowych modeli procesów losowych do prognozowania w diagnostyce maszyn*. Rozprawa habilitacyjna, Politechnika Śląska, Gliwice 1989.
- [10] Luo M., Kuhnell B. T.: *Forecasting machine condition using grey-system theory*. Bulletin of MCCM, Monash Univ. 1990, Vol. 2, No 1.
- [11] Raheja D., Llinas J., Nagi R., Romanowski C.: *Data fusion / data mining based architecture for condition based maintenance*. International Journal of Production Engineering, Vol. 44, No 14, 2006, pp 2869 -2887.
- [12] Sijing C., Guangxu T., Hualin G.: *Grey system theory applied to rock mechanics*. International Journal of Rock Mechanics, Vol.30, No 4, 1993, pp 473-478.
- [13] Tabaszewski M.: *Koncepcja wielosymptomowej prognozy diagnostycznej w oparciu o sieci neuronowe*. 2007, (publikacja w przygotowaniu)
- [14] Tabaszewski M.: *Metody doboru modeli prognostycznych w automatycznych systemach diagnostycznych*. Diagnostyka , vol. 30, tom 2, 2004, str. 125-128.
- [15] Tabaszewski M.: *Prognozowanie resztkowej miary eksploatacji mlyna wentylatorowego w oparciu o sieci neuronowe*. Diagnostyka , nr. 3(39)/2006, str. 149-156.
- [16] Tylicki H.: *Optimalizacja procesu prognozowania stanu technicznego pojazdów mechanicznych*. Rozprawa habilitacyjna, ATR, Bydgoszcz 1998, str. 103.
- [17] Wang T. C., Liou M. C., Hung H. H.: *Application of grey theory on forecasting the exchange rate between TWD and USD*. Internet 2005, pp 1 – 8.
- [18] Wen K. L., Chang T. C.: *The research and development of completed GM(1,1) model toolbox using Matlab*. International Journal of Computational Cognition, 2005, Vol. 3, No 3, pp 42-48.
- [19] Yao A. W. L., Chi S. C.: *Analysis and design of a Taguchi-Grey based electricity demand predictor for energy management systems*. Energy Conversion & Management, 2004, Vol. 45, pp 1205-1217.
- [20] Zhang H., Li Z., Chen Z.: *Application of grey modeling method to fitting and forecasting wear trend of marine diesel engines*. Tribology International, 2003, Vol.36, pp 753 – 756.
- [21] Zhang L., Wang Z., Zhao S.: *Short-term fault prediction of mechanical rotating parts on the basis of fuzzy-grey optimizing method*. Mechanical Systems and Signal Processing, 2007, Vol.21, pp 856-865.



Prof. dr hab. **Czesław CEMPEL** jest kierownikiem Zakładu Wibroakustyki i Bio-Dynamiki Systemów Wydziału Budowy Maszyn i Zarządzania Politechniki Poznańskiej, mult. dr h. c., członek korespondent Polskiej Akademii Nauk, członek Komitetu Badań Naukowych w trzeciej kadencji. Jest członkiem wielu organizacji naukowych krajowych i zagranicznych np. IMEKO, EUROSCIENCE, GAMM. Jeden z założycieli PTDT w 1990r. Obecnie jest honorowym przewodniczącym PTDT. Zajmuje się wibroakustyką i diagnostyką maszyn, inżynierią systemów, ekologią. Autor ponad 370 opublikowanych prac, 14 skryptów i książek.



Dr inż. **Maciej TABASZEWSKI** jest adiunktem w Instytucie Mechaniki Stosowanej Politechniki Poznańskiej. Jego zainteresowania dotyczą metod prognozowania wartości symptomów, stanu maszyn oraz czasu resztkowego do awarii, a także wykorzystania metod sztucznej inteligencji w procesie prognozowania, modelowania miar sygnałów diagnostycznych i pomiarów wielkości mechanicznych. Zajmuje się także programowaniem obiektowym dla potrzeb narzędzi cyfrowej analizy sygnałów, oraz metodami eksploracji danych.

Praca przedstawiona jako wykład plenarny na XXXIV Sympozjum 'Diagnostyka Maszyn', Węgierska Górka, marzec 2007.