

METODY DOBORU MODELI PROGNOSTYCZNYCH W AUTOMATYCZNYCH SYSTEMACH DIAGNOSTYCZNYCH

Maciej TABASZEWSKI

Instytut Mechaniki Stosowanej
Ul. Piotrowo 3, 60-965 Poznań,
fax. 61 6652309, Maciej.Tabaszewski@put.poznan.pl

Streszczenie

Praca zawiera próbę rozwiązania problemu wyboru optymalnego modelu prognostycznego w automatycznych (skomputeryzowanych) systemach nadzoru diagnostycznego. Wraz z napływem nowych danych pomiarowych założony wcześniej model prognostyczny może się dezaktualizować co wymaga uruchomienia mechanizmu generacji (wyboru) nowego modelu prognostycznego bez wymaganej wiedzy eksperta w oparciu tylko o zgromadzone wcześniej dane. W pracy przedstawiono wyniki różnych proponowanych metod zastosowanych w celu przeciwdziałania dezaktualizacji modelu prognostycznego.

Słowa kluczowe: modele symptomowe, prognozowanie wartości symptomu.

METHODS OF SELECTION OF FORECASTING MODELS IN AUTOMATIC CONDITION MONITORING SYSTEMS

Abstract

The paper contains an attempt of solution of optimal choice of forecasting model in automatic condition monitoring systems. As the new measured data are gathered an assumed earlier forecasting model can become inadequate. It requires to start a mechanism of generating or choosing a new forecasting model without expert knowledge, based only on some gathered earlier data. The paper presents results of the various methods used for avoidance of loss of timelines of forecasting models.

Keywords: symptom models, symptom value forecasting

1. WPROWADZENIE

W wielu przypadkach diagnostyki eksploatacyjnej maszyn mają zastosowanie środki diagnozy o wysokim stopniu automatyzacji [1]. W rozwiązaniu takim z reguły wykorzystuje się komputer wraz z odpowiednim oprogramowaniem pozwalającym na automatyzację pomiarów, automatyzację wnioskowania diagnostycznego i identyfikacji uszkodzeń bez udziału człowieka jako eksperta. Z punktu widzenia diagnostyki eksploatacyjnej maszyn bardzo istotny jest również problem prognozy wartości symptomu i prognozy stanu. Rodzi się jednak problem jak w przypadku systemu automatycznego, który ma wypracować prognozę bez udziału eksperta dobrać odpowiedni model prognostyczny w warunkach gdy obserwowanych jest wiele miar sygnałów diagnostycznych, których dokładnego zachowania nie da się przewidzieć na samym początku uruchomienia systemu? Można oczywiście założyć określone modele jednak nigdy nie będzie pewności, że modele te sprawdzą się w przyszłości w miarę napływu nowych danych diagnostycznych.

2. SPOSOBY PRZECIWDZIAŁANIA DEZ-AKTUALIZACJI MODELU

W systemach budowanych w oparciu o techniki komputerowe, w których chodzi o maksymalne „odciążenie” obsługi można wdrożyć do celów prognozowania takie techniki jak:

- sieci neuronowe,
- modele autoregresyjne i średniej ruchomej,
- modele o zmiennych parametrach,
- modele regresyjne,
- modele oparte o krzywe sklepane,
- wyrównywanie wykładnicze itp..

Niektóre z wymienionych metod opierają się na szeregach czasowych i nie wymagają uwzględniania informacji o zmiennych niezależnych w modelach co ma duże znaczenie gdy niewiadomo jakie te zmienne przyjąć. Modele te jak i regresyjne wymagają jednak założeń co do struktury lub postaci. Przykładowo model sieci neuronowej może mieć różną ilość neuronów w warstwie ukrytej, model

autoregresyjny ARIMA różną ilość wyrazów związaną z autoregresją i średnią ruchomą itp. W przypadku systemów diagnostycznych, które rejestrują wiele symptomów okazuje się, że przynajmniej w początkowej fazie eksploatacji takiego systemu nie daje się z góry założyć sposobu zachowania się konkretnego symptomu, stąd początkowo założona struktura lub postać modelu użytego do prognozy może stać się nieadekwatna po pewnym czasie co odbija się na jakości prognozy i wymaga jego przebudowy.

Pierwszym rozwiązaniem problemu jest wybór metod czy modeli, które dzięki swojej elastyczności pozwalają na przewyciężenie ich dezaktualizacji w miarę napływu nowych danych pomiarowych.

W przypadku sieci neuronowej istnieją metody dające się zaimplementować w oprogramowaniu, pozwalające na odpowiedni dobór struktury modelu np.[2]: metody wrażliwościowe redukcji sieci, metody redukcji z zastosowaniem funkcji kary, metody rozbudowy sieci np. algorytm Fahlmana. Taką weryfikację i przebudowę modelu należałoby dokonać w przypadkach gdy stary model staje się nieadekwatny, co wiązałoby się także (choć nie zawsze) z długotrwałym ponownym uczeniem sieci. Podobnie istnieją pewne wytyczne dotyczące doboru wyrazów modeli typu ARIMA, natomiast powierzenie takiej przebudowy modelu odpowiedniemu programowi komputerowemu aby odbywała się ona gdy tylko zachodzi taka konieczność nie jest problemem łatwym. Inną możliwością jest zastosowanie modeli wyrównywania wykładniczego np. Browna, Holta. Tutaj znowu jednak jawi się problem doboru odpowiednich współczynników modeli, które jednak można aktualizować w oparciu o informacje o błędzie prognozy. Wreszcie można wybrać np. modele o zmiennych współczynnikach czy model trendu pelzającego, które z definicji „potrafią przystosować się” do nowych danych pomiarowych.

Przedstawiony problem można rozwiązać także inaczej bez ograniczania możliwości zastosowania innych metod np. nieliniowych modeli trendu. Ogólnie przeciwdziałanie dezaktualizacji modelu może odbywać się za pomocą jednej wspólnej metody dla wszystkich możliwych modeli prognozowania. Może to być przykładowo:

- wybór „najlepszego” modelu (metody) dla celów prognozy ze zbioru rozpatrywanych jako tego, który dokonywał ostatnio najlepszych prognoz,
- wybór „najlepszego” modelu (metody) dla celów prognozy ze zbioru rozpatrywanych modeli jako tego, który był ostatnio najlepiej dopasowany do danych pomiarowych,
- wybór modelu na podstawie decyzji wcześniej wyuczonej sieci neuronowej, która potrafi rozpoznać rodzaj trendu.

2.1. Wybór modelu w oparciu o śledzenie błędu prognozy

Proponowane rozwiązanie wydaje się być oczywiste. Rozpatrywany jest pewien zbiór modeli i metod identyfikacji parametrów tych modeli (funkcji strat). Wraz z napływem nowych danych pomiarowych określany jest dotychczasowy średni błąd prognozy poszczególnych metod. Następnie wybierany jest model o najmniejszym średnim błędzie prognozy i za pomocą tego modelu dokonuje się prognozy (lub tylko sugeruje się prognozę jako najbardziej odpowiednią). Po uzyskaniu kolejnego pomiaru można dokonać kolejnego, aktualnego oszacowania błędu prognozy i dokonać kolejnego wyboru. W momencie kiedy na podstawie nowych danych przyjmowany do pewnej chwili model przestaje się sprawdzać, system zmienia model na inny. Taki algorytm będzie działał z pewnym niewielkim „opóźnieniem”, tym większym, im większa jest liczba uśrednień założonych przy obliczaniu średniego błędu prognozy, jednak jak zostanie to przedstawione na przykładzie w dalszej części pracy, metoda ta daje dokładniejsze prognozy niż przyjęcie na stałe którekolwiek z rozpatrywanych modeli.

W celu wyznaczenia jakości modeli pod względem prognozy można posłużyć się np. miarą [2 s. 117]:

- MAPE (ang. *Mean Absolute Percentage Error*) [2]:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|P_i - \hat{P}_i|}{P_i} \cdot 100\%, \quad (1)$$

gdzie:

N - ilość prognoz, P_i – rzeczywiste realizacje symptomu, \hat{P}_i - wartość prognozy dla symptomu.

2.2. Wybór modelu w oparciu o oszacowanie jakości dopasowania

Drugi z proponowanych sposobów opiera się o ocenę jakości dopasowania. Zgodnie z tym podejściem należy wybrać ten model dla wyznaczenia wartości prognozy ze zbioru rozpatrywanych, który najlepiej odzwierciedla zachowanie obserwowanego symptomu. Takie podejście wydaje się być uzasadnione przy założeniu, że w rozpatrywanym zbiorze modeli znajduje się model dobrze opisujący matematycznie zmianę symptomu. Oczywiście nie ma pewności, że w rozpatrywanym zbiorze modeli jest ten właściwy. Jeżeli jakiś model w miarę napływu nowych danych okaże się lepszy pod względem jakości dopasowania to system zmienia sposób prognozowania. W takim przypadku jednak, o tym, że dany model przestał dobrze opisywać symptom można przekonać się dopiero po uzyskaniu nowych danych, więc co najmniej jedna prognoza będzie obciążona większym błędem niż wynikałoby to z możliwości rozpatrywanych modeli. Wydaje się jednak, że jeżeli charakter zmian nie będzie zbyt

gwałtowny nie powinno się to odbić istotnie na jakości prognozy. Pozostaje jednak istotne pytanie czy wysoka jakość dopasowania trendu do danych determinuje dobrą prognozę? Wydaje się jednak, że tak może być tylko wtedy gdy dysponujemy modelem, który matematycznie jest bardzo dobrym opisem obserwowanego zjawiska. W przypadku symptomów diagnostycznych i ich różnorodności zachowań znalezienie takich modeli wydaje się bardzo trudne. Wydaje się więc, że proponowane podejście ma raczej większe uzasadnienie w przypadku identyfikacji parametrów modelowanego systemu niż prognozy zachowania symptomu.

Miarą jakości dopasowania dla dowolnych nieliniowych modeli trendu może być:

- SSE (ang. *sum of squared errors*):

$$SSE = \sum_{i=1}^N (S_i - \hat{S}_i)^2, \quad (2)$$

lub też:

- współczynnik determinacji

$$R^2 = \frac{SST - SSE}{SST}, \quad (3)$$

gdzie:

N – ilość obserwacji, S_i – obserwowana wartość symptomu, \hat{S}_i – teoretyczna (modelowa) wartość symptomu,

$SST = \sum_{i=1}^N (S_i - \bar{S})^2$, \bar{S} – wartość średnia S .

2.3. Wybór modelu w oparciu o „obraz” krzywej życia

Kolejnym proponowanym podejściem jest zastosowanie sieci neuronowych do rozpoznawania charakteru zmian symptomu (krzywej życia). Proces uczenia sieci polegałby wtedy na przedstawianiu kolejnych „obrazów” krzywych życia oraz odpowiadających im właściwych decyzji. Byłby to typowy przykład klasyfikacji podobnie jak np. w rozpoznawaniu pisma, tylko że zamiast liter przedstawia się sieci kształt zmian symptomu. Takie podejście wymaga oczywiście odpowiedniego przygotowania (unormowania) zarówno wzorców uczących jak i późniejszych, uzyskiwanych w trakcie działania systemu, krzywych życia. W proponowanej sieci wejścia stanowią cechy charakterystyczne unormowanych krzywych życia, na wyjściu natomiast otrzymujemy decyzję o tym, który model powinien stanowić podstawę do uzyskania prognozy gdyż jego cechy charakterystyczne są najbliższe aktualnie podanym na wejściu sieci. Decyzja taka jest wypracowana w oparciu o porównanie wartości wyjściowych z sieci. Każdy neuron w warstwie wyjściowej sieci określa jedną klasę cech charakterystycznych. Sieć taka może być trenowana z wykorzystaniem algorytmu wstecznej propagacji błędów z klasyczną funkcją celu. Funkcje aktywacji stanowią funkcje

sigmoidalne. Proponuje się wykorzystanie sieci dwuwarstwowej (warstwa ukryta i wyjściowa).

3. PRZYKŁADOWE PORÓWNANIE METOD

Aby sprawdzić przydatność proponowanych podejść w problemie doboru modelu trendu dla prognozy wartości symptomu zaimplementowano poszczególne metody w odpowiednich programach komputerowych pozwalając na automatyczne podejmowanie decyzji co do wyboru modelu i sposobu prognozowania. Oparto się tutaj o wyniki uzyskane z systemu nadzoru diagnostycznego zainstalowanego na młynach wentylatorowych w jednej z polskich elektrociepłowni. Wykonywane przez system pomiary obejmują wartości skuteczne prędkości drgań w paśmie od 5 – 1000Hz.

Pierwsza z proponowanych metod stosowana była dla różnej ilości uśrednień użytych do wyznaczenia średniego błędów prognozy. W przypadku metody związanej z jakością dopasowania wybór modelu był zdeterminowany jedną (ostatnią) wartością współczynnika determinacji. Zastosowano tutaj cztery modele dopasowywane metodą najmniejszych kwadratów (choć w dwu pierwszych proponowanych metodach można także rozpatrywać zbiór różnych funkcji strat):

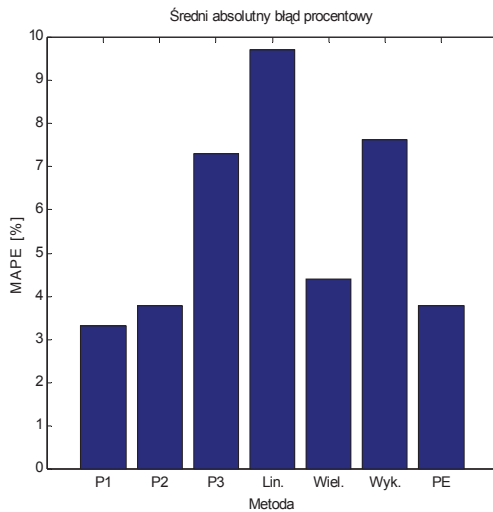
- model liniowy
- model wielomianowy
- model wykładniczy
- model nieliniowy, podstawowy *procesora energii (PE)* [3]:

$$S = a_0 \left(1 - \frac{\Theta}{a_1} \right)^{a_2},$$

gdzie: S – modelowa wartość symptomu, a_i – współczynniki modelu, Θ – miara eksploatacji.

Wykorzystano także podejście oparte o sieć neuronową. W procesie uczenia sieci rozpatrywano wspomniane cztery modele po uwzględnieniu odpowiedniej normalizacji obrazów krzywych życia. Normalizacja odbywała się w ten sposób aby wartości krzywej życia zawsze zawierały się w przedziale od $<0-1>$. Aby zwiększyć ilość wzorców uczących każdy zadawany przebieg podczas uczenia podawany był sieci dziesięciokrotnie z różnym udziałem szumu i różnymi parametrami modelu. Należy zaznaczyć także, że każdy z proponowanych trendów na etapie uczenia sieci miał tak dobrane parametry aby uwypuklić cechy zachowania tych trendów: charakter liniowy, dla wielomianu charakter parabolicznego wzrostu wartości symptomu, dla modelu wykładniczego – bardziej „stromy” wzrost wartości symptomu, oraz dla modelu *PE* asymptotyczny wzrost wartości symptomu wraz ze zbliżaniem się do czasu awarii maszyny. Proces uczenia sieci realizowano dla różnych jej struktur ostatecznie wybierając sieć o 15-stu wejściach, 5-ciu neuronach sigmoidalnych w warstwie ukrytej i czterech (cztery możliwe obszary decyzyjne) sigmoidalnych w war-

stwie wyjściowej. Uzyskany niewielki błąd pozwolił jednoznacznie klasyfikować rodzaj trendu dla zbioru testującego.



Rys.1. Błąd procentowy uzyskiwany w oparciu o różne metody (modele) prognozowania

Ostateczne porównanie uzyskanych wyników dotyczące omawianych metod przedstawiono na rysunku 1. Zilustrowano tutaj osiągnięty średni procentowy błąd prognozy w oparciu metodę o śledzenia błędu prognozy (P1), współczynnika determinacji (P2), na podstawie decyzji sieci neuronowej (P3) oraz dla poszczególnych metod przyjętych na stałe (bez zmiany modeli w trakcie pozyskiwania nowych danych). Zaproponowana metoda oparta o model typowany jako najlepszy pod względem osiągniętych do określonej chwili prognozach, pozwala na poprawienie jakości prognozy i uniknięcie poważnych błędów w przypadku błędnie założonego modelu (w tym przypadku np. wykładniczego). W rozpatrywanym przykładzie dobre rezultaty uzyskano także w oparciu o współczynnik determinacji, jednak ogólnie nie ma jednoznacznej zależności między jakością prognozy a jakością dopasowania modelu.

4. WNIOSKI

W wyniku przeprowadzonych prac nad wyborem metody automatycznego doboru modelu trendu dla celów prognozowania można sformułować następujące wnioski:

- dla rozpatrywanych danych wszystkie trzy metody wypracowują różne decyzje o wyborze modelu,
- najlepszą metodą wypracowania decyzji o doborze modelu trendu jest śledzenie średniego błędu prognozy i na jej podstawie wybór dalszych działań w zakresie obliczania wartości przyszłych,
- mimo iż zaproponowana metoda działa z pewnym opóźnieniem sugerowanie się po-

przednimi rezultatami co do prognozy i ekstrapolowanie ich na przyszłość daje istotną poprawę jakości prognozowania i pozwala uniknąć błędów ze stosowania jednego z góry ustalonego modelu,

Zaproponowana metoda śledzenia średniego błędu prognozy jest kolejną możliwością obok stosowania np. modeli o zmiennych parametrach. Jednak w przypadku gdy istnieje konieczność stosowania modeli matematycznych opartych o pewne przesłanki co do sposobu zmian cech stanu (np. oparte o model procesora energii [4][3]) takie podejście polegające na wyborze jednego modelu z pewnego „metamodelu” w oparciu o analizę błędu prognozy wydaje się jedynym rozwiązaniem do zastosowania w automatycznych systemach diagnostycznych.

LITERATURA

1. Żółtowski B., Podstawy diagnostyki maszyn, ATR Bydgoszcz 1996.
2. Osowski, S. Sieci neuronowe do przetwarzania informacji, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2000.
3. Tabaszewski, M. Diagnostyczne modele symptomowe maszyn jako systemów działaniowych, Rozprawa doktorska, Politechnika Poznańska, Wydział Budowy Maszyn, Poznań 2000.
4. Cempel C., Theory of Energy Transforming System and their Application in Diagnostics of the Operating Systems, Applied Mathematics and Computer Science, Vol. 3, No. 3, 533-548, 1993.



Dr inż. Maciej TABASZEWSKI jest adiunktem w Instytucie Mechaniki Stosowanej Politechniki Poznańskiej. Specjalność: diagnostyka drganiowa maszyn, elementy sztucznej inteligencji w diagnostyce, programowanie obiektowe, modelowanie oraz prognozowanie symptomów diagnostycznych, przetwarzanie sygnałów.