

MODELE ODWROTNE I MODELOWANIE DIAGNOSTYCZNE

Wojciech CHOLEWA

Politechnika Śląska, Katedra Podstaw Konstrukcji Maszyn
ul. Konarskiego 18a, 44-100 Gliwice, fax +48 32 237 1360, email wch@polsl.pl

Streszczenie

Praca dotyczy ogólnej metodologii badań diagnostycznych, Wskazano podejścia bazujące na biernych i czynnych eksperymentach diagnostycznych. Zaproponowano podejście mieszane, w którym stosowane są modele odwrotne współdziałające ze szczególnymi układami wnioskującymi wykonanymi z zastosowaniem sieci przekonań. Opracowanie zawiera ogólne wprowadzenie do modeli odwrotnych oraz do sieci przekonań.

Słowa kluczowe: model odwrotny, model diagnostyczny, sieć przekonań

INVERSE MODELS AND DIAGNOSTIC MODELING

Summary

The paper deals with a general methodology for diagnostic investigations. It presents basic approaches connected with passive as well as active diagnostic experiments. It suggests a mixed approach making use of inverse models followed by a particular diagnostic reasoning done by means of belief networks. The paper contains a basic introduction to the inverse models and to belief networks.

Keywords: inverse model, diagnostic model, belief network

1. WSTĘP

Głównym zadaniem diagnostyki technicznej jest rozpoznawanie stanu obiektu (którym może być również proces) na podstawie dostępnych o nim informacji. Stosowane metody takiego rozpoznawania można podzielić ogólnie na dwie klasy [9]:

- diagnostyka wsparta modelami,
- diagnostyka symptomowa.

Istotą *diagnostyki wspartej modelami* jest analizowanie różnic występujących pomiędzy wynikami obserwacji obiektu i wynikami stosowania modelu dostrojonego do tego obiektu oraz umożliwiającego symulowanie działania obiektu o zadanym stanie technicznym. O adekwatności możliwych do uzyskania diagnoz decyduje w pierwszym rzędzie jakość stosowanego modelu. Metody te znalazły szerokie zastosowanie zwłaszcza w diagnostyce układów sterujących oraz w diagnostyce procesów [4]. W szczególności można je stosować tam gdzie wskazanie odpowiedniego zdeterminowanego modelu obiektu jest możliwe.

Diagnostyka symptomowa bazuje na założeniu, że skutkiem zmiany stanu obiektu powinno być powstanie objawów świadczących o nim. Większość stosowanych metod przyjmuje, że obserwowane są różne procesy resztkowe [1], których cechy są nośnikami informacji o stanie obiektu. Związki zachodzące pomiędzy tymi cechami i stanem

obiektu formułowane są w postaci relacji diagnostycznych. Relacje te pozyskiwane na podstawie opinii i doświadczenia specjalistów oraz w wyniku badań diagnostycznych są niestety często niepewne i niedokładne. Diagnostyka symptomowa jest stosowana głównie tam, gdzie określenie wyczerpującego modelu obiektu jest trudne lub niemożliwe co powoduje, że bezpośrednio zastosowanie diagnostyki wspartej modelami nie jest możliwe.

2. RELACJA DIAGNOSTYCZNA

Jednym z podstawowych pojęć diagnostyki technicznej jest relacja diagnostyczna. *Relacja diagnostyczna* (w tym empiryczna relacja diagnostyczna [8]) może być definiowana jako podzbiór R przestrzeni ocen P równej iloczynowi kartezyjskiemu dziedzin S_1, S_2, \dots relewantnych dla rozpatrywanego zadania diagnostycznego. Dla zadania diagnostycznego ograniczonego do jednego obiektu, rozpatrywanego w stałych warunkach działania, minimalna rodzina takich dziedzin obejmuje zbiór stanów S_1 oraz zbiór symptomów S_2 , prowadząc do najprostszej postaci relacji diagnostycznej

$$R \subset P = S_1 \times S_2 \quad (1)$$

gdzie R jest zbiorem wszystkich możliwych (lub zaobserwowanych) par (s_1, s_2) określających stan s_1 i odpowiadający mu symptom s_2 .

Badania umożliwiające pozyskiwanie relacji diagnostycznych obejmują:

- badania aktywne, w których możliwe jest modyfikowanie stanu obiektu
- badania bierne, w których nie jest możliwe celowe modyfikowanie stanu, który można jedynie obserwować
- badania symulacyjne, odpowiadające badaniom aktywnym, w których obiekt zastąpiony został przez jego model

W wymienionych klasach modele mogą dotyczyć jednego wskazanego obiektu, zbioru rozpatrywanych, znanych obiektów lub klasy nieznanych obiektów odpowiadających zadanej konstrukcji.

Reguła diagnostyczna

Klasyczne podejście do zadań pozyskiwania relacji diagnostycznych przyjmuje, iż poszukiwany jest model relacji (1). Jako szczególnie uprzywilejowaną formę zapisu takiego modelu relacji uznano zbiory reguł występujących w postaci

$$\text{jeżeli przesłanka to konkluzja} \quad (2)$$

gdzie w zależności od potrzeb i stopnia złożoności obiektu reguły są regułami przyczynowo-skutkowymi lub regułami diagnostycznymi. W regułach przyczynowo-skutkowych przesłanką jest stan a konkluzją symptom. W regułach diagnostycznych odwrotnie.

Model globalny

Inną, często stosowaną techniką pozyskiwania relacji diagnostycznych jest modelowanie związków zachodzących (lub obserwowanych) pomiędzy dziedzinami omawianych relacji, za pomocą sieci neuronowych. Intensywny rozwój teorii tych sieci oraz dostępne aktualnie oprogramowanie pozwalają na uzyskiwanie zadawalających wyników w większości przypadków.

Wymieniać można liczne przykłady metod postępowania. Ich wspólną cechą jest to, że wynikiem realizowanego procesu identyfikacji są modele globalne uogólniające dane i zastępujące te dane. Pozwala to na znaczne ograniczenie niezbędnych zasobów (obszar pamięci) i przyspieszenie procesu wnioskowania. Wadą takiego postępowania jest globalny charakter rozpatrywanych modeli, pociągający za sobą wysokie koszty (czas obliczeń) ich identyfikacji oraz utrudniający lub ograniczający możliwości ich doskonalenia.

Model lokalny

Znaczne zmniejszenie kosztów przechowywania danych oraz ograniczenie czasów dostępu do nich spowodowało wzrost zainteresowania metodami bazującymi na modelach lokalnych wyznaczanych dla wskazanego, ograniczonego obszaru przestrzeni

ocen, dopiero wtedy gdy są potrzebne. Odróżnia to je od modeli globalnych wyznaczanych "na zapas" dla wszystkich możliwych obszarów przestrzeni ocen. Stosowanie takich modeli lokalnych jest możliwe wtedy, gdy czasy realizacji procesu wnioskowania przez układ diagnozujący nie są krytyczne.

Ciekawą modyfikacją omawianych metod jest przyjęcie założenia, iż rezygnuje się z wyznaczania globalnych modeli relacji R (1) i zastępuje je bezpośrednio gromadzeniem elementów tych relacji. Dysponując wyliczeniem elementów zbioru R można wskazać elementy należące do rozpatrywanego obszaru przestrzeni. Na elementach tych można rozpiąć model lokalny pozwalający na dalsze działania. Model taki może być specyfikowany jawnie lub może występować w postaci ukrytej w systemie diagnozującym.

3. MODELOWANIE DIAGNOSTYCZNE

Analizując zalety i wady zarówno diagnostyki wspartej modelami jak i diagnostyki symptomowej można zauważyć, że możliwe jest postępowanie mieszane, w którym zastosowane zostaną równocześnie koncepcje obu wymienionych rodzajów diagnostyki. Istotą proponowanego postępowania jest modelowanie diagnostyczne polegające na łącznym rozwiązaniu dwóch zadań częściowych:

- definiowanie *modelu przybliżonych reguł diagnostycznych*, pozwalających na wyznaczanie obrazów sygnałów diagnostycznych (obrazów wartości cech sygnałów diagnostycznych) będących rozmytymi zbiorami klas tych sygnałów (klas wartości cech tych sygnałów),
- definiowanie *modelu przekonań o klasach stanów obiektu* uwarunkowanych obrazami cech sygnałów diagnostycznych.

Ze względu na sprzężenia występujące pomiędzy wymienionymi zadaniami częściowymi ich łączne rozwiązanie jest trudne (lub niemożliwe) do bezpośredniego wyznaczenia. Bardzo pomocne przy poszukiwaniu rozwiązania są różne iteracyjne sposoby postępowania, wśród których szczególne znaczenie mają metody ewolucyjnego doskonalenia tych rozwiązań.

Pierwsze z zadań częściowych jest w zasadzie zadaniem klasyfikacji (klasyfikacji rozmytej). Cechą szczególną proponowanego postępowania jest to, że poszukiwany klasyfikator jest wyznaczany na podstawie znanego przyczynowo-skutkowego modelu działania obiektu, pozwalającego symulować jego wybrane zachowania. Nie wymaga się aby model ten był wyczerpujący w stopniu wystarczającym do stosowania klasycznych metod diagnostyki wspartej modelowo. Model ten ma jedynie umożliwić wyznaczenie modelu odwrotnego, pełniącego rolę preklasyfikatora sygnałów diagnostycznych (wartości cech sygnałów

diagnostycznych). Uwzględniając ograniczone wymagania stawiane odwracaniu modelowi przyczynowo-skutkowemu, nie należy oczekiwać iż tak otrzymany preklasyfikator pozwoli na wyznaczenie wystarczająco adekwatnej diagnozy.

Należy zauważyć, że:

- definiowanie modelu działania obiektu oraz odwracanie tego modelu nie wymaga zastosowania wiedzy, na której bazuje diagnostyka symptomowa,
- dotychczasowe zastosowania diagnostyki symptomowej dowodzą wysokiej jakości oraz przydatności tej wiedzy.

Oznacza to, że celowym staje się jej użycie do skutecznego zrealizowania drugiego zadania cząstkowego, polegającego na wnioskowaniu o stanie obiektu na podstawie wyników preklasyfikacji jego sygnałów. Można podejmować próby rozwiązywania tego zadania za pomocą sieci neuronowych. Niedogodnością takiego postępowania będą jednak trudności w interpretowaniu uzyskanego rozwiązania. Może to, zwłaszcza dla złożonych obiektów, utrudnić proces walidacji wprowadzanych procedur diagnostycznych. Wydaje się, że narzędziem szczególnie przydatnym w rozwiązywaniu tego zadania będą sieci przekonań, nazywane również sieciami bayesowskimi lub sieciami Bayesa.

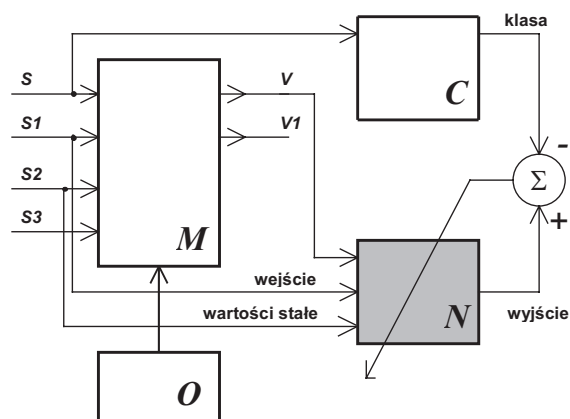
4. MODEL ODWROTNY

Rys. 1 ilustruje zaproponowaną koncepcję odwracania modeli. Zakłada się, że znany jest model M (rys. 1) obiektu O , który pozwala na wyznaczenie wartości wyjść $\{v, v1\}$ dla zadanego zbioru wartości wejść $\{s, s1, s2, s3\}$. Model ten może być zapisany (na przykład) w postaci relacji empirycznych [8] lub programu komputerowego. Z punktu widzenia zastosowań diagnostycznych wymienione wartości wejść i wyjść mogą mieć następujące znaczenie:

- s wartości poszukiwane jako wynik procesu diagnozowania,
- $s1$ znane wartości, określające warunki działania obiektu,
- $s2$ znane wartości, które dla rozpatrywanego obiektu nie ulegają zmianom,
- $s3$ wartości trudne do oszacowania i pomiaru, które należy przyjmować jako wartości losowe wpływające na ograniczenie dokładności modelu,
- v znane wartości, będące skutkiem działania obiektu i określane w wyniku pomiaru lub odpowiedniej symulacji,
- $v1$ nieznane lub pomijane wartości, będące skutkiem działania obiektu.

Model M opisuje relacje przyczynowo-skutkowe występujące pomiędzy wartościami wejściowymi - przyczynami $\{s, s1, s2, s3\}$ oraz wartościami wyjściowymi - skutkami $\{v, v1\}$. W wyniku odwracania modelu M zamierzamy (rys. 1) uzyskać model odwrotny N , przekształcający znane,

określone w wyniku pomiaru lub symulacji wartości $\{v, s1\}$ w poszukiwane wartości $\{s\}$. Można przypuszczać, iż dokładny model odwrotny N nie istnieje, ponieważ brak jest podstaw do zakładania, iż model M jest odwzorowaniem jednojednoznacznym. Dla uniknięcia wynikających stąd trudności (powodujących, że zadanie może nie posiadać rozwiązania) ogranicza się dokładność (ziarnistość) poszukiwanego modelu odwrotnego, zakładając, iż będzie on wyznaczał klasy wartości parametrów v (czyli nominalne wartości parametrów), a nie dokładne wartości tych parametrów. Klasyfikator definiujący wyznaczone klasy oznaczono literą C (rys. 1).



Rys. 1. Wyznaczanie modelu odwrotnego N dla danego modelu M obiektu O , z zastosowaniem klasyfikatora C

Zaletą proponowanego postępowania jest to, że stosowanie modelu M i wyznaczanie modelu odwrotnego N mogą być traktowane jako procesy rozłączne - realizowane w różnym czasie i na różnych komputerach (co pokazano w [2]). Możliwe jest sekwencyjne realizowanie procesów stosowania modelu M i wyznaczania modelu odwrotnego N , pozwalające na iteracyjne doskonalenie wyznaczonego modelu odwrotnego [5], [7].

5. SIEĆ BAYESOWSKA

Sieć bayesowska stanowi zwartą formę reprezentacji gęstości łącznego dyskretnego rozkładu zbioru zmiennych losowych. Sieć ta bazuje na koncepcji warunkowej niezależności zmiennych umożliwiającej ograniczenie liczby danych niezbędnych do zapisania gęstości łącznego rozkładu dyskretnego. Ograniczenie polega na wyznaczeniu tej gęstości jako iloczynu kilku innych gęstości o znacznie mniejszych rozmiarach. Jedna wielowymiarowa tablica prawdopodobieństw łącznych zostaje zastąpiona zbiorem dwuwymiarowych tablic prawdopodobieństw warunkowych, które pozwalają na wyznaczenie wartości prawdopodobieństwa łącznego, wtedy gdy jest ono potrzebne.

Niech $\underline{Z} = \{Z_1, Z_2, \dots\}$ będzie zbiorem dyskretnych zmiennych (losowych), przyjmujących wartości ze skończonych zbiorów. Siecią bayesowską nad \underline{Z} jest para (D, P) gdzie D jest acyklicznym (nie zawierającym cykli) grafem skierowanym. Węzły tego grafu reprezentują zmienne ze zbioru \underline{Z} , a

$$P = \{p_1(z_1 | pa(z_1)), p_2(\dots), \dots\} \quad (2)$$

jest zbiorem prawdopodobieństw warunkowych określonych dla kolejnych zmiennych. Zapis $p_i(z_i | pa(z_i))$ oznacza prawdopodobieństwo warunkowe

$$p_i(Z_i = z_i | (pa(Z_i) = pa(z_i))) \quad (a7)$$

gdzie $pa(Z)$ jest zbiorem rodziców węzła Z . Prawdopodobieństwa warunkowe (3) są zapisywane w postaci tablic przyporządkowanych węzłom (zmiennym). Wartości prawdopodobieństw warunkowych mogą być pozyskiwane z różnych źródeł, do których należą znane analityczne lub numeryczne modele obiektów, wyniki eksperymentów czynnych, wyniki eksperymentów biernych, opinie specjalistów.

Podczas tworzenia sieci bayesowskiej można przyjąć założenie, że gałęzie sieci będą dobierane wyłącznie tak, aby reprezentowały relacje przyczynowo-skutkowe. Sieci takie nazywane są przyczynowymi sieciami bayesowskimi. Założenie to nie obowiązuje jednak jako założenie domyślne dla wszystkich sieci. Podkreślić należy, że skierowane gałęzie ogólnej sieci bayesowskiej wyznaczają jedynie uporządkowanie węzłów (węzeł nadrzędny / podrzędny) niezbędne dla prawidłowego reprezentowania łącznego rozkładu zmiennych losowych. Nie wskazują one na istnienie relacji przyczynowo-skutkowych.

W procesie konstruowania sieci bayesowskiej można wyróżnić dwie fazy: określanie węzłów sieci i łączących je gałęzi czyli wyznaczanie postaci sieci oraz ustalanie wartości w tablicach prawdopodobieństw warunkowych, które są przyporządkowane węzłom sieci. Próby praktycznego zastosowania sieci pokazują, że obie fazy związane są z koniecznością rozwiązania szeregu trudnych zadań. Postać sieci i wartości prawdopodobieństw warunkowych można rozpatrywać jako wynik odpowiedniego procesu optymalizacji.

Skuteczne algorytmy wnioskowania z zastosowaniem sieci bayesowskich omawiane są w licznych pracach, np. [10], [6], [3]. Szczególną grupą trudnych zadań, omawianych w literaturze w niewielkim zakresie, jest weryfikacja i ocenianie jakości (wartościowanie) sieci.

6. POSUMOWANIE

Bardzo zwięźle pokazano możliwość uzupełnienia podstawowych klas badań diagnostycznych,

obejmujących diagnostykę wspartą modelami oraz diagnostykę symptomową o nowe działania bazujące na obu klasach podstawowych. Działania te nazywano w pracy modelowaniem diagnostycznym. Zdaniem autora, konsekwentne rozwijanie przedstawionej koncepcji modelowania diagnostycznego pozwoli na uporządkowanie różnych, stosowanych obecnie metod badań i prowadzić będzie do jakościowo nowych rozwiązań.

LITERATURA

- [1] CEMPEL Cz.: Podstawy wibroakustycznej diagnostyki maszyn. WNT, Warszawa 1982.
- [2] CHOLEWA W., WHITE M.: Inverse modelling in rotordynamics for identification of unbalance distribution. *Machine Vibration* (1993) 2, 157-167.
- [3] COWELL R. G., DAVID A. P., LAURITZEN S. L., SPIEGELHALTER D. J. : Probabilistic Networks and Expert Systems. Springer, New York 1999.
- [4] Diagnostyka procesów. Red.: KORBICZ J., KOŚCIELNY J. M., KOWALCZUK Z., CHOLEWA W., WNT, Warszawa 2002.
- [5] Diagnostyka techniczna. Odwrotne modele diagnostyczne. Red.: CHOLEWA W., KICIŃSKI J. Wydawnictwo Politechniki Śląskiej, Gliwice 1997.
- [6] JENSEN V. J. : Bayesian Networks and Decision Graphs. Springer, New York 2002.
- [7] KLIMEK A.: Metody doskonalenia odwrotnych modeli diagnostycznych. Zeszyty Naukowe Politechniki Śląskiej, Mechanika z.134, Gliwice 1999.
- [8] MOCZULSKI W.: Metody pozyskiwania wiedzy dla potrzeb diagnostyki maszyn. Politechnika Śląska. Zeszyty Naukowe 1382. Gliwice 1997.
- [9] NATKE H. G., CEMPEL Cz.: Model-Aided Diagnosis of Mechanical Systems. Springer, Berlin 1997.
- [10] PEARL J.: Fusion, propagation and structuring in belief networks. *Artificial Intelligence*, 1986, Vol. 29, No. 2, ss. 241-288.



Prof. dr hab. inż. Wojciech CHOLEWA, Kierownik Katedry Podstaw Konstrukcji Maszyn w Politechnice Śląskiej. Prowadzi badania z zakresu budowy i eksploatacji maszyn, ze szczególnym uwzględnieniem diagnostyki technicznej oraz metod sztucznej inteligencji.