

Anna TIMOFIEJCZUK

Katedra Podstaw Konstrukcji Maszyn, Wydział Mechaniczny Technologiczny,
Politechnika Śląska, Gliwice

ZAAWANSOWANE METODY WNIOSKOWANIA DIAGNOSTYCZNEGO

Streszczenie. Celem diagnostyki technicznej jest identyfikacja stanu obiektu technicznego. Podstawą wnioskowania diagnostycznego są symptomy, które identyfikuje się głównie na podstawie analizy sygnałów resztkowych. Referat dotyczy wybranych, zaawansowanych metod wnioskowania diagnostycznego rozwijanych w latach poprzednich oraz obecnie w Katedrze Podstaw Konstrukcji Maszyn Politechniki Śląskiej. W referacie przedstawiono przegląd metod reprezentacji wiedzy metod oraz metod wnioskowania diagnostycznego stosowanych najczęściej w diagnostyce maszyn. W końcowej części referatu pokazano przykład zastosowania wnioskowania diagnostycznego z uwzględnieniem kontekstu.

ADVANCED METHODS OF DIAGNOSTIC INFERENCE

Summary. The goal of technical diagnostics is to identify the state of a technical object. The bases of diagnostic inference are symptoms, which are mainly identified on the basis of analysis of residual signals. The paper deals with advanced methods of diagnostic inference developed in Department of Fundamentals of Machinery Design of Silesian University of Technology. It includes a review of approaches to knowledge representation and diagnostic inference. In the last part of the paper an example of application of diagnostic inference with the use of contexts was presented.

1. Wstęp

Zadaniem *diagnostyki technicznej* jest identyfikacja stanu obiektu (maszyny lub procesu), której celem jest *detekcja i lokalizacja* uszkodzeń. Obecnie badania diagnostyczne polegają głównie na obserwacji zarówno *procesów użytecznych* takich jak wytworzona energia czy ciśnienie medium roboczego, procesów związanych z działaniem obiektu, czego przykładem są prędkość obrotowa elementów wirujących, temperatura substancji smarujących, ale przede wszystkim tak zwanych *procesów resztkowych*, które są niezamierzonym efektem działania maszyny, a które zawsze towarzyszą temu działaniu. Przykładami takich procesów są drgania i hałas. Obserwowane procesy nazywa się w diagnostyce maszyn *sygnałami*. Sygnałem definiuje się *przebieg dowolnej wielkości fizycznej*

mogącej być nośnikiem informacji [3,5]. Działania, których celem jest wyznaczenie *cech sygnałów*, nazywa się *analizą sygnału*. *Cechą sygnału* nazywa się uporządkowaną parę {nazwa cechy, wartość cechy} [4] lub {*atrybut cechy, wartość cechy*} [16]. Cechy, a w szczególności ich wartości, są *symptomami* stanu obiektu. Wartości cechy mogą świadczyć zarówno o tym, że w obiekcie nie wystąpiła żadna nieprawność, jak również o miejscu i rodzaju niesprawności.

Symptomy diagnostyczne są podstawą metod *wnioskowania diagnostycznego*. Biorąc pod uwagę kierunek wnioskowania, metody rozumowania, stosowane w diagnostyce maszyn, można podzielić na metody dedukcyjne, redukcyjne, przez analogię oraz z uwzględnieniem kontekstu [35].

Metody *wnioskowania diagnostycznego* oparte są głównie na rozumowaniu *dedukcyjnym*, które charakteryzuje się tym, że kierunek rozumowania jest zgodny z kierunkiem wynikania logicznego. Innym schematem rozumowania jest *redukcja*, która charakteryzuje się odwrotnym kierunkiem rozumowania w porównaniu z dedukcją. Szczególnym przypadkiem redukcji jest *indukcja niepełna*, która polega na przyjęciu określonego stwierdzenia za prawdziwe na podstawie odpowiednio licznego zbioru przykładów. Wnioskowanie indukcyjne jest zawodne. Wnioskowanie przez *analogię* polega na przyjęciu określonego rozwiązania na podstawie zbioru przykładów, wśród których poszukuje się analogii do badanego przypadku. Podejście to nosi nazwę wnioskowania opartego na przykładach (ang. Case-based reasoning, CBR). Wnioskowanie z uwzględnieniem kontekstu polega na poszukiwaniu określonego rozwiązania z uwzględnieniem kontekstu, który określa zakres wiedzy i danych potrzebny do znalezienia rozwiązania. Ten rodzaj wnioskowania nazywa się wnioskowaniem z uwzględnieniem kontekstu (ang. Context-based reasoning, CxBR).

Referat dotyczy wybranych, zaawansowanych metod wnioskowania diagnostycznego rozwijanych obecnie w Katedrze PKM Politechniki Śląskiej. Rozważając problem wnioskowania diagnostycznego nie można pominąć metod reprezentacji wiedzy wykorzystywanej w procesie formułowania diagnozy. W referacie przedstawiono przegląd metod reprezentacji wiedzy stosowanych najczęściej w diagnostyce maszyn. Oprócz charakterystyki metod wnioskowania diagnostycznego najczęściej wykorzystywanych w systemach diagnostycznych opisano także metody nowe, bazujące na CBR i CxBR, które są obecnie bardzo dynamicznie rozwijane. W końcowej części referatu pokazano przykład wnioskowania diagnostycznego z zastosowaniem sceny dynamicznej.

2. Metody reprezentacji wiedzy

Podstawą identyfikacji stanu obiektu technicznego jest wiedza dotycząca badanych obiektów. Wiedza ta może być gromadzona i reprezentowana na wiele sposobów. Metody

gromadzenia i zapisu wiedzy są przedmiotem wielu opracowań i są często różnie rozumiane [12,15,16,18,35].

Metody *reprezentacji* wiedzy dzieli się na reprezentację za pomocą języka naturalnego oraz za pomocą zbioru symboli [12,35]. Przykładem pierwszej grupy metod jest wiedza zapisana w postaci opisów literaturowych. Ze względu na złożony charakter opisów w języku naturalnym ten sposób reprezentacji wiedzy jest nieprzydatny w systemach komputerowych. Dla potrzeb takich systemów stosuje się reprezentację wiedzy w postaci symbolicznej. Wyróżnia się zapis wiedzy w postaci *proceduralnej* i *deklaratywnej* [12,15,16,35].

Proceduralna reprezentacja wiedzy polega na jej zapisie w postaci procedur lub algorytmów określających sposób postępowania podczas realizacji określonego zadania. Przykładem zapisu proceduralnego może być sposób postępowania prowadzący do identyfikacji określonego rodzaju uszkodzenia obiektu technicznego. W przypadku tym procedura będzie określała kolejność testów i analizy określonych sygnałów diagnostycznych.

Deklaratywna reprezentacja wiedzy, stosowana najczęściej w metodach wnioskowania diagnostycznego, polega na zapisie wiedzy w postaci *stwierdzeń* lub *reguł*. Przykładami tego sposobu reprezentacji wiedzy są *bazy danych*.

Badania literaturowe wykazują, że do najczęściej stosowanych metod zapisu wiedzy zalicza się [12] jej reprezentację w postaci stwierdzeń, reguł, sieci semantycznych, ram i scenariuszy.

Stwierdzenie w formie podstawowej zapisuje się w postaci uporządkowanej trójki [6,12]:

$$x(o, a, v), \quad (1)$$

gdzie: o oznacza rozpatrywany obiekt, a jest atrybutem obiektu, a v wartością tego atrybutu. Treść stwierdzenia jest często rozszerzana o dodatkowe wartości, takie jak: t , które oznacza przedział czasu, w którym obiekt o jest rozpatrywany, w przypadku definiowania *stwierdzeń dynamicznych*, b , która jest miarą przekonania o prawdziwości stwierdzenia, w przypadku definiowania *stwierdzeń przybliżonych*, w , która jest wagą danego stwierdzenia. Przykładem stwierdzenia jest:

$$x(\text{sygnał}, \text{wartość_średnia}, 3.5) \quad (2)$$

Regułą nazywa się następujący zapis [6, 12]:

$$\text{if PRZESŁANKA then KONKLUZJA} \quad (3)$$

Części reguły nazywane *przesłanką* i *konkluzją* mogą być zapisywane w postaci stwierdzeń w formie podstawowej, stwierdzeń dynamicznych (reguły dynamiczne) lub przybliżonych (reguły przybliżone). Przykładem może być następująca reguła:

if W widmie drgań wystąpiła składowa 2X
then Przeciążenie (4)

W części konkluzji może wystąpić nie tylko wniosek, ale także zalecenie wykonania dodatkowych testów lub procedur. Taka reguła nosi nazwę *reguły działania*. Przykładem reguły działania może być:

if W widmie drgań wystąpiła składowa 2X
then Zbadaj różnice faz drgań w kierunku pionowym (5)

Zapis stwierżeń w postaci *sieci semantycznych* umożliwia reprezentację relacji występujących między stwierżeniami. Relacje te są rozumiane jako iloczynny kartezjańskie zbiorów obiektów, atrybutów obiektów i wartości atrybutów [6].

Ramą nazywa się strukturę [6] złożoną z klatek, w których wpisywane są nazwy cech obiektu oraz ich wartości. Zapis wiedzy w postaci ram jest podstawą reprezentacji wiedzy w postaci *przykładów*, na których bazuje wnioskowanie oparte na przykładach (ang. Case-based Reasoning, CBR).

Reprezentacja wiedzy w postaci *scenariuszy* została oparta na teorii opisanej w [20]. Scenariusz jest strukturą podobną do ramy, w której wyróżnia się także klatki, zawierające opisy scen oraz ich elementy. Taka reprezentacja wiedzy pozwala na zapis sekwencji zdarzeń. Scenariusze są podstawą wnioskowania opartego na kontekście (ang. Context Based Reasoning, CxBR). Sposób reprezentacji wiedzy diagnostycznej determinuje często zastosowanie określonej metody wnioskowania.

3. Metody wnioskowania diagnostycznego

Metody wnioskowania diagnostycznego to sposoby interpretacji zgromadzonej wiedzy dotyczącej pewnej grupy badanych obiektów. Jak opisano we wstępie, bazują one na rozumowaniu dedukcyjnym. Metody te można podzielić na wiele sposobów. Szczegółowy podział tych metod, uwzględniający sposób reprezentacji wiedzy oraz jej specyfikację, zamieszczono w [12,15,16,35], gdzie wyróżniono metody *eksperckie* i *oparte na modelu*.

Przegląd metod wnioskowania zamieszczony w niniejszym rozdziale nie jest kompletny. Spośród metod opisywanych w literaturze wybrano tylko te, które są najczęściej wykorzystywane w diagnostyce maszyn. Opisano także takie metody, które są lub były przedmiotem badań w katedrze PKM Politechniki Śląskiej.

3.1. Eksperckie metody wnioskowania diagnostycznego

W grupie metod eksperckich wyróżnia się sposoby wnioskowania bazujące na danych numerycznych oraz metody bazujące na wiedzy reprezentowanej symbolicznie. Do grupy pierwszej zalicza się między innymi *metody rozpoznawania obrazów* oraz *sieci neuronowe*.

Drugą grupę metod wnioskowania stanowią między innymi *tablice decyzyjne* i *systemy doradcze*.

Sieci neuronowe, ich podstawy oraz zastosowanie są opisywane w wielu publikacjach. Do najważniejszych polskich opracowań z tego zakresu należą [12,23]. Opracowania te wskazują na bardzo różnorodne możliwości zastosowania metod bazujących na teorii modeli neuronowych. Przegląd oraz przykłady zastosowań sieci neuronowych w diagnostyce maszyn zamieszczono w [12]. Sieć neuronowa zbudowana jest z połączonych ze sobą komórek nazywanych neuronami. *Neuron* jest komórką, która po przekroczeniu pewnego progu aktywacji, określonego przez funkcję aktywacji (np. skokową lub sigmoidalną), wykonuje samodzielne obliczenia. Model matematyczny neuronu określa równanie [12]:

$$y = f\left(\sum_{p=1}^P w_p u_p + u_0\right), \quad (6)$$

gdzie u_p jest wejściem neuronu $p=1,2,\dots,P$, u_0 jest progiem aktywacji neuronu, w_p - wagą, a $f()$ jest funkcją aktywacji.

Sieć neuronowa ma budowę warstwową. Wyróżnia się warstwę wejściową, wyjściową i warstwy ukryte. Sieci bez warstw ukrytych nazywane są perceptronami. Sieci tego rodzaju oraz ich modyfikacje są bardzo często stosowane w systemach diagnostycznych.

Zagadnienia *rozpoznawania obrazów*, w szerokim ujęciu, obejmują dużą grupę metod związanych zarówno z pozyskiwaniem, przetwarzaniem, analizą jak i rozpoznawaniem obrazów. Polski termin „obraz” jest odpowiednikiem dwóch terminów angielskich: *image*, który odpowiada dosłownemu znaczeniu słowa „obraz” oraz *pattern*, który jest rozumiany jako wzorec, a w szczególnym przypadku także obraz dosłownie rozumiany.

Dane przetwarzane za pomocą metod rozpoznawania obrazów mają zawsze postać opisu obrazu. Zadanie rozpoznawania obrazu jest zadaniem klasyfikacji, które polega na przyporządkowaniu rozpoznawanego obiektu do znanej klasy. Klasa jest reprezentowana przez wzorec [8,12,22,24,25]. W szczególnym przypadku wzorcem może być także obraz, czego przykładami są: obrazy termowizyjne, zdjęcia mikroskopowe, wykresy, zdjęcia rentgenowskie, czy wyniki badań ultrasonograficznych. Innymi przykładami obrazów mogą być sygnały dźwiękowe lub składy substancji chemicznej.

W diagnostyce technicznej stan obiektu jest identyfikowany na podstawie charakterystycznej grupy symptomów, które stanowią wzorec stanu. Zagadnienia identyfikacji stanu technicznego nazywane są rozpoznawaniem obrazów.

Metody rozpoznawania obrazów można podzielić na dwie grupy. Pierwsza bazuje na opisie obrazu w postaci zbioru charakterystyk. Do grupy tej zalicza się metody minimalno-odległościowe, aproksymacyjne, funkcji potencjalnych, statystyczne oraz wykorzystujące

sieci neuronowe. Drugie podejście związane jest z zastosowaniem syntaktycznego opisu obrazu. Syntaktyczny opis obrazu wykorzystuje metody: ciągowe, drzewowe i grafowe.

Metody minimalnoodległościowe [8,21] są bardzo znaną grupą metod rozpoznawania obrazów. Polegają one na wyznaczeniu pewnej miary (metryki), która określa odległość rozpoznawanego obiektu od jego wzorca (obrazu). Obiekt jest zaliczany do tej klasy, dla której odległość między obiektem i wzorcem reprezentującym klasę jest najmniejsza. Przykładem tego sposobu rozpoznawania obrazów jest metoda *najbliższego sąsiada* oraz jej odmiany.

Metody aproksymacyjne [8,21] polegają na określeniu funkcji przynależności obiektu do klasy. Funkcja ta jest aproksymowana na podstawie zbioru obiektów, który traktuje się jako zbiór uczący. Podstawowym problemem w tym przypadku jest określenie tzw. funkcji bazowych, które są podstawą aproksymacji.

Metody funkcji potencjalnych [8,21] są podobnym rozwiązaniem do dwóch poprzednich sposobów rozpoznawania obrazów. W tym przypadku funkcja przynależności obiektu do klasy jest tworzona jako złożenie funkcji składowych. Funkcje te są silnie malejące. Ich postać jest analogiczna do funkcji określającej rozkład potencjału elektrycznego wokół określonego punktu. Z tego powodu funkcje składowe nazywane są funkcjami potencjalnymi.

W przypadku zastosowania *metod statystycznych* [8,21] zbiór cech opisujących obraz jest traktowany jako obserwacje statystyczne. Rozpoznawanie obrazów sprowadza się do weryfikacji hipotez statystycznych. Wyróżnia się także grupę metod, w których rozpoznawanie bazuje na regule klasyfikacji Bayesa, opisane zależnością (10) podaną w dalszej części referatu.

Sieci neuronowe [12,23] są obecnie wykorzystywane w wielu dziedzinach. Jednym z ich zastosowań jest rozpoznawanie obrazów. Zadanie to jest realizowane poprzez trenowanie sieci i nauczenie jej rozpoznawania obiektów należących do zbioru danych trenujących. Główne założenia zastosowania oraz cechy sieci neuronowych opisano w poprzednim punkcie.

Metody wykorzystujące syntaktyczny opis obrazu [8,21] w postaci ciągu, drzewa lub grafu wymagają zdefiniowania gramatyki, która określa sposób generowania opisu obrazu. Dla zdefiniowanej gramatyki określa się tzw. analizator syntaktyczny, nazywany także automatem rozpoznającym.

W przypadku *metod ciągowych* gramatyką nazywa się uporządkowaną czwórkę:

$$G_c = (\Omega_T, \Omega_N, P, S), \quad (7)$$

gdzie Ω_T i Ω_N są odpowiednio zbiorem symboli terminalnych i nieterminalnych, P jest - zbiorem projekcji, a S - zbiorem symboli startowych. Zbiór projekcji określa rozpoznane sekwencje symboli terminalnych (słowa), które oznacza się za pomocą symboli nieterminalnych. Rozróżnia się kilka przypadków definiowania języka ciągowego za pomocą

gramatyki. Odmiany te określają strukturę generowanych ciągów, a w szczególności występowanie w nich symboli nieterminalnych oraz ich zastępowanie określonym ciągiem symboli terminalnych.

W *metodach drzewowych* języki opisu obrazu definiuje gramatyka, która jest czwórką, w przypadku drzew o nieskierowanych krawędziach i piątką dla skierowanych krawędzi drzewa. Drugi przypadek gramatyki definiuje się jako:

$$G_d = (\Omega, r, \Gamma, P, Z), \quad (8)$$

gdzie Ω jest sumą zbiorów Ω_T i Ω_{N^c} , r jest funkcją określającą przypisywanie symboli wierzchołkom drzewa, P jest zbiorem produkcji, a Z jest zbiorem symboli startowych. Przez produkcje rozumie się w tym przypadku fragmenty drzewa opisu obrazu.

Gramatyka grafowa, określająca język opisu obrazu, jest definiowana jako:

$$G_g = (N, \Omega, \Gamma, P, S), \quad (9)$$

gdzie N jest zbiorem symboli nieterminalnych wierzchołków grafu, Ω to zbiór symboli terminalnych, Γ jest zbiorem symboli przypisywanych krawędziom grafu, S jest zbiorem symboli startowych, P jest zbiorem produkcji.

Tablica decyzyjna [4,11,12] jest uporządkowanym zbiorem reguł, który może stanowić reprezentację wiedzy lub być środkiem wspomagającym wnioskowanie diagnostyczne. Tablica decyzyjna składa się z czterech części zawierających opis testów lub pytań, odpowiedzi na te pytania, opis konkluzji lub działań oraz część, w której konkluzje są przypisywane do określonych reguł. Reguły w tablicy zapisywane są w kolumnach i są to zwykle reguły złożone. Odpowiedzi na testy i pytania określają treści zawarte w częściach przesłankowych tych reguł. Najprostszym przypadkiem jest odpowiedź o postaci *tak* lub *nie*. Odpowiedzi mogą przyjmować także bardziej złożoną postać w przypadkach, gdy reguły zawarte w tablicach są regułami dynamicznymi bądź przybliżonymi.

System doradczy jest zbiorem programów komputerowych, których działanie polega na formułowaniu wniosków na podstawie wiedzy z określonej dziedziny [6]. Głównymi elementami systemu doradczego są: układ objaśniający, układ wnioskujący, baza wiedzy i baza danych. Wnioskowanie w systemach doradczych może odbywać się na wiele sposobów. Do najważniejszych publikacji z zakresu tej tematyki należą: [6,11,12,15,16]

3.2. Wnioskowanie diagnostyczne oparte na modelu

Grupę metod wnioskowania diagnostycznego bazujących na modelu podzielono na metody oparte na analizie niespójności oraz metody umożliwiające analizę relacji przyczynowo-

skutkowych między uszkodzeniami diagnozowanego obiektu. W diagnostyce maszyn wykorzystuje się najczęściej metody z drugiej grupy. Przykładami są bardzo często stosowane *drzewa uszkodzeń*, *drzewa sprawdzeń* oraz *sieci przekonania*.

Drzewa uszkodzeń (ang. fault trees) charakteryzują się strukturą umożliwiającą reprezentację zależności przyczynowo-skutkowych między uszkodzeniami [6,15]. Węzły drzewa reprezentują zdarzenia, które są uszkodzeniami. Wyróżnia się:

- zdarzenia podstawowe, które jednoznacznie określają element uszkodzony i rodzaj uszkodzenia,
- zdarzenia nierozpoznane, które wymagają przeprowadzenia dodatkowych testów lub uzupełnienia danych,
- zdarzenia złożone, które są wynikiem wystąpienia innych zdarzeń.

Relacje między zdarzeniami odpowiadają gałęziom drzewa. Zdarzenia są powiązane ze sobą za pomocą operatorów logicznych.

Drzewo sprawdzeń ma strukturą określającą kolejność wykonywania testów [4, 15]. Węzły drzewa sprawdzeń odpowiadają przeprowadzanym badaniom. Gałęzie drzewa reprezentują kolejność ich wykonywania zgodnie z wynikami poszczególnych testów lub badań.

Sieci przekonania, nazywane także *sieciami bayesowskimi*, są oparte na wnioskowaniu za pomocą metod statystycznych, wykorzystujących twierdzenie Bayes'a o następującej postaci [12]:

$$P(A | B) = \frac{P(A, B)}{P(B)} = \frac{P(B | A)P(A)}{P(B)}, \quad (10)$$


gdzie $P(A)$ i $P(B)$ są odpowiednio wartościami prawdopodobieństwa tego, że stwierdzenia A i B są prawdziwe, $P(A, B)$ jest prawdopodobieństwem łącznym określającym wartość miary prawdopodobieństwa tego, że stwierdzenia A i B są jednocześnie prawdziwe, $P(A|B)$ jest prawdopodobieństwem warunkowym, określającym miarę przekonania o tym, że stwierdzenie A może być uznane za prawdziwe wtedy, gdy stwierdzenie B jest prawdziwe. Sieć przekonania jest acyklicznym grafem o skierowanych gałęziach. Węzły grafu reprezentują stwierdzenia oraz wartości określające stopnie przekonania o prawdziwości stwierżeń. Gałęziom drzewa odpowiadają tabele zawierające wartości prawdopodobieństw warunkowych wszystkich stwierżeń, które są połączone daną gałęzią. Wnioskowanie w sieci polega na identyfikacji prawdopodobieństw kolejnych węzłów. Dla danego węzła uwzględnia się prawdopodobieństwa węzłów leżących wyżej w hierarchii sieci. Węzły te na nazywane są rodzicami.

4. Wnioskowanie oparte na przykładach

Wnioskowanie oparte na przykładach (ang. Case-based Reasoning, ang. CBR) jest często nazywane w polskiej literaturze wnioskowaniem przez analogie [2,33,34]. Ten sposób wnioskowania rozwinął się w latach 70. jako kontynuacja teorii skryptów [20], a obecnie jest to jedna z bardziej dynamicznie rozwijających się metod uczenia maszynowego i automatycznego wnioskowania [2,33,34].

Wnioskowanie bazujące na przypadkach polega na rozwiązywaniu problemów poprzez poszukiwanie najbardziej podobnych rozwiązań problemów już rozwiązanych (rys. 1) i ich adaptację. Nowe przykłady są następnie dopisywane do bazy przykładów.

Pośród bardzo wielu obszarów zastosowań tych metod można wymienić diagnostykę medyczną, sterowanie lotami samolotów czy diagnostykę procesów technologicznych [2,11,19].




Rys. 1. Przykład przeszukiwania bazy przykładów

Fig. 1. Example of searching a case base

Wnioskowanie oparte na przykładach jest nazwą dużej grupy metod, w której wyróżnia się między innymi wnioskowanie oparte na wzorcach, analogii oraz na przykładach.

5. Wnioskowanie oparte na kontekście

Wnioskowanie oparte na kontekstach (ang. Context-based Reasoning, CxBR) opisano po raz pierwszy w latach 80 w USA [8,14]. Jest ono obecnie intensywnie rozwijane za granicą [18,9,10]. Wnioskowanie oparte na kontekście można scharakteryzować jako automatyczne wnioskowanie analogiczne w skutkach do zachowań ludzkich podczas podejmowania decyzji, np. w czasie działań militarnych lub obsługi pojazdu. Kontekstem w tym przypadku jest ciąg następujących po sobie sytuacji, dla których charakterystyczna jest zmiana warunków otoczenia i zmiana parametrów charakterystycznych, np. dla obsługiwanego obiektu.



Rys. 2. Przykład obserwacji opartej na kontekstach [8]

Fig. 2. Example of observation based on contexts [8]

Istotą tego wnioskowania jest wykorzystywanie podzbioru istotnych (w zależności od kontekstu) informacji bez potrzeby przeszukiwania wszystkich dostępnych danych. Podstawą wnioskowania opartego na kontekstach są dwa założenia [8]. Pierwsze związane jest z tym, że podczas wnioskowania nie wykorzystuje się całej posiadanej wiedzy, a jedynie fragment związany z kontekstem rozpatrywanego zagadnienia. Drugie dotyczy obserwacji tego samego obiektu przeprowadzanych w różnych kontekstach. Stwierdza się, że obserwacje te są ze sobą zgodne. Obserwacja obiektu w określonym kontekście, w szczególności w kilku kontekstach, ma stanowić cały obraz obiektu.

Na rysunku 2 pokazano przykład obserwacji przezroczystej skrzynki z przegrodami zawierającymi kule. Skrzynka obserwowana jest przez dwóch obserwatorów $O1$ i $O2$, których obserwacje umożliwiają otrzymanie pełnego obrazu obiektu.

Taki sposób wnioskowania pozwala na rozłożenie obserwacji „złożonych” na obserwacje „proste”. W przypadku wnioskowania opartego na kontekstach nie określa się jednoznacznie sposobu reprezentacji wiedzy. Wiedza może być reprezentowana w formie reguł lub przykładów.

Uwzględnianie kontekstu podczas realizacji procedur wnioskowania diagnostycznego polega na interpretacji cech sygnałów w wybranym kontekście. Przykładem takiego podejścia jest rozpatrywanie sygnałów w kontekście symptomów charakterystycznych dla danego podzespołu maszyny (przekładni, czy zespołu wirnika). Zmiana kontekstu w potocznym rozumieniu powoduje zmianę zbioru cech sygnałów diagnostycznych branych pod uwagę podczas formułowania diagnozy.

Przeprowadzone badania literaturowe wskazują na to, że wnioskowanie oparte na kontekstach nie było dotychczas stosowane w Polsce dla opisywanych problemów. Metody te, opisane po raz pierwszy w latach 80 [33], są obecnie intensywnie rozwijane za granicą [8,9] [10,14].

6. Przykład zastosowania wnioskowania diagnostycznego z uwzględnieniem kontekstu

Wnioskowanie diagnostyczne z uwzględnieniem kontekstu jest obecnie jednym z kierunków badań prowadzonych w Katedrze PKM Politechniki Śląskiej. Podstawą

wnioskowania są wyniki sygnałów rejestrowanych podczas działania maszyny wirnikowej. Sygnały te są złożone, stąd interpretacja ich wyników jest często trudna. Celem opracowywanej metody wnioskowania z uwzględnieniem kontekstu jest uproszczona oraz częściowa automatyzacja procedur wnioskowania.

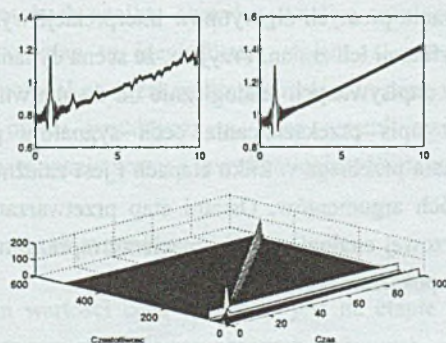
Podstawą opracowywanej metody jest zastosowanie koncepcji sceny dynamicznej [26,27,28,29,30,32]. Koncepcja ta jest również wynikiem badań prowadzonych w Katedrze PKM.

6.1. Scena dynamiczna w diagnostyce maszyn

W potocznym rozumieniu scena dynamiczna jest zbiorem obiektów, których cechy charakterystyczne, takie jak: położenie, kolor, wielkość są funkcjami czasu. W opisywanych badaniach scena dynamiczna jest wynikiem obserwacji działania maszyny i analizy sygnałów zarejestrowanych podczas tego działania.

Przykładami obiektów sceny są cechy sygnałów, takie jak: przebiegi wartości średnich, średniokwadratowych, funkcja korelacji, kowariancji lub charakterystyki czasowo-częstotliwościowe (rys.3). Wymienione cechy mogą być wyznaczone w różnych dziedzinach (mogą być funkcjami różnych parametrów, czasu lub częstotliwości) i są zapisywane jako macierze lub wektory o różnych rozmiarach.


Istotą analizy sceny oraz interpretacji jej obiektów jest to, że wynikiem zastosowania odpowiednich przekształceń mogą być informacje dotyczące nie tylko zmiennego działania maszyny, ale także ich określona interpretacja. Możliwa jest również identyfikacja oddziaływań zachodzących między maszyną i jej otoczeniem oraz zjawisk zachodzących w otoczeniu maszyny.



Rys. 3. Przykłady cech sygnałów diagnostycznych [32]

Fig. 3. Example of features of diagnostic signals [32]

Opracowany sposób analizy sceny będącej zbiorem obiektów w postaci cech sygnałów diagnostycznych (rys.4) [26,32] oparto na analogii do analizy sceny w potocznym rozumieniu, która charakteryzuje się rozpatrywaniem obiektów z uwzględnieniem kontekstu.



Rys. 4. Schemat sceny dynamicznej zawierającej cechy sygnałów diagnostycznych [32]


Fig. 4. Scheme of dynamic scene containing features of diagnostic signals [32]

Przykładem takiej interpretacji może być traktowanie pewnych obiektów jako pierwszoplanowych, innych jako drugoplanowych.

Przejsięcie do innej płaszczyzny spojrzenia na scenę związane jest z uwzględnieniem kontekstu związanego z identyfikacją ruchu obiektów czy przynależnością obiektów do zbiorów będących tłem, zakłóceniem lub zbiorem obiektów dostarczających określonych informacji.

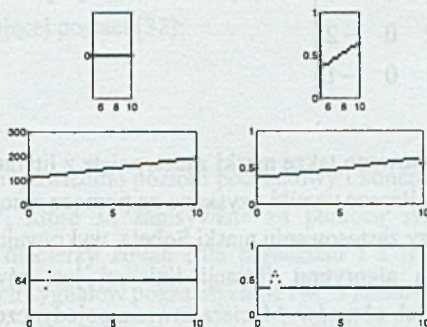
6.2. Zapis sceny

Scena dynamiczna, rozumiana jako zbiór wyników analizy sygnałów diagnostycznych, wymaga określonego sposobu zapisu. Jednym z głównych założeń opracowywanych metod była możliwość zastosowania prostych algorytmów interpretacji wyników analizy sygnałów oraz automatycznej identyfikacji ich zmian. Przyjęto, że scena dynamiczna jest zapisywana w formie prostych macierzy zapisywanych analogicznie do dwubarwnych obrazów cyfrowych [13,17,28]. Szczegółowy opis przekształcania cech sygnałów pominięto w referacie. Przetwarzanie cechy sygnału przebiega w kilku etapach i jest zależne od tego, czy cecha jest funkcją jednego lub dwóch argumentów. Ostatni etap przetwarzania cechy polega na jej zapisie do postaci macierzowej analogicznie do macierzy reprezentujących obrazy cyfrowe. Przykłady takich obrazów pokazano na rys. 5 i 6.



Rys. 5. Obraz reprezentujący cechy, które są funkcjami jednego argumentu (z rys.3) [32]

Fig. 5. Image representing features, which are one-argument functions (form Fig.3) [32]



Rys. 6. Obrazy reprezentujące cechy, które są funkcjami dwóch argumentów (z rys.3) [32]

Fig. 6. Image representing signal features, which are two-argument functions (from Fig.3) [32]

Na rysunku 6 pokazano cechy zidentyfikowane na podstawie charakterystyki czasowo-częstotliwościowej (rys.3). Pokazane obrazy reprezentują przekroje charakterystyki odpowiadające składowym sygnału. Obrazy te zawierają przebiegi amplitudy przekształceń częstotliwości zidentyfikowanych składowych.

Celem przekształceń wyników analizy sygnałów jest wyeliminowanie niewielkich zmian wartości cechy, które nie są istotne z diagnostycznego punktu widzenia, oraz umożliwienie zastosowania prostych metod identyfikacji zmian. Istotnym problemem jest w tym przypadku przekształcanie charakterystyk czasowo-częstotliwościowych. Z punktu widzenia możliwości identyfikacji poprawnej diagnozy najistotniejsza jest poprawna identyfikacja składowych sygnału i ich zmian.

Kolejne etapy analizy sceny dynamicznej zostały zrealizowane za pomocą metod analizy danych opartych na sposobach analizy obrazów. Analiza sceny została przeprowadzona w trzech etapach. Pierwszy etap to identyfikacja zmian za pomocą metod przetwarzania obrazów. Kolejny etap polegał na przekształceniu zmian do postaci opisu obrazu za pomocą metod bazujących na opisie syntaktycznym. Etap ostatni, związany z formułowaniem wniosku, polega na rozpatrywaniu sceny z uwzględnieniem kontekstu.


6.3. Identyfikacja zmian cech sygnałów

Identyfikacja zmian wartości cech sygnałów jest na etapie obecnym ograniczona do wykrywania charakterystycznych miejsc na obrazach cyfrowych, co zostało przeprowadzone za pomocą konwolucyjnych metod filtracji obrazów. W przypadku cyfrowej filtracji obrazów odpowiednikiem impulsowej odpowiedzi filtru jest macierz nazywana matrycą lub maską filtru. Maskę, wraz z przykładem, przedstawia się jako macierz [13,21,24]:

$$w = \begin{bmatrix} w_1 & w_2 & w_3 \\ w_4 & w_5 & w_6 \\ w_7 & w_8 & w_9 \end{bmatrix} = \begin{bmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{bmatrix} \quad (11)$$

W ramach badań zastosowano także maski zaczerpnięte z literatury oraz zdefiniowane w czasie badań [13,21,24]. Najlepsze wyniki uzyskano za pomocą zmodyfikowanego algorytmu filtracji liniowej [13,29] przy zastosowaniu maski Sobela, wykrywającej linie pionowe (11).

Efektom zastosowania algorytmu filtracji liniowej jest również macierz zapisana analogicznie do dwubarwnych obrazów. Macierz zawiera pojedyncze wartości odpowiadające chwilom czasu, w których poziom określonej wartości cechy uległ zmianie [5,11]. Przykłady obrazów reprezentujących zmiany wartości cech sygnałów z rys. 2 pokazano na rys. 7.



Rys. 7. Obrazy reprezentujące zmiany wartości cech, które są funkcjami dwóch argumentów (z rys.3 i 6) [32]

Fig. 7. Images representing changes of values of signal features (two-argument functions) (from Fig.3 and 6) [32]

6.4. Syntaktyczny zapis zmian

Kolejny etap realizacji metody polega na zapisie identyfikowanych zmian w macierzach nazwanych macierzami zmian. Opracowany zapis bazuje na syntaktycznym opisie obrazów, a w szczególności na metodach ciągowych i drzewowych. Syntaktyczny opis obrazu jest realizowany za pomocą skończonego zbioru symboli języka opisu obrazu. W omawianym przykładzie wszystkie wyniki analizy sygnałów zapisane w formie dwubarwnych obrazów podzielono na cztery segmenty czasowe. Podział ten traktuje się jako analizę sceny dynamicznej w kolejnych kadrach, które są fragmentami obrazów cyfrowych zawierających przebiegi wartości średnich, skutecznych oraz przekroje charakterystyki czasowo-częstotliwościowej reprezentowane za pomocą dwóch obrazów umożliwiających identyfikację zmian częstotliwości i amplitudy.

Opracowany opis identyfikowanych zmian składa się z alfabetu zawierającego zbiór symboli terminalnych, które są liczbami całkowitymi. Symbole te oznaczają odpowiednio numer poziomu wartości cechy oraz jednostkę czasową rozpatrywanego przedziału.

Elementarny zapis cechy między dwoma kolejnymi wartościami definiuje się jako trójkę uporządkowaną o następującej postaci [32]:

$$[Pp; T; Pk], \quad (12)$$


gdzie Pp i Pk oznaczają odpowiednio poziom początkowy i końcowy wartości danej cechy w przedziale o długości T , które są zapisywane za pomocą symboli ze zbioru symboli terminalnych. Fragment macierzy zmian (dla przedziału I i II) odpowiadający zmianom zidentyfikowanym dla cech sygnałów pokazanych na rys. 3 zawarto w tabl. 1.

Tablica 1

Fragment macierzy zmian

	I	II
Sk.I (f)	-	-
Sk.I (A)	-	-
Sk.II (f)	[1,250,3]	[3,250,5]
Sk.II (A)	[1,250,2]	[2,250,4]
Sk.III (f)	[5,70,5] [(2,7),60,(2,7)] [5,120,5]	[5,250,5]
Sk.III (A)	[5,50,5] [(2,9),90,(9,2)] [5,110,5]	[5,250,5]

Ze względu na to, że wyniki analizy sygnałów zostały podzielone na cztery segmenty, efektem zastosowania opracowanych koncepcji i algorytmów formułowania diagnozy są cztery odpowiadające im wnioski.



Rys. 8. Alfabet opisu identyfikowanych zmian [32]

Fig. 8. Alphabet of description of identified changes [32]

Zapis zmian w postaci ciągów symboli

	I	II	III	IV
Składowa I (f)	-	-	A	A
Składowa I (A)	-	-	B	B
Składowa II (f)	B	B	B	B
Składowa II (A)	B	B	B	B
Składowa III (f)	ANA	A	A	A
Składowa III (A)	ANA	A	A	A

Wartości liczbowe pokazane w tabl. 1 są w następnym etapie przetwarzane do postaci ciągu symboli literowych. Zastosowany alfabet został wprowadzony podczas realizacji opisywanych badań. Przyjęty alfabet pokazano na rys. 8. Wyniki zastosowania alfabetu pokazano w tabl.2, która jest podstawą wnioskowania.

6.5. Analiza sceny z uwzględnieniem kontekstu

Głównym założeniem, które przyjęto na początku badań, jest znajomość częstotliwości charakterystycznej, która w opisywanym przypadku jest częstotliwością obrotów. Na podstawie zbioru symboli, przedstawionego w punkcie poprzednim, zdefiniowano 8 reguł określających charakter zmian w danym segmencie (tabl.3) [29,32]. Przyjęto, że charakter zmiany w danym segmencie określa się na podstawie symboli, które występują w danym segmencie. W niektórych przypadkach bierze się także pod uwagę kolejność ich występowania.

Reguły określania charakteru zmian opracowano na podstawie analizy przebiegów zmian wartości cech sygnałów diagnostycznych. Osiem wymienionych reguł przyjęto ze względu na to, że są one najczęściej pojawiającymi się przypadkami charakteru zmian.

Jednym z celów opisywanych badań było opracowanie takiej metody, która umożliwia rozdzielenie identyfikowanych symptomów na dwa zbiory symptomów związane z badanym obiektem i z jego otoczeniem. Drugi zbiór symptomów przyjęto nazywać tłem.

Tablica 3

Reguły wnioskowania o charakterze zmian [32]

Charater zmiany	Symbole charakterystyczne
Stały poziom S	A, D
Wzrost poziomu WP	A, B, D, E, G, J, K
Spadek poziomu SP	A, C, D, F, H, I, L

Spadek i wzrost poziomu SiW	SP, (może wystąpić w tym miejscu S), WP
Wzrost i spadek poziomu WiS	WP, (może wystąpić w tym miejscu S), SP
Nagły sp. i wz. poziomu Niw	(SP lub S), O lub M, (S lub WP)
Nagły wz. i sp. poziomu NWiS	(WP lub S), Ł lub N, (S lub SP)
Wahania poziomu (W)	Wszystkie inne kombinacje

Rozdzielenie symptomów polega na porównywaniu charakteru zmian kolejnych przebiegów reprezentujących zmiany częstotliwości i amplitudy składowych sygnału w ramach jednego segmentu [32]. Należy podkreślić, że głównym przedmiotem analizy w czasie realizowanych badań były charakterystyki czasowo-częstotliwościowe oraz przebiegi wartości średnich i skutecznych.

Pierwszy kontekst używany podczas formułowania wniosku związany jest z określeniem rodzaju symptomu. Kontekst jest określany przez zbiór reguł pokazanych w tabl. 4 [32]. Kontekst I jest podstawą rozdzielania identyfikowanych symptomów, a przez to określania zgodności lub niezgodności charakteru zmian składowych sygnału z charakterem zmian składowej o częstotliwości charakterystycznej.

Tablica 4

Zbiór reguł określających kontekst I [32]

	kX(f)	kX(A)
Wartości cechy uznane za zmienne w czasie	WP	WP
	WP	S
	SP	SP
	SP	S
Wartości cechy uznane za stałe w czasie	S	S
	S	WP

Drugi etap formułowania diagnozy związany jest z zastosowaniem kontekstu II, który pozwala na identyfikację określonej niesprawności (tabl. 5). W omawianych przykładach zadanie to polega przykładowo na stwierdzeniu relacji liczbowej między częstotliwością zidentyfikowanej składowej i częstotliwością obrotów. Wyniki zastosowania dwóch kontekstów opisanych za pomocą reguł zawartych w tabl. 4 i 5 pokazano w tabl. 6.

Termin „niewyrównoważenie” oznacza, że składowa w danym przedziale jest symptomem niewyrównoważenia. Termin „tło” wskazuje, że zidentyfikowana składowa nie jest związana ze zmianami warunków działania obiektu i nie jest wynikiem wystąpienia jednej z typowych niesprawności. Składowe takie mogą być wynikiem zjawisk zachodzących w otoczeniu

obserwowanego obiektu. Znak „-”, oznacza, że w danym przedziale nie została zidentyfikowana określona składowa. Przykładowo składowa I jest identyfikowana tylko w przedziałach III i IV.

Tablica 5

Zbiór reguł określających kontekst II [32]

	1X(f)	1X(A)	kX(f)	kX(A)
Symptomy związane z działaniem obiektu	S	S	S	S
	WP	WP	WP	WP
	WP	S	WP	S
	WP	W	WP	W
Tło	Wszystkie inne przypadki			

Tablica 6

Zapis zmian w postaci ciągów symboli

	Przedział 1	Przedział 2	Przedział 3	Przedział 4
Skł 1	Zmienna	Zmienna	Zmienna	Zmienna
	Niewyważenie	Niewyważenie	Niewyważenie	Niewyważenie
Skł. 2	-	Zmienna	Stała	-
	-	Przeciążenie	Tło	-
Skł 3	-	Zmienna	Zmienna	-
	-	Tło	Przeciążenie	-

7. Podsumowanie

W referacie przedstawiono przegląd najważniejszych metod reprezentacji wiedzy oraz metod wnioskowania stosowanych w systemach diagnostyki technicznej. Należy podkreślić, że przegląd ten nie jest kompletny i zawarto w nim głównie te metody, które były lub są przedmiotem badań w Katedrze PKM Politechniki Śląskiej. Oprócz metod dobrze znanych w opisie tym zawarto także metody nowe, które są obecnie coraz częściej stosowane w diagnostyce maszyn. Do metod tych należą: wnioskowanie oparte na przykładach i wnioskowanie z uwzględnieniem kontekstu. Wnioskowanie z uwzględnieniem kontekstu jest przedmiotem badań obecnie realizowanych w Katedrze PKM. Przykład zastosowania tej metody pokazano w końcowej części referatu.

Omawiając zaprezentowany przykład należy podkreślić, że istotą proponowanego rozwiązania jest rozpatrywanie wyników analizy sygnałów jak obiektów sceny dynamicznej. Scena dynamiczna może być analizowana z uwzględnieniem kontekstu. Umożliwia to

oddziaływanie na wybór rozpatrywanych obiektów sceny w określonych etapach wnioskowania.

Kontekst może być zadawany z góry lub określany automatycznie na podstawie poprzednich wyników diagnozowania obiektu. Określony kontekst będzie z kolei wpływał na liczbę i rodzaj analizowanych sygnałów na scenie. Kluczowym problemem jest także określony sposób definiowania kontekstów. Podkreślić należy, że koncepcja sceny dynamicznej została tak opracowana, by umożliwić obserwację działania obiektu z uwzględnieniem wielu kryteriów, co pozwala na jednoczesne zastosowanie kilku kontekstów. Rozszerzeniem tej koncepcji jest zastosowanie podejścia wielokontekstowego.

Literatura

1. Akman V., *Steps Toward Formalizing Context*. Mehmet Surav 17(3), Fall, 1996.
2. Althoff K. D., Auriol E., Barletta R., Mango M., *A Review of Industrial Case-Based Reasoning Tools*. AI Perspectives Report, Oxford, UK, AI Intelligence.
3. Cempel C., *Podstawy wibroakustycznej diagnostyki maszyn*, WNT, Warszawa 1982,
4. Cholewa W., Kaźmierczak J., *Diagnostyka techniczna maszyn. Przetwarzanie cech sygnałów*. Skrypt nr 1693, Politechnika Śląska, Gliwice 1992.
5. Cholewa W., Moczulski W., *Diagnostyka techniczna maszyn. Pomiar i analiza sygnałów*. Skrypt nr 1758, Politechnika Śląska, Gliwice 1993.
6. Cholewa W., Pedrycz W., *Systemy ekspertowe*, Politechnika Śląska, Gliwice 1987.
7. Duda R. O., Hart P. E., *Pattern Classification and Scene Analysis*. John Wiley & Sons, LTD 1980.
8. Ghindini C., Giunchiglia F., *Local models semantics, or contextual reasoning = locality + compatibility*. Artificial Intelligence, 127:221-259, 2001.
9. Giunchiglia F., *Contextual reasoning*. Epistemologia (Special Issue on I Linguaggi e laMacchine), XVI:39-49, 1993.
10. Gonzalez A. J., Ahlers R., *Context-based representation of intelligent behavior in trainingsimulations*. Transaction of Society for Computer Simulation International, vol. 15, ss.153-166, 1999.
11. Jagielski J. (2001), *Inżyniera wiedzy w systemach ekspertowych*. Lubuskie Towarzystwo Naukowe, Zielona Góra.
12. Korbicz J., Kościelny M. J., Kowalczyk Z., Cholewa W., *Diagnostyka procesów. Modele. Metody sztucznej inteligencji. Zastosowania*, WNT, Warszawa 2002.
13. Markiewicz K., Timofiejczuk A., *Application of simple methods of image analysis in identification of changes of diagnostic signals*. 3th Symposjum on Artificial Intelligence Methods, 2002.
14. McCarthy J., *Notes on formalizing context*. Computing Natural Language, Center for the Study of Language and Information, s. 13-50. Stanford University, 1993.

15. Moczulski W., *Metody pozyskiwania wiedzy dla potrzeb diagnostyki maszyn*, Politechnika Śląska, s. Mechanika, z.130, nr 1382, Gliwice 1997.
16. Moczulski W.: *Diagnostyka techniczna. Metody pozyskiwania wiedzy*, ZN Politechniki Śląskiej, Gliwice 2002.
17. Molerus M, Timofiejczuk A., *Application of semantic and syntactic description in identification of changes of diagnostic signals*. 3th Symposium on Artificial Intelligence Methods, 2002.
18. Pieczyński A., *Reprezentacja wiedzy w diagnostycznym systemie ekspertowym*, Lubuskie Towarzystwo Naukowe w Zielonej Górze, Zielona Góra 2003.
19. Pokojski J. (2001), *Application of Case Based Reasoning in Machine Design*. Proceedeengs of Symposium on Methods of Artificial Intelligence in Mechanics and Mechanical Engineering, Gliwice, s. 209 – 216.
20. Shank M. P., Abelson R. P. (1977), *Scripts, Plans, Goals and Understanding*. Hillsdale, NJ, Erlbaum.
21. Tadeusiewicz R., Flasiński M., *Rozpoznawanie obrazów*, PWN, Warszawa, 1991.
22. Tadeusiewicz R., *Systemy wizyjne robotów przemysłowych*, WNT, Warszawa 1992.
23. Tadeusiewicz R., *Sieci neuronowe*, Akademicka Oficyna Wydawnicza, Warszawa, 1993.
24. Tadeusiewicz R., Korohoda P., *Algorytmy i metody komputerowej analizy i przetwarzania obrazów*, Materiały Szkoły Letniej TEMPUS S-JEP-07181-94, Wydawnictwo Poldex, Kraków, 1997.
25. Tadeusiewicz, R., Ogiela, M.R., *Medical Image Understanding Technology. Artificial Intelligence and Soft-Computing for Image Understanding*, Springer, Vol. 156, 2004.
26. Timofiejczuk A., *Koncepcja opisu działania maszyny wirnikowej w postaci scen dynamicznych*. II KDT, ss. 237-238, Warszawa, 19-22.09 2000.
27. Timofiejczuk A., *Dynamic scene: a basis of identification of a technical state of machinery*. SPIE AeroSense Meeting on Aerospace/Defense Sensing Simulation and Control, Orlando, USA, ss. 287-296, Orlando, Florida, 16-20.04 2001.
28. Timofiejczuk A., *Application of diagnostic system based on dynamic scene identification*. 16th AeroSense Meeting on Aerospace/Defense Sensing, Simulation and Control, Orlando, Florida, 01-05.04 2002.
29. Timofiejczuk A., *Zastosowanie metod analizy obrazów w identyfikacji zmian cech sygnałów diagnostycznych*. XXIX Ogólnopolskie Sympozjum "Diagnostyka Maszyn", Węgierska Górka, 04-09.03 2002.
30. Timofiejczuk A. (2002), *Zastosowanie analizy obrazów w identyfikacji zmian cech sygnałów diagnostycznych*. Diagnostyka, vol. 27, s. 67 – 74.
31. Timofiejczuk A., *Metody analizy sygnałów niestacjonarnych*. Wydawnictwo Politechniki Śląskiej, Gliwice 2003.
32. Timofiejczuk A., *Context-based approach In technical diagnostocs*. Sympozjum AIMETH 2004, Gliwice 2004.

33. Weyhrauch R. W., *Prolegomena to a theory of mechanized formal reasoning*. Artificial Intelligence, 13(1), 1980.21.
34. Watson I. (1997), *Applying Case-Based Reasoning: Techniques for Enterprise Systems*, Morgan Kaufmann Publisher.
35. Żółtowski B., Cempel c. (red.), *Inżynieria diagnostyki maszyn*. Biblioteka Problemów Eksploatacji, Warszawa, Bydgoszcz 2004.

Abstract

The main task of technical diagnostics is to identify the state of an object. Diagnostic experiments consist mainly in observation of operation parameters and residual processes (e.g. noise, vibration), which are side-effects of machinery operation. According to technical diagnostics, the processes are understood to be signals. A signal is a course of any physical quantity, which provides information. An operation, which lets us to determine signal features is called signal analysis. Values of signal features are considered to be diagnostic symptoms. They are the basis of methods of diagnostic inference. The paper deals with a review of selected methods of advanced diagnostic inference developed in Department of Fundamentals of Machinery Design (DFMD) of Silesian University of Technology at Gliwice

Methods of diagnostic knowledge representation are a subject of numerous publications. One can distinguish representations by means of natural language and a set of symbols. Symbolic representation can be divided into procedural (procedures, algorithms) and declarative (statements, rules). According to bibliography, the most often applied knowledge representations are statements, rules, semantic networks, frames and scenarios.

Diagnostic inference is a way of interpretation of gathered knowledge related to a group of investigated objects. Detailed division of these methods is presented among others in. One can distinguish between expert methods and approaches based on models. The review presented in the paper is not complete and it includes short descriptions of the most important approaches and these methods, which have been developed in DFMD. In the full version of the paper an example of application of selected methods is included.