Rozdział 2

Modele procesów diagnostyki technicznej

Krzysztof PSIUK, Sebastian RZYDZIK

2.1. Wstęp

Proces diagnozowania obiektów technicznych (urządzeń technicznych i procesów przemysłowych) można zrealizować na dwa sposoby:

1. Metodami opartymi na analizie symptomów, tzw. **diagnostyka symptomowa**.
2. Metodami stosującymi modele obiektów poddawanych diagnostyce, tzw. **diagnostyka wsparta modelowo**.

W przypadku diagnostyki symptomowej przeprowadza się proces wnioskowania diagnostycznego polegający na poszukiwaniu nieznanych wartości stanów technicznych (w szczególności niezdatności) na podstawie znanych wartości parametrów diagnostycznych (symptomów):

$$S \Rightarrow Z \tag{2.1}$$

gdzie S jest symptomem stanu technicznego Z.

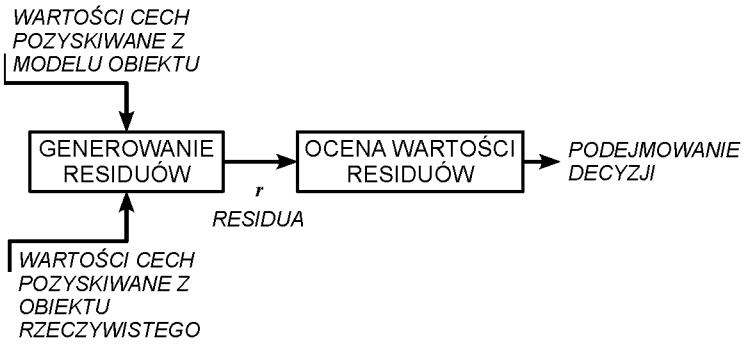

Rys. 2.1: Schemat procesu generowania residuum

W przypadku diagnostyki wspartej modelowo zakłada się, że dysponujemy modelem obiektu technicznego. Zwykle rozpatruje się model matematyczny obiektu. Model może reprezentować poprawną pracę obiektu lub reprezentować pracę tego obiektu w przypadku wystąpienia pewnej niesprawności. Diagnozowanie stanu technicznego polega na porównywaniu ze sobą wybranych wielkości (wartości

cech) pozyskiwanych z modelu obiektu i obiektu rzeczywistego (rys. 2.1). Na podstawie tego porównania wyznaczane są tzw. *residua* [2.27, 2.19], które mogą nas informować m.in. o pojawieniu się niesprawności w diagnozowanym obiekcie technicznym.

2.2. Podstawowe schematy procesu diagnozowania

Jak już powiedziano we wstępie, w przypadku diagnostyki symptomowej, stan danej maszyny określany jest na podstawie objawów tego stanu, które nazywane są symptomami stanu technicznego. Można tutaj przytoczyć porównanie z diagnostyką medyczną, w której stan pacjenta lekarz ocenia na podstawie zaobserwowanych objawów, którą może być np. podwyższona temperatura ciała pacjenta. W przypadku diagnostyki maszyn, obiektami badań są maszyny i urządzenia lub zachodzące w nich procesy, a objawami symptomy stanu technicznego. Na rys. 2.2 przedstawiono ogólny schemat procesu wnioskowania stosowany w diagnostyce symptomowej.

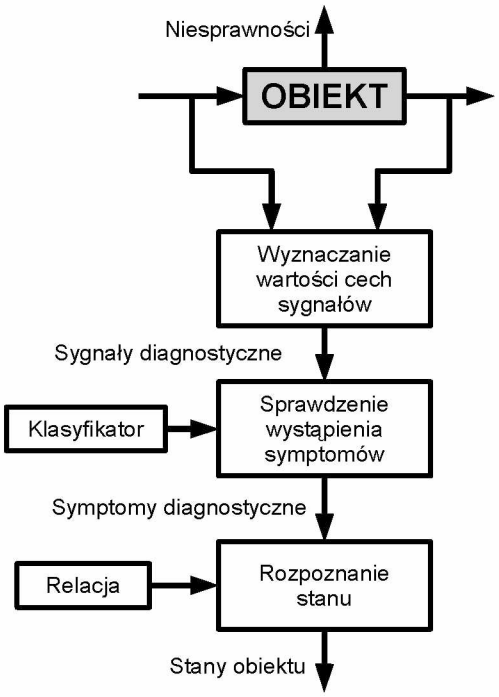

Rys. 2.2: Schemat procesu wnioskowania stosowany w diagnostyce symptomowej (opracowano na podstawie [2.48, 2.30])

Na przedstawionym schemacie pokazano, że na podstawie sygnałów wejścia i wyjścia z obserwowanego obiektu wyznaczane są wartości cech sygnałów diagnostycznych. Wyznaczone wartości cech sygnałów diagnostycznych są następnie klasyfikowane do określonej klasy stanów. W kolejnym kroku, na podstawie przeprowadzonej klasyfikacji określa się stan obiektu.

Należy tutaj zwrócić uwagę, że taki sposób określenia stanu dotyczy przypadku diagnostyki maszyn i urządzeń. W przypadku diagnostyki procesów przemysłowych proces diagnozowania składa się z trzech etapów [2.22, 2.30]:

- detekcji uszkodzenia,
- lokalizacji uszkodzenia,

- identyfikacji uszkodzenia.

Detekcja uszkodzeń definiowana jest jako wykrycie, zauważenie powstania uszkodzenia w obiekcie oraz chwili, w której to uszkodzenie nastąpiło. Lokalizacja pozwala na określenie rodzaju, miejsca i czasu wystąpienia uszkodzenia. Lokalizacja uszkodzenia może nastąpić dopiero po jego detekcji. Kolejnym krokiem jest identyfikacja uszkodzenia. Identyfikacja uszkodzenia określa rozmiar i charakter zmienności uszkodzenia w czasie.

Ogólny schemat procesu diagnozowania stanu technicznego obiektu z użyciem jego modelu pokazano na rys. 2.3. Wartości mierzonych sygnałów wejściowych U, pozyskiwane z diagnozowanego obiektu, są podawane na wejścia modelu obiektu. Na podstawie porównania sygnałów wyjściowych obiektu Y z sygnałami wzorcowymi generowanymi przez model obiektu mogą być wyznaczane: residua r, parametry obiektu $\hat{\Theta}$ lub stany techniczne z [2.20, 2.21]. Na podstawie porównania wartości wymienionych zmiennych z wartościami zmiennych pochodzącymi z działającego obiektu wyznaczane są symptomy s, z użyciem których przeprowadzana jest diagnostyka stanu obiektu (rozpoznawanie niesprawności f). Należy pamiętać, że rozpoznawane stany techniczne badanego obiektu mogą zależeć również od stanów technicznych układów wykonawczych. Ponadto niesprawności w funkcjonowaniu aparatury pomiarowej (czujniki i tory pomiarowe) mogą powodować generowanie fałszywych danych pomiarowych, co w konsekwencji może doprowadzić do nieprawidłowego rozpoznania stanu technicznego diagnozowanego obiektu [2.19].

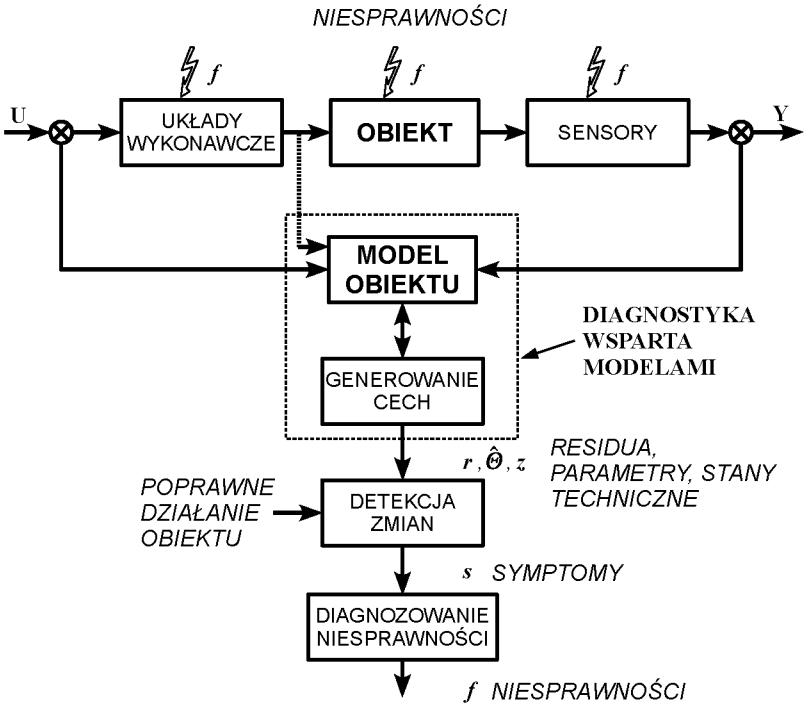

Rys. 2.3: Ogólny schemat procesu diagnozowania niesprawności obiektu z użyciem modelu obiektu (na podstawie [2.20])

Modele obiektów należy używać ze świadomością, że model nie zawsze musi zachowywać się podobnie jak obiekt działający w zadanych warunkach o określonym stanie technicznym. Przyjęte zazwyczaj uproszczenia, mające na celu uogólnienie modelu do pewnej klasy rozpatrywanych obiektów technicznych, powodują, że modele wykazują największą zgodność w stosunku do obiektów rzeczywistych tylko dla określonego zbioru branych pod uwagę stanów technicznych i jeszcze mniejszej liczby wyróżnionych warunków działania. W przypadku, gdy zachodzi potrzeba jak

najlepszego dopasowania modelu do wybranego egzemplarza obiektu technicznego przeprowadza się tzw. *strojenie modelu* za pomocą udostępnionych parametrów [2.43].

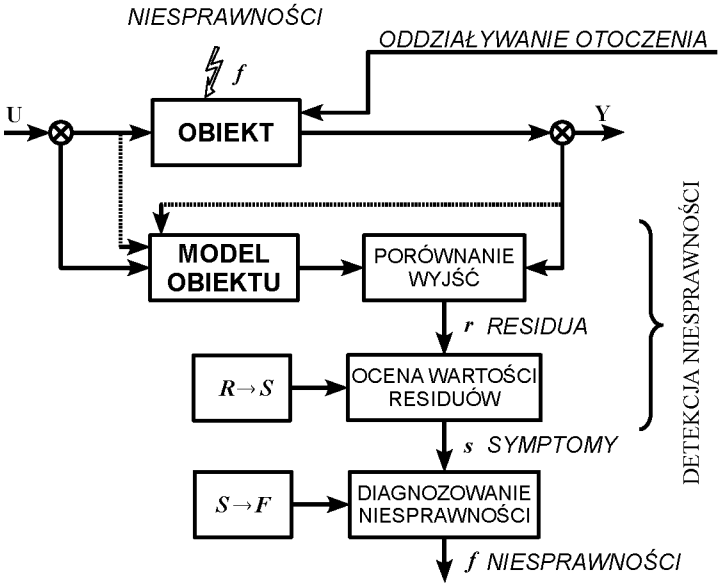

Rys. 2.4: Schemat procesu diagnozowania niesprawności obiektu z zastosowaniem modelu obiektu (na podstawie [2.20] i [2.27])

Na rys. 2.4 pokazano schemat szczególnego przypadku diagnozowania niesprawności z użyciem modelu obiektu. W wyniku porównania wartości wyjść generowanych przez obiekt rzeczywisty oraz model tego obiektu generowane są residua r. W kolejnym kroku wyznaczane są symptomy diagnostyczne s na podstawie zbiorów relacji odwzorowań wartości residuów r na wartości tych symptomów s. Etapy od porównania wyjść aż do wyznaczenia symptomów nazywa się *fazą detekcji niesprawności*. Ostatnim etapem jest przeprowadzenie wnioskowania diagnostycznego na podstawie relacji (p. 2.5):

$$S \Rightarrow F \tag{2.2}$$

gdzie S jest symptomem danej niesprawności F.

W celu uproszczenia procesu diagnozowania zwykle pomija się wpływ stanu urządzeń wykonawczych i pomiarowych oraz innych obiektów technicznych na stan diagnozowanego obiektu i zastępuje się go tzw. *oddziaływaniem otoczenia*.

Inną grupą modeli są modele diagnostyczne. Na rys. 2.5 pokazano schemat procesu diagnozowania z użyciem takiej grupy modeli. Modele diagnostyczne wprowadza się w przypadku, gdy model obiektu jest zbyt złożony lub jego identyfikacja jest nieopłacalna ze względu na przyjęte kryteria. Model diagnostyczny przekształca cechy sygnałów diagnostycznych w klasy stanów technicznych (patrz diagnostyka symptomowa, por. rys. 2.2).

2.3. Modele obiektów

W diagnostyce technicznej przyjęto, że model obiektu jest to uproszczone odwzorowanie właściwości obiektu wybranych ze względu na możliwość oceny jego zdatności do wykonywania stawianych mu zadań [2.53]. Uproszczenie to polega na ograniczeniu zbioru właściwości obiektu uwzględnianych

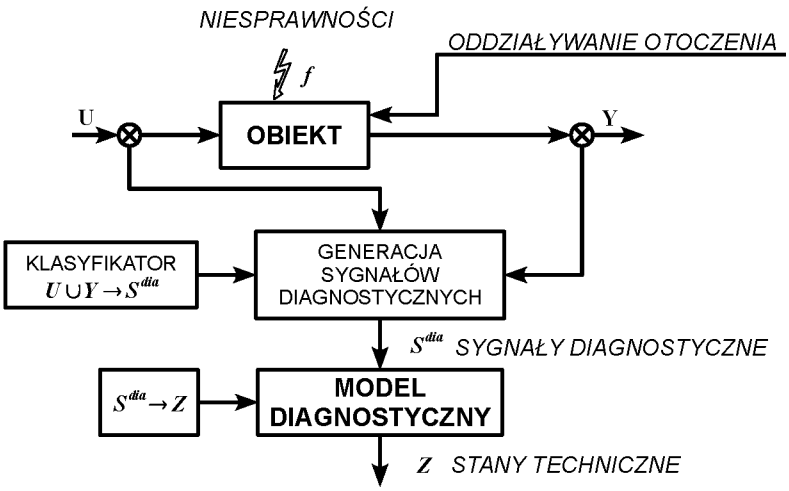

Rys. 2.5: Schemat procesu diagnozowania niesprawności obiektu z zastosowaniem modelu diagnostycznego (na podstawie [2.20] i [2.27])

podczas identyfikacji jego modelu. Skutkiem czego może być brak zgodności szczegółowych wniosków z analizy relacji pomiędzy cechami sygnałów diagnostycznych i cechami stanu obiektu wyznaczonymi z modelu obiektu z wnioskami wyznaczonymi na podstawie obserwacji obiektu rzeczywistego [2.10].

Obiekty techniczne mogą być reprezentowane przez [2.49]:

1. *Model matematyczny* - przybliżony opis jakiejś klasy zjawisk wyrażony przy użyciu aparatu matematycznego;
2. *Model nominalny* - system założeń przyjmowanych w danej nauce w celu ułatwienia (lub umożliwienia) rozwiązania pewnego problemu badawczego;
3. *Model realny* - przedmiot lub układ przedmiotów (zdarzeń, sytuacji) spełniających założenia danej teorii, lub dostatecznie podobny do układu badanego, ale prostszy i łatwiej dostępny badaniom;
4. *Model teoretyczny* - konstrukcja hipotetyczna odwzorowująca dany rodzaj rzeczywistości w sposób uproszczony, sprowadzający jej cechy do związków najistotniejszych, budowana w celach heurystycznych;
5. *Model semantyczny* - logiczne odwzorowanie, czyli interpretacja danej teorii w postaci układu (dziedziny) przedmiotów opisywanego prawdziwie przez tę teorię.

Wśród modeli obiektów technicznych należy rozróżnić ich dwie podstawowe grupy:

1. modele indywidualne,
2. modele grupowe.

Modele indywidualne opisują jeden wybrany obiekt. Natomiast modele grupowe opisują szereg obiektów podobnych ze względu na wybrane cechy. Modele indywidualne można tworzyć na podstawie modeli grupowych rozpatrywanych wówczas jako szczególne przypadki dla konkretnych egzemplarzy obiektów technicznych.

W najprostszym przypadku wprowadza się założenie, że każdy obiekt jest traktowany jak *czarna skrzynka* (rys. 2.6). Przyjęte uogólnienie pozwala wyodrębnić obiekt z jego otoczenia i nie zajmować się jego strukturą wewnętrzną. Konsekwencją takiego podejścia jest to, że [2.10]:

- oddziaływanie otoczenia na obiekt odbywa się wyłącznie za pośrednictwem wejść obiektu,
- oddziaływanie obiektu na otoczenie odbywa się wyłącznie za pośrednictwem wyjść obiektu,
- zbiór wejść i zbiór wyjść układu są zbiorami rozłącznymi.

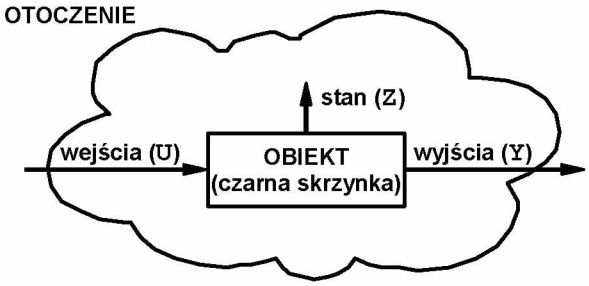

Rys. 2.6: Koncepcja „czarnej skrzynki'

Dla znanych wartości wejść obiektu i znanych wartości cech stanu tego obiektu można wyznaczyć wartość jego wyjścia na podstawie:

$$\mathtt{Y} = \mathtt{U} \times \mathtt{Z} \tag{2.3}$$

gdzie:

U - zbiór cech wejściowych,
Y - zbiór cech wyjściowych,
Z - przestrzeń cech stanów.

2.4. Modele diagnostyczne

Na potrzeby badań diagnostycznych tworzy się modele diagnostyczne [2.5, 2.4, 2.8, 2.24, 2.38, 2.52] (rys. 2.7). Model diagnostyczny przekształca dane o oddziaływaniu otoczenia na obiekt (poprzez

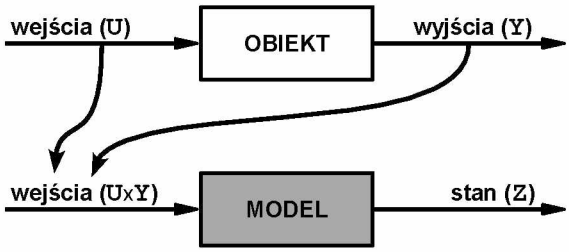

Rys. 2.7: Model diagnostyczny [2.10]

wejścia U) i obiektu na otoczenie (poprzez wyjścia Y) w stan obiektu Z [2.8]. Inaczej, jest to relacja pomiędzy cechami stanu obiektu a cechami sygnałów diagnostycznych [2.10, 2.11]:

$$\mathbf{M} \subset \mathtt{U} \times \mathtt{Y} \times \mathtt{Z} \tag{2.4}$$

gdzie:

M - model obiektu,
U - zbiór cech wejściowych,
Y - zbiór cech wyjściowych,
Z - przestrzeń cech stanów.

Modele diagnostyczne mogą być modelami ilościowymi, gdzie dane zapisane są w postaci liczb lub modelami jakościowymi, gdzie dane reprezentowane są w sposób przybliżony. W dużej liczbie przypadków modele diagnostyczne tworzą klasyfikatory. Klasyfikatory są używane w procesie klasyfikacji, czyli przyporządkowywania obiektów do wybranych klas na podstawie opisujących je cech.

Spośród wielu metod identyfikacji modelu diagnostycznego można wymienić:

- metodę regresyjną [2.5],
- metodę eksploatacyjnej analizy modalnej [2.45],
- metodę z zastosowaniem modelu odwrotnego [2.12],
- metody wykorzystujące opis obiektu w przestrzeni stanów [2.2],
- metody wykorzystujące sieci neuronalne [2.29],
- logikę rozmytą [2.28].

Niezależnie od przyjętej metodyki tworzenia modeli diagnostycznych, głównym problemem jest właściwa identyfikacja modelu. Zazwyczaj nie można obserwować wszystkich wejść obiektu lub z pewnych względów należy pominąć niektóre wejścia. Wiąże się to ze zredukowaniem rzędu modelu lub jego linearyzacją. W związku z tym model diagnostyczny może nie w pełni odwzorowywać zachowania obiektu. Dlatego też tworząc model diagnostyczny należy przewidzieć możliwość dostrajania go poprzez zmianę wybranych parametrów konfiguracyjnych.

2.5. Relacje stosowane w diagnostyce maszyn

Jednym z głównych celów diagnostyki technicznej jest ocena stanu technicznego maszyny. Ocena stanu maszyny może być realizowana w sposób „bezpośredni" lub „pośredni". Bezpośrednia ocena stanu może być realizowana przez [2.6, 2.10]:

- badanie elementów lub sposobu współdziałania współpracujących elementów,
- wykorzystanie arbitralnej oceny specjalistów.

Pierwsza z metod możliwa jest do zrealizowania jedynie poprzez demontaż maszyny. Wymaga przeprowadzenia odpowiednich badań, a czasem wymaga adaptacji samych elementów dla potrzeb przeprowadzenia badań. W drugim przypadku, gdy wykorzystywana będzie wiedza specjalistów, pojawia się problem związany z metodami formalizowania sposobów wyznaczanej opinii oraz ich właściwej oceny.

Stan maszyny może być również określony w sposób pośredni. Metody pośrednie określenia stanu polegają na tym, że na podstawie obserwacji sygnałów diagnostycznych wyznaczane są cechy stanu. Sygnałem diagnostycznym jest najczęściej przebieg dowolnej wielkości fizycznej, zależnej od stanu maszyny, który umożliwia przeniesienie informacji o jej stanie. Wartości wybranych cech sygnałów diagnostycznych maszyny, która znajduje się w określonym stanie, są symptomami tego stanu. Metody pośrednie mogą być stosowane do maszyn o wspólnej lub zbliżonej konstrukcji.

Zastosowanie pośrednich metod wyznaczania stanu maszyny wiąże się z przyjęciem pewnych założeń. Wyznaczenie bezpośrednich relacji pomiędzy symptomami stanu, a cechami sygnałów diagnostycznych nie jest zadaniem prostym. Wynika to między innymi ze złożoności budowy maszyn, oraz własności losowych procesów związanych z wytworzeniem i eksploatacją maszyn. W celu wyznaczenia takich relacji opracowuje się odpowiednie modele maszyn. Opracowane modele pozwalają na wnioskowanie o:

- rodzaju wielkości fizycznej, która powinna być obserwowana,
- rodzaju cech obserwowanych sygnałów, wrażliwych na zmiany stanu maszyny,

- zalecanej lokalizacji czujników pomiarowych,
- wymaganych warunkach działania maszyny podczas prowadzonych badań.

Stan maszyny zmienia się w sposób dynamiczny wraz z upływem czasu. Zmiany stanu mogą wpływać na zmiany cech sygnałów diagnostycznych. Zmienne w czasie wartości cech sygnałów diagnostycznych mogą stanowić podstawę do próby podejmowania decyzji o rozpoznaniu stanu maszyny. Podstawą do wykonania takich operacji jest założenie, że proces zmiany stanu oraz proces zmian sygnałów diagnostycznych odbywają się równolegle. Na tej podstawie poszukuje się zależności pomiędzy elementami obydwu procesów. Możliwość takiego opisu daje pojęcie relacji. Relacją *R* dwóch zbiorów *A* i *B* określa współzależność łączącą wybrane elementy należące do obydwu zbiorów [2.10]. W opisywanym przypadku wyróżniamy dwa zbiory na których definiujemy relacje. Są to:

- zbiór stanów badanego obiektu S_u,
- zbiór wartości cech sygnału diagnostycznego Z_u.

2.5.1. Klasy relacji diagnostycznych

Podczas prowadzonych badań diagnostycznych często wprowadza się różnego rodzaju relacje. Na rys. 2.8 pokazano klasy relacji diagnostycznych oraz związki pomiędzy nimi. Pokazane na rysunku

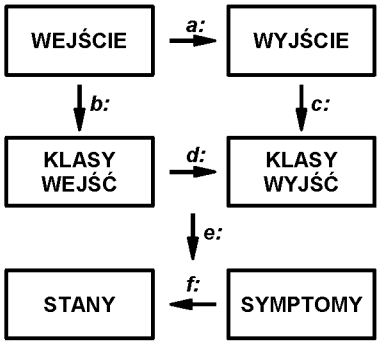

Rys. 2.8: Relacje stosowane w diagnostyce maszyn [2.12]

identyfikatory relacji reprezentują [2.12]:

a: model obiektu - relacja *wejście-wyjście*;

b: klasyfikator wejściowych cech modelu, który pozwala na przekształcanie cech ilościowych w cechy jakościowe;

c: klasyfikator wyjściowych cech modelu, który pozwala na przekształcanie cech ilościowych w cechy jakościowe (identyfikowany zazwyczaj z użyciem metod grupowania);

d: przybliżony model obiektu;

e: operacja odwracania modelu;

f: model odwrotny, który pozwala na wnioskowanie o klasie stanu technicznego obiektu na podstawie dostępnych symptomów.

2.5.2. Typy relacji diagnostycznych

W badaniach diagnostycznych proces diagnozowany i sygnał diagnostyczny są najczęściej opisywane za pomocą uporządkowanych w czasie ciągów dyskretnych stanów/zdarzeń. Przykład takich uporządkowanych ciągów zdarzeń przedstawiono na rys. 2.9. Oś pozioma na tym rysunku jest osią czasu makro [2.10] i przyrasta od strony lewej do prawej. Bloki oznaczone na tym rysunku w postaci okręgów reprezentują chwilowe wartości cech sygnałów diagnostycznych. Bloki przedstawione w postaci

prostokątów odpowiadają zaś stanom badanego obiektu. Bloki połączone są liniami zakończonymi strzałkami, które odpowiadają relacjom, które mogą być identyfikowane w takiej sieci. Dla tak zdefiniowanej sieci można określić różne typy relacji. Pierwszą grupę relacji mogą stanowić relacje opisujące związki pomiędzy stanami badanego obiektu S_u i wartości cech sygnałów diagnostycznych Z_u zdefiniowane w następujący sposób [2.10]:

$$R1(S, Z) \subset S_U \times Z_U \tag{2.5}$$

Pierwszy typ relacji pokazano na rys. 2.9 za pomocą pionowych linii. Relacje tego typu są niezależne od czasu i zakłada się w nich równoczesność występowania obydwu zdarzeń jednocześnie. Można wtedy przyjąć, iż stan obiektu jest określany na podstawie wartości cech sygnału diagnostycznego.

Drugi z typów relacji diagnostycznych wiąże między sobą elementy jednej przestrzeni stanów. Do tej grupy relacji zaliczymy relacje wiążące kolejne w ciągu zdarzeń stany obiektu R1(S), a także zmieniające się w czasie wartości cech sygnałów diagnostycznych R2(Z). Jak widać na rys. 2.9 relacje tego typu są równoległe do osi czasu, a więc będą związane z jego upływem. Odpowiada to sytuacji, w której aktualny stan obiektu jest wynikiem jego stanów wcześniejszych.

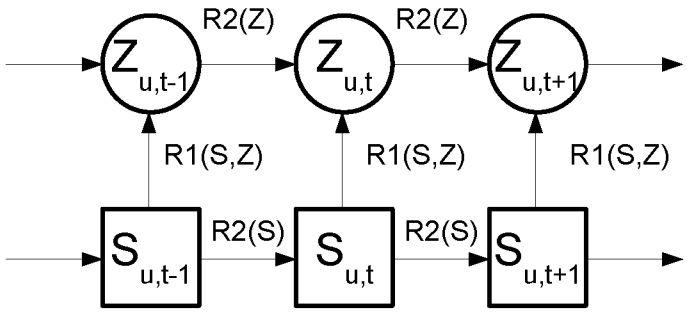

Rys. 2.9: Sieć relacji dla procesu diagnozowanego i sygnału diagnostycznego [2.10]

Przedstawiony na rys. 2.9 schemat jest z praktycznego punktu widzenia mało przydatny, ze względu na liczbę możliwych cech stanu. Dlatego wymaga on modyfikacji.

2.5.3. Modele relacji diagnostycznych

W praktycznych zastosowaniach wprowadza się ograniczenia związane z licznością zbioru rozpatrywanych cech sygnałów diagnostycznych. Wprowadzone ograniczenia wynikają między innymi z [2.10]:

- niemożliwości przeprowadzenia pomiarów niektórych oddziaływań pomiędzy obiektem badań i środowiskiem,
- ograniczenia liczby oddziaływań obiektu badań na otoczenie.

Przyjęte ograniczenia nie pozostają również bez wpływu na wyniki prowadzonych badań. Pociągają one za sobą ograniczenia zakresu wiedzy o naturze zjawisk zachodzących w obiekcie oraz wiedzy dotyczącej oddziaływań obiektu z otoczeniem.

Podsumowując, przedstawiony na rys. 2.9 schemat nie uwzględnia odwzorowań stanów w przestrzeniach o ograniczonej liczbie wymiarów. Aby to uwzględnić schemat ten uzupełnia się o dodatkowe elementy nazywane *obrazami stanów maszyny* im$s_{u,t}$ oraz obrazami *wartości sygnału diagnostycznego* im$(z_{u,t})$ [2.10]. Uzupełniony schemat przedstawiono na rys. 2.10. W badaniach diagnostycznych wprowadza się ograniczenia jedynie na rozpatrywaną liczbę cech sygnałów diagnostycznych.

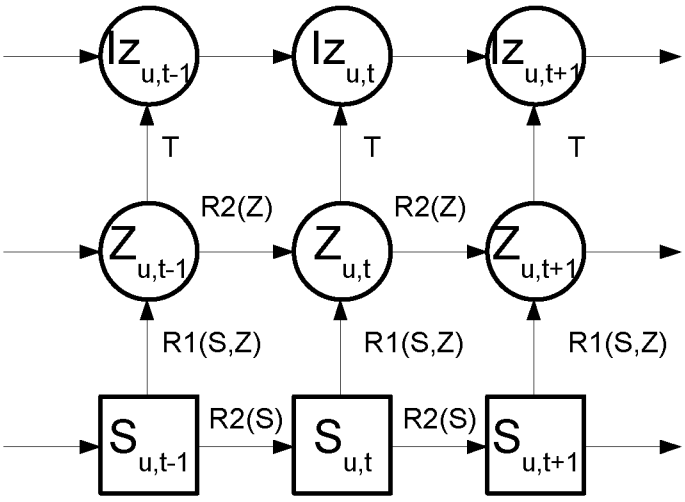

Rys. 2.10: Sieć relacji z uwzględnieniem obrazów cech [2.10]

2.5.4. Identyfikacja relacji diagnostycznych

Głównym celem prowadzenia badań diagnostycznych jest ocena stanu obserwowanego obiektu. Ocenę tą wykonuje się na podstawie opracowanych relacji diagnostycznych wiążących cechy sygnałów diagnostycznych z klasami stanów. Konieczna jest więc identyfikacja relacji diagnostycznych określających relacje przyczynowo-skutkowe, w których określone symptomy służą do rozpoznawania określonych stanów technicznych obiektu. Aby takie relacje określić prowadzi się badania eksperymentalne, w których dla dobrze znanego stanu obserwuje się sygnały diagnostyczne i poszukuje symptomów identyfikujących określony stan obiektu.

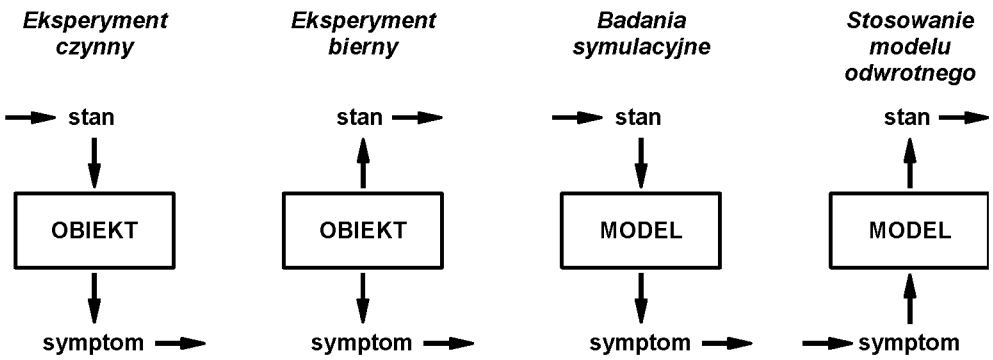

Rys. 2.11: Metody identyfikacji relacji w diagnostyce technicznej [2.12]

W diagnostyce technicznej wyróżnia się dwie podstawowe formy eksperymentów diagnostycznych na podstawie których identyfikuje się model diagnostyczny obiektu [2.12] (rys. 2.11):

- eksperyment czynny,
- eksperyment bierny.

Eksperyment czynny polega na celowym wprowadzeniu do badanego obiektu określonej niesprawności i obserwacji sygnałów diagnostycznych. Ponieważ w takim przypadku znany jest stan obiektu,

można poszukiwać symptomów, które posłużą do rozpoznania określonego stanu. W przypadku rzeczywistych obiektów trudno jest prowadzić tego typu badania. Jest to spowodowane faktem, że obiekt zazwyczaj pracuje i właściciel nie zezwoli na jego zatrzymanie jak również celowe wprowadzanie uszkodzeń. Dlatego też tego typu rozwiązania stosowane są głównie w przypadku niewielkich obiektów, o niewielkich kosztach wytworzenia, wytwarzanych w dużych seriach. Z tego powodu częściej od eksperymentu czynnego prowadzony jest eksperyment bierny.

Eksperyment bierny polega na obserwacji badanego obiektu bez ingerencji w jego stan. Na podstawie przeprowadzanych obserwacji prowadzone są badania zmierzające do identyfikacji relacji pomiędzy stanem obiektu a aktualnymi symptomami.

Interesującym sposobem prowadzenia eksperymentów jest wykorzystanie do tego celu modeli obiektów. Jeżeli znany jest dobry model obiektu, to wprowadzając modyfikacje do tego modelu możemy zmieniać jego stan. Wynikiem działania takiego modelu mogą być np. sygnały diagnostyczne, które będzie można również otrzymywać z rzeczywistych obiektów. Na podstawie otrzymanych sygnałów diagnostycznych możliwe będzie zidentyfikowanie relacji diagnostycznych. Wprowadzając do modelu obiektu określone zmiany, powodujące zmianę jego stanu, można w stosunkowy prosty sposób, przy niewielkich nakładach budować relacje diagnostyczne dla różnych stanów obiektu. W przypadku, gdy dysponujemy modelem obiektu możemy użyć go do:

- prowadzenia badań symulacyjnych (podczas których dla zadanych stanów generowane będą symptomy),
- odwracania modeli i stosowania modelu odwrotnego (identyfikacja relacji symptom-stan).

Użycie modelu w badaniach symulacyjnych pozwala zmniejszyć koszty oraz przeprowadzić badania, których nie można byłoby zrealizować na rzeczywistym obiekcie (np. testowanie niesprawności reaktorów jądrowych). W diagnostyce technicznej relacja stan-symptom nie jest użyteczna. Bardziej interesuje nas relacja odwrotna symptom-stan. Taka relacja jest realizowana z zastosowaniem tzw. modeli odwrotnych (p. 2.6.5).

2.6. Rodzaje modeli diagnostycznych

2.6.1. Modele lokalne i modele globalne

W badaniach diagnostycznych opartych na modelach, wyróżnia się klasę modeli globalnych i klasę modeli lokalnych (rys. 2.12). Model globalny opisuje dane uczące w pełnej przestrzeni ich wartości [2.25]. Podczas identyfikacji modeli globalnych pojawiają się dwa skrajne problemy związane z nadmiarem danych uczących oraz ich brakiem. Zwykle wprowadzane uproszczenia pogarszają jakość ich działania. Z drugiej strony wystarcza jeden model do rozpoznawania stanu całego obiektu. Natomiast model lokalny jest to model, który reprezentuje dane uczące tylko w wybranym obszarze przestrzeni wartości. Należy zaznaczyć, że model globalny nie jest sumą wypadkową modeli lokalnych. W pracach [2.12, 2.13, 2.17] pokazano, że zastosowanie modeli lokalnych jest rozwiązaniem bardziej korzystnym, niż zastosowanie modeli globalnych. Głównym argumentem są tutaj koszty identyfikacji modelu globalnego. Wśród innych zalet tworzenia modeli lokalnych, w odniesieniu do modeli globalnych, wymienia się:

- łatwiejszą identyfikację (związaną m.in. z mniejszą liczbą obserwowanych wejść i mniejszą liczbą wyznaczanych parametrów),
- zwykle wyższą dokładność.

Wadami modeli lokalnych jest to, że tego typu modele nie zawsze:

- reprezentują obiekt we wszystkich warunkach działania,
- uwzględniają wszystkie stany obiektu.

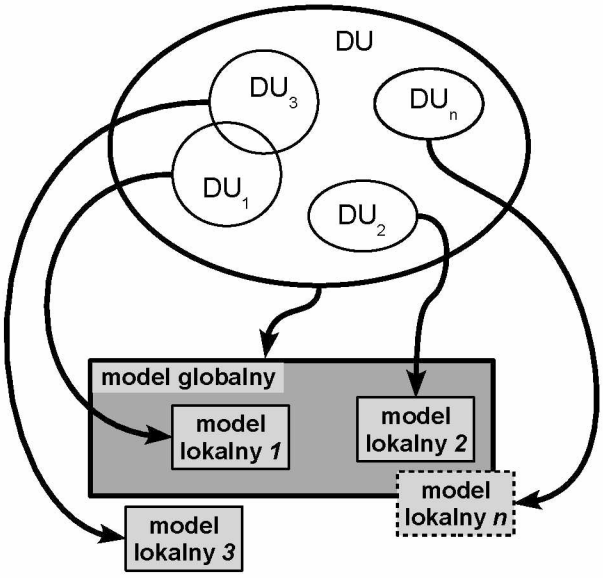

Rys. 2.12: Model globalny i model lokalny. DU - zbiór danych uczących, DU_n - podzbiór danych uczących

Modele lokalne mogą być identyfikowane osobno, przy czym należy uwzględnić na wejściu identyfikowanego modelu lokalnego wszystkie cechy sygnałów diagnostycznych całego obiektu, które mogą przyjmować formę dodatkowych wejść z danymi pochodzącymi od innych modeli lokalnych związanych z fragmentami obiektu. Wynika z tego pewna trudność polegająca na tym, że nie zawsze będzie możliwa dokładna identyfikacja modelu. W związku z tym, jak wspomniano wcześniej, należy przewidzieć możliwość strojenia modelu. W celu ułatwienia zadania identyfikacji stosuje się dekompozycję jednego modelu globalnego na zbiór modeli lokalnych związanych z fragmentami obiektu [2.39]. Podział rozpatrywanego obiektu na fragmenty nie musi być podziałem rozłącznym. Jest to możliwe w przypadku jeżeli przewidziano odpowiednie agregowanie lub uzgadnianie wyjść modeli lokalnych.

2.6.2. Wielomodele

W pracy [2.48] wielomodele zdefiniowano jako modele o ustalonej strukturze, które są zbudowane co najmniej z dwóch modeli składowych. Najbardziej popularnymi strukturami łączenia modeli są:

1. struktura szeregowa, gdzie wyjście jednego modelu jest wejściem drugiego modelu, a poszczególne modele składowe tworzą kolejne stopnie identyfikujące ogólny model obiektu;
2. struktura równoległa, gdzie wejście i wyjście każdego modelu składowego jest powiązane z wejściem i wyjściem pozostałych modeli składowych;
3. struktura hierarchiczna, gdzie modele składowe są połączone na zasadzie nadrzędności i podrzędności;
4. struktura sieciowa, gdzie modele składowe są połączone w sposób nieuporządkowany, a w ogólnym przypadku każdy z każdym;
5. struktura mieszana, będąca połączeniem powyższych.

Modele składowe powinny być identyfikowane niezależnie od siebie, ale tak, żeby była ogólnie zachowana możliwie zupełna reprezentacja warunków działania całego obiektu oraz możliwie zupełna reprezentacja stanów całego obiektu. Liczba modeli składowych zależy od liczby i rodzaju posiadanych danych oraz od stopnia skomplikowania modelowanego obiektu.

2.6.3. Modele wielowarstwowe

Modele wielowarstwowe stosuje się, gdy występuje nadmierna liczba możliwych do wyznaczenia cech sygnałów diagnostycznych i/lub występuje duża liczba cech stanu na podstawie których rozpoznawana jest klasa stanu [2.8]. Modele te należą do klasy wielomodeli, przy czym modele składowe

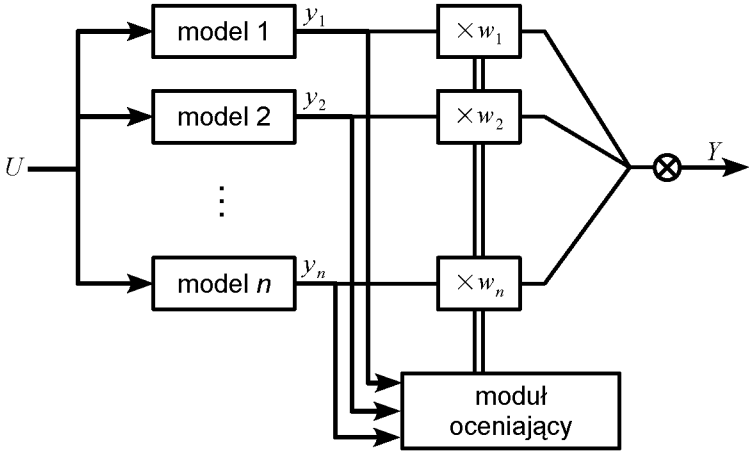

Rys. 2.13: Model wielowarstwowy [2.48]

połączone są ze sobą równolegle (rys. 2.13). W związku z tym każdy model posiada taką samą porcję informacji na wejściu. Natomiast wyjściem modelu wielowarstwowego jest wyjście modelu (modeli) najlepiej reprezentującego stan techniczny diagnozowanego obiektu rozpatrywanego w chwili czasu. Wybór modelu następuje poprzez oszacowanie w module oceniającym ilości informacji o stanie technicznym obiektu dostarczanej przez poszczególne modele. Zaletą modeli wielowarstwowych jest to, że zastosowane modele mogą uzupełniać się nawzajem, polepszając tym samym skuteczność działania modelu. Natomiast wadą jest to, że każdy model dostaje tę samą porcję informacji oraz to, że nie ma szczegółowych wytycznych wspomagających dobór parametrów mechanizmu wybierającego model najlepiej reprezentujący stan obiektu (problem oceny informacji o stanie).

2.6.4. Modele wieloaspektowe

Modele wieloaspektowe również należą do klasy wielomodeli o strukturze równoległej. W odróżnieniu do modeli wielowarstwowych, każdy model składowy modelu wieloaspektowego posiada inną porcję informacji na wejściu (rys. 2.14). Każdy model składowy odpowiada jednemu aspektowi, w którym może być rozpatrywany modelowany obiekt. Liczba modeli (aspektów) zależy od liczby rodzajów źródeł informacji, na podstawie których modele składowe są identyfikowane.

2.6.5. Modele odwrotne

Modele odwrotne przekształcają, za pomocą relacji diagnostycznych, symptomy diagnostyczne w klasy stanów technicznych [2.8]. Modele odwrotne są identyfikowane na dwa sposoby:

1. przez odwracanie analitycznego modelu obiektu (zazwyczaj modelu matematycznego),
2. na podstawie danych uczących zebranych i opracowanych w trakcie eksperymentów diagnostycznych.

W przypadku, gdy nie jest możliwe analityczne wyznaczenie modelu odwrotnego, przeprowadza się identyfikację modelu odwrotnego z użyciem drugiego sposobu. W pierwszym etapie budowany jest numeryczny model symulacyjny, a następnie generowane są sygnały dla zadanych przypadków stanów technicznych. Otrzymane sygnały są weryfikowane z sygnałami pochodzącymi z rzeczywistego obiektu. W drugim etapie, na podstawie zebranych danych, wyznacza się model odwrotny [2.25].

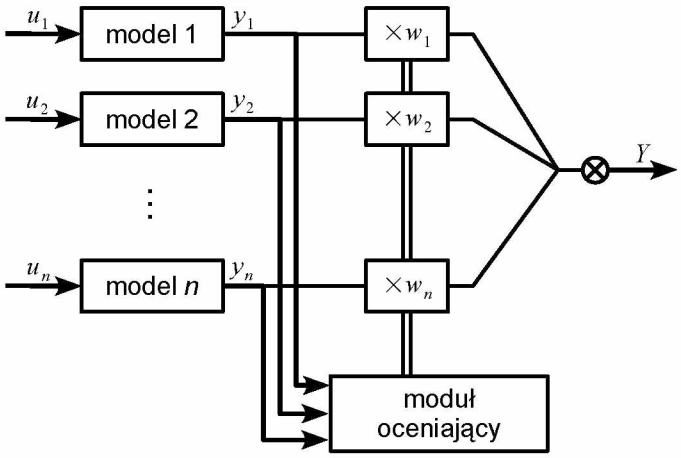

Rys. 2.14: Model wieloaspektowy [2.48]

2.6.6. Modele wielomodułowe

Jak wspomniano wcześniej jednym ze sposobów tworzenia modeli jest rezygnacja z poszukiwania globalnego modelu diagnostycznego i zastąpienie go zbiorem modeli lokalnych, z których każdy pozwala na wyznaczenie (uwzględnienie) cech diagnostycznych dotyczących wyłącznie wybranego funkcjonalnego lub strukturalnego fragmentu obiektu [2.23].

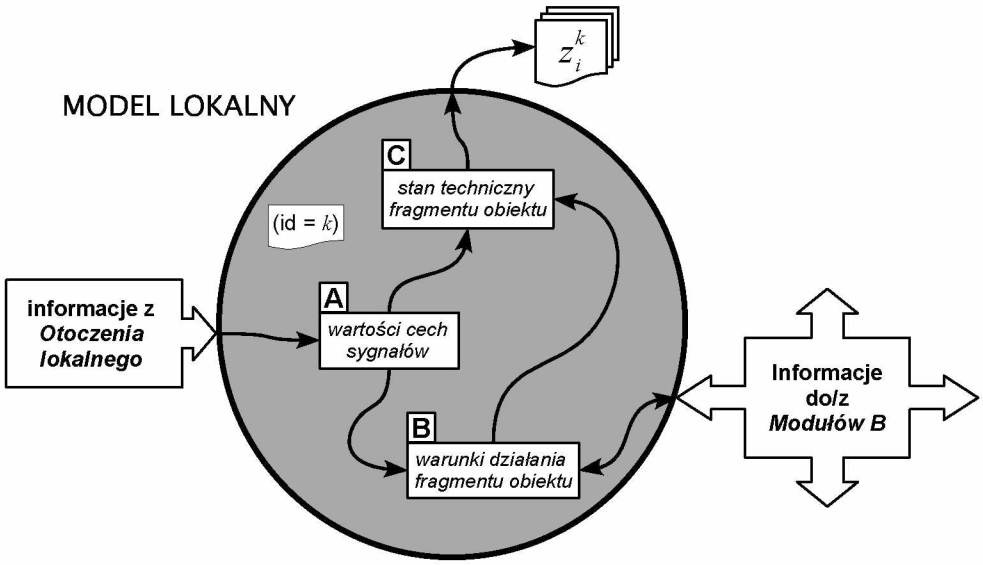

Rys. 2.15: Postać diagnostycznego modelu lokalnego [2.39]. A, B, C - moduły k-tego modelu lokalnego; z_i^k - i-ty stan k-tego fragmentu obiektu

Model lokalny może być modelem lokalnym strukturalnie (przestrzennie, terytorialnie), jak np. model łożyska tocznego, lub modelem lokalnym funkcjonalnie (lecz o możliwym znacznym rozproszeniu terytorialnym), jak np. model układu chłodzenia. W pracy [2.39] zaproponowano, że każdy model lokalny zbudowany jest z trzech współdziałających ze sobą modułów (rys. 2.15):

1. Modułu A, którego zadanie polega na obserwacji lokalnego nośnika informacji o stanie fragmentu obiektu (sygnału diagnostycznego);

2. Modułu B, którego zadanie polega na wnioskowaniu o warunkach działania fragmentu obiektu i całego obiektu oraz na uzgadnianiu wspólnej opinii o tych warunkach działania z innymi Modułami B;
3. Modułu C, którego zadanie polega na wnioskowaniu o stanie technicznym obiektu na podstawie wyników obserwacji lokalnych nośników informacji oraz wyników rozpoznawania i uzgadniania warunków działania całego obiektu.

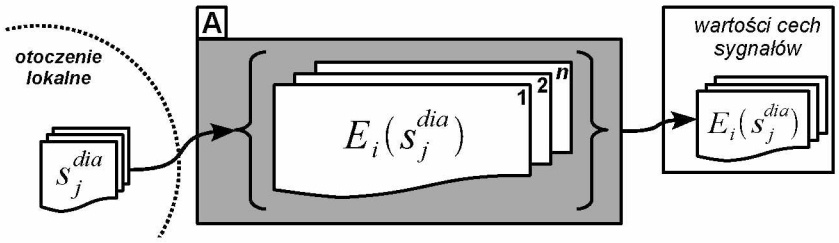

Rys. 2.16: Postać Modułu A

Zadaniem Modułu A (rys. 2.16) jest wyznaczanie wartości cech sygnałów diagnostycznych s^{dia} pozyskanych z fragmentu obiektu o_i związanego z modelem lokalnym m_i^L. W związku z tym Moduł A będzie zawierał zbiór funkcji i procedur wyznaczających wartości cech sygnałów diagnostycznych [2.34, 2.30]. Moduł A ma dostęp wyłącznie do cech sygnałów pozyskanych z fragmentu obiektu związanego z tym modelem. Nie są dla niego dostępne (bezpośrednio) cechy sygnałów pochodzących z innych fragmentów obiektu.

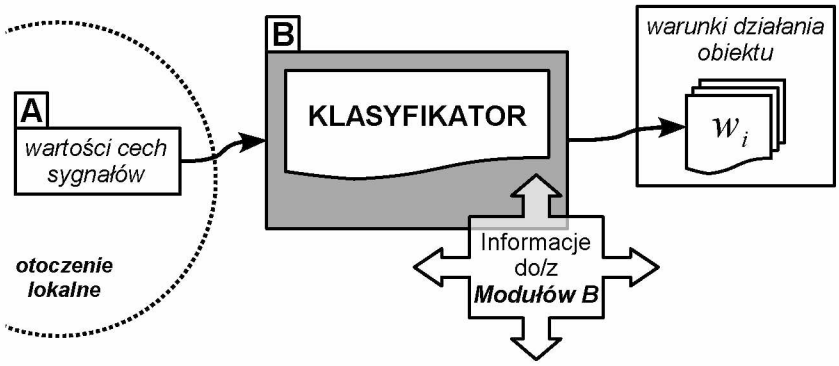

Rys. 2.17: Postać Modułu B

Zadaniem Modułu B (rys. 2.17) jest rozpoznawanie warunków działania W fragmentu obiektu o_i związanego z modelem lokalnym m_i^L oraz uzgadnianie z innymi Modułami B warunków działania całego obiektu. Zakłada się, że Moduł B ma dostęp do wyników działania Modułu A. Każdy Moduł B ma przypisany pewien zbiór warunków działania fragmentu obiektu związanego z modelem lokalnym oraz zbiór warunków działania całego obiektu. Działanie Modułu B polega na wykonaniu trzech kroków:

Krok 1 Rozpoznawanie warunków działania fragmentu obiektu.

Krok 2 Rozpoznawanie warunków działania całego obiektu.

Krok 3 Uzgadnianie z innymi Modułami B warunków działania całego obiektu.

W pierwszym kroku są rozpoznawane warunki działania dla fragmentu obiektu. Następnie stanowią one dane wejściowe do drugiego etapu - wyznaczania propozycji warunków działania całego obiektu.

Ostatecznie, w procesie agregacji lub uzgadniania opinii Moduły B wypracowują wspólną opinię wskazując ostatecznie warunki działania fragmentów obiektu i całego obiektu.

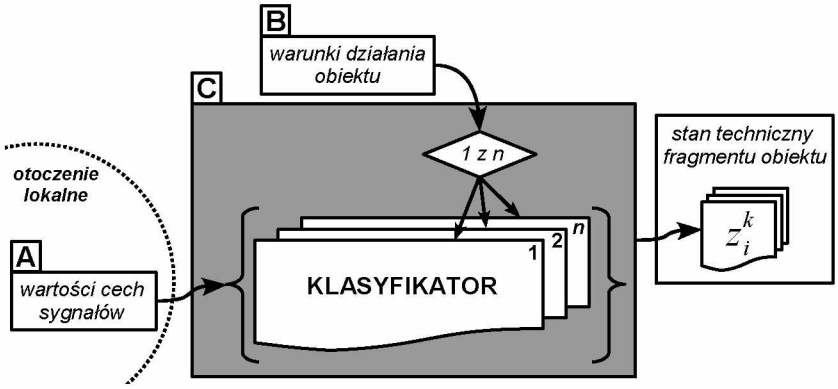

Rys. 2.18: Postać Modułu C

Moduł C (rys. 2.18) jest klasyfikatorem stanu. Jego zadaniem jest klasyfikacja (rozpoznanie) stanu fragmentu obiektu o_i związanego z modelem lokalnym m_i^L. W celu przeprowadzenia procesu klasyfikacji stanu niezbędna jest znajomość wartości cech relewantnych oraz warunków działania w jakich znajduje się obiekt.

Wyniki rozpoznawania klas stanów, traktowane jak stopnie przekonania, stanowią wejście do sieci stwierdzeń (Moduł D) (rys. 2.19). Na podstawie obliczeń, uwzględniających m.in. wiedzę subiektywną zawartą w tablicach prawdopodobieństw warunkowych, wyznaczana jest wartość stopnia przekonania o klasie stanu technicznego całego obiektu [2.41, 2.31, 2.3].

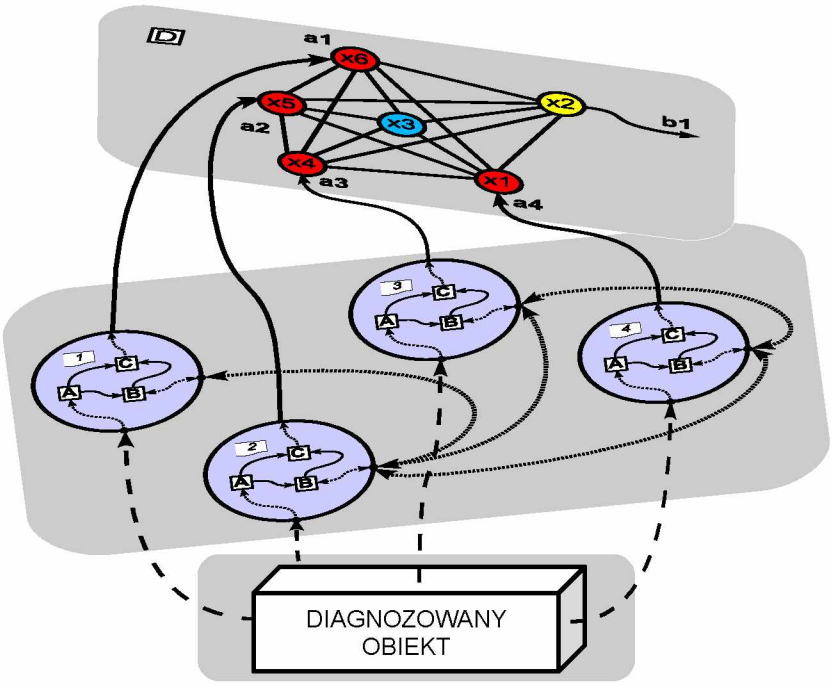

Rys. 2.19: Synteza modelu wielomodułowego [2.39]

Sieć stwierdzeń składa się z trzech zbiorów stwierdzeń:

1. wejściowych,
2. pomocniczych,
3. wyjściowych.

Każdy element tych zbiorów przyjmuje wartości z przedziału $[0; 1]$ i są to wartości stopnia przekonania o wystąpieniu danego stanu technicznego. Każdy stan obiektu jest związany z wybranym stwierdzeniem wejściowym. Oprócz stwierdzeń wejściowych są jeszcze stwierdzenia pomocnicze (np. spełniające rolę stwierdzeń grupujących stwierdzenia związane ze stanami wybranego fragmentu obiektu) oraz stwierdzenia wyjściowe, które reprezentują stany całego obiektu.

2.6.7. Inne klasy modeli

Oprócz powyżej wymienionych klas modeli w literaturze poświęconej diagnostyce technicznej można spotkać inne klasy modeli, takie jak:

Model statystyczny: W modelu statystycznym dane reprezentowane są w postaci łącznych rozkładów gęstości prawdopodobieństw ich wartości [2.8].

Model przekonań: W modelu przekonań dane reprezentowane są w postaci rozkładów przekonań o ich wartościach, gdzie modele przekonań są odpowiednikami modeli statystycznych, w których miary prawdopodobieństwa zastąpiono miarami subiektywnych przekonań [2.8].

Model strukturalny: Model strukturalny odwzorowuje dynamiczną strukturę modelowanego układu, jak również wzajemne oddziaływanie występujące pomiędzy elementami rozpatrywanego układu [2.35, 2.5].

Model logiczny: Model logiczny jest budowany w oparciu o aparat logiki matematycznej. Obejmuje stwierdzenia, orzekające o własnościach i właściwościach modelowanego obiektu oraz wnioski, dotyczące stanu obiektu, które na ich podstawie można wyciągnąć, a dotyczące własności i zachowania się modelowanego układu [2.35, 2.37].

2.7. Doskonalenie modeli

2.7.1. Ocena modelu obiektu

Analiza i ocena wyników generowanych przez opracowany model obiektu jest nieodzownym składnikiem każdej symulacji. Ocena polega na porównaniu wyników uzyskanych z przeprowadzonej symulacji i obserwacji obiektu rzeczywistego. Informacjami o własnościach obiektu rzeczywistego mogą być zarówno dane zebrane w czasie obserwacji pracy obiektu, jak i wyniki dostarczone przez odpowiednio uproszczone modele analityczne obiektów. Wprowadzone przybliżenia w modelu obiektu mające na celu uproszczenie systemu rzeczywistego powodują występowanie odchyłek. Jeżeli w systemie rzeczywistym spełniona jest zależność:

$$Y_r = f_r\left(U_r, t_r\right) \tag{2.6}$$

gdzie

Y_r - wyjścia obiektu rzeczywistego;
U_r - wejścia obiektu rzeczywistego;
t_r - czas;
$f_r(.)$ - funkcja wiążąca wejścia i wyjścia obiektu, funkcja przejścia.

to w modelu obiektu spotykamy się z sytuacją następującą:

$$Y_m \pm \Delta Y = f_m\left(U_m, t_m\right) \tag{2.7}$$

gdzie

Y_m - wyjścia obiektu rzeczywistego;
U_m - wejścia obiektu rzeczywistego;
t_m - czas;
$f_m(.)$ - funkcja wiążąca wejścia i wyjścia obiektu, funkcja przejścia;
ΔY - odchyłka modelowania.

Odchyłka modelowania zależy od następujących czynników [2.32]:

- od niedokładności związanych z określeniem parametrów systemu rzeczywistego,
- od niedokładności uwarunkowanych odchyłkami pomiarów wykonywanych podczas badań,
- od niedokładności uwarunkowanych istnieniem czynników inaczej występujących w badaniach modelowych niż w badaniach systemów rzeczywistych, przez co zmieniają się parametry modelu. Niedokładności tego rodzaju występują zwłaszcza w stanach, w których istotną rolę odgrywają nieliniowe charakterystyki wiążące ze sobą poszczególne parametry. Konsekwencją istnienia tego typu niedokładności może być całkowita rozbieżność pomiędzy wynikami badań modelowych i rzeczywistością,
- od niedokładności wywołanych niepełnym uwzględnieniem w modelu czynników wpływających na podstawowe zjawiska, tj. od niedokładności wynikających z przybliżonego modelowania.

W celu dokonania oceny modelu obiektu niezbędne jest przyjęcie metryki określonej na przestrzeni wszystkich par *wejście-wyjście* [2.18]. Metryką określoną na zbiorze W nazywamy przekształcenie $d : W^2 \rightarrow \Re$ takie, że:

1. $d(w, w) = 0$ dla wszystkich $w \in W$;
2. $d(w_1, w_2) = d(w_2, w_1)$ dla wszystkich par $w_1, w_2 \in W$;
3. $d(w_1, w_3) = d(w_1, w_2) + d(w_2, w_3)$ dla wszystkich trójek $w_1, w_2, w_3 \in W$;

Dla każdych dwóch par *wejścia–wyjścia* metryka d przyporządkowuje liczbę rzeczywistą dodatnią, która jest odległością między tymi parami. W przypadku badania zgodności obiektu rzeczywistego z jego modelem mamy:

$$d\left((x_r, y_r), (x_m, y_m)\right) \tag{2.8}$$

gdzie

x_r, y_r - odnosi się do obiektu rzeczywistego;
x_m, y_m - odnosi się do modelu.

W powyższym przypadku metryka d może być interpretowana jako wartość bezwzględna odchyłki między tymi parami.

Po przyjęciu odpowiedniej metryki należy ustalić próg decyzyjny, określający kiedy pary *wejścia–wyjścia* modelu i obiektu rzeczywistego są dostatecznie bliskie ze względu na cele, do których model został przeznaczony. Korzysta się tutaj z pojęcia tolerancji, czyli modelowa para *wejścia–wyjścia* (x_m, y_m) jest w granicach tolerancji pary systemu rzeczywistego (x_r, y_r) jeżeli:

$$d\left((x_r, y_r), (x_m, y_m)\right) \leqslant L \tag{2.9}$$

gdzie L jest poziomem akceptacji.

Dużą liczbę metryk stanowią metryki oparte na normach określonych na przestrzeniach liniowych. Norma wyznacza odległość od zera (należącego do przestrzeni liniowej) do każdego elementu należącego do tej przestrzeni. Przykładami norm mogą być [2.18]:

- maksimum odchyłki

$$\|\rho\| = max\{\rho(t) : t \in D(\rho)\} \tag{2.10}$$

- całka z wartości bezwzględnej odchyłki

$$\|\rho\| = \int_D (\rho)|\rho(t)|dt \tag{2.11}$$

- całka z kwadratu odchyłki

$$\|\rho\| = \int_D (\rho)\rho^2(t)dt \tag{2.12}$$

Mając normę $\|.\|$, metrykę d_0 definiuje się jako:

$$d_0(\rho, \rho') = \|\rho - \rho'\| \tag{2.13}$$

Jest to odległość pomiędzy ρ i ρ', która jest odległością różnicy $\rho - \rho'$ od zera. Na przykład dla całki z kwadratu mamy:

$$d_0(\rho, \rho') = \int_{[0,\tau]} \left[\rho(t) - \rho'(t)\right]^2 dt \tag{2.14}$$

gdzie $[0, \tau]$ jest wspólną dziedziną wielkości ρ i ρ'.

Ponieważ $e = \rho - \rho'$ jest trajektorią odchyłki, więc $d_0(\rho, \rho')$ jest scałkowaną odchyłką kwadratową.

Jak już powiedziano, w wynikach obserwacji obiektu rzeczywistego i jego modelu zawsze występuje pewna niezgodność w przestrzeniach par *wejścia–wyjścia* tych systemów. Przyczyn tej niezgodności można poszukiwać w funkcjach wyjściowych i w funkcjach przejścia.

W przypadku funkcji wyjściowych dąży się do minimalizacji odległości pomiędzy wartościami generowanymi na wyjściach obiektu rzeczywistego i jego modelu. Dla założonej metryki związanej z przestrzenią klas stanów wyjściowych przyjmuje się, że ε_y jest granicą niezgodności wartości pojawiających się na wyjściach, tj. dla wszystkich $q \in Q$ mamy:

$$d_y\left(y_r\left(q\right), y_m\left(q\right)\right) \leqslant \varepsilon_y \tag{2.15}$$

W przypadku funkcji przejścia dąży się do minimalizacji odległości pomiędzy trajektoriami tych funkcji wyznaczonych dla obiektu rzeczywistego i jego modelu. Dla założonej metryki związanej z przestrzenią klas stanów przyjmuje się, że ε_h jest granicą niezgodności odpowiadających sobie kolejnych punktów trajektorii funkcji przejścia, tj. dla wszystkich $q \in Q$ mamy:

$$d_h\left(h_r\left(q\right), h_m\left(q\right)\right) \leqslant \varepsilon_h \tag{2.16}$$

Do oceny jakości modelu obiektu można również użyć metod statystycznych. Do najbardziej popularnych metod należą:

- *Test χ^2 (Chi-kwadrat).* Test χ^2 służy do weryfikacji hipotezy, że zbiór danych empirycznych (w tym przypadku otrzymanych za pomocą modelu) ma taki sam rozkład jak obserwacje zarejestrowane w obiekcie rzeczywistym. Stosowany jest on przy testowaniu hipotez nieparametrycznych. Test jest prosty do wykonania, lecz wymaga dużej liczby obserwacji (rzędu dziesiątek).
- *Analiza wariancji.* Analiza wariancji pozwala sprawdzić, czy wartości średnie wielu populacji (reprezentowane przez wartości zmiennych pozyskanych z modelu i odpowiadające im wartości zmiennych zarejestrowanych w obiekcie rzeczywistym) różnią się istotnie. W ogólnym przypadku testy analizy wariancji służą do badania wpływu pewnych kontrolowanych parametrów na postać populacji wyjściowej i jej charakterystyki. W szczególności jednak, przyjmując takie same wartości wejściowe dla wszystkich zmiennych, zarówno modelowych, jak i rzeczywistych, można sprawdzić hipotezę statystyczną o równości średnich wartości tych zmiennych.

- *Analiza regresji.* Funkcją regresji I rodzaju zmiennej losowej Y względem zmiennej X jest funkcja przyporządkowująca poszczególnym wartościom zmiennej X wartości oczekiwane w odpowiednim warunkowym rozkładzie zmiennej Y. Przy porównywaniu przebiegów z modelu i obiektu rzeczywistego szczególnie istotną rolę odgrywa liniowa funkcja regresji:

$$f(x) = ax + b \tag{2.17}$$

gdzie a jest współczynnikiem regresji liniowej Y względem X wyrażającym przyrost wartości oczekiwanej zmiennej Y spowodowany jednostkowym przyrostem wartości zmiennej losowej X. Przedmiotem testów będzie sprawdzenie czy b nie różni się w sposób istotny od 0 oraz czy a nie różni się istotnie od 1. Wartości zmiennych a i b, dla znanych wartości ciągów $\{X_n\}$ i $\{Y_n\}$, wyznacza się ze wzorów:

$$a = \frac{\sum\limits_{i=1}^{n} (X_i - \bar{X})(Y_i - \bar{Y})}{\sum\limits_{i=1}^{n} (X_i - \bar{X})^2} \tag{2.18}$$

$$b = \bar{Y} - a\bar{X}$$

gdzie $\bar{X}$ i $\bar{Y}$ są średnimi arytmetycznymi odpowiednio z ciągów $\{X_n\}$ i $\{Y_n\}$.

2.7.2. Doskonalenie modelu diagnostycznego

Celem doskonalenia modeli diagnostycznych, zarówno globalnych jak i lokalnych, jest poprawa jakości ich działania. Wynikiem działania modeli diagnostycznych jest wskazanie jednego lub zbioru stanów diagnozowanego obiektu. Zatem doskonalenie modeli powinno prowadzić do poprawy jakości stawianych diagnoz. Modele można doskonalić przez zmianę:

- struktury modelu (jego postaci),
- rodzaju parametrów modelu i ich wartości,
- liczby i rodzaju cech na wejściu modelu,
- zbioru przykładów uczących (zbiór powinien zawierać dane uczące związane z jak największą liczbą możliwych klas stanów technicznych i warunków działania obiektu).

Ostatnia z wymienionych metod doskonalenia modeli może pośrednio wpływać na strukturę modelu oraz wartości parametrów modelu. Identyfikowanie modeli globalnych jest dużo kosztowniejsze niż identyfikowanie modeli lokalnych. Również doskonalenie modeli globalnych jest trudne i nie zawsze uzasadnione. Powodem jest przeszukiwanie wielowymiarowych przestrzeni, co wiąże się z przeprowadzeniem dużej liczby obliczeń.

Jedną z ciekawszych metod doskonalenia modeli diagnosycznych jest doskonalenie ewolucyjne z zastosowaniem algorytmu przedstawionego na rys. 2.20. Zastosowanie algorytmu ewolucyjnego wymaga określenia [2.1]:

- sposobu kodowania fenotypu w genotypie (sposobu reprezentacji potencjalnych rozwiązań),
- sposobu tworzenia populacji początkowej,
- funkcji oceniającej (funkcji przystosowania),
- sposobu selekcji i sukcesji osobników,
- sposobu prowadzenia operacji genetycznych,
- warunku (warunków) zakończenia działania algorytmu,
- wartości różnych parametrów używanych w algorytmie (rozmiaru populacji, prawdopodobieństwa użycia operatorów genetycznych itp.).

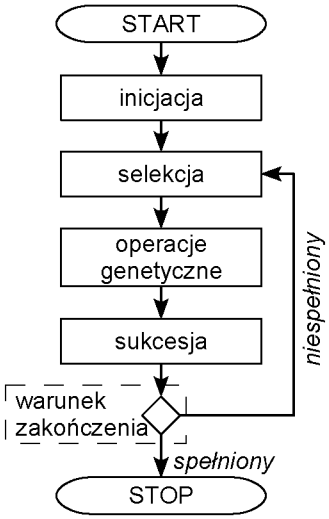

Rys. 2.20: Schemat algorytmu ewolucyjnego

Bardzo ważnym elementem jest funkcja oceniająca, która ma decydujący wpływ na skuteczność działania algorytmu ewolucyjnego. Pomimo jej dużego znaczenia nie ma wytycznych na opracowanie jej postaci. Najczęściej funkcję oceniającą dobiera się indywidualnie na potrzeby rozpatrywanego zadania. Pozostałe elementy można dobrać zgodnie z wytycznymi zawartymi w literaturze (np. [2.1, 2.33]).

W pracach [2.46] i [2.39] pokazano optymalizację zbioru danych uczących z zastosowaniem algorytmu ewolucyjnego. Dla znanych wartości cech sygnałów diagnostycznych i dla znanych klas stanów przyjęto, że jako klasyfikator stanu zostanie użyta sieć neuronalna. Zastosowana sieć neuronalna była jednocześnie funkcją oceniającą osobniki w kolejnych iteracjach (pokoleniach) użytego algorytmu ewolucyjnego. Na potrzeby optymalizacji przyjęto, że:

- genotyp osobnika jest chromosomem zbudowanym z rzeczywistoliczbowego ciągu o długości odpowiadającej liczbie rozpatrywanych cech;
- fenotyp osobnika stanowi rozkład przykładów trenujących w przestrzeni cech relewantnych;
- populacje początkowe są generowane losowo;
- selekcja jest przeprowadzana metodą selekcji proporcjonalnej;
- sukcesja jest przeprowadzana według modelu elitarnego;
- krzyżowanie osobników jest przeprowadzane metodą krzyżowania jednopunktowego;
- wartości parametrów algorytmu są następujące:
  - liczba osobników jest stała i wynosi 30,
  - liczba rozpatrywanych cech jest równa $max\ 7$,
  - liczba pokoleń jest równa 50,
  - współczynnik krzyżowania wynosi 30 [%],
  - współczynnik mutacji wynosi 1 [%].

W wyniku optymalizacji otrzymano zbiory cech relewantnych, czyli cech, które niosą istotne informacje pozwalające na jak najlepsze rozpoznanie stanu technicznego diagnozowanego obiektu.

2.8. Identyfikacja modeli diagnostycznych

Przed przystąpieniem do budowy modelu należy dysponować zbiorami zmiennych procesowych (parametry pracy, sygnały sterujące, inne sygnały wejściowe, sygnały wyjściowe). Zbiory te powinny zostać

zarejestrowane podczas normalnej pracy obiektu lub podczas badań laboratoryjnych. Następnie wyznaczane są zbiory sygnałów diagnostycznych S^{dia} według jednej z metod [2.26]:

1. w wyniku oceny wartości zmiennej procesowej (np. kontrola granic alarmowych);
2. w wyniku wyliczenia i oceny wartości parametru zmiennej procesowej (np. szybkość zmian, średnia);
3. w wyniku kontroli związków jakościowych między zmiennymi procesowymi (np. relacje między wartościami zmiennych, zgodność kierunków zmian);
4. w wyniku wyliczenia i oceny residuum (rys. 2.1).

Zatem, w celu identyfikacji modelu diagnostycznego należy dysponować:

- zbiorem klas warunków działania,
- zbiorem danych uczących zawartym w zbiorze wartości cech sygnałów diagnostycznych,
- zbiorem danych testujących zawartym w zbiorze wartości cech sygnałów diagnostycznych.

Powyżej wymienione zbiory powinny być określone na drodze analizy badanego obiektu lub jego fragmentu, w przypadku identyfikowania modeli lokalnych.

Jeżeli dysponujemy gotowym zbiorem klas stanów Z wówczas nie trzeba przeprowadzać identyfikacji tego zbioru. W przeciwnym razie klasy stanów technicznych można wyznaczyć przeprowadzając na przykład analizę procesów resztkowych towarzyszących badanemu obiektowi. Zastosowanie wiedzy eksperckiej (np. zawartej w poradnikach, normach, zaleceniach itp.) lub wiedzy pozyskiwanej w sposób automatyczny ze zbiorów danych [2.35] pozwala na zdefiniowanie zbioru klas stanów Z. W przypadku metod pozyskiwania wiedzy do poszukiwania takiego zbioru można użyć na przykład metod grupowania [2.44, 2.42, 2.51, 2.47].

Kolejny krok identyfikacji modelu diagnostycznego polega na przeprowadzeniu operacji redukcji liczby cech sygnałów diagnostycznych. Podobnie jak w przypadku tworzenia zbioru klas stanów, tak i tutaj zbiór cech relewantnych można określić z użyciem wiedzy specjalistów lub z użyciem wiedzy pozyskiwanej automatycznie [2.9, 2.5]. W tym celu można użyć metody optymalizacji ewolucyjnej (rys. 2.20) lub poddać zbiór danych uczących analizie wrażliwości. Rozpoczynając analizę wrażliwości należy [2.39]:

- ustalić zbiór stanów technicznych Z i zbiór warunków działania W, które będą brane pod uwagę w analizie wrażliwości;
- określić interesujące, ze względów diagnostycznych, klasy stanu Z^k i klasy warunków działania W^k;
- przyporządkować rozpatrywane stany poszczególnym klasom stanu, a warunki działania danym klasom warunków działania;
- określić zbiór rozpatrywanych cech sygnałów diagnostycznych S_i^{dia} związany z modelem.

Następnie należy użyć jednego z pośród wielu algorytmów [2.40]:

- analiza wariancji;
- metody rangowe (np. nieparametryczny test Kruskala-Wallisa);
- metoda FAST (ang. Fourier Amplitude Sensitivity Test).

Budowę pojedynczego klasyfikatora stanu przeprowadza się na podstawie danych zawartych w:

- zbiorze klas warunków działania,
- zbiorze klas stanów,
- zbiorze cech relewantnych.

Do budowy klasyfikatora stanu można użyć jednej z wielu metod, np.:

- systemu ekspertowego [2.16],
- tablicy decyzyjnej [2.36],
- klasyfikacji i grupowania z użyciem miar odległości,
- sieci neuronalnej [2.29].

Budowa klasyfikatora może być przeprowadzana z nauczycielem lub bez nauczyciela. Najczęściej jest dostępny zbiór przykładów trenujących, w związku z tym budowa klasyfikatora jest przeprowadzana z nauczycielem. Sprawność otrzymanego klasyfikatora ocenia się na podstawie jego weryfikacji z użyciem danych testujących zawartych w zbiorze cech sygnałów diagnostycznych S^{dia}.

W przypadku użycia logiki rozmytej zakłada się, że na wejście identyfikowanego modelu podawane są dane o wartościach ostrych. Wartości tych danych w pierwszym etapie są rozmywane z użyciem zadanej funkcji rozmywania [2.50, 2.26, 2.7]. Rozmyte wartości danych stanowią wejście do systemu wnioskowania rozmytego. Następnie w wyniku działania układu wnioskującego otrzymujemy wektor stanów z przyporządkowanymi wartościami stopni przekonania o wystąpieniu danego stanu.

2.9. Proces diagnozowania

Na rys. 2.2 przedstawiono schemat prowadzenia procesu wnioskowania z wykorzystaniem diagnostyki symptomowej. Jak widać, proces tan składa się z kilku etapów. W kolejnych punktach opisane zostaną szczegóły dotyczące poszczególnych etapów.

2.9.1. Cechy sygnałów, symptomy

Według [2.14] proces wnioskowania diagnostycznego oparty jest o informacje pozyskane w wyniku prowadzenia obserwacji diagnozowanego obiektu. W wyniku prowadzonej obserwacji można uzyskać informacje dotyczące wielkości związanych z działaniem obserwowanego obiektu (np. temperatura pary w turbinie, czy natężenie przepływu pary) lub wielkości fizycznych związanych z procesami resztkowymi, powstającymi w czasie działania obserwowanego obiektu (np. poziom drgań obudowy podpory łożyska ślizgowego w turbozespole). Do opisu nośnika informacji pozyskiwanych z obiektu posługujemy się pojęciem sygnału, a dokładniej sygnału diagnostycznego. Skutecznym sposobem opisu sygnałów diagnostycznych są zbiory wartości cech takich sygnałów, które mogą być efektem przeprowadzonych analiz. Na przykład dla sygnałów rozpatrywanych jako proces stochastyczny, takimi cechami mogą być estymaty sygnału. W celu uporządkowania badań wprowadza się rozróżnienie pomiędzy klasami cech sygnałów oraz ich wartościami. Przykładem klasy cechy diagnostycznej może być *Temperatura czynnika roboczego*, a jego wartością liczba $40°C$. Należy tutaj zwrócić uwagę, że wartości cech mogą należeć do różnych klas. Wartości cech sygnałów diagnostycznych, w ogólnym przypadku, mogą być wartościami punktowymi lub funkcyjnymi. Przykładem wartości punktowych może być *Maksymalna temperatura oleju silnika*, a wartości funkcyjnych *Gęstość rozkładu temperatury*. Zarówno sygnały diagnostyczne, jak również ich cechy rozpatrywane są w różnych dziedzinach np. dziedzinie czasu, częstotliwości czy dziedzinie modalnej. Sygnały będące wynikiem obserwacji badanego obiektu należy w dalszym kroku poddać analizie. Bazą do przeprowadzenia analizy jest przyjęcie odpowiedniego modelu sygnału. Można tutaj wyróżnić [2.14]:

- Uniwersalne modele sygnałów określane w postaci modeli niezależnych od badanego obiektu i obserwowanego sygnału (modele nieparametryczne).
- Modele bazujące na założeniu, że model może być pozyskany z analizowanych danych, bez potrzeby uwzględniania informacji o badanym obiekcie (np. modele autoregresyjne AR, z ruchomą średnią MA lub autoregresyjne z ruchomą średnią ARMA).
- Modele bazujące na założeniu, że model powinien uwzględniać specyficzne skutki wywołane działaniem badanego obiektu.

Szczegółowe metody analizy sygnałów można znaleźć w wielu publikacjach np. [2.6, 2.15, 2.14]. Wynikiem analizy sygnałów są wartości cech sygnałów, które w kolejnym kroku należy poddać działaniu klasyfikatora, którego wynikiem jest otrzymanie symptomów diagnostycznych. Ponieważ zdefiniowanie pojęcia symptom nie jest zadaniem prostym, przyjmuje się, że symptom jest objawem czegoś. W diagnostyce przyjęto, że symptom jest objawem wystąpienia jakiegoś stanu w obserwowanym obiekcie. Ponieważ te same symptomy mogą być objawami różnych stanów, w jakich może znaleźć się diagnozowany obiekt, przyjmuje się, że symptom jest rozumiany jako symptom klasy lub klas stanu. Dla określenia symptomów definiujących daną klasę stanów można przyjąć, że zgodne są chwilowe wartości sygnałów diagnostycznych i odpowiadającego tej klasie wzorca wartości cech sygnałów [2.30].

2.9.2. Detekcja uszkodzeń

Zagadnienia dotyczące detekcji i lokalizacji uszkodzeń są związane bardziej z diagnostyką procesów niż diagnostyką maszyn i urządzeń. Jednakże z uwagi na fakt, że należą one również do diagnostyki symptomowej zostały tutaj opisane. Detekcja uszkodzeń jest procesem, w którym sygnały diagnostyczne są generowane na podstawie zmiennych procesowych. W tym celu stosuje się algorytmy, których zadaniem jest wyodrębnienie z sygnałów diagnostycznych informacji o uszkodzeniach czyli symptomów. Metody detekcji uszkodzeń można podzielić na dwie grupy:

- metody wykorzystujące związki pomiędzy zmiennymi procesowymi,
- metody bazujące na kontroli parametrów zmiennych procesowych.

Pierwsza grupa metod wymaga pozyskania informacji o badanym obiekcie. Informacje takie są reprezentowane w postaci modeli ilościowych lub jakościowych, np. modele analityczne, neuronowe czy rozmyte. Dane te można również uzyskać badając związki pomiędzy zmiennymi procesowymi. Do tej grupy metod można zaliczyć metody w których wykorzystuje się modele obiektów budowane z wykorzystaniem na przykład [2.30]:

- równań fizycznych,
- transmitancji obiektu,
- równań stanu,
- na podstawie obserwatorów stanu,
- identyfikacji on-line,
- modeli neuronowych i rozmytych.

Kolejna grupa metod do wykrywania symptomów uszkodzeń wykorzystuje analizę wyłącznie jednej zmiennej procesowej. Analizując przebieg zmian takiej zmiennej sprawdza się, czy nie zostały przekroczone narzucone wartości graniczne, dopuszczalna szybkość zmian sygnału itp. Prowadzi się również analizę stochastyczną lub spektralną. Celem prowadzenia takich analiz jest uchwycenie zmian zachodzących w sygnale diagnostycznym, które to mogą być symptomami uszkodzeń. Metody stosowane w tej grupie wykorzystują między innymi [2.30]:

- redundancję sprzętową,
- sygnały sprzężeń zwrotnych,
- związki statystyczne pomiędzy zmiennymi procesowymi,
- relacje między zmiennymi procesowymi,
- analizę sygnałów i kontrolę ograniczeń,
- parametry statystyczne sygnałów,
- analizę spektralną.

2.9.3. Lokalizacja uszkodzeń

Na podstawie sygnałów diagnostycznych generowanych przez algorytmy detekcyjne prowadzony jest kolejny krok - lokalizacja uszkodzeń. Lokalizacja uszkodzeń, podobnie jak detekcja uszkodzeń, dotyczy głównie zadań diagnostycznych prowadzonych w diagnostyce procesów. Jej wynikiem jest wskazanie miejsca w obiekcie, gdzie wystąpiło uszkodzenie lub wskazanie stanu obiektu. Aby można było to wykonać konieczna jest znajomość relacji pomiędzy symptomami i stanami obiektu. Ponieważ wiedza na temat obiektów może być niepełna lub niepewna, nie zawsze udaje się jednoznacznie wskazać uszkodzenie. Problemy z tym związane wynikają również z ograniczonej rozróżnialności klas stanów i niepewnością sygnałów diagnostycznych. Istnieje duża różnorodność metod lokalizacji uszkodzeń. W pracy [2.30] wyróżniono między innymi metody:

- w których relacje wynikają ze struktury zastosowanych modeli matematycznych,
- wymagające określenia relacji w fazie uczenia,
- bazujące na wiedzy specjalistów,
- wykorzystujące funkcje logiczne,
- oparte na regułach,
- oparte o sieci neuronowe,
- rozpoznawania obrazów.

Bibliografia

[2.1] Arabas J. *Wykłady z algorytmów ewolucyjnych.* Wydawnictwa Naukowo-Techniczne, Warszawa 2001.

[2.2] Basseville M., Abdelghani M., Beneveniste A. *Subspace-based fault detection algorithms for vibration monitoring*, wolumen 36/1.

[2.3] Bednarski M. *Metody doskonalenia sieci bayesowskich stosowanych w diagnostycznych systemach doradczych.* Zeszyt 131. Katedra Podstaw Konstrukcji Maszyn Politechniki Śląskiej, Gliwice, 2006.

[2.4] Cempel Cz. *Podstawy wibroakustycznej diagnostyki maszyn.* WNT, Warszawa, 1982.

[2.5] Cempel Cz. *Diagnostyka wibroakustyczna maszyn.* PWN, Warszawa, 1989.

[2.6] Cempel Cz., Tomaszewski F., redaktorzy. *Diagnostyka maszyn. Zasady ogólne. Przykłady zastosowań.* Międzyresortowe Centrum Naukowe Eksploatacji Majątku Trwałego, Radom, 1992.

[2.7] Cholewa W. *Metoda diagnozowania maszyn z zastosowaniem zbiorów rozmytych.* Mechanika. Zeszyty Naukowe Politechniki Śląskiej. Zeszyt 79. Wydawnictwo Politechniki Śląskiej, Gliwice, 1983.

[2.8] Cholewa W. Diagnostyczne modele obiektów. Kiciński J., redaktor, *Modelowanie i diagnostyka oddziaływań mechanicznych, i magnetycznych w turbozespołach energetycznych*, strony 27–52, Gdańsk, 2005. Wydawnictwo IMP PAN.

[2.9] Cholewa W. Relewantne cechy sygnałów. Kiciński J., redaktor, *Modelowanie i diagnostyka oddziaływań mechanicznych, i magnetycznych w turbozespołach energetycznych*, strona 1261–1296, Gdańsk, 2005. Wydawnictwo IMP PAN. r. 26.

[2.10] Cholewa W., Kaźmierczak J. *Diagnostyka techniczna maszyn. Przetwarzanie cech sygnałów.* Skrypt uczelniany 1904. Wydawnictwo Politechniki Śląskiej, Gliwice 1995.

[2.11] Cholewa W., Kaźmierczak J. *Data Processing and Reasoning in Technical Diagnostics.* WNT, Warszawa 1995.

[2.12] Cholewa W., Kiciński J. *Odwrotne modele diagnostyczne.* Wydawnictwo Politechniki Śląskiej, Gliwice, 1997.

[2.13] Cholewa W., Kiciński J. *Diagnostyka techniczna. Metody odwracania nieliniowych modeli obiektów.* Mechanika. Zeszyty Naukowe Politechniki Śląskiej. Zeszyt 120. Wydawnictwo Politechniki Śląskiej, Gliwice 2001.

[2.14] Cholewa W., Korbicz J., Moczulski W., Timofiejczuk A. Metody analizy sygnałów. Korbicz J., Kościelny J. M., Kowalczuk Z., Cholewa W., redaktorzy, *Diagnostyka procesów. Modele, metody sztucznej inteligencji, zastosowania*, strony 115–146. WNT, Warszawa 2002.

[2.15] Cholewa W., Moczulski W. *Diagnostyka techniczna maszyn. Pomiary i analiza sygnałów.* Skrypt uczelniany 1758. Politechnika Śląska, 1993.

[2.16] Cholewa W., Pedrycz W. *Systemy doradcze.* Skrypt uczelniany 1447. Wydawnictwo Politechniki Śląskiej, Gliwice 1987.

[2.17] Cholewa W., White M.F. *Application of neural networks for inversing of vibration models.* Mechanika. Zeszyty Naukowe Politechniki Śląskiej. Zeszyt 116. Wydawnictwo Politechniki Śląskiej, Gliwice, 1994.

[2.18] Evans G. W., Wallace G. F., Sutherland G. L. *Symulacja na maszynach cyfrowych.* WNT, Warszawa 1973.

[2.19] Frisk E. *Model-based fault diagnosis applied to an SI-Engine.* Praca doktorska, Examensarbete utfört i Fordonssystem vid Tekniska Högskolan i Linköping, Linköping, 1996.

[2.20] Isermann R. Model-based fault detection and diagnosis. Status and applications. *IFAC Committee SAFEPROCESS*, 2004.

[2.21] Isermann R. Model-based fault detection and diagnosis. Status and applications. *Annual Reviews in Control, vol. 29*, strony 71–85, 2005.

[2.22] Isermann R., Ballé P. Terminology in the field of supervision, fault detection and diagnosis. *IFAC Committee SAFEPROCESS*, 1996.

[2.23] Kiciński J., redaktor. *Modelowanie i diagnostyka oddziaływań mechanicznych, i magnetycznych w turbozespołach energetycznych*, Gdańsk, 2005. Wydawnictwo IMP PAN.

[2.24] Kiciński J. Symptomy diagnostyczne turbozespołów energetycznych określone metodą komputerowej i analogowej symulacji ich defektów. *Mat. Ogólnopolskiego Seminarium Wibrodiagnostyka turbozespołów energetycznych*, strony 51–92, Gdańsk 1994.

[2.25] Klimek A. *Metody doskonalenia odwrotnych modeli diagnostycznych.* Mechanika. Zeszyty Naukowe Politechniki Śląskiej. Zeszyt 134. Wydawnictwo Politechniki Śląskiej, Gliwice 1999.

[2.26] Kościelny J. M. *Diagnostyka zautomatyzowanych procesów przemysłowych.* Akademicka Oficyna Wydawnicza EXIT, Warszawa 2001.

[2.27] Kościelny J. M. Modele w diagnostyce procesów. Korbicz J., Kościelny J. M., Kowalczuk Z., Cholewa W., redaktorzy, *Diagnostyka procesów. Modele, metody sztucznej inteligencji, zastosowania*, strony 29–56. WNT, Warszawa 2002.

[2.28] Kościelny J. M., Syfert M. Current diagnostics of power boiler system with use of fuzzy logic. *Proc. 4th IFAC Symp. Fault Detection, Supervision and Safety for Technical Process. SAFEPROCESS 2000*, 2:681–686, 2000.

[2.29] Korbicz J. Sztuczne sieci neuronowe i ich zastosowanie w diagnostyce procesów przemysłowych. *Pomiary Automatyka Kontrola*, 4:129–133, 1998.

[2.30] Korbicz J., Kościelny J. M., Kowalczuk Z., Cholewa W., redaktorzy. *Diagnostyka procesów. Modele, metody sztucznej inteligencji, zastosowania.* WNT, Warszawa 2002.

[2.31] Leray P., Francois O. BNT Structure Learning Package: Documentation and Experiments. Laboratoire PSI - INSA Rouen- FRE CNRS 2645, BP 08 - Av. de l'Université, 76801 St-Etienne du Rouvray Cedex, 15th November 2004.

[2.32] Martin F. F. *Wstęp do modelowania cyfrowego.* PWN, Warszawa 1970.

[2.33] Michalewicz Z. *Algorytmy genetyczne + struktury danych = programy ewolucyjne.* WNT, Warszawa, 1999.

[2.34] Moczulski W. Knowledge discovery in diagnostic databases. *Proc 2nd Symp. Methods of Artificial Intelligence in Mechanics and Mechanical Engineering, AI-Mech, Gliwice*, 2:149–154, 2001.

[2.35] Moczulski W. *Metody pozyskiwania wiedzy dla potrzeb diagnostyki maszyn.* Mechanika. Zeszyty naukowe Politechniki Śląskiej. Zeszyt 130. Wydawnictwo Politechniki Śląskiej, Gliwice 1997.

[2.36] Pollack S. L., Hicks H. T. Jr, Harrison W. J. *Tablice decyzyjne.* PWN, Warszawa 1975.

[2.37] Psiuk K. *Obiektowe modele procesu propagacji stanów w układach maszyn.* Zeszyt 119. Katedra Podstaw Konstrukcji Maszyn Politechniki Śląskiej, Gliwice 2001.

[2.38] Radkowski S. *Wibroakustyczna diagnostyka uszkodzeń niskoenergetycznych.* Biblioteka Problemów Eksploatacji. Warszawa-Radom, 2002.

[2.39] Rzydzik S. *Identyfikacja stanu w układach rozproszonych.* Zeszyt 135. Katedra Podstaw Konstrukcji Maszyn Politechniki Śląskiej, Gliwice, 2007.

[2.40] Sławik D. *Metody badania wrażliwości cech sygnałów diagnostycznych.* Zeszyt 126. Katedra Podstaw Konstrukcji Maszyn Politechniki Śląskiej, 2006.

[2.41] Schwall M. L., Gerdes J. C., Bäker B., Forchert T. A probabilistic vehicle diagnostic system using multiple models. 2003.

[2.42] Sobczak W., Malina W. *Metody selekcji i redukcji informacji.* WNT, Warszawa, 1985.

[2.43] Sreedharan P., Haves P. Comparison of chiller models for use in model-based fault detection. *International Conference for Enhanced Building Operations, Austin, July 17*, 2001.

[2.44] Tadeusiewicz R., Flasiński M. *Rozpoznawanie obrazów.* Współczesna nauka i technika. Informatyka. Wydawnictwo naukowe PWN, Warszawa, 1991.

[2.45] Uhl T. Zastosowanie analizy modalnej w diagnostyce. *Diagnostyka t. 10*, strony 24–32.

[2.46] Urbanek G. *Zastosowanie algorytmów ewolucyjnych w identyfikacji odwrotnych modeli diagnostycznych.* Zeszyt 132. Katedra Podstaw Konstrukcji Maszyn Politechniki Śląskiej, Gliwice, 2006.

[2.47] Urbanek G. Grupowanie, klasyfikacja, selekcja. `http://https://kpkm.polsl.pl/PROJEKTY/Klas/`, 2007.

[2.48] Wojtusik J. *Wielomodele diagnostyczne maszyn wirnikowych.* Zeszyt 128. Katedra Podstaw Konstrukcji Maszyn Politechniki Śląskiej, Gliwice, 2006.

[2.49] Wydawnictwo Naukowe PWN. *Encyklopedia Popularna.* PWN, Warszawa 1992.

[2.50] Zadeh L. A. Fuzzy sets. *Information and Control*, 8 (3):338–353, 1965.

[2.51] Zahn C. T. Graph-theoretical methods for detecting and describing gestalt clusters. *IEEE Transactions on Computers*, 1:68–86, 1971.

[2.52] Żółtowski B. *Podstawy diagnostyki maszyn.* Wydawnictwo Uczelniane ATR, Bydgoszcz, 1996.

[2.53] Żółtowski B., Ćwik Z. *Leksykon diagnostyki technicznej.* Wydawnictwo Uczelniane Akademii Techniczno-Rolniczej, Bydgoszcz, 1996.