

Henryk BOROWCZYK, Jarosław SPYCHAŁA
 Air Force Institute of Technology (Instytut Techniczny Wojsk Lotniczych)

ON DESIGNING AN EXPERT DIAGNOSTIC SYSTEM OF THE AIRCRAFT TURBINE ENGINE FUNCTIONAL UNITS

Projektowanie ekspertowego systemu diagnostycznego zespołów funkcjonalnych lotniczego silnika turbinowego

Abstract: *The paper presents issues related to the design of an expert diagnostic system of turbine engine functional units. Dedicated diagnostic stations and on-board flight data recorders are the sources of diagnostic signals. The signals were parameterized or identified dynamic models to get a compact representation in the form of a set of parameters. The set of diagnostic parameters was subjected to integer encoding. On this basis, a multi-valued diagnostic model describing the relationship between the set of faults and the set of symptoms (code values of diagnostic parameters) was determined. The proposed approach can be used in the design of expert diagnostic systems for propulsion units of any aircraft.*

Keywords: turbine engine, signal parameterization, multi-valued diagnostic model, diagnostic expert system

Streszczenie: *W pracy przedstawiono zagadnienia związane z projektowaniem ekspertowego systemu diagnostycznego funkcjonalnych zespołów lotniczego silnika turbinowego. Sygnały z dedykowanych stanowisk diagnostycznych oraz pokładowych rejestratorów parametrów lotu poddano parametryzacji oraz identyfikacji modeli dynamicznych w celu uzyskania kompaktowej reprezentacji – zbioru parametrów. Zbiór taki poddano kodowaniu całkowito-liczbowemu. Wyznaczono wielowartościowy model diagnostyczny opisujący relacje między zbiorem uszkodzeń i zbiorem symptomów (kodowych wartości parametrów diagnostycznych). Zaproponowane podejście może być stosowane w projektowaniu ekspertowych systemów diagnostycznych zespołów napędowych dowolnego typu statków powietrznych – bezałogowych i załogowych.*

Słowa kluczowe: silnik turbinowy, parametryzacja sygnałów, wielowartościowy model diagnostyczny, ekspertowy system diagnostyczny

1. Introduction

The turbine engines are complex, multi-range and multidimensional control objects, which implies the complexity of their control systems [8, 12, 15]. The turbine engine control system consists of a control object (an engine: an inlet, a compressor, a combustion chamber, a turbine, an afterburner, and an outlet nozzle) and a set of analogue and discrete regulators with varying degrees of autonomy.

The operation process of the control system is divided into the following ranges:

- start-up - a transition from null to idle speed,
- ranges fixed between the idling speed and the maximum permissible speed,
- transition ranges - acceleration and deceleration of speed,
- working range with afterburner.

Due to the changing properties of the object, appropriate sets of controllers are used in each range - the control system changes its structure and parameters.

Diagnosis of this class of objects requires the use of computer support in the form of expert diagnostic systems whose main component is the knowledge base [5, 7, 9, 10, 17]. The knowledge base contains formalised, structured information about the object being diagnosed [5, 6, 14]. Knowledge is obtained as a result of active and passive experiments carried out on the real object, studies on simulation models and expert knowledge queries [11, 12, 16, 18, 19].

The actual control system of the turbine engine was the subject of active and passive diagnostic experiments carried out at the Air Force Institute of Technology [4]. The active experiments consisted of introducing simulated functional element failures and studying the time course of diagnostic signals. The set of simulated damages was determined on the basis of previous reliability tests and analysis of operating principles, assuming that the introduced damages do not pose a threat to the safety of the engine, aircraft and research team.

Before entering the expert diagnostic system, expert knowledge must be properly prepared (formalised) and saved in a form accepted by the used inference engine [5, 6, 12, 13]. The design of the expert diagnostic system was developed based on the PC-Shell system [12]. It is a domain-independent, expert shell system with hybrid properties. Thanks to the array architecture, the knowledge base can be divided into any number of heterogeneous sources of knowledge. This allows decomposition of a complex object into subsystems and relatively independent development of diagnostic inference modules for individual subsystems.

2. Diagnostic experiment

The following experiments can be discriminated in the diagnostics of complex technical objects [1]:

- primary research - determining the value of symptoms $d_r \in D$, $r = 1, 2, \dots, t$ for known conditions (faults) $e_i \in E$, $i = 1, 2, \dots, n$ of the object. It allows building a diagnostic model - relations between conditions and symptoms,
- operational - determining the current values of symptoms and then the current condition of the object using the diagnostic model,
- complex - combines the features of an operational and research experiment.

An operational diagnosing method determined by the constructor/manufacturer of the engine is described in the standard test procedure [4, 11]. Test schedule results from the sequence of switching dynamic subsystems at individual operation range - from start-up to full power. The change of the test range is possible after getting positive results of the previous study.

Research experiments should consider the above limitations and provide detailed information on the engine, including non-standard ranges. It allows the standardisation of the diagnostic data analysis

A research experiment comprises introducing real or simulated faults of elements and examining temporary waveforms of diagnostic signals.

In diagnostics, two fault classes are considered:

- discrete fault - works / does not work (1/0),
- continuous fault - parameters of elements are inconsistent with the values specified in the technical guide - above or below the norm.

The set of faults is determined based on reliability tests and the analysis of the functioning principles. The introduced faults do not pose a threat to the safety and the research team.

3. Formalisation of diagnostic knowledge

Diagnostic tests produce sets of signals that must be processed into a form that enables effective diagnostic inference. In the first stage, signals of various physical nature are transformed into a dimensionless form [5, 11]:

$$\bar{y}(t) = \frac{y(t)}{y_{odn}} \quad (1)$$

where: $y(t)$ - the measured value of the physical signal, y_{odn} - the reference value

Reference values determined during the construction [5, 11] or the maximum absolute values of signals observed in operation can be used. In the second case, non-dimensional signal values $[-1, 1]$ (when the physical signal takes both positive and negative values) or $[0, 1]$ - when the physical signal accepts only positive values are got.

The next step is the parametrization of signals - replacing the time series with a set of parameters describing the waveforms with accuracy enough for diagnosis. The operation is carried out in a fixed time-event frame, at a specific starting event and/or the initial moment, and the final event and/or the final moment.

For continuous signals, one of the following methods can be used:

- sparse sampling of the signal representative values from the entire course of the signal [5],
- methods for identifying dynamic models - a set of parameters of the model that map the signal waveform is used for further analyses [3].

With discrete signals, the parametrization most often comprises determining the moments of time (relative to the start of the observation frame), in which the signal's value changes.

Parameterization of continuous signals with the sparse sampling method

Sparse sampling of the continuous signal consists in replacing the time course with a finite set of characteristic signal values and/or characteristic moments of time - fig. 1 [5].

The method of sparse sampling and quantisation of time courses of continuous diagnostic signals, three approaches are possible (used jointly or separately) [1]:

- a fixed set of moments characteristic for the time course of the signal and determining the value of the signal at these moments (e.g. beginning of observation - $[t_0, n(t_0)]$),
- a set of characteristic signal values and determining the time of their achievement (e.g. - $[n = 0,8, t(n = 0,8)]$),
- a set of events on the signal waveform (e.g. reaching the maximum value) and determining the time of event occurrence and signal value $[n_{\max}, t(n_{\max})]$.




Fig. 1. Scheme of the sparse sampling and quantization of the speed signal in the acceleration process [5]

The selection process of sampling moments and the number of quantisation levels depends on the considered waveforms and is carried out with the use of expert knowledge on the engine functioning principles.

After sparse sampling and/or quantisation, for each signal, a set of pairs $[t_i, y_{ji}]$ is got, where: t_i - time, y_{ji} - the value of the signal y_j at the time t_i . They make up the basis for developing the knowledge base of the expert diagnostic system.

Parameterization of a continuous signal by the dynamic model identification

The purpose of identification is to build a mathematical model that, with the required accuracy, maps the dynamic properties of the tested engine. It comprises determining unknown parameters of the model based on measured output and input signals. Examples of dynamic models are autoregressive AR models of time series written in the form of:

$$y(t) = a_1 y(t-1) + a_2 y(t-2) + \dots + a_{na} y(t-n_a) \tag{2}$$

where: n_a - model order.

Signals used in diagnostics of dynamic objects can be treated, in the first approximation, like time series, and model parameters (2) as carriers of information about the state of the diagnosed object [3].

In this case, separate identification of each of the selected signals is carried out, in a specific time-event frame.

For fault e_i and signal y_j , the representation is obtained in the form of a parameter vector of the identification model

$$(e_i, y_j) \rightarrow [a_{j1}^i, a_{j2}^i, \dots, a_{jna_j}^i] \tag{3}$$

while for the whole fault collection $E = \{e_i\}$, $i = 1, 2, \dots, n$ - the matrix:

$$(E, y_j) \rightarrow \begin{bmatrix} a_{j1}^1, a_{j2}^1, \dots, a_{jna_j}^1 \\ \dots \\ a_{j1}^i, a_{j2}^i, \dots, a_{jna_j}^i \\ \dots \\ a_{j1}^n, a_{j2}^n, \dots, a_{jna_j}^n \end{bmatrix} \tag{4}$$

For the sake of simplifying the further analysis, it is convenient to determine the representation (4) of a specific signal y_j using models of the same order. Models of different signals may be of different orders .

4. Multivalued diagnostic - decision model

The finite set of diagnostic parameters results from signals parametrization. Parameters are real numbers, differing in sign and absolute values. It is therefore advisable to normalise the parameters to the range $[-1,1]$ using the following relationship:

$$a'_i = \frac{a_i}{a_{i\max}}; \quad a_{i\max} = \max_{j=1,\dots,n} |a_i(e_j)| \quad (5)$$

where:

n – number of faults;

e_j – j -th fault.

As a result, new data sets of normalised scalar quantities are got.

For the inference, the exact values of parameters are less important than the respective ranges interpretable in the set of technical conditions [1, 4].

The ranges of the variability of diagnostic parameters should be separated into intervals in the way ensuring the highest faults isolation and keeping down the number of incorrect diagnoses. Integer-valued coding consists in assigning one signed integer number to a specified real numbers interval [1, 2]. The principle of coding can be the same for parameters or set individually for each of them.

The parameter x may be represented by the code value X_C , the general coding principle gets the form (6).

The code 0 is assigned to the range (x_{1-}, x_1) of nominal values of the parameter. It should be noted that the number of ranges/codes below and above the nominal range (K_-, K) may differ.

$$X_c = \begin{cases} k-1 & \text{for } x \in [x_{k-1}, x_k), k \leq K \\ \dots \\ 1 & \text{for } x \in [x_1, x_2) \\ 0 & \text{for } x \in (x_{1-}, x_1) \\ -1 & \text{for } x \in (x_{2-}, x_{1-}] \\ \dots \\ -(k_- - 1) & \text{for } x \in (x_{k-}, x_{(k_- - 1)}], k_- \leq K_- \end{cases} \quad (6)$$

where: $\dots < x_{k-} < \dots < x_{1-} < x_1 \dots < x_k < \dots$

Determining thresholds $x_k, k=1,2,\dots,K$ and $x_{k-}, k_-=1,2,\dots,K_-$ is a formal problem of data clustering or heuristic. A heuristic approach uses expert knowledge and requires no large set of statistical data. After gathering the appropriate experimental material, the initially determined thresholds are periodically updated using formal methods [2, 5, 6].

With a research experiment, where the engine's condition is known, the analysis should start with determining the range of nominal values of the considered parameters [4]. Subsequent thresholds are set at the points of significant changes in the values of parameters. After parameter coding, a multi-valued diagnostic model describing the relationship between the set of faults and the set of symptoms is got.

Table 1

Generalized diagnostic model - acceleration

fault	psp1	psp2	psp3	psp4
"U0"	Xc_0_1	Xc_0_2	Xc_0_3	Xc_0_4
"U1"	Xc_1_1	Xc_1_2	Xc_1_3	Xc_1_4
"U2"	Xc_2_1	Xc_2_2	Xc_2_3	Xc_2_4
"U3"	Xc_3_1	Xc_3_2	Xc_3_3	Xc_3_4
"U4"	Xc_4_1	Xc_4_2	Xc_4_3	Xc_4_4
"U5"	Xc_5_1	Xc_5_2	Xc_5_3	Xc_5_4
...

This form of the model is convenient for further analyses, aimed at determining the optimal set of symptoms ensuring faults isolation with assumed accuracy [2], and then a set of inference rules in the expert diagnostic system [5, 7, 10, 12].

5. Structure of the expert diagnostic system

Expert diagnostic system ESD_Engine was developed using the PC Shell software [12]. It enables a combination of a rule representation of knowledge and procedural programming.

The ESD_Engine application consists of one knowledge base main module saved in the file named ESD_Engine.bw and four knowledge source files:

- startup.zw;
- acceleration.zw;
- afterburner.zw;
- compressor.zw.

The main module contains a declaration of knowledge sources and a control block, which manages the retrieval of diagnostic data and starts the inference process.

Diagnostic data - results of the current diagnostic test of functional systems made on the ranges: start-up, acceleration/deceleration, afterburning and geometry control - are stored in an Excel file called ESD_Engine_Data.xls. Data are downloaded by an expert system using a dynamic data exchange mechanism (DDE).

The knowledge source files: startup.zw, acceleration.zw, afterburner.zw, compressor.zw contain the declaration of attributes used in the knowledge base and a set of diagnostic inference rules.

The facts database is created based on the results of diagnostic tests. In the first stage, the names of attributes are placed in the source of knowledge in the facets block.

Attributes are described by a facet `val_oneof` or `val_someof` that declare an allowed set of attribute values. The `val_oneof` means that the attribute database can only appear once in the knowledge base, while the `val_someof` enables the multiple occurrences of the attribute.

Assigning a value to the attribute creates a new fact that is entered the knowledge base:

```
addFact( _, psp1, Psp1);
```

In the designed knowledge base, facts are added during the program execution from the control block in the main module. The rule comprises a conclusion and a conditional part separated by an `if` word. Premises in the conditional part relate to the Boolean operators AND, OR. Blocks of rules are placed in the sources of knowledge start-up, acceleration, afterburner and compressor.

The rules are properly numbered – table 2:

Table 2

Inference rules - acceleration

1000: faultAcceleration = "U0" if psp1== Xc_0_1 & psp2 == Xc_0_2 & psp3 == Xc_0_3 & psp4 == Xc_0_4;
1001: faultAcceleration = "U1" if psp1== Xc_1_1 & psp2 == Xc_1_2 & psp3 == Xc_1_3 & psp4 == Xc_1_4;
1002: faultAcceleration = "U2" if psp1== Xc_2_1 & psp2 == Xc_2_2 & psp3 == Xc_2_3 & psp4 == Xc_2_4;
1003: faultAcceleration = "U3" if psp1== Xc_3_1 & psp2 == Xc_3_2 & psp3 == Xc_3_3 & psp4 == Xc_3_4;
1004: faultAcceleration = "U4" if psp1== Xc_4_1 & psp2 == Xc_4_2 & psp3 == Xc_4_3 & psp4 == Xc_4_4;
1005: faultAcceleration = "U5" if psp1== Xc_5_1 & psp2 == Xc_5_2 & psp3 == Xc_5_3 & psp4 == Xc_5_4;
...

Based on the set of rules an inference algorithm is created by an expert system - the order of searching matches the order in the list of rules.

The change of this algorithm is possible by changing the rules order, which may be important with increasing the number of rules as the knowledge increases.

6. Summary

The paper presents issues related to the design of an expert diagnostic system of the main functional units of the aircraft turbine engines.

The proposed expert diagnostic system ESD-Engine can use various sources of diagnostic data:

- dedicated diagnostic stations;
- on-board flight data recorders.

Diagnostic stations and on-board recorders provide dynamic records of binary and analogue signals. In the first stage of the analysis, it was proposed to reduce the entries to a uniform. The parametrization of diagnostic signals results in a finite set of parameters containing information to faults isolation. After parameters coding for considered faults, a multi-valued diagnostic model (a generalisation of binary models) describing the relationship between the set of faults and the set of symptoms (code values of diagnostic parameters) is got. Such a form of the model is convenient for further analyses, aimed at determining the optimal set of symptoms ensuring faults isolation with the assumed accuracy [2], and then a set of inference rules in the expert diagnostic system.

The applied formalism allows to present diagnostic knowledge for any range of a turbine engine operation in the form of two modules: a multi-valued diagnostic model and

a set of inference rules. The set of inference rules is implemented in the shell expert system, e.g. PC Shell [12].

The proposed approach can be used in the design of expert diagnostic systems for propulsion units of any aircraft - unmanned and crewed.

7. References

1. Borowczyk H. (red.): Problemy kompleksowego diagnozowania układu łożyskowania turbinowego silnika śmigłowego. Wydawnictwo Instytutu Technicznego Wojsk Lotniczych, Warszawa 2011.
2. Borowczyk H.: Quasi-informacyjna metoda wyznaczania programu diagnozowania złożonych obiektów technicznych. Mechanical Engineering. WAT, Warszawa 1984.
3. Borowczyk H.: Zastosowanie metody identyfikacji modelu matematycznego oraz wielowartościowego kodowania w procesie tworzenia diagnostycznego modelu układu sterowania. Prace Naukowe ITWL, No. 18, 2004.
4. Borowczyk H., Kącki C., Kobański A.: Technologia identyfikacji uszkodzeń turbinowych silników odrzutowych typu 89 przy pomocy stanowiska diagnostycznego KAPSO-17MK, ITWL, Warszawa 1991.
5. Borowczyk H., Lindstedt P.: Formalizacja wiedzy eksperckiej w diagnostyce systemów sterowania lotniczych silników turbinowych. Diagnostyka procesów i systemów, J. Korbicz, K. Patan, M. Kowal, Warszawa 2007.
6. Borowczyk H., Zboiński M., Formalizacja wiedzy w diagnostyce tribologicznej układu łożyskowania. Problemy Eksploatacji, 2011.
7. Cholewa W.: Wspomaganie procesu wnioskowania w diagnostyce technicznej. V Krajowa Konferencja Diag'2003, WAT, Warszawa 2003.
8. Guasch A., Quevedo J., Milne R.: Fault diagnosis for gas turbines based on the control system. Engineering Applications of Artificial Intelligence, No. 13, 2000.
9. Knosala R.: Zastosowanie metod sztucznej inteligencji w inżynierii produkcji. WNT, Warszawa 2002.
10. Korbicz J. et al.: Diagnostyka procesów. Modele. Metody sztucznej inteligencji. Zastosowania. WNT, Warszawa 2002.
11. Lindstedt P.: Praktyczna diagnostyka maszyn i jej teoretyczne podstawy. Warszawa 2002.
12. Michalik K.: PC SHELL 4.5 Szkieletowy system ekspertowy. AITECH (Artificial Intelligence Laboratory). Katowice 2006.
13. Mulawka J.J.: Systemy ekspertowe. WNT, Warszawa 1997.
14. Pawlak M.: Systemy ekspertowe w eksploatacji maszyn. Lublin 1996.
15. Volponi A.J., Gas Turbine Engine Health Management: Past, Present, and Future Trends. Journal of Engineering for Gas Turbines and Power, 2014. 136.10.1115/1.4026126

16. Witoś M. et al.: Structural health monitoring of aero-engines in non-stationary operations. *Applied Condition Monitoring*, Springer 2018. DOI 10.1007/978-3-319-61927-9_1.
17. Witoś M. et al.: Expert SHM and CM of Turbojet Engine FCU Using Instantaneous Angular Speed Signal. *Advances in Condition Monitoring of Machinery in Non-Stationary Operations*. Cham: Springer International Publishing, 2019.
18. Żokowski M., Spychała J., Majewski P.: Detection Damage in Bearing System of Jet Engine Using the Vibroacoustic Method. *Acta Mechanica et Automatica*, No. 11(3), 2017.
19. Żokowski M. et al.: Structure Health Monitoring of Aircraft Power Unit Using Vibration Signal. *Condition Monitoring of Machinery in Non-stationary Operations*. Cham: Springer International Publishing, 2019.

PROJEKTOWANIE EKSPERTOWEGO SYSTEMU DIAGNOSTYCZNEGO ZESPOŁÓW FUNKCJONALNYCH LOTNICZEGO SILNIKA TURBINOWEGO

1. Wprowadzenie

Lotnicze silniki turbinowe są złożonymi, wielozakresowymi i wielowymiarowymi obiektami sterowania, co implikuje złożoność ich systemów sterowania [8, 12, 15]. System sterowania tworzą: obiekt sterowania oraz zestaw analogowych i dyskretnych regulatorów o różnym stopniu autonomiczności. Proces funkcjonowania systemu sterowania dzieli się na następujące zakresy:

- rozruch – przejście ze stanu spoczynku do prędkości obrotowej biegu jałowego,
- zakresy ustalone między prędkością obrotową biegu jałowego a maksymalną,
- zakresy przejściowe – przyspieszanie i zmniejszanie prędkości obrotowej,
- zakres pracy z dopalaczem.

Ze względu na zmieniające się właściwości obiektu, w każdym zakresie wykorzystywane są odpowiednie zestawy regulatorów – system sterowania zmienia swoją strukturę i parametry. Diagnostowanie tej klasy obiektów wymaga zastosowania komputerowego wspomaganie w postaci ekspertowych systemów diagnostycznych, których głównym składnikiem jest baza wiedzy [5, 7, 9, 10, 17]. Baza wiedzy zawiera sformalizowane, ustrukturalizowane informacje o diagnozowanym obiekcie [5, 14]. Wiedza pozyskiwana jest w wyniku czynnych i biernych eksperymentów przeprowadzanych na obiekcie rzeczywistym, badań na modelach symulacyjnych oraz kwerendy wiedzy ekspertów [11, 12, 16, 18, 19]. Rzeczywisty system sterowania lotniczego silnika turbinowego był przedmiotem czynnych i biernych eksperymentów diagnostycznych przeprowadzanych w ITWL [4]. Eksperymenty czynne polegały na wprowadzaniu symulowanych uszkodzeń elementów funkcjonalnych i badaniu czasowych przebiegów sygnałów diagnostycznych. Zbiór uszkodzeń określono na podstawie wcześniejszych badań niezawodnościowych oraz analizy zasad funkcjonowania systemu.

Uzyskana wiedza ekspercka musi zostać odpowiednio przygotowana (sformalizowana) i zapisana w postaci akceptowanej przez wykorzystywany aparat wnioskowania [5, 12, 13]. Projekt ekspertowego systemu diagnostycznego opracowano w oparciu o system PC-Shell [12]. Jest to dziedzicznie niezależny, szkieletowy system ekspertowy o właściwościach hybrydowych. Dzięki zastosowaniu architektury tablicowej, bazę wiedzy

można podzielić na dowolną liczbę heterogenicznych źródeł wiedzy. Umożliwia to dekompozycję złożonego obiektu na podukłady i względnie niezależny rozwój modułów wniosowania diagnostycznego dla poszczególnych podukładów.

2. Eksperyment diagnostyczny

W diagnostyce złożonych obiektów technicznych można wyróżnić następujące rodzaje eksperymentów [1]:

- badawczy – określenie wartości symptomów $d_r \in D$, $r = 1, 2, \dots, t$ dla znanych stanów obiektu $e_i \in E$, $i = 1, 2, \dots, n$, co umożliwi zbudowanie modelu diagnostycznego – relacji między stanami a symptomami,
- operacyjny – określenie bieżących wartości symptomów, a następnie ustalenie aktualnego stanu obiektu z wykorzystaniem modelu diagnostycznego,
- zespolony – łączy cechy eksperymentu operacyjnego i badawczego.

Metodyka diagnozowania operacyjnego w obszarze procesów funkcjonowania ustalana jest zazwyczaj przez konstruktora/producenta obiektu i opisana w formie standardowej próby kontrolnej [4, 11]. Harmonogram próby wynika z kolejności włączania układów dynamicznych na poszczególnych zakresach pracy – od rozruchu do pełnego ciągu/mocy. Zmiana zakresu pracy, w którym odbywa się diagnozowanie, możliwa jest po uzyskaniu pozytywnych rezultatów badań poprzedzających. Eksperyment badawczy powinien uwzględniać powyższe uwarunkowania, a jednocześnie dostarczać szczegółowej informacji o funkcjonowaniu obiektu, w tym na zakresach niestandardowych. Umożliwia to ujednoczenie procesu analizy wyników badań diagnostycznych uzyskanych dla obiektu zdatnego i z uszkodzeniami.

W diagnostyce funkcjonalnej rozpatrywane są dwie klasy uszkodzeń:

- uszkodzenia dyskretnie – działa/ nie działa (1/0),
- uszkodzenia ciągłe – parametry elementów funkcjonalnych są niezgodne z wartościami określonymi w warunkach technicznych eksploatacji – powyżej lub poniżej normy.

Eksperyment badawczy (czynny) na obiekcie rzeczywistym polega na wprowadzaniu rzeczywistych lub symulowanych uszkodzeń elementów funkcjonalnych i badaniu czasowych przebiegów sygnałów diagnostycznych.

3. Formalizacja wiedzy diagnostycznej

Wynikiem badań diagnostycznych są zbiory sygnałów, które muszą być przetworzone do postaci umożliwiającej skuteczne wniosowanie diagnostyczne.

W pierwszym etapie sygnały różnej natury fizycznej sprowadza się do postaci bezwymiarowej [5, 11]:

$$\bar{y}(t) = \frac{y(t)}{y_{odn}} \quad (1)$$

gdzie: $y(t)$ – zmierzona wartość sygnału fizycznego, y_{odn} – wartość odniesienia.

Jako wartości odniesienia można przyjmować wartości obliczeniowe (określane podczas konstruowania układu) [5, 11] lub maksymalne bezwzględne wartości sygnałów obserwowane podczas eksploatacji. W drugim przypadku uzyskuje się sygnały bezwymiarowe o wartościach z przedziału $[-1,1]$ (gdy sygnał fizyczny przyjmuje wartości zarówno dodatnie jak i ujemne) lub $[0,1]$ – gdy sygnał fizyczny przyjmuje wyłącznie dodatnie wartości.

Kolejnym krokiem jest parametryzacja sygnałów – zastąpienie przebiegów czasowych zbiorem parametrów opisujących przebiegi z wystarczającą dla diagnostyki dokładnością. Operacja przeprowadzana jest w ustalonej ramie czasowo-zdarzeniowej, przy określonym zdarzeniu inicjującym i/lub chwili początkowej oraz zdarzeniu finalnym i/lub chwili końcowej.

Do sygnałów ciągłych można zastosować jedną z poniższych metod:

- rozrzedzone próbkowanie sygnału polegające na wyborze z całego przebiegu zbioru reprezentatywnych wartości [5],
- metody identyfikacji modeli dynamicznych – do dalszych analiz przyjmuje się zbiór parametrów modelu odwzorowującego przebieg sygnału [3].


W przypadku sygnałów dyskretnych (w szczególności dwustanowych) parametryzacja najczęściej sprowadza się do wyznaczenia chwil czasu (względem początku ramy obserwacji), w których następuje skokowa zmiana wartości sygnału.

Parametryzacja sygnałów ciągłych metodą rozrzedzonego próbkowania

Rozrzedzone próbkowanie sygnału ciągłego polega na zastąpieniu przebiegu czasowego skończonym zbiorem charakterystycznych wartości sygnału i/lub charakterystycznych chwil czasu (rys. 1) [5].

W metodzie rozrzedzonego próbkowania i kwantowania czasowych przebiegów ciągłych sygnałów diagnostycznych możliwe są trzy podejścia (stosowane łącznie lub rozdzielnie) [1]:

- przyjęcie ustalonego zbioru chwil charakterystycznych dla czasowego przebiegu sygnału i określenie wartości sygnału w tych chwilach (np. początek obserwacji $[t_0, n(t_0)]$);
- przyjęcie ustalonego zbioru charakterystycznych wartości sygnału i określenie czasów ich osiągnięcia (np. $[n = 0, 8, t(n = 0, 8)]$);
- przyjęcie ustalonego zbioru zdarzeń na przebiegu sygnału (np. osiągnięcie maksymalnej wartości) i określenie czasu zaistnienia zdarzenia oraz wartości sygnału $[n_{max}, t(n_{max})]$.



Rys. 1. Schemat rozrzedzonego próbkowania i kwantowania sygnału prędkości obrotowej w procesie przyspieszania [5]

W pierwszym przypadku można mówić o rozrzedzonym próbkowaniu, w drugim – o rozrzedzonym kwantowaniu sygnałów, natomiast trzeci stanowi ich połączenie.

Dobór liczności zbioru chwil próbkowania oraz liczności poziomów kwantowania zależy od rozpatrywanych przebiegów i przeprowadzany jest doświadczalnie z wykorzystaniem wiedzy eksperckiej o zasadach funkcjonowania badanego obiektu.

W rezultacie rozrzedzonego próbkowania i/lub kwantowania, dla każdego sygnału otrzymuje się zbiór par $[t_i, y_{ji}]$, gdzie: t_i – i -ta chwila, y_{ji} – wartość j -tego sygnału w chwili t_i . Stanowią one podstawę do opracowania bazy wiedzy ekspertowego systemu diagnostycznego.

Parametryzacja sygnałów ciągłych metodą identyfikacji modeli dynamicznych

Celem identyfikacji jest zbudowanie matematycznego modelu, który z wymaganą dokładnością odwzoruje właściwości dynamiczne badanego obiektu. Polega na wyznaczeniu nieznanymi parametrów modelu wybranej klasy na podstawie zmierzonych sygnałów wyjściowych oraz wejściowych. Przykładem modeli dynamicznych są autoregresyjne modele AR szeregów czasowych zapisane w postaci:

$$y(t) = a_1 y(t-1) + a_2 y(t-2) + \dots + a_{n_a} y(t-n_a) \quad (2)$$

gdzie: n_a – rząd modelu.

Sygnały wykorzystywane w diagnostyce obiektów dynamicznych mogą być traktowane w pierwszym przybliżeniu jako szeregi czasowe, a parametry modelu (2) jako nośniki informacji o stanie diagnozowanego obiektu [3]. W takim przypadku przeprowadza się oddzielnie identyfikację każdego z wybranych sygnałów, w określonej ramie czasowo-zdarzeniowej, dla obiektu zdanego i z uszkodzeniami.

Dla uszkodzenia $e_i \in E$ i sygnału y_j otrzymuje się reprezentację w postaci wektora parametrów modelu identyfikacyjnego

$$(e_i, y_j) \rightarrow [a_{j1}^i, a_{j2}^i, \dots, a_{jna_j}^i] \quad (3)$$

natomiast dla całego zbioru uszkodzeń/stanów $E = \{e_i\}$, $i = 1, 2, \dots, n$ – macierz:

$$(E, y_j) \rightarrow \begin{bmatrix} a_{j1}^1, a_{j2}^1, \dots, a_{jna_j}^1 \\ \dots \\ a_{j1}^i, a_{j2}^i, \dots, a_{jna_j}^i \\ \dots \\ a_{j1}^n, a_{j2}^n, \dots, a_{jna_j}^n \end{bmatrix} \quad (4)$$

Dla uproszczenia dalszych analiz dogodnie jest wyznaczyć reprezentację (4) określonego sygnału y_j na podstawie modeli jednakowego rzędu, natomiast modele różnych sygnałów mogą być różnych rzędów.

4. Wielowartościowy model diagnostyczno-decyzyjny

W wyniku parametryzacji sygnałów otrzymuje się skończony zbiór parametrów diagnostycznych zawierający informację o stanie obiektu [1, 4]. Parametry są liczbami rzeczywistymi, różniącymi się znakami i wartościami bezwzględnymi. Celowe jest zatem przeprowadzenie normalizacji parametrów (sprowadzenie do przedziału $[-1, 1]$) z wykorzystaniem następującej zależności:

$$a_i' = \frac{a_i}{a_{i\max}}; \quad a_{i\max} = \max_{j=1, \dots, n} |a_i(e_j)| \quad (5)$$

gdzie:

n – liczba rozpatrywanych stanów/uszkodzeń,

e_j – j -ty stan/ uszkodzenie.

W rezultacie otrzymuje się nowe zbiory danych, których elementami są znormalizowane wielkości skalarnie. W procesie wnioskowania istotne są nie tyle dokładne wartości parametrów, ile ich przynależność do odpowiednich zakresów dających się zinterpretować w zbiorze klas stanu technicznego diagnozowanego obiektu [1, 4]. Zakresy zmienności parametrów diagnostycznych należy zatem podzielić na przedziały w taki sposób, aby

z jednej strony zapewnić jak najwyższą rozdzielczość (rozdzielność stanów/uszkodzeń), a z drugiej – zminimalizować liczbę błędnych diagnoz.

Kodowanie całkowitoliczbowe polega na przypisaniu wartościom parametrów z określonego przedziału liczb rzeczywistych jednej liczby całkowitej ze znakiem [1, 2]. Zasada kodowania może być jednakowa dla wszystkich parametrów lub ustalana indywidualnie dla każdego z nich. Oznaczając przez X_C wartość kodową parametru x uzyskaną w wyniku kodowania całkowitoliczbowego, zasadę kodowania można przedstawić w postaci (6).

$$X_C = \begin{cases} k-1 & \text{dla } x \in [x_{k-1}, x_k), k \leq K \\ \dots \\ 1 & \text{dla } x \in [x_1, x_2) \\ 0 & \text{dla } x \in (x_{1-}, x_1) \\ -1 & \text{dla } x \in (x_{2-}, x_{1-}] \\ \dots \\ -(k_- - 1) & \text{dla } x \in (x_{k_-}, x_{(k_- - 1)}], k_- \leq K_- \end{cases} \quad (6)$$

gdzie: $\dots < x_{k_-} < \dots < x_{1-} < x_1 \dots < x_k < \dots$

Kod 0 przypisywany jest przedziałowi wartości nominalnych (x_{1-}, x_1) parametru x obiektu zdatnego. Należy przy tym zauważyć, że liczby przedziałów/kodów poniżej i powyżej przedziału nominalnego (K_- i K) nie muszą być jednakowe.

Wyznaczanie progów x_k , $k = 1, 2, \dots, K$ i x_{k_-} , $k_- = 1, 2, \dots, K_-$ można rozpatrywać jako zagadnienie formalne klasteryzacji danych lub heurystyczne. W pierwszym podejściu stosuje się metody heurystyczne wykorzystujące wiedzę ekspercką i nie wymagające dużego zbioru danych statystycznych. W procesie rozwoju systemu diagnostycznego, po zgromadzeniu odpowiedniej ilości materiału eksperymentalnego, wstępnie wyznaczone progi poddawane są okresowej aktualizacji z zastosowaniem metod formalnych [2, 5, 6].

W przypadku eksperymentu badawczego, gdzie stan obiektu (w tym stan zdatności) jest znany, analizę należy rozpocząć od określenia przedziału nominalnych wartości rozpatrywanych parametrów [4]. Kolejne progi ustala się w punktach istotnych zmian wartości parametrów uporządkowanych monotonicznie.

Po przeprowadzeniu kodowania parametrów dla wszystkich rozpatrywanych uszkodzeń otrzymuje się wielowartościowy model diagnostyczny (uogólnienie stosowanych powszechnie modeli binarnych) opisujący relacje między zbiorem uszkodzeń i zbiorem symptomów (kodowych wartości parametrów diagnostycznych).

Tabela 1

Uogólniony model diagnostyczny – przyspieszanie

uszkodzenie	psp1	psp2	psp3	psp4
"U0"	Xc_0_1	Xc_0_2	Xc_0_3	Xc_0_4
"U1"	Xc_1_1	Xc_1_2	Xc_1_3	Xc_1_4
"U2"	Xc_2_1	Xc_2_2	Xc_2_3	Xc_2_4
"U3"	Xc_3_1	Xc_3_2	Xc_3_3	Xc_3_4
"U4"	Xc_4_1	Xc_4_2	Xc_4_3	Xc_4_4
"U5"	Xc_5_1	Xc_5_2	Xc_5_3	Xc_5_4
...

Taka forma modelu jest dogodna do dalszych analiz, mających na celu wyznaczenie optymalnego zbioru symptomów zapewniającego rozróżnialność stanów z założoną dokładnością [2], a następnie zbioru reguł wnioskowania w ekspertowym systemie diagnostycznym [5, 7, 10, 12].

5. Struktura ekspertowego systemu diagnostycznego

Ekspertowy system diagnostyczny **ESD_Silnik** układów funkcjonalnych silnika turbinowego **Silnik** opracowany został z wykorzystaniem systemu szkieletowego PC Shell [12]. Umożliwia on połączenie regułowej reprezentacji wiedzy i programowania proceduralnego.

Aplikacja **ESD_Silnik** składa się z następujących modułów:

- modułu głównego *knowledge base* **ESD_Silnik** zapisanego w pliku o nazwie **ESD_Silnik.bw**,
- źródła wiedzy *knowledge source* **rozruch** zapisanego w pliku o nazwie **rozruch.zw**,
- źródła wiedzy *knowledge source* **akceleracja** zapisanego w pliku o nazwie **akceleracja.zw**,
- źródła wiedzy *knowledge source* **dopalacz** zapisanego w pliku o nazwie **dopalacz.zw**,
- źródła wiedzy *knowledge source* **sprezarka** zapisanego w pliku o nazwie **sprezarka.zw**.

Moduł główny zawiera deklarację źródeł wiedzy oraz blok sterowania *control*, który zarządza pobieraniem danych diagnostycznych i uruchamia proces wnioskowania.

Dane diagnostyczne – rezultaty bieżącego badania diagnostycznego układów funkcjonalnych wykonane w zakresach: rozruch, akceleracja/deceleracja, dopalanie i sterowanie geometrią – przechowywane są w pliku Excel o nazwie **ESD_Silnik_Dane.xls**,

skąd pobierane są przez system ekspertowy z wykorzystaniem mechanizmu dynamicznej wymiany danych (DDE).

Źródła wiedzy *rozwuch.zw*, *akceleracja.zw*, *dopalacz.zw*, *sprezarka.zw* zawierają (umieszczone w bloku *facets*) deklaracje atrybutów wykorzystywanych w bazie wiedzy oraz zbiór reguł (blok *rules*) wnioskowania diagnostycznego.

Baza faktów tworzona jest na podstawie wyników badań diagnostycznych. W pierwszym etapie budowy bazy ustala się nazwy wszystkich atrybutów, które umieszczane są w źródle wiedzy w bloku *fasets*.

Atrybuty opisane są fasetą typu *val oneof* lub fasetą typu *val someof*, które deklarują dozwolony zbiór wartości atrybutów. Faseta *val oneof* oznacza, że w bazie wiedzy atrybut może wystąpić tylko raz natomiast faseta *val someof* umożliwia wielokrotne wystąpienie atrybutu. Przypisanie atrybutowi wartości tworzy nowy fakt, który wprowadzany jest do bazy wiedzy:

```
addFact( _, psp1, Psp1);
```

W projektowanej bazie wiedzy fakty dodawane są w sposób dynamiczny podczas wykonywania programu z bloku sterowania (*control*), który znajduje się w module głównym.

Reguły składają się z konkluzji i części warunkowej oddzielonej słowem *if*. Przesłanki w części warunkowej są połączone za pomocą operatorów logicznych AND i OR algebry Boole'a. Bloki reguł umieszczane są w źródłach wiedzy *rozwuch*, *akceleracja*, *dopalacz* i *sprezarka*.

Reguły są odpowiednio ponumerowane – tabela 2:

Tabela 2

Reguły wnioskowania – przyspieszanie

1000: uszkodzeniePrzyspieszanie = "U0" if psp1== Xc_0_1 & psp2 == Xc_0_2 & psp3 == Xc_0_3 & psp4 == Xc_0_4;
1001: uszkodzeniePrzyspieszanie = "U1" if psp1== Xc_1_1 & psp2 == Xc_1_2 & psp3 == Xc_1_3 & psp4 == Xc_1_4;
1002: uszkodzeniePrzyspieszanie = "U2" if psp1== Xc_2_1 & psp2 == Xc_2_2 & psp3 == Xc_2_3 & psp4 == Xc_2_4;
1003: uszkodzeniePrzyspieszanie = "U3" if psp1== Xc_3_1 & psp2 == Xc_3_2 & psp3 == Xc_3_3 & psp4 == Xc_3_4;
1004: uszkodzeniePrzyspieszanie = "U4" if psp1== Xc_4_1 & psp2 == Xc_4_2 & psp3 == Xc_4_3 & psp4 == Xc_4_4;
1005: uszkodzeniePrzyspieszanie = "U5" if psp1== Xc_5_1 & psp2 == Xc_5_2 & psp3 == Xc_5_3 & psp4 == Xc_5_4;
...

W wyniku opisania zbioru reguł umożliwiających zidentyfikowanie rozpatrywanych uszkodzeń powstaje algorytm przeszukiwania (wnioskowania) przez system ekspertowy – kolejność przeszukiwania jest zgodna z kolejnością na liście reguł.

Zmiana tego algorytmu jest możliwa poprzez zmianę kolejności reguł, co może mieć istotne znaczenie w przypadku zwiększania liczby reguł w miarę przyrostu wiedzy o funkcjonowaniu systemu w rzeczywistych warunkach eksploatacyjnych.

6. Podsumowanie

W pracy przedstawiono zagadnienia związane z projektowaniem ekspertowego systemu diagnostycznego głównych funkcjonalnych zespołów lotniczych silników turbinowych.

Proponowany ekspertowy system diagnostyczny ESD-Silnik może wykorzystywać różne źródła danych diagnostycznych:

- dedykowane stanowiska diagnostyczne,
- pokładowe rejestratory parametrów lotu.

Stanowiska diagnostyczne oraz rejestratory pokładowe dostarczają dynamicznych zapisów sygnałów dwustanowych i analogowych w postaci graficznej lub cyfrowej. W pierwszym etapie analizy zaproponowano sprowadzenie zapisów do jednolitego formatu. W wyniku parametryzacji sygnałów otrzymuje się skończony zbiór parametrów diagnostycznych zawierający informację o stanie badanego obiektu.

Po przeprowadzeniu kodowania parametrów dla wszystkich rozpatrywanych uszkodzeń otrzymuje się wielowartościowy model diagnostyczny (uogólnienie stosowanych powszechnie modeli binarnych) opisujący relacje między zbiorem uszkodzeń i zbiorem symptomów (kodowych wartości parametrów diagnostycznych).

Taka forma modelu jest dogodna do dalszych analiz, mających na celu wyznaczenie optymalnego zbioru symptomów zapewniającego rozróżnialność stanów z założoną dokładnością [2], a następnie zbioru reguł wnioskowania w ekspertowym systemie diagnostycznym.

Zastosowany formalizm umożliwia przedstawienie wiedzy diagnostycznej dla dowolnego zakresu pracy silnika turbinowego w postaci dwóch modułów: wielowartościowego modelu diagnostycznego i zbioru reguł wnioskowania.

Zbiór reguł wnioskowania uzyskany na podstawie wielowartościowego modelu diagnostycznego implementuje się bezpośrednio w szkieletowym systemie diagnostycznym, np. PC-Shell [12].

Zaproponowane podejście może być stosowane w projektowaniu ekspertowych systemów diagnostycznych zespołów napędowych dowolnego typu statków powietrznych – bezzałogowych i załogowych.

7. Literatura

1. Borowczyk H. (red.): Problemy kompleksowego diagnozowania układu łożyskowania turbinowego silnika śmigłowego. Wydawnictwo Instytutu Technicznego Wojsk Lotniczych, Warszawa 2011.
2. Borowczyk H.: Quasi-informacyjna metoda wyznaczania programu diagnozowania złożonych obiektów technicznych. Mechanical Engineering. WAT, Warszawa 1984.
3. Borowczyk H.: Zastosowanie metody identyfikacji modelu matematycznego oraz wielowartościowego kodowania w procesie tworzenia diagnostycznego modelu układu sterowania. Prace Naukowe ITWL, No. 18, 2004.
4. Borowczyk H., Kącki C., Koblański A.: Technologia identyfikacji uszkodzeń turbinowych silników odrzutowych typu 89 przy pomocy stanowiska diagnostycznego KAPSO-17MK, ITWL, Warszawa 1991.
5. Borowczyk H., Lindstedt P.: Formalizacja wiedzy eksperckiej w diagnostyce systemów sterowania lotniczych silników turbinowych. Diagnostyka procesów i systemów, J. Korbicz, K. Patan, M. Kowal, Warszawa 2007.
6. Borowczyk H., Zboński M., Formalizacja wiedzy w diagnostyce tribologicznej układu łożyskowania. Problemy Eksploatacji, 2011.
7. Cholewa W.: Wspomaganie procesu wnioskowania w diagnostyce technicznej. V Krajowa Konferencja Diag'2003, WAT, Warszawa 2003.
8. Guasch A., Quevedo J., Milne R.: Fault diagnosis for gas turbines based on the control system. Engineering Applications of Artificial Intelligence, No. 13, 2000.
9. Knosala R.: Zastosowanie metod sztucznej inteligencji w inżynierii produkcji. WNT, Warszawa 2002.
10. Korbicz J. et al.: Diagnostyka procesów. Modele. Metody sztucznej inteligencji. Zastosowania. WNT, Warszawa 2002.
11. Lindstedt P.: Praktyczna diagnostyka maszyn i jej teoretyczne podstawy. Warszawa 2002.
12. Michalik K.: PC SHELL 4.5 Szkieletowy system ekspertowy. AITECH (Artificial Intelligence Laboratory). Katowice 2006.
13. Mulawka J.J.: Systemy ekspertowe. WNT, Warszawa 1997.
14. Pawlak M.: Systemy ekspertowe w eksploatacji maszyn. Lublin 1996.
15. Volponi A.J., Gas Turbine Engine Health Management: Past, Present, and Future Trends. Journal of Engineering for Gas Turbines and Power, 2014. 136.10.1115/1.4026126
16. Witoś M. et al.: Structural health monitoring of aero-engines in non-stationary operations. Applied Condition Monitoring, Springer 2018. DOI 10.1007/978-3-319-61927-9_1.
17. Witoś M. et al.: Expert SHM and CM of Turbojet Engine FCU Using Instantaneous Angular Speed Signal. Advances in Condition Monitoring of Machinery in Non-Stationary Operations. Cham: Springer International Publishing, 2019.

18. Żokowski M., Sychała J., Majewski P.: Detection Damage in Bearing System of Jet Engine Using the Vibroacoustic Method. *Acta Mechanica et Automatica*, No. 11(3), 2017.
19. Żokowski M. et al.: Structure Health Monitoring of Aircraft Power Unit Using Vibration Signal. *Condition Monitoring of Machinery in Non-stationary Operations*. Cham: Springer International Publishing, 2019.