

## SYNTEZA I ANALIZA SYMPTOMOWYCH METOD DIAGNOZOWANIA

Aleksander JASTRIEBOW<sup>1),2)</sup>, Stanisław GAD<sup>2)</sup>, Grzegorz SŁOŃ<sup>2)</sup>

<sup>1)</sup> Politechnika Radomska, Katedra Informatyki  
ul. Malczewskiego 29, 26-600 Radom

<sup>2)</sup> Politechnika Świętokrzyska, Katedra Urządzeń i Systemów Automatyki; Katedra Energoelektroniki  
Al. Tysiąclecia Państwa Polskiego 7, 25-314 Kielce; e-mail: [enega@tu.kielce.pl](mailto:enega@tu.kielce.pl)

### Streszczenie

Przedstawiono pewne ogólne podejście do budowy symptomowych metod diagnostycznych opartych na dostępnej wiedzy ekspertowej. Opisano kryteria budowy podobnych algorytmów. Przedstawiono wyniki syntezy i analizy wybranych metod diagnozowania na przykładzie problemu lokalizacji uszkodzeń wyposażenia elektrycznego pojazdów samochodowych.

Słowa kluczowe: wiedza ekspertowa, symptomowe metody diagnozowania, rozmyte mapy kognitywne, pojazdy samochodowe.

### SYNTHESIS AND ANALYSIS OF SYMPTOM DIAGNOSING METHODS

#### Summary

General approach to the building symptom diagnostic methods, based on the available expert knowledge was presented. Criteria of building similar algorithms were described. Results of the synthesis and analysis of chosen diagnosing methods, on the example of the problem of faults localization in motorcar's electrical equipment's, were presented.

Keywords: expert knowledge, symptom diagnostic methods, fuzzy cognitive maps, motorcar vehicles.

## 1. WSTĘP

W nowoczesnych systemach diagnozowania technicznego problem wyboru odpowiednich metod detekcji i lokalizacji uszkodzeń zależy zarówno od wiedzy ekspertowej o diagnozowanym obiekcie jak i od możliwości jej wykorzystania [3-4, 6]. Przy tym informacja ta może być zadana zarówno przed rozpoczęciem procesu diagnostycznego jak i w jego trakcie. Systemy diagnostyczne oparte na wiedzy i jej przetwarzaniu i uzupełnianiu zwykle nazywa się inteligentnymi. Realizację inteligentnych systemów diagnozowania można podzielić na dwa etapy:

- monitorowanie środowiska obiektu,
- lokalizacja możliwych uszkodzeń.

Synteza odpowiednich algorytmów diagnozowania faktycznie polega na opracowaniu w każdej chwili odwzorowania (zgodnie z posiadaną informacją) tablicy wartości symptomów w przedziale liczb od 0 do 1, reprezentujących możliwe uszkodzenia. Takie odwzorowania opisywano zwykle różnymi operatorami w zależności od ilości i typu informacji (numeryczne, statystyczne, sztuczne sieci neuronowe i inne) [3-4, 6, 8]. W pracy przedstawiono w pewnym sensie ogólne podejście do syntezy symptomowych metod diagnostycznych, opartych na wiedzy ekspertowej. Opisano kryteria budowy podobnych reguł. Dla celów inteligentnego diagnostycznego monitorowania, zaproponowano w szczególności zastosowanie rozmytych map kognitywnych [1, 2, 5]. Koncepcja rozmytych map

kognitywnych łączy w sobie wiedzę ekspertową z wnioskowaniem decyzyjnym opartym pewnych elementach logiki rozmytej w celu przezwyciężenia ewentualnych nieokreśloności w modelach diagnostycznego monitorowania.

Analiza metod diagnozowania zwykle polega na realizacji na rzeczywistym obiekcie lub badaniach symulacyjnych.

W pracy przedstawiono niektóre wyniki analizy wybranych metod diagnozowania na przykładzie problemu lokalizacji uszkodzeń elektrycznego wyposażenia samochodu [8].

## 2. SYNTEZA SYMPTOMOWYCH ALGORYTMÓW DIAGNOZOWANIA

Realizacja symptomowych algorytmów diagnozowania zależy, w dużym stopniu, od posiadanej informacji o diagnostycznym obiekcie, a w szczególności o powiązaniach pomiędzy sygnałami symptomowymi, a możliwymi uszkodzeniami [3-4,6]. Dla każdej chwili wprowadzono zbiory symptomów ( $S$ ) i uszkodzeń ( $F$ ) w postaci:

$$\begin{aligned} S(t) &= \langle S_1(t), \dots, S_n(t) \rangle \\ F(t) &= \langle F_1(t), \dots, F_k(t) \rangle \end{aligned} \quad (1)$$

gdzie:

- liczby rzeczywiste  $F_j(t)$  charakteryzują stopień uszkodzenia,  $F_j \in \langle 0, 1 \rangle$ ,  $j = 1, \dots, k$  (0 – brak

- uszkodzenia, 1 – uszkodzenie pewne);
- liczby rzeczywiste  $S_i(t)$  charakteryzują (w pewnym sensie) natężenie występowania  $i$ -tego symptomu,  $S_i \in \langle 0, 1 \rangle$ ,  $i = 1, \dots, n$  (0 – brak wystąpienia symptomu, 1 – całkowite wystąpienie symptomu);
- $t = 0, 1, \dots, T$  – ogólny dyskretny czas.

**Uwaga:**

Określenie wartości funkcji  $S_i(t)$  ze zbioru  $S$  (w czasie  $t$ ) zależy od informacji ekspertowej. Może ono polegać np. na zadaniu (dla każdego  $i = 1, 2, \dots, n$ ) zbioru wartości dyskretnych, określonych przez ekspertów:

$$S_i(t) \in \{S_{i1}, \dots, S_{im_i}\}$$

gdzie:  $S_{ij} \in \langle 0, 1 \rangle$ ,  $i = 1, \dots, n$ ,  $j = 1, \dots, m_i$ ,  $t = 0, 1, \dots, T$ .

Oznaczając:

$$m = \max \{m_1, \dots, m_n\}$$

otrzymuje się macierz możliwych wartości symptomów (można założyć, że brakujące elementy mają wartość zerową):


$$SM = \{S_{ij}, i = 1, \dots, n, j = 1, \dots, m\} \quad (2)$$

Do pełnego przedstawienia obiektu diagnozowania brakuje opisu zależności pomiędzy zbiorami (tablicami)  $S$  i  $F$ , które można określić za pomocą pewnej macierzy współczynników  $W$ , często nazywanej informacyjną:

$$W = \{W_{ij}, i = 1, \dots, n, j = 1, \dots, k\} \quad (3)$$

Uwzględniając (1)-(3), obiekt diagnozowania można przedstawić w następującej postaci (schemat zamieszczona na rys. 1):

$$OD = \langle S, W, F \rangle \quad (4)$$



Rys. 1. Schemat blokowy obiektu diagnozowania, gdzie:  $W_e$  – warstwa wejściowa,  $W_y$  – warstwa wyjściowa,  $W_L$  – warstwa powiązań funkcyjnych

Nieznane rzeczywiste zależności funkcyjne z rys. 1 (dynamiczne lub statyczne) pomiędzy  $S(t)$  i  $F(t)$  z uwzględnieniem  $W$  można ogólnie zapisać w formie (5):

$$F(t+1) = \Phi[S(t), W, F(t), t] \quad (5)$$

gdzie:  $\Phi$  – nieznan operator odwzorowania,  $t = 0, 1, \dots, T$  – dyskretny czas obserwacji,  $F(0)$  – warunek początkowy.

Trzeba zauważyć, że przy braku czasu w (5) otrzymuje się model statyczny (chwilowy) (6):

$$F = \Phi[S, W] \quad (6)$$

Problem budowy algorytmów diagnozowania polega na odpowiedniej (możliwie optymalnej) ocenie operatora  $\Phi[\ ]$  oraz parametrów macierzy  $W$  dla zadanych zbiorów  $S(t)$  i  $F(t)$ ,  $t = 0, \dots, T$  w zależności od wstępnej informacji ekspertowej. Kryterium identyfikacji  $\Phi[\ ]$  można w takim razie przedstawić ogólnie w formie (7).

$$\inf_{\hat{\Phi}, \hat{W}} \sum_{t=0}^T \left\| \Phi[S(t), W, F(t), t] - \hat{\Phi}[S(t), \hat{W}, F(t), t] \right\|^2 \quad (7)$$

gdzie:  $\hat{\Phi}[\ ]$  – ocena modelu z klasy  $K\Phi$ ;  $\hat{W}$  – ocena wektora parametrów  $W$  ze zbioru  $OP$ ,  $\| \ \|$  – znak normy w odpowiedniej przestrzeni.

Jest oczywiste, że rozwiązanie problemu optymalizacji (7) zależy od informacji:

- o klasie wybranych modeli ( $K\Phi$ );
- o zbiorze ograniczeń parametrów  $\hat{W}(OP)$ .

W związku z tym opracowanie algorytmu diagnozowania będzie faktycznie skutkiem istniejącej informacji (ekspertowej) o klasie modeli  $K\Phi$ , zbiorze ograniczeń  $OP$  oraz możliwości rozwiązania problemu optymalizacji (7) przy tej informacji. Zgodnie z tymi zasadami poniżej opisano kilka wybranych algorytmów diagnozowania (monitorowania) symptomowego wynikających z rozwiązania zadania (7).

**2.1. Algorytmy logiczne**

Przy wyborze algorytmu diagnozowania w postaci funkcji logicznej powinna być znana cała informacja o symptomach i uszkodzeniach w postaci zerojedynkowej. Wtedy operator  $\Phi[\ ]$  jest funkcją logiczną:

$$F_j = \Phi_j(S_1^{\sigma_1}, S_2^{\sigma_2}, \dots, S_m^{\sigma_m}) \quad (j = 1, \dots, k)$$

gdzie:

$$S_i^{\sigma_i} = \begin{cases} S_i, & \sigma_i = 0 \\ \bar{S}_i, & \sigma_i = 1 \end{cases}$$

$$\sigma_i \in \{0, 1\}, \quad (i = 1, \dots, n),$$

$$S = \{S_1, \dots, S_m\} \text{ – zbiór symptomów,}$$

$$F = \{F_1, \dots, F_k\} \text{ – zbiór uszkodzeń,}$$

$$\Phi = \{\Phi_1, \dots, \Phi_k\} \text{ – zbiór powiązań funkcyjnych.}$$

Z zasad logiki Boole'a wynika, że każda funkcja logiczna może być przedstawiona w ekwiwalentnej formie dysjunkcji koniunkcji  $S_i$  oraz ich negacji [7]. W związku z tym operator  $\Phi[\ ]$  może być przedstawiony w następującej postaci:

$$F_j = \bigcup_{\Phi_j(\sigma_1, \dots, \sigma_m)=1} (S_1^{\sigma_1} \cap S_2^{\sigma_2} \cap \dots \cap S_m^{\sigma_m}) \quad (j=1, \dots, k) \quad (8)$$

W tym przypadku problem optymalizacji (7) ma automatyczne rozwiązanie w postaci (8).

## 2.2. Metoda Bayes'a

Operator  $\Phi[ ]$  przedstawia się w postaci następujących rozkładów warunkowych prawdopodobieństw (9) – (11) [3]:

$$F_{j^*} = \arg \max_{1 \leq j^* \leq k} P(F_j / S) \quad (9)$$

$$P(F_j / S) = [P(F_j(\omega)) \cdot P(S / F_j)] / P(S) \quad (10)$$

$$P(S) = \sum_{j=1}^k P(F_j(\omega)) \cdot P(S / F_j) \quad (11)$$

gdzie:  $P(S/F_j)$  – warunkowe prawdopodobieństwo zbioru symptomów  $S$  przy zadanym  $F_j$ ,  $P(F_j/S)$  – warunkowe prawdopodobieństwo uszkodzenia  $j$  przy zadanym symptomach, które zgodnie z (9) określają możliwe uszkodzenia.

## 2.3. Jednokierunkowe sztuczne sieci neuronowe typu MLP

Operator  $\Phi[ ]$  opisuje się jednokierunkowymi sieciami neuronowymi typu MLP (z jedną warstwą ukrytą) [3-4]:

$$F = \Gamma_j[W_1 \cdot \Gamma_j[W_2 \cdot S]] \quad (12)$$

gdzie:  $W = [W_1 : W_2]$  – macierz wag,  $\Gamma_j[ ]$  – diagonalny operator funkcji aktywacji (np. sigmoidalnych, liniowych i innych).

W tym przypadku rozwiązanie zadania optymalizacji (7) przy wybranych funkcjach aktywacji faktycznie nazywane jest uczeniem sztucznych sieci neuronowych typu MLP. Dla jego rozwiązania stosuje się różne metody optymalizacji (np. algorytm wstecznej propagacji błędów, metody gradientowe, ewolucyjne i inne).

## 2.4. Rozmyte mapy kognitywne

Przy rozwiązaniu zadania optymalizacji (7) w problemie diagnostycznego monitorowania z użyciem rozmytych map kognitywnych operator  $\Phi[ ]$  może być sformułowany w postaci [1-2, 5] – dynamicznej:

$$F_j(t+1) = f\left(\sum_{i=1}^n W_{ij} S_i(t) + F_j(t)\right), \quad j = 1, \dots, k \quad (13)$$

– lub statycznej

$$F_j = f\left(\sum_{i=1}^n W_{ij} S_i\right), \quad j = 1, \dots, k \quad (14)$$

gdzie:  $f()$  jest funkcją normalizującą do przedziału

$$\langle 0, 1 \rangle, \text{ np.: } f(x) = \frac{1}{1 + e^{-\lambda x}}, \quad \lambda > 0 \text{ – parametr.}$$

Przy zadanej macierzy parametrów  $W$  (wiedza ekspertowa) i wybranej funkcji  $f(x)$  zadanie optymalizacji (7) ma rozwiązanie w postaci (13) lub (14). Jeżeli wektor parametrów  $W$  nie jest w pełni określony, to rozwiązanie zadania (7) faktycznie określa procedurę wyboru optymalnych parametrów (podobnie do metody nauczania sieci neuronowych), np. za pomocą numerycznych algorytmów optymalizacji.


W następnym rozdziale zostaną przedstawione wybrane wyniki analizy symulacyjnej na przykładzie diagnozowania wyposażenia elektrycznego samochodu.

## 3. WYBRANE WYNIKI ANALIZY SYMULACYJNEJ

Analiza symulacyjna była przeprowadzona dla diagnozowania wyposażenia elektrycznego samochodu metodami logicznymi, numerycznymi oraz sieciami neuronowymi typu MLP i neuronowo-rozmytymi typu TSK [3]. Badania prowadzono zarówno na symulacyjnych sygnałach diagnostycznych, jak i na obiekcie rzeczywistym (samochód marki NUBIRA) [3,8]. Dla zilustrowania działania jednego z algorytmów (sztuczne sieci neuronowe typu MLP) przytoczono wybrane wyniki tej analizy dla konkretnego uszkodzenia wyposażenia elektrycznego pojazdu – sondy  $\lambda$  (kompletny wykaz uszkodzeń i symptomów zamieszczono w [3,8]).

### 3.1. Analiza uszkodzenia sondy $\lambda$


Uszkodzenie sondy  $\lambda$ , oznaczone jako  $F_{27}$ , analizowano symulacyjnie za pomocą sieci neuronowych typu MLP. Wyniki przytoczono na rys. 2 i 3 oraz w tablicach 1 i 2 odpowiednio dla uczenia i testowania sieci:



Rys. 2. Wyniki uczenia – uszkodzenie  $F_{27}$ , gdzie: MSE – błąd średniokwadratowy

Tablica 1. Wyniki uczenia dla uszkodzenia  $F_{27}$ .

Najlepsza sieć	Uczenie
Liczba epok	19
Minimum MSE	0,003515132
Końcowy MSE	0,003515132

Rys. 3. Wyniki testowania – uszkodzenie  $F_{27}$ Tablica 2. Wyniki testowania dla uszkodzenia  $F_{27}$ .

Kryteria	$F_{27}$
MSE	0,000639564
NMSE	0,002558255
MAE	0,022567809
Min Abs Error	0,015137255
Max Abs Error	0,047151182
r	0,999829787

gdzie:

MSE – błąd średniokwadratowy,  
 NMSE – znormalizowany błąd średniokwadratowy,  
 MAE – średni błąd bezwzględny,  
 Min Abs Error – minimalny błąd bezwzględny,  
 Max Abs Error – maksymalny błąd bezwzględny,  
 r – współczynnik korelacji.

#### 4. WNIOSKI

Pracę poświęcono opisaniu ogólnego podejścia do syntezy symptomowych algorytmów diagnozowania w postaci zadania optymalizacji. Opracowano ogólne modele, kryteria i rozwiązania w zależności od wstępnej informacji. Przedstawiono kilka różnych algorytmów diagnozowania, w szczególności metody oparte na rozmytych mapach kognitywnych. Przytoczono również wybrane wyniki analizy symulacyjnej proponowanych metod.

#### LITERATURA

- [1] Borisow W. W., Krugłow W., Fiedułow A. C.: *Rozmyte modele i sieci*. Moskwa, Wyd. Telekom 2007 (w j. rosyjskim).
- [2] Jastriebow A. I., Gad S., Słoń G., *Inteligentny system diagnostycznego monitorowania elektrycznego wyposażenia samochodu*. Materiały XIII Konferencja Naukowa Zastosowania Komputerów w Elektrotechnice - ZKwE. Poznań 2008, str. 195-196.

- [3] Jastriebow A. I., Gad S., Słoń G., *Modele i reguły decyzyjne w symptomowej diagnostyce technicznej*. DIAGNOSTYKA 3(39), 2006, str. 199-208.
- [4] Korbicz J., Kościelny J. M., Kowalczyk Z., Cholewa W. (red.), *Diagnostyka procesów. Modele. Metody sztucznej inteligencji. Zastosowania*. Warszawa, WNT, 2002.
- [5] Kosko B.: *Fuzzy cognitive maps*. Int. Journal of Man-Machine Studies. V. 24. 1986, pp. 65-75.
- [6] Michalski R. (red.), *Diagnostyka maszyn roboczych. Detekcja, relacje, wnioskowanie robocze*. Olsztyn, Wyd. Instytutu Technologii Eksploatacji, 2004.
- [7] Szaporev S. D., *Logika matematyczna*. S. Petersburg, Wyd. „BHW – Petersburg”, Russia, 2005 (w języku rosyjskim).
- [8] Yastrebov A. I., Gad S., Slon G., *Artificial Neural Networks in Diagnostic of Motorcar Vehicles' Electrical Equipment*. Łódź, Proc. of International conference on signals and electronic systems ICSES 2006, pp. 781-784.



Prof. dr hab. inż.

**Alexander YASTREBOV** jest profesorem nadzwyczajnym w Politechnice Świętokrzyskiej w Kielcach. Jest specjalistą w dziedzinie matematyki i informatyki stosowanej. Opublikował ponad 170 prac naukowych z zakresu automatyki, identyfikacji, diagnostyki oraz sztucznej inteligencji.



Dr hab. inż. **Stanisław**

**GAD** jest pracownikiem naukowym Politechniki Świętokrzyskiej w Kielcach. Jest członkiem Sekcji Podstaw Eksploatacji KBM Polskiej Akademii Nauk. Zainteresowania naukowe obejmują zagadnienia diagnostyki urządzeń

pojazdowych oraz elektrotechniki i elektroniki pojazdów samochodowych. Ma w swoim dorobku ponad 110 publikacji naukowych.



Dr inż. **Grzegorz SŁOŃ** jest adiunktem w Politechnice Świętokrzyskiej w Kielcach. Zajmuje się elektrotechniką teoretyczną, informatyką stosowaną, elektrotechniką i elektroniką pojazdową oraz wykorzystaniem sztucznej inteligencji w diagnostyce. Jest autorem i współautorem

ponad 50 prac naukowych.