

MODELE I REGUŁY DECYZYJNE W SYMPTOMOWEJ DIAGNOSTYCE TECHNICZNEJ

Aleksander JASTRIEBOW, Stanisław GAD, Grzegorz SŁOŃ

Politechnika Świętokrzyska
Al. Tysiąclecia P. P. 7, 25-314 Kielce, e-mail: enega@tu.kielce.pl

Streszczenie

W pracy przedstawiono modele i reguły decyzyjne stosowane w symptomowej diagnostyce technicznej. Modele podzielono na dwie grupy: matematyczne i informacyjne. Opisano kryteria budowy takich modeli. Na podstawie opisanych modeli przedstawiono reguły decyzyjne. Na przykładzie diagnozowania wyposażenia elektrycznego samochodów przedstawiono wyniki symulacyjnej analizy wybranych reguł. Wyniki analizy potwierdzają wysoką efektywność metod opartych na sztucznych sieciach neuronowych.

Słowa kluczowe: model matematyczny i informacyjny, sztuczne sieci neuronowe, reguły logiczne, reguły numeryczne, diagnostyka, pojazdy.

MODELS AND DECISION RULES IN SYMPTOM TECHNICAL DIAGNOSTIC

Summary

In the paper models and decision rules, applied in the symptom technical diagnostic, are presented. Models have been split into two groups: mathematical and informative. Criteria of designing of such models are described. On the basis of described models, decision rules have been presented. Results of the simulating analysis of chosen rules have been presented on the example of diagnosing of car's electrical equipment. Results of the analysis confirm high efficiency of methods artificial neural networks.

Keywords: mathematical and informative model, artificial neural networks, logic rules, numeric rules, diagnostic, vehicles.

1. WSTĘP

Nowoczesne systemy decyzyjne w diagnostyce technicznej w większości oparte są na odpowiednim modelu i metodzie diagnozowania, zastosowanie których przeważnie zależy zarówno od złożoności badanego obiektu jak i istnienia odpowiedniej informacji o jego związkach wewnętrznych, parametrach wejściowo – wyjściowych, urządzeniach pomiarowych i innych [3, 5, 6].

Modele, a w związku z tym i metody, stosowane w diagnostyce technicznej zależą od wybranego podejścia do rozwiązywanego problemu i mogą być podzielone na następujące klasy:

- modele matematyczne oparte na analizie wewnętrznych powiązań obiektu diagnozowania;
- modele informacyjne (cybernetyczne), oparte na aproksymacji zależności wyjścia (uszkodzenia) od wejścia (symptomy) diagnozowanego systemu.

Do pierwszej klasy można odnieść znane modele opisywane równaniami różniczkowymi (różnicowymi) stanu, różne filtry typu Kalmana, Luenbergera, regułach logicznych, algorytmach numerycznych i innych [6]. Druga grupa reguł

decyzyjnych oparta jest na tzw. zależnościach wyjścia od wejścia (podejście cybernetyczne albo informacyjne), które można nazwać metodami uczącymi, realizowanymi na podstawie danych eksperymentalnych: wejściowych i wyjściowych. Do takich modeli można odnieść reguły decyzyjne oparte na sztucznych sieciach neuronowych, neuronowo – rozmytych, algorytmach genetycznych, systemach eksperckich i innych [1, 2, 6, 8].

W drugim rozdziale niniejszego referatu opisano matematyczne i informacyjne modele diagnostyki technicznej symptomowej (z jednej strony logiczne, numeryczne, bayes'owskie i rozmyte, a z drugiej - sztuczne sieci neuronowe typu MLP, TSK).

W oparciu o przedstawione modele, w rozdziale 3 przedstawiono algorytmy diagnostyczne i ich możliwe realizacje komputerowe (reguły logiczne, numeryczne, bayes'owskie oraz MLP, TSK, banki sztucznych sieci neuronowych oraz sieci neuronowe o specjalnej strukturze).

W rozdziale 4, na przykładzie diagnozowania wybranych elementów elektrycznego wyposażenia samochodu, przedstawiono wyniki analizy symulacyjnej zaproponowanych metod

diagnozowania. Z przedstawionej analizy wynika, że z punktu widzenia dokładności najbardziej efektywnymi są reguły oparte na bankach sztucznych sieci neuronowych. Dokładniejszy opis wad i zalet poszczególnych metod zamieszczono we wnioskach.

Literatura zawiera niektóre znane autorom pozycje związane z omawianą tematyką.


2. MODELE (MATEMATYCZNE I INFORMACYJNE) W SYMPTOMOWYCH SYSTEMACH DIAGNOZOWANIA

Proces symptomowego diagnozowania oparty jest na następującej transformacji pewnych danych informacyjnych w odpowiednie symptomy (cechy) obiektu diagnostycznego (rys. 1).



Rys. 1. Schemat procesu symptomowego diagnozowania układów technicznych. $(X=[X_1, X_2, \dots, X_n]^T$ – dane pomiarowe (informacyjne), $S=[S_1, S_2, \dots, S_k]^T$ – dane symptomowe, $F=[F_1, F_2, \dots, F_l]^T$ – dane wyjściowe (uszkodzenia)).

Modele matematyczne i informacyjne symptomowych systemów diagnozowania buduje się w oparciu o podejście, przedstawione na rys. 2.



Rys. 2. Schemat symptomowego modelowania diagnostycznego. S – symptomy (wejście), Φ – nieznaną funkcją określającą zależności między S i F, F – uszkodzenie (wyjście)

Zależności między F i S, wg na rys. 2, mogą być zapisane następująco:

$$F = \Phi[S]. \quad (1)$$

Dla odnalezienia nieznanej funkcji Φ buduje się model decyzyjny w postaci (2):

$$\hat{F} = G[S], \quad (2)$$

gdzie:

$G[\]$ – aproksymujący model $\Phi[\]$, \hat{F} – ocena F.

Wtedy dla znalezienia modelu G w (2) z zadanej klasy należy rozwiązać następujący problem optymalizacyjny:

$$E = \|G - \Phi\| \rightarrow \inf_{G \in K_G}, \quad (3)$$

gdzie: $\| \cdot \|$ – odpowiednio wybrana norma bliskości, K_G – wybrana klasa modeli G, E – błąd modelowania.

Od istnienia tej lub innej informacji o problemie (3) zależy wybór odpowiedniego modelu G i reguły symptomowego decyzyjnego diagnozowania [6].

Poniżej przedstawiono 2 ważne podejścia do rozwiązywania problemu (3) – matematyczne i informacyjne (cybernetyczne). Trzeba zauważyć, że, oprócz prezentowanych, istnieją inne modele np. adaptacyjny, które również mogą być stosowane w zależności od jakości posiadanej informacji [1, 3].

2.1. Symptomowe diagnostyczne modele matematyczne

Modele tego typu dla obiektów diagnostycznych będą przedstawione w postaci (opracowanych na podstawie wiedzy teoretycznej i ekspertowej) następujących zbiorów (należy zauważyć, że istnieją pewne metody opracowania symptomów, oparte na analizie sygnałów stanów (residuów) [6]):

- możliwych uszkodzeń ($F = [F_1, \dots, F_l]^T$);
- odpowiadających im symptomów ($S = [S_1, S_2, \dots, S_k]^T$);
- oraz pewnych matematycznych połączeń (tablic) między F i S.

A. Logiczne modele symptomowe

W takich modelach dodatkowo do F i S należy zastosować następującą wiedzę:

- zbiór (PG) granic zmian sygnałów symptomowych dla pracy normalnej i z uszkodzeniami:

$$PG = \begin{cases} S_i \in [a_i, b_i] - \text{norma ln a praca} \\ S_i \notin [a_i, b_i] - \text{uszkodzenie} \end{cases}, \quad (4)$$

$$(i = 1, \dots, k);$$

- logiczne relacje (LR) między S i F określające dokładnie uszkodzenie lub normalną pracę:

$$S_j \rightarrow F_{j1} \vee F_{j2} \vee \dots \vee F_{jk} \quad (5)$$

$$(j = 1, \dots, k; \{j1, j2, \dots, jk\} \in \{1, 2, \dots, k\}).$$

Wtedy, uwzględniając (4), (5), model logiczny może być przedstawiony w postaci następującego zbioru:

$$ML = \{S, F, PG, LR\}. \quad (6)$$

Działanie modelu (6) i zbudowanych na jego podstawie logicznych reguł diagnozowania odbywa się bardzo dobrze przy precyzyjnie obliczanych granicach w (4). Niestety, niewielkie błędy są w stanie praktycznie wyeliminować prawidłowość relacji logicznych (5) w diagnozowaniu uszkodzeń.

B. Numeryczne modele diagnostyczne

W numerycznych (kombinatorycznych) modelach symptomowych, oprócz zbiorów F, S, PG, powinny być opracowane [4]:

- zbiór klas uszkodzeń $\Omega = \{\Omega_1, \dots, \Omega_m\}$, gdzie: $\Omega_j = \{F_{i1}, \dots, F_{ij}\}$ - zbiór uszkodzeń w j - klasie; ($j = 1, \dots, m$);
- macierz informacyjną MI dla zadanych zbiorów F, S, Ω w następującej formie (7):

Klasy (Ω)	Uszkodzenia obiektu	Wartości symptomów			
		S ₁	S ₂	...	S _k
Ω ₁	F ₁	α ₁₁	α ₁₂	...	α _{1k}
	F ₂	α ₂₁	α ₂₂	...	α _{2k}

Ω ₁	F _{r₁}	α _{r₁1}	α _{r₁2}	...	α _{r₁k}
	F _{r₁+1}	α _{r₁+11}	α _{r₁+12}	...	α _{r₁+1k}
	F _{r₁+2}	α _{r₁+21}	α _{r₁+22}	...	α _{r₁+2k}
Ω ₂
	F _{r_m}	α _{r_m1}	α _{r_m2}	...	α _{r_mk}

Ω _m	F _{r_{m-1}+1}	α _{r_{m-1}+11}	α _{r_{m-1}+12}	...	α _{r_{m-1}+1k}
	F _{r_{m-1}+2}	α _{r_{m-1}+21}	α _{r_{m-1}+22}	...	α _{r_{m-1}+2k}

Ω _m	F _{r_m}	α _{r_m1}	α _{r_m2}	...	α _{r_mk}

gdzie: $\alpha_{ij} = 0, 1, \dots$ - stopień ważności symptomu S_j dla uszkodzenia F_i (np. 0 oznacza, że S_j nie jest symptomem uszkodzenia F_i), $i = 1, \dots, l, j = 1, \dots, k$.

Przy takim podejściu model numeryczny może być przedstawiony w następującej postaci:

$$MN = \{S, F, PG, MI\}. \tag{8}$$

C. Probabilistyczne modele diagnostyczne

W modelach probabilistycznych symptomy, uszkodzenia i inne parametry traktowane są jako zmienne losowe ze swoimi rozkładami prawdopodobieństwa. Przy pełnej znanej informacji o absolutnych i warunkowych rozkładach informacji zwykle stosowane są modele Bayes'a, a przy niepełnej - adaptacyjne, oparte na ocenach pewnych parametrów diagnostycznych [5]. W metodach Bayes'a zwykle zadana jest następująca informacja:

- zbiór absolutnych rozkładów prawdopodobieństw uszkodzeń:

$$FP = \{P(F_1(\omega)), P(F_2(\omega)), \dots, P(F_l(\omega))\},$$

gdzie: $\omega \in \bar{\Omega}, \{\bar{\Omega}, \bar{F}, P\}$ - przestrzeń probabilistyczna, ω - zdarzenie elementarne, $\bar{\Omega}$ - zbiór zdarzeń elementarnych, \bar{F} - δ -algebra $\bar{\Omega}$, $P(\cdot)$ - prawdopodobieństwo spełniające odpowiednie warunki;

- zbiór warunkowych rozkładów prawdopodobieństw w postaci macierzowej

$$PW = \{P\{S_j / F_i\}\}_{j=1, i=1}^{k, l}.$$

Wtedy model probabilistyczny może być przedstawiony następującą zależnością:

$$MP = \{S, F, FP, PW\}. \tag{9}$$

D. Rozmyte modele diagnostyczne

W tego rodzaju modelach również należy określić zbiory S i F . Rozmyte modele symptomowe wykorzystują technikę zbiorów i logiki rozmytej, w której dla każdego symptomu ze zbioru S określa się przedział jego zmienności. Każdy taki przedział jest następnie podzielony na wybraną liczbę „podprzedziałów”, dla których definiowane są odpowiednie zbiory funkcji przynależności.:

$$FS = \{\mu_i(S_j), j = 1, \dots, k; i = 1, \dots, r\}.$$

Następnie budowana jest macierz diagnostyczna określająca powiązania zbioru symptomów S ze zbiorem uszkodzeń F :

S	S ₁	...	S _i	...	S _k
F ₁	γ ₁₁	...	γ _{1i}	...	γ _{1k}
F ₂	γ ₂₁	...	γ _{2i}	...	γ _{2k}
...
F _i	γ _{i1}	...	γ _{ii}	...	γ _{ik}
...
F _l	γ _{l1}	...	γ _{li}	...	γ _{lk}

gdzie:

$$\gamma_{ji} = \begin{cases} 1, S_i \text{ jest symptomem } F_j \\ 0, S_i \text{ nie jest symptomem } F_j \end{cases}$$

Wtedy model rozmyty może być przedstawiony w postaci:

$$MR = \{S, F, FS, MD\}. \tag{10}$$

2.2. Symptomowe informacyjne modele diagnostyczne

Przy realizacji symptomowych modeli informacyjnych zadanie optymalizacji (3) powinno być zamienione na następujące:

$$E_u = \sum_S \|G(S) - F\| \rightarrow \min, \tag{11}$$

gdzie: E_u - nazywa się zwykle błędem uczenia.

Do tego błędu dochodzi też tzw. błąd uogólnienia E_G , otrzymywany zwykle przy testowaniu zbudowanego modelu na danych S , nie należących do próbki uczącej. W związku z tym ogólny błąd E będzie się składał z sum tych części:

$$E = E_u + E_G \tag{12}$$

Jest jasne, że w dobrze zbudowanych modelach informacyjnych:

$$E_u \rightarrow 0, E_G \rightarrow 0 \tag{13}$$

Trzeba jednak zauważyć, że nie we wszystkich uczących modelach informacyjnych może być spełniona zależność (13) (co oznacza, że E w (12) nie dąży do zera). Takie modele zwykle nazywane są modelami źle uwarunkowanymi i trzeba o tym pamiętać przy budowie np. modeli opartych na sztucznych sieciach neuronowych.

Poniżej zaprezentowano najpowszechniejsze uczące modele informacyjne.

A. Modele neuronowe typu MLP

Modele neuronowe przy realizacji w zasadzie potrzebują bardzo mało informacji, a konkretnie – zbiorów S i F. Przy tym zbiór S gra rolę sygnałów wejściowych (uczących), a zbiór F odpowiednich sygnałów wyjściowych (nauczyciela), w budowanych regułach decyzyjnych opartych na jednokierunkowych sztucznych sieciach neuronowych (MLP). Do tych modeli trzeba dodać liczbę warstw ukrytych (WU) neuronów, funkcję aktywacji (FA) oraz algorytm uczenia. Wtedy model neuronowy typu MLP można przedstawić w postaci:

$$MSN = \{S, F, WU, FA\}. \quad (14)$$

B. Modele neuronowo-rozmyte typu TSK

Struktura tych neuronowo-rozmytych modeli powinna realizować reguły rozmyte oparte na modelach (10). Te modele mają strukturę MLP ze zbiorami S, F na wejściu i wyjściu (dane uczące) oraz pięcioma warstwami ukrytymi, realizującymi procedurę wnioskowania rozmytego. Przy tym w pierwszej i drugiej warstwie ukrytej funkcja aktywacji odpowiada wybranej funkcji wyostżenia (zazwyczaj funkcja Gauss'a), a w pozostałych – ma charakter liniowy [2, 6]. Takie modele mają następującą strukturę:

$$MNR = \{S, F, FL\}, \quad (15)$$

gdzie: FL – wektor liniowych funkcji wyjściowych MLP (wnioskowanie TSK) aproksymujących F.

C. Banki modeli MLP i TSK

Banki MLP i TSK odpowiednio składają się z l (liczba uszkodzeń F) modeli MSN i MNR i wyglądają następująco:

– BMSN = {MSN(i) = {S, F_i, WU, FA}, i = 1, ..., l},
 – BMNR = {MNR(i) = {S, F_i, FL_i}, i = 1, ..., l},
 gdzie: MSN(i) – model (13), MNR(i) – model (14) dla i-tego uszkodzenia

D. Sieci neuronowe o specjalnej strukturze

odele oparte na jednokierunkowych sztucznych sieciach neuronowych o specjalnej strukturze ogą zawierać cztery elementy [2]:

- warstwa wejściowa (S);
- warstwa wyjściowa (F);
- możliwa jedna warstwa ukryta;
- połączenie bezpośrednie S z F.

Neurony w takich sieciach realizują zwykle aproksymacje funkcji logicznych (np. AND i OR). Takie sieci już przy budowie potrzebują dodatkowej informacji, opartej na powiązaniu między zbiorami S i F (np. w postaci macierzy diagnostycznych albo funkcji logicznych). W związku z tym takie modele mogą być zapisane w postaci:

$$MSS = \{S, F, MLI, FL\}, \quad (16)$$


gdzie: ML – dodatkowe logiczne informacje o powiązaniach pomiędzy S i F,

FL – funkcje logiczne (np. AND, OR i inne).

Trzeba zauważyć, że takie sieci nie potrzebują procesu uczenia, a przy budowie odpowiednie wagi określa się zazwyczaj zerami lub jedynkami.

3. REGUŁY DIAGNOSTYCZNE

Ogólnie reguły diagnostyczne w symptomowej diagnostyce można przedstawić jak na rys. 4



Rys. 4. Schemat reguł diagnostycznych (RD – zbiór reguł decyzyjnych, F_{j*} – uszkodzenie obiektu, C – ogólne koszty reguł decyzyjnych)

W zależności od modeli opisujących powiązania zbiorów S i F z możliwymi „kosztami” C, poniżej opisano pokrótce reguły diagnostyczne RD.

3.1. Reguły diagnostyczne dla modeli matematycznych

A. Logiczne reguły diagnostyczne (LRD)

Logiczne reguły diagnostyczne, odpowiadające modelowi logicznemu (6), mogą być przedstawione w następującej formie:

$$S_{i1} \wedge S_{i2} \wedge \dots \wedge S_{il} \rightarrow F_i \quad (17)$$

$$(i = 1, \dots, l; \{i1, i2, \dots, il\} \in \{1, 2, \dots, l\})$$

Często, jako alternatywę dla (17) można stosować (18):

$$\bar{S}_1 \wedge \dots \wedge (S_{i1} \wedge S_{i2} \wedge \dots \wedge S_{il}) \wedge \dots \wedge \bar{S}_k \rightarrow F_i \quad (18)$$

gdzie uwzględnia się odwrotne własności pozostałych sygnałów ze zbioru S, ie będących symptomami uszkodzenia F_i.

Podobne podejście pozwala na znalezienie jednoznacznego rozwiązania w przypadku niejednoznaczności odwzorowania między zbiorami S i F.

Trzeba zauważyć, że:

- odwzorowanie za pomocą LRD jest szybkie i dokładne;
- wadą tej metody jest brak odporności na drobne przekłamanie sygnałów symptomowych oraz ich granic ze zbioru PG.

B. Numeryczne reguły diagnostyczne (NRD)

Dla modeli numerycznych (8) powinna być określona, na podstawie zmierzonych sygnałów

symptomowych, w postaci „zero-jedynkowej” wartość obiektu diagnozowania (19) [4]:

$$\beta = [\beta_1, \beta_2, \dots, \beta_k], \quad (19)$$

gdzie: $\beta_i = \begin{cases} 0 & \text{gdy } S_j \text{ nie jest symptomem } F_i \\ 1 & \text{gdy } S_j \text{ jest symptomem } F_i \end{cases}$

Kolejne kroki w opracowaniu numerycznych algorytmów diagnostycznych są następujące.

1) Wprowadzenie podzbiorów S typu:

$$S^n = \{ \{S_{i_1}, \dots, S_{i_n}\}, \quad i_1, \dots, i_n \in \{1, 2, \dots, k\} \} \quad (20)$$

gdzie: $n = 1, 2, 3, \dots, k$.

Wtedy, stosując (20), można określić

$$\bar{S} = \{S^1, S^2, \dots, S^k\}, \quad (21)$$

który jest zbiorem wszystkich podzbiorów S.

2) Określenie kryteriów diagnozowania w postaci pewnych zadań optymalizacji (22), (23), (24):

$$\max_{1 \leq j \leq m} I(\omega, \Omega_j) \quad (22)$$

$$|I(\omega, \Omega_{j^*}) - I(\omega, \Omega_j)| \geq \eta_1, \quad j = 1, \dots, m; \quad j \neq j^* \quad (23)$$

$$\frac{I(\omega, \Omega_{j^*})}{\sum_{j \neq j^*} I(\omega, \Omega_j)} \geq \eta_2 \quad (24)$$

Przy tym $\{\eta_1, \eta_2\}$ zwykle nazywane są parametrami algorytmów diagnozowania, j^* – numer zdiagnozowanej klasy uszkodzeń.

W (22) ÷ (24) wprowadzono następujące oznaczenia:

$$a) \quad I(\omega, \Omega_j) = \frac{1}{r_j - r_{j-1}} \sum_{S^i} I_{S^i}(\omega, \Omega_j) \quad (25)$$

gdzie: $\{I_{S^i}(\omega, \Omega_j), i = 1, \dots, k; j = 1, \dots, m\}$,

$I_{S^i}(\omega, \Omega_j)$ – liczba całkowita określająca podobieństwo (w szczególności równość) części obiektu ω z klasą uszkodzeń Ω_j , wyznaczana na podstawie porównań, na zbiorach S^i mocy i ($i = 1, \dots, k$), obiektu ω z odpowiednimi wierszami obiektu Ω_j – zgodnie z macierzą MI.

b) dla zbioru \bar{S} , $I(\omega, \Omega_j)$ wyznacza się na podstawie następującej zależności:

$$I(\omega, \Omega_j) = \frac{1}{r_j - r_{j-1}} \sum_{\Omega_j} \left(2^{\rho(\omega_{r_j}, \omega)} - 1 \right), \quad (26)$$

gdzie: $j = 1, \dots, m$; $\rho(\omega_{r_j}, \omega)$ – liczba całkowita, spełniająca warunki podobieństwa (w szczególności równości) opisane w a).

c) warunki podobne do b), a $I(\omega, \Omega_j)$ wyznacza się na podstawie zależności:

$$I(\omega, \Omega_j) = \frac{1}{r_j - r_{j-1}} \sum_{\Omega_j} \left(2^{\rho(\omega_{r_j}, \omega)} \right), \quad (27)$$

gdzie: $j = 1, \dots, m$; $\rho(\omega_{r_j}, \omega)$ – liczba całkowita, spełniająca podobne jak w b) warunki podobieństwa (w szczególności równości), opisane w a).

3) Określenie reguł decyzyjnych jako pewnych metod numerycznych rozwiązywania zadań optymalizacji (21), (22) lub (23) z uwzględnieniem (24), (25), (26).

Podsumowując powyższe rozważania można ogólnie przedstawić NRD w postaci następujących kroków:

- Określenie systemu podzbiorów $\{S^j, j = 1, \dots, k\}$ dla wybranej wartości j .
- Określenie kryteriów podobieństwa obiektu i macierzy informacyjnej MI.
- Wybór kryterium spośród (21) ÷ (23) z uwzględnieniem zależności (24) ÷ (26).
- Diagnoza klasy uszkodzeń j^* z możliwością wskazania najbardziej prawdopodobnego uszkodzenia z tej klasy (F_{j^*}).

C. *Probabilistyczne reguły diagnostyczne (PRD)*

Probabilistyczne (Bayes'owskie) reguły diagnostyczne, oparte na modelach (9), określa się następującymi zależnościami [5]:

$$F_{j^*} = \arg \max_{1 \leq j^* \leq l} P(F_j/S), \quad (28)$$

$$P(F_j/S) = [P(F_j(\omega)) \cdot P(S/F_j)] / P(S), \quad (29)$$

$$P(S) = \sum_{j=1}^l P(F_j(\omega)) \cdot P(S/F_j), \quad (30)$$

gdzie: $P(S/F_j)$ – warunkowe prawdopodobieństwo zbioru symptomów S przy zadanym F_j .

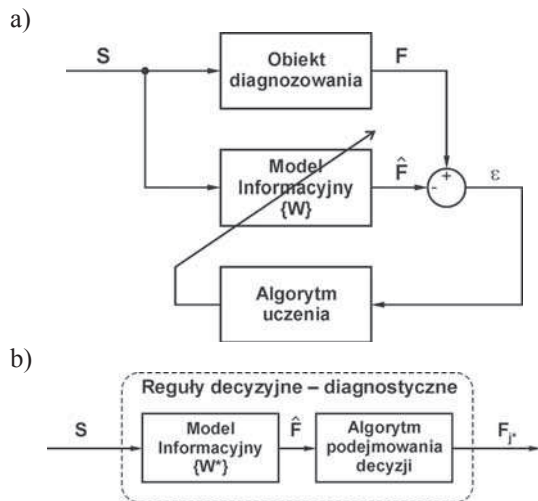
D. *Rozmyte reguły diagnostyczne (RRD)*

Rozmyte reguły diagnostyczne oparte są na logice i wnioskowaniu rozmytym i realizowane (z uwzględnieniem modeli (10)) za pomocą logiki IF – THEN [6, 8].

3.2. Reguły decyzyjne diagnostyczne dla modeli informacyjnych

Proces budowy modeli informacyjnych i reguł decyzyjnych przedstawiono poniżej (rys. 5).


Poniżej zostaną przedstawione wybrane reguły decyzyjne – diagnostyczne opisane na rys. 5 b).



Rys. 5. Ogólny schemat budowy modelu informacyjnego (a) oraz reguły diagnostycznej (b). (S – zbiór symptomów, F – zbiór uszkodzeń, \hat{F} – zbiór ocen uszkodzeń, ε – różnica między uszkodzeniami i ich ocenami, W – zbiór regulowanych parametrów modelu, W^* – zbiór parametrów optymalnych)

A. Reguły decyzyjne oparte na MLP


Na rys. 6 przedstawiono model informacyjny oraz algorytm podejmowania decyzji opartych na jednokierunkowych, wielowarstwowych sztucznych sieciach neuronowych typu MLP [2].



Rys. 6. Schemat reguły decyzyjnej diagnostycznej opartej na MLP

B. Neuronowo – rozmyte reguły decyzyjne oparte na TSK

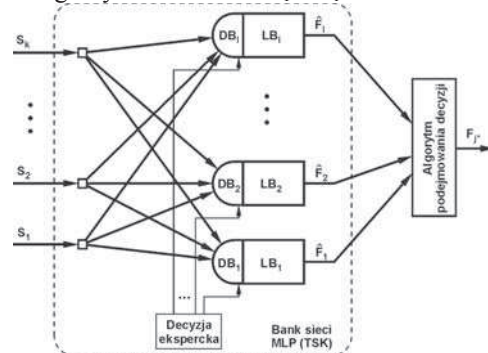
Na rys. 7 przedstawiono model informacyjny oraz algorytm podejmowania decyzji opartych na rozmyto-neuronowych sztucznych sieciach typu TSK [2].



Rys. 7. Ogólny schemat reguł decyzyjnych diagnostycznych opartych na sieciach neuronowo-rozmytych typu TSK. ($L1 \div L6$ – warstwa neuronów z gausowskimi funkcjami aktywacji w $L1$ i $L2$)

C. Reguły decyzyjne oparte na banku sieci MLP i TSK


Na rys. 8 przedstawiono schemat reguł decyzyjnych opartych na banku sieci MLP (TSK), który zawiera zestaw pojedynczych sieci MLP (TSK) (wg rys. 6 i 7), służących do lokalizacji poszczególnych uszkodzeń $F_1 \div F_l$.



Rys. 8. Schemat reguł decyzyjnych opartych na banku sieci MLP (TSK). ($DB_1 \div DB_l$ – bloki dyskryminacyjne, $LB_1 \div LB_l$ – bloki lokalizacyjne)

D. Reguły decyzyjne oparte na sztucznych sieciach neuronowych o specjalnej strukturze

Na rys. 9 zaprezentowano schemat reguł decyzyjnych opartych na jednokierunkowych sztucznych sieciach neuronowych o specjalnej strukturze. Szczególną uwagę należy zwrócić na to, że przy stosowaniu takich sieci na wyjściu otrzymuje się informację o uszkodzeniach, które faktycznie występują przy zadanej informacji o symptomach.



Rys. 9. Schemat reguł decyzyjnych opartych na jednokierunkowych sztucznych sieciach neuronowych o specjalnej strukturze (\cap , \cup – oznaczenia sztucznych neuronów realizujących operacje logiczne: AND i OR)

4. WYBRANE WYNIKI ANALIZY SYMULACYJNEJ REGUŁ DECZYJNYCH PRZY DIAGNOZOWANIU URZĄDZEŃ ELEKTRYCZNEGO WYPOSAŻENIA SAMOCHODU

Działanie reguł i modeli diagnostycznych opisanych w rozdziałach 2 i 3 poddano analizie symulacyjnej dla wybranych urządzeń elektrycznego wyposażenia pojazdu samochodowego [2]. Poniżej, w tablicach 1 i 2, przedstawiono zbiory symptomów i uszkodzeń dla wybranych urządzeń elektrycznego wyposażenia samochodu.

Tablica 1.
Zbiór wybranych sygnałów symptomowych

S ₁ – napięcie akumulatora
S ₂ – napięcie regulowane - wyjście z alternatora
S ₃ – prąd wzbudzenia alternatora
S ₄ – sygnał z wyłącznika zapłonu - I
S ₅ – sygnał zapłonowy z wyłącznika zapłonu
S ₆ – czujnik położenia i prędkości wału korbowego CPS
S ₇ – sygnał immobilisera
S ₈ – sygnał z czujnika spalania detonacyjnego
S ₉ – sygnał z czujnika temperatury powietrza MAT
S ₁₀ – sygnał zasilania przekaźnika pompy paliwa
S ₁₁ – sygnał zasilania pompy paliwa
S ₁₂ – sygnał strumień zasilania paliwem (ciśnienie paliwa)
S ₁₃ – sygnał z czujnika poziomu paliwa
S ₁₄ – sygnał z czujnika położenia przepustnicy
S ₁₅ – sygnał z czujnika pedału przyspieszenia
S ₁₆ – sygnał wtryskiwacza
S ₁₇ – wtryskiwacz
S ₁₈ – sygnał z wyłącznika zapłonu pojazdu, załączający wyłącznik elektromechaniczny rozrusznika
S ₁₉ – sygnał załącznika styków wyłącznika elektromechanicznego rozrusznika
S ₂₀ – sygnał prądowy zasilania uzwojeń rozrusznika

S ₂₁ – moment obrotowy wirnika rozrusznika
S ₂₂ – sygnał sterujący impulsem zapłonu elektronicznego
S ₂₃ – sygnał wn z cewki
S ₂₄ – sygnał wn na świecy
S ₂₅ – iskra zapłonowa
S ₂₆ – sygnał z czujnika temperatury silnika CTS
S ₂₇ – sygnał zał. wentylatora chłodnicy I
S ₂₈ – sygnał zał. wentylatora chłodnicy II
S ₂₉ – sygnał z czujnika ciśnienia w obwodzie chłodzenia
S ₃₀ – sygnał z czujnika temperatury oleju
S ₃₁ – sygnał z Sondy λ1
S ₃₂ – sygnał z Sondy λ2
S ₃₃ – układ recyrkulacji spalin
S ₃₄ – sygnał z czujnika ciśnienia w kolektorze ssącym MAP
S ₃₅ – sygnał z czujnika ciśnienia oleju
S ₃₆ – zawór zmiennej geometrii układu dolotowego VIGS

Tablica 2.
Zbiór wybranych uszkodzeń

F ₀ – poprawna praca
F ₁ – uszkodzenie silnika spalinowego (silnik uszkodzony awaryjnie - zablokowany)
F ₂ – uszkodzenie immobilisera
F ₃ – uszkodzenie czujnika położenia i prędkości wału korbowego CPS
F ₄ – uszkodzenie alternatora
F ₅ – uszkodzenie regulatora napięcia
F ₆ – uszkodzenie akumulatora
F ₇ – uszkodzenie stacyjki
F ₈ – uszkodzenie elektrycznego sterownika układu zapłonowego
F ₉ – uszkodzenie cewki zapłonowej
F ₁₀ – uszkodzenie przewodu zapłonowego
F ₁₁ – uszkodzenie świecy zapłonowej
F ₁₂ – uszkodzenie stacyjki
F ₁₃ – uszkodzenie przewodu stacyjka - rozrusznik
F ₁₄ – uszkodzenie wyłącznika elektromagnetycznego
F ₁₅ – uszkodzenie rozrusznika
F ₁₆ – uszkodzenie mechanizmu sprzęgającego
F ₁₇ – uszkodzenie przekaźnika pompy paliwa
F ₁₈ – uszkodzenie pompy paliwa
F ₁₉ – uszkodzenie sterownika urządzenia wtryskowego
F ₂₀ – uszkodzenie wtryskiwacza
F ₂₁ – uszkodzenie termostatu
F ₂₂ – nieszczelność układu chłodzenia
F ₂₃ – uszkodzenie wentylatora układu chłodzenia
F ₂₄ – uszkodzenie pompy olejowej
F ₂₅ – zatkana magistrala olejowa
F ₂₆ – uszkodzenie zaworu recyrkulacji spalin

Tablica 5.
Wytypowane klasy uszkodzeń

Badany obwód	Uszkodzenia	Klasa
Silnik	F ₀ , F ₁ , F ₃₀ , F ₂ , F ₃	Ω ₁
Układ zasilania	F ₄ , F ₅ , F ₆	Ω ₂
Układ zapłonowy	F ₇ , F ₈ , F ₉ , F ₁₀ , F ₁₁	Ω ₃
Układ rozruchu	F ₁₂ , F ₁₃ , F ₁₄ , F ₁₅ , F ₁₆	Ω ₄
Układ zas. w paliwo	F ₁₇ , F ₁₈ , F ₁₉ , F ₂₀ , F ₃₁ , F ₃₂	Ω ₅
Układ chłodzenia	F ₂₁ , F ₂₂ , F ₂₃	Ω ₆
Układ smarowania	F ₂₄ , F ₂₅ , F ₃₃	Ω ₇
Układ wydechowy	F ₂₆ , F ₂₇ , F ₂₈ , F ₂₉	Ω ₈

Dla diagnozowania zastosowano następujące reguły:

- logiczne typu (17);
- logiczne typu (18);
- numeryczne typu NRD (n = 1, (22), (25));
- sieciowe oparte na MLP.

Badania symulacyjne przeprowadzono na opracowanym oprogramowaniu¹, na próbkach losowych dla obiektu diagnozowania opisanego w tablicach od 1 do 5. Wyniki badań opisano w tablicach 6 i 7.

Tablica 6.
Wyniki diagnozowania dla wybranych uszkodzeń

Uszkodzenie	Reguła Logiczna (17)	Reguła Logiczna (18)	Reguła numeryczna	Zastosowanie SSN	Uszkodzenie	Reguła Logiczna (17)	Reguła Logiczna (18)	Reguła numeryczna	Zastosowanie SSN
F ₁	+	+	+	+	F ₁₈	+	+	+	+
F ₂	+	+	+	+	F ₁₉	+	+	+	+
F ₃	+	+	+	+	F ₂₀	+	+	+	+
F ₄	+	+	+	+	F ₂₁	+	+	+	+
F ₅	+	+	+	+	F ₂₂	+	+	+	+
F ₆	+	+	+	+	F ₂₃	+	+	+	+
F ₇	+	+	+	+	F ₂₄	+	+	+	-
F ₈	+	+	+	+	F ₂₅	+	+	+	-
F ₉	+	+	+	+	F ₂₆	+	+	+	-
F ₁₀	+	+	+	+	F ₂₇	+	+	+	+
F ₁₁	+	+	+	-	F ₂₈	+	+	+	+
F ₁₂	+	+	+	+	F ₂₉	+	+	+	-
F ₁₃	+	+	+	-	F ₃₀	+	+	+	+
F ₁₄	+	+	+	+	F ₃₁	+	+	+	+
F ₁₅	+	+	+	+	F ₃₂	+	+	+	+
F ₁₆	+	+	+	+	F ₃₃	+	+	+	+
F ₁₇	+	+	+	+					

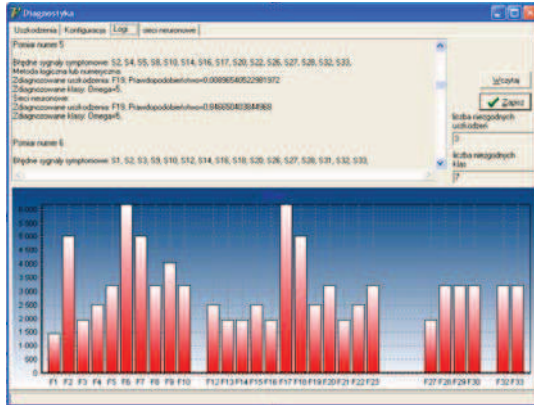
Tablica 7.
Wyniki diagnozowania z wyborem klas uszkodzeń

Uszkodzenie	Reguła Logiczna (17)	Reguła Logiczna (18)	Reguła numeryczna	Zastosowanie SSN	Uszkodzenie	Reguła Logiczna (17)	Reguła Logiczna (18)	Reguła numeryczna	Zastosowanie SSN
F ₁	+	-	+	+	F ₁₈	+	-	+	+
F ₂	+	-	+	+	F ₁₉	+	-	+	+
F ₃	+	-	+	+	F ₂₀	+	-	+	+
F ₄	+	+	+	+	F ₂₁	+	-	+	+
F ₅	+	-	+	+	F ₂₂	+	-	+	+
F ₆	+	+	+	+	F ₂₃	+	+	+	+
F ₇	+	+	+	+	F ₂₄	+	+	+	-
F ₈	+	-	+	+	F ₂₅	+	+	+	-
F ₉	+	-	+	+	F ₂₆	-	-	-	-
F ₁₀	+	-	+	+	F ₂₇	+	-	+	+
F ₁₁	-	-	-	-	F ₂₈	+	+	+	+
F ₁₂	+	+	+	+	F ₂₉	+	+	+	+
F ₁₃	+	-	+	+	F ₃₀	+	-	+	+
F ₁₄	+	-	+	+	F ₃₁	-	-	-	+
F ₁₅	+	-	+	+	F ₃₂	+	-	+	+
F ₁₆	+	-	+	+	F ₃₃	+	+	+	+
F ₁₇	+	-	+	+					

W tablicach 6 i 7 symbol „+” oznacza wynik diagnozowania poprawny, a „-” – wynik diagnozowania błędny (nie zdiagnozowano). Symbolem „+*” oznaczono niejednoznaczny wynik diagnozowania (wskazanie więcej niż jednego uszkodzenia).

Rys. 10 przedstawia wyniki lokalizacji przypadkowych uszkodzeń. Ponadto porównano wyniki diagnozowania dla reguł numerycznych i dla sieci neuronowych typu MLP. Badania przeprowadzono na próbkach symulujących dokonanie tysiąca pomiarów. Wykryto 180 rozbieżności przy lokalizacji uszkodzeń i 406 – przy rozpoznawaniu klas pomiędzy algorytmem numerycznym a MLP. Przy tym dodatkowo trzeba zauważyć, że wyniki działania algorytmu numerycznego (tym bardziej reguł logicznych) były często niejednoznaczne, a sieć neuronowa zawsze typowała jeden wynik.

¹ Obliczenia wykonane przez dyplomanta prof. A. Jastriebow – Marcina Krysiaka – w ramach pracy inżynierskiej [7].



Rys. 10. Wyniki badań na 1000 próbkach losowych sygnałów symptomowych

Podsumowując wyniki przeprowadzonych badań można stwierdzić, że: najbardziej zawodna w diagnozowaniu uszkodzeń jest reguła logiczna (17), sieć neuronowa z zasady wskazuje jedno uszkodzenie oraz reguły numeryczne lepiej się sprawdzają przy określaniu klasy niż przy lokalizacji poszczególnych uszkodzeń.

5. WNIOSKI

Praca została poświęcona analizie wybranych modeli i reguł, stosowanych w symptomowej diagnostyce technicznej. Przedstawiono modele matematyczne i informacyjne. Z ich pomocą określono odpowiednie reguły diagnostyczne. Na przykładzie diagnozowania wyposażenia elektrycznego samochodów zaprezentowano wyniki symulacyjnej analizy metod diagnozowania wybranych spośród opisanych w pracy. Wyniki analizy pokazały, że najbardziej efektywną metodą lokalizacji uszkodzeń jest stosowanie reguł opartych wykorzystaniu sztucznych sieci neuronowych (banków sieci).

LITERATURA

- [1] Cypkin J. Z., *Podstawy teorii układów uczących*. Moskwa, Wyd. „Nauka”, 1970 (w języku rosyjskim).
- [2] Jastriebow A., Gad S., Słoń G., Zawadzki A., Łaskawski M., Kałwa D., *Komputerowy system diagnozowania samochodowego układu elektrycznego oparty na modelach sztucznej inteligencji*. Mat. konferencyjne VII Szkoły-Konferencji Metrologia Wspomagana Komputerowo MWK'05, TOM III, Waplewo 2005, str. 257-264.
- [3] Jastriebow A., Kułakowski A. *Sztuczne sieci neuronowe w układach decyzyjnych z niepełną informacją*. Mat. VI Krajowej Konferencji Inżynieria Wiedzy i Systemy Ekspertowe, Wrocław, 2006 (w druku).
- [4] Jastriebow A., Gad S., Słoń G., *Zastosowanie numerycznych algorytmów klasyfikacji*

w symptomowej diagnostyce technicznej. Materiały XI Konferencji Naukowej Zastosowania Komputerów w Elektrotechnice ZKwE'2006, Poznań 2006, str. 67-69.

- [5] Kasabov N. *Foundations of neural networks, fuzzy systems and knowledge engineering*. London, The Mit Press Cambridge, Massachusetts, London, 1998.
- [6] Korbicz J., Kościelny J. M., Kowalczyk Z., Cholewa H. (red.). *Diagnostyka procesów. Modele. Metody sztucznej inteligencji. Zastosowania*. Warszawa, WNT, 2002.
- [7] Krysiak M. *Reguły logiczne i sieci neuronowe przy komputerowej realizacji diagnostycznych relacji*. Praca dyplomowa inżynierska, prom.: prof. A. Jastriebow, Politechnika Świętokrzyska, Kielce, 2006.
- [8] Wang K. *Intelligent condition monitoring and diagnosis systems*. Amsterdam, IOS Press, 2003.



Prof. dr hab. inż. **Aleksander JASTRIEBOW** jest profesorem nadzwyczajnym w Politechnice Świętokrzyskiej w Kielcach. Jest specjalistą w dziedzinie matematyki i informatyki stosowanej. Opublikował ponad 160 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 100 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 45 prac naukowych.