

DUER Stanisław

OCENA RYZYKA PODEJMOWANIA DECYZJI W SYSTEMACH INTELIGENTNYCH

Streszczenie

W artykule zawarto analityczne podstawy oceny niejednoznaczności w inteligentnych systemach wspomagających podejmowanie decyzji. Zaprezentowano podstawy oceny wiarygodności informacji w systemach inteligentnych oraz problematykę jej weryfikowania.

WSTĘP

W praktyce badawczej i nie tylko spotykamy się z szerokim dzisiaj stosowaniem sztucznej inteligencji i innych opracowanych systemów, które rozwiązują skomplikowane i trudne problemy. Szczególnie takie zadania, gdzie tradycyjne stosowane metody wnioskowania: dedukcyjne, probabilistyczne i metody analityczne są nie skuteczne i często nie możliwe do zastosowania, gdy należy w rozwiązaniu danego problemu np. przeanalizować duży zbiór informacji wejściowej itp. Tworzone są w tym celu specjalistyczne systemy wnioskujące pracujące na bazie sztucznej inteligencji lub systemy ekspertowe, w których stosowane jest wnioskowanie na bazie posiadanej informacji wielo- płaszczyznowo. Sposób przetwarzania informacji przez te systemy jest zbliżone do postępowania człowieka, potrafiącego się uczyć i dostosowywać swój sposób myślenia (wnioskowania) do aktualnej sytuacji- algorytmy wnioskowania genetycznego. Tworzy się wówczas możliwości zmiany samej sztucznej inteligencji kierunku inteligencji naturalnej człowieka.


W systemach sztucznej inteligencji i w systemach ekspertowych rozwiązujących wielorakie zadania spotykamy się z problemem pojęcia decyzji prawdziwej „Prawda” lub nieprawdziwej „Fałsz”. Moduły wnioskujące (decyzyjne) tych systemów, które wykorzystują meta-wiedzę wnioskują w logice dwu- i wielowartościowej (często w logice trójwartościowej) mimo coraz większej ich doskonałości popełniają jednak błędy, czyli nie są jeszcze doskonałe [12, 13]. Ważny jest tutaj jednak człowiek, który te systemy konstruuje opracowuje dla nich oprogramowanie i je kontroluje (określa jakość- wiarygodność decyzji).

1. OPTYMALIZOWANIE PROCESU WYPRACOWANIA DECYZJI O STANIE OBIEKTU TECHNICZNEGO W SYSTEMIE DIAGNOSTYCZNYM, ZE SZTUCZNĄ SIECIĄ NEURONOWĄ

Wielkości $R_{j,k}$ i Y_j charakteryzują się odpowiednimi funkcjami gęstości prawdopodobieństw $f(R_{j,k})$ i $f(Y_j)$. Wykorzystując te wielkości i podstawiając je do zależności (3.24) uzyskano zależność, którą przedstawiono w postaci:

$$P_{ps} = \iint_{G_1} f(R_{j,k}) f_1(Y_j) dr dy + \iint_{G_2} f(R_{j,k}) f_1(Y_j) dr dy \quad (1)$$

Optymalizowanie procesu niejednoznaczności identyfikowania stanów obiektu technicznego w systemie diagnostycznym, ze sztuczną siecią neuronową polega optymalizowaniu obszaru wyznaczonego przez linie proste (płaszczyzny) opisujące przedziały podejmowania decyzji (Rys. 1).



Rys. 1. Optymalizacyjne płaszczyzny w ocenie jakościowej pracy automatu diagnozującego, gdzie: G_3 – jest płaszczyzną ograniczającą obszar decyzyjny przez prostą (l_3) równoległą do osi (OY) i przechodzącą przez punkt $(-\Delta r_{j,k})$, G_4 – jest płaszczyzną ograniczającą obszar decyzyjny opisany przez prostą (l_4) równoległą do osi (OY) i przechodzącą przez punkt $(+\Delta r_{j,k})$

Źródło: Opracowanie własne

Wyznaczenie granic obszaru całkowania (G_1) i (G_2), gdzie jednocześnie zachodzą zdarzenia należy wykreślić granice płaszczyzn, wewnątrz których znajdują się zdarzenia. Na podstawie rysunku (Rys. 1) można wyznaczyć graficznie obszary całkowania G_1 - to obszar, w którym występują jednocześnie zdarzenia (będące przedziałami zmian wartości cech wielkości diagnostycznych) $(-\Delta r_{j,k} < R_{j,k} < +\Delta r_{j,k})$ i $(Y_j < -\Delta Y_{j,k} < R_{j,k})$ oraz obszar G_2 - to obszar całkowania, w którym jednocześnie występują zdarzenia $(-\Delta r_{j,k} < R_{j,k} < +\Delta r_{j,k})$ i $(Y_j > +\Delta Y_{j,k} > -R_{j,k})$ przedstawiając tak wyznaczone obszary całkowania (G_1 i G_2) to otrzymano postać wynikową:

$$P_{ps} = \int_{-\Delta r_{j,k}}^{+\Delta r_{j,k}} f(R_{j,k}) \left(\int_{-\infty}^{-\Delta r_{j,k} - R_{j,k}} f_1(Y_j) dy \right) dr + \int_{-\Delta r_{j,k}}^{+\Delta r_{j,k}} f(R_{j,k}) \left(\int_{+\Delta r_{j,k} - R_{j,k}}^{+\infty} f_1(Y_j) dy \right) dr \quad (2)$$

Fałszywy alarm jak i pozorny spokój (poprawne nierozpoznanie stanu obiektu) są wysoce niepożądanym błędem wnioskowania diagnostycznego mogącym występować przy

wypracowaniu decyzji (rozpoznawania stanu) przez automaty diagnozujące. Fałszywe informacje po pierwsze obciążają zbędnie system przetwarzania danych automatu diagnozującego oraz po drugie błędne decyzje mogą zakłócić poprawne użytkowanie obiektu (zbędne np. wykonywanie czynności profilaktycznych wskazanych przez automat diagnozujący itp.). Wykorzystując wcześniejsze rozważania można stwierdzić, że dla tak przedstawionej sytuacji (rys. 3.3) zachodzi konieczność ograniczonego wykorzystanie automatu diagnozującego w zakresie wypracowania określonego typu decyzji diagnostycznych. Wydaje się, że zasadniczym problemem jaki tu występuje to jest zależenie Odpowiedzi na pytanie, jakiego typu zastosować rozwiązania pozwalające uzyskać (otrzymać) jak największą wartość prawdopodobieństwa poprawnego wypracowania decyzji rozpoznania stanu elementów, a w konsekwencji i stanu samego obiektu [1-12, 13, 14, 15].

Jednym ze sposobów rozwiązania tego problemu to optymalizacja przedziału możliwych wartości sygnału (Rys. 1). Wyznaczenie właściwego zakresu przedziałów dopuszczalnych i granicznych zmian wartości sygnałów diagnostycznych, można dokonać sposobem empirycznym przy minimalizowaniu tych wielkości oddzielnie dla każdego z prawdopodobieństw niejednoznaczności rozpoznawania stanów: fałszywego alarmu (P_{fa}) i pozornego spokoju (P_{ps}). Z analizy informacji przedstawionej (Rys. 1) wynika, że optymalny sposób wypracowania decyzji w systemie jest wtedy, gdy wartości prawdopodobieństw (P_{fa}) i (P_{ps}) są minimalne. Zdarzenie to zachodzi wtedy i tylko wtedy, gdy wartości błędów cech mierzonych sygnałów diagnostycznych i błędy wyznaczenia przedziałów dopuszczalnych i granicznych zmian sygnałów diagnostycznych będących podstawą przy wypracowaniu decyzji znajdują się we właściwym obszarze decyzyjnym (obszar niezakreskowany) (Rys. 1). Powyższą sytuację zapisano w postaci zależności:

$$\Delta r_{j,k} = \begin{cases} P_{fa} = \min \\ P_{ps} = \min \end{cases} \quad (3)$$

Z analizy tej zależności (3) wynika, że wyznaczenie optymalnego przedziału jest możliwe jedynie w sytuacji dla minimalnej wartości (P_{fa}) i (P_{ps}).

2. OCENA NIEJEDNOZNACZNOŚCI ROZPOZNANIA STANÓW SYSTEMU RADIOLOKACYJNEGO W INTELIGENTNYM SYSTEMIE DIAGNOSTYCZNYM, ZE SZTUCZNĄ SIECIĄ NEURONOWĄ (DIAG)

Metodę weryfikacji oceny niejednoznaczności identyfikowania stanów obiektu technicznego w systemie diagnostycznym, ze sztuczną siecią neuronową zaprezentowano w przykładzie z wykorzystaniem systemu radiolokacyjnego. Podstawą tej metody jest komputerowy program diagnostyczny DIAG, w którym wykorzystano algorytm sztucznej sieci neuronowej. Obiekt testowy posiada złożoną strukturę wewnętrzną i jest przy tym trudny do diagnozowania dlatego, że posiada mieszaną strukturę funkcjonalną i informacyjną (analogowo-cyfrową) [5-9, 12].

Wykonanie procesu oceny niejednoznaczności identyfikowania stanów obiektu technicznego w systemie diagnostycznym, ze sztuczną siecią neuronową wymagało przygotowania eksperymentu testującego dla oceny pracy automatu diagnostycznego. Podstawą w tym badaniu było przygotowanie wektorów danych wejściowych sygnałów diagnostycznych obiektu (Tabela 1) dla zakładanych (testowanych) stanów elementów funkcjonalnych obiektu.

Tab. 1. Struktura wewnętrzna obiektu testującego

Assembly of object	Structure of the object					
E ₁	e _{1,1}	e _{1,2}	-	-	-	-
E ₂	e _{2,1}	e _{2,2}	e _{2,3}	e _{2,4}	e _{2,5}	e _{2,6}
E ₃	e _{3,1}	-	-	-	-	-
E ₄	e _{4,1}	e _{4,2}	e _{4,3}	e _{4,4}	-	-
E ₅	e _{5,1}	-	-	-	-	-
E ₆	e _{6,1}	e _{6,2}	-	-	-	-
E ₇	e _{7,1}	e _{7,2}	e _{7,3}	e _{7,4}	e _{7,5}	-

Wektory testowe muszą opisywać jeden z dwóch pewnych stanów obiektu: zdatności stan {2} oraz stan nie zdatności stan {0}. W pierwszym przypadku (przypadek 1) stanu zdatności {2}, który jest opisany wektorem zdatności wszystkich jego elementów funkcjonalnych [$\varepsilon(e_{1,1}); \dots; \varepsilon(e_{i,j}); \dots; \varepsilon(e_{I,J})$], gdzie: ($\varepsilon(e_{i,j})$) - stan zdatności j-tego elementu w i-tym zespole funkcjonalnym obiektu.

$$\begin{aligned} [X(e_{i,j})] &= [(X(e_{1,1})), \dots, (X(e_{i,j})), \dots, (X(e_{I,J}))] \mapsto \\ &\mapsto (\varepsilon(e_{1,1})), \dots, (\varepsilon(e_{i,j})), \dots, (\varepsilon(e_{I,J}))] = \{2\} \end{aligned} \quad (3)$$

W drugim teście dla (przypadek 2) stan nie zdatności - {0} jest opisany wektorem nie zdatności wszystkich jego elementów funkcjonalnych [$\varepsilon(e_{i,j})$]. Informacyjnie wydaje się ciekawszym być ten eksperyment, w którym przyjęty do testowania modułu wnioskującego, w tym i całego systemu diagnostycznego jest wektor informacji wejściowej taki, w którym elementy tego wektora będą mieszane tzn. będą zawierać (opisywać) i stany zdatności, stany nie zdatności oraz stany zdatności nie pełnej (czyli wszystkie możliwe stany w obiekcie).

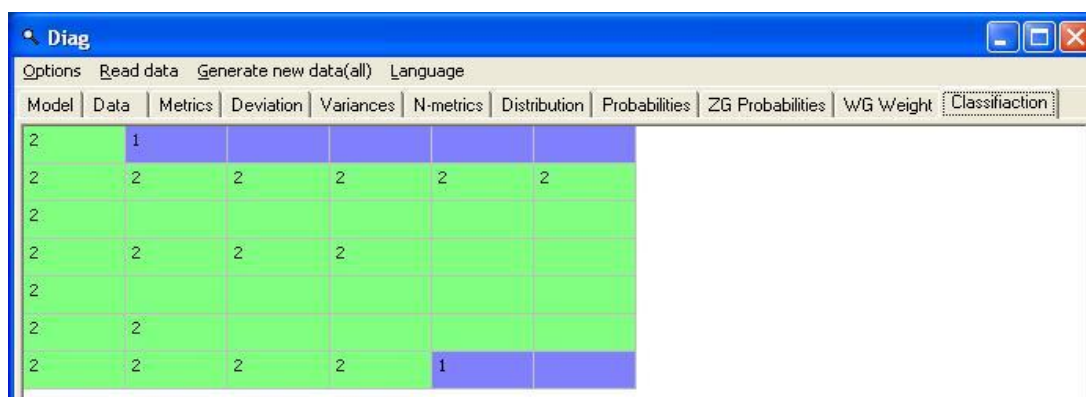
$$\begin{aligned} [X(e_{i,j})] &= [(X(e_{1,1})), \dots, (X(e_{i,j})), \dots, (X(e_{I,J}))] \mapsto \\ &\mapsto (\varepsilon(e_{1,1})), \dots, (\varepsilon(e_{i,j})), \dots, (\varepsilon(e_{I,J}))] = \{2,1,0\} \end{aligned} \quad (4)$$

Opracowany do badań model obiektu testującego jakość pracy automatu diagnostycznego posiada strukturę wewnętrzną (funkcjonalną) opisaną w postaci (Tabeli 1) przy następującym jej podziale: **obiekt – zespół – element funkcjonalny (moduł)**. Obiekt badany (testowany) składa się ze 21 elementów podstawowych na wyjściu, których wyróżniono 21 sygnały diagnostyczne. Wyznaczone sygnały diagnostyczne stanowią zbiór informacji wejściowej (testującej) dla systemu diagnostycznego, którą przedstawiono w postaci tablicowej (Tabele 2 i 3), gdzie: przypadek (1) – zbiór stanów zdatności wszystkich elementów obiektu; ; przypadek (2) – zbiór stanów mieszanych (zdatności i nie zdatności) wszystkich elementów obiektu.

W efekcie badania diagnostycznego w systemie diagnostycznym uzyskano zbiór informacji diagnostycznej, którą zestawiono w postaci „Tablicy stanów obiektu technicznego” dla przypadku 1 i 2, wyniki przedstawiono w (Tabelach 2 i 3) oraz na (Rys. 2 i 3).

Tab. 2. „Testowa tablica stanów obiektu technicznego” (przykład 1)

State of the object	State of assembly	Vector of states of elements in the object $\{\varepsilon(e_{i,j})\}$					
2	2	2	2	∅	∅	∅	∅
	2	2	2	2	2	2	2
	2	2	∅	∅	∅	∅	∅
	2	2	2	2	0	∅	∅
	2	2	∅	∅	∅	∅	∅
	2	2	2	∅	∅	∅	∅
	2	2	2	2	2	2	2



Rys. 2. Postać wynikowa (testowa) wypracowanej decyzji diagnostycznej z wykorzystaniem programu DIAG (przykład 1)

Źródło: Opracowanie własne

Tab. 3. „Testowa tablica stanów obiektu technicznego” (przykład 2)

State of the object	State of assembly	Vector of states of elements in the object $\{\varepsilon(e_{i,j})\}$					
0	2	2	2	∅	∅	∅	∅
	2	2	2	2	2	2	2
	2	2	∅	∅	∅	∅	∅
	0	2	2	2	0	∅	∅
	2	2	∅	∅	∅	∅	∅
	2	2	2	∅	∅	∅	∅
	1	1	1	1	1	1	1



Rys. 3. Postać wynikowa (testowa) wypracowanej decyzji diagnostycznej z wykorzystaniem programu DIAG (przykład 2)


Źródło: Opracowanie własne

Prezentowana metoda oceny jakości odnowy obiektu technicznego nie jest procesem kosztownym (tak dla czasu jej realizacji, czy też nakładów na nią ponoszonych). Uzyskane rezultaty badań zestawiono w postaci „Tablicy stanów obiektu technicznego” (Tabela 2 i 3) dają w zasadzie ocenę bezpośrednią. Z informacji w niej zawartej można stwierdzić, który z elementów obiektu jest rozpoznany przy określonym jego stanie zdatności ($\varepsilon(e_{i,j})$). Na potrzeby jakościowej oceny procesu rozpoznania stanów opracowano funkcję jakościowej oceny procesu diagnozowania obiektu.

Jeżeli znamy czas diagnozowania (rozpoznania stanów) poszczególnych elementów obiektu, to wówczas funkcję jakościowej procesu rozpoznania stanów obiektu w systemie diagnozowania ($F_r = f(t_d(e_{i,j}))$ lub $F_{nr} = f(t_d(e_{i,j}))$), gdzie: t_d – jest czasem identyfikowania stanu (diagnozowania) obiektu technicznego dla j -tego elementu w i -tym zespole obiektu ($e_{i,j}$). Wykreślone wielkości przedstawiono graficznie na (Rys. 4).

Z analizy jakości procesu rozpoznania stanów obiektu ($F_r = f(t_d(e_{i,j}))$) przedstawionej graficznie na rys. 4 wynika, że w połowie czasu wykonywanej diagnostyki ($1/2t_d$) rozpoznano dla przypadku (1) 45% wszystkich elementów obiektu, które były diagnozowane. Dla przypadku (2) 65% wszystkich elementów, które były diagnozowane.

Dodatkową informację w zakresie oceny jakości rozpoznania stanów obiektu uzyskano z analizy zbioru informacji zawartej w (Tabelach 2 i 3) będącymi końcową postacią informacją diagnostyczną „Tablica stanu obiektu technicznego”. Wynika z nich, że wszystkie elementy obiektu, które poddano diagnostyce zostały rozpoznane: dla obu przypadków (1 i 2) nie gorzej niż na poziomie „nie pełnej zdatności – stan {1}”. Wynik ten świadczy, że jakość rozpoznania stanów obiektu w systemie diagnostycznym jest zadawalająca.



Rys. 4. Wykres funkcji jakościowej rozpoznania (zidentyfikowania) stanów elementów obiektu technicznego (F_r) przez system diagnostyczny, gdzie: 1 – wykres dla wektora testującego (przykład 1) - zbiór stanów zdatności wszystkich elementów obiektu; 2 – wykres dla wektora testującego (przykład 2) - zbiór stanów mieszanych (zdatności i nie zdatności) wszystkich elementów obiektu, $t_d(e_{i,j})$ – jest czasem diagnozowania (identyfikowania) j -tego elementu podstawowego w i -tym zespole funkcjonalnym obiektu.

Źródło: Opracowanie własne

PODSUMOWANIE

W pracy zaprezentowano metodę oceniania niejednoznaczności rozpoznania stanów obiektu technicznego w systemie diagnostycznym, ze sztuczną siecią neuronową. W pracy scharakteryzowano i opisano strukturę systemu diagnostycznego oraz jego elementów składowych, w tym szczególnie modułów: pomiarowego oraz diagnozującego, ze sztuczną siecią neuronową. Istotnym elementem w tym systemie jest sztuczna sieć neuronowa, dlatego w celu zrozumienia tej problematyki, która ma wpływ na jakość diagnozowania przedstawiono schemat i algorytm diagnostycznej sieci neuronowej. Poziom niejednoznaczności identyfikowania stanów obiektu technicznego jest także określony wartościami błędów pozornego spokoju lub wielkości błędu fałszywego alarmu.

Uzyskane wyniki badania jakości diagnozowania obiektu potwierdzają, że istnieje możliwość określania, a także optymalizowania problematyki niejednoznaczności rozpoznawania stanów obiektu technicznego. Zaprezentowane definicje w artykule, które określając jakość rozpoznania i nierozpoznania stanu obiektu są nowatorskie i mają duże znaczenie praktyczne.

BIBLIOGRAFIA

1. Będkowski L., Dąbrowski T.: *Podstawy eksploatacji, cz. 2*. Wyd. WAT, Warszawa 2006, str. 187.
2. Duer S.: *Artificial Neural Network-based technique for operation process control of a technical object*. Defence Science Journal, 2009, Vol. 59, No. 3, May, pp. 305-313.
3. Duer S., Duer R.: *Diagnostic system with an artificial neural network which determines a diagnostic information for the servicing of a repairable technical object*. Neural Computing & Applications, 2010, Vol. 19, No. 5, pp. 755-766.
4. Duer S.: *Investigation of the operation process of a repairable technical object in an expert servicing system with an artificial neural network*. Neural Computing & Applications, 2010, Vol. 19., No. 5., pp. 767-774.
5. Duer S.: *Diagnostic system with an artificial neural network in diagnostics of an analogue technical object*. Neural Computing & Applications, 2010, Vol. 19., No. 1., pp. 55-60.
6. Duer S.: *Expert knowledge base to support maintenance of a radar system*. Defence Science Journal, 2010, Vol. 60, No. 5., pp. 531-540.
7. Duer S.: *Qualitative evaluation of the regeneration process of a technical object in a maintenance system with an artificial neural network*. Neural Computing & Applications. 2011, Vol. 20, No. 5, pp. 741-752.
8. Duer S.: *Assessment of the quality of decisions worked out by an artificial neural network which diagnoses a technical object*. Neural Computing & Applications. 2011, DOI: 10.1007/s00521-011-0725-0. <http://www.springerlink.com/openurl.asp?genre=article&id=doi:10.1007/s00521-011-0725-0>
9. Duer S.: *Modelling of the operation process of repairable technical objects with the use information from an artificial neural network*. Expert Systems With Applications. 38 2011, pp. 5867-5878. <http://dx.doi.org/10.1016/j.eswa.2010.11.036>.
10. Duer S.: *Examination of the reliability of a technical object after its regeneration in a maintenance system with an artificial neural network*. Neural Computing & Applications. 2011, DOI 10.1007/s00521-011-0723-2 <http://www.springerlink.com/openurl.asp?genre=article&id=doi:10.1007/s00521-011-0723-2>.

11. Duer S.: *Applications of an artificial intelligence for servicing of a technical object*. Neural Computing & Applications. 2011, DOI: 10.1007/s00521-011-0788-y.
12. Duer S. *Inteligentny system wspomagający proces odnawiania cech eksploatacyjnych w złożonych obiektach technicznych*. Wydawnictwo Politechniki Koszalińskiej. Koszalin 2012, str. 242.
13. Nakagawa T.: *Maintenance Theory of Reliability*. Springer – Verlag London Limited, 2005, p. 264.
14. Palkova Z., Okenka I.: *Programovanie*. Slovak University of Agriculture in Nitra, 2007, p. 203.
15. Palkova Z.; *Modeling the optimal capacity of an irrigation system using queuing theory*. Warszawa : Warsaw University of Life Sciences Press. No. 55 (2010), pp. 5-11.

THE RISK ASSESSMENT WHEN DECIDING IN THE INTELLIGENT SYSTEMS

Abstract

The article provides an analytical basis for assessing uncertainties in intelligent decision support systems. Presents the basis for assessing the reliability of information in intelligent systems and the verification problems.

Autor:

Prof. nazw. dr hab. inż. Stanisław DUER – Politechnika Koszalińska, Wydział Mechaniczny, ul. Raławicka 15-17, 75-620 Koszalin, e-mail: stanislaw.duer@tu.koszalin.pl