

## Metody reprezentacji i pozyskiwania wiedzy w systemach diagnostycznych

### 1. Reprezentacja wiedzy w systemach diagnostycznych

Reprezentacja wiedzy w systemach diagnostycznych jest trudnym i ważnym, ale dotąd jeszcze nie w pełni rozwiązany problem. Dwie podstawowe formy reprezentacji wiedzy to forma symboliczna i niesymboliczna. Można je przedstawić za pomocą opisów, które zawierają pierwotne cechy i pojęcia zaprezentowane w danym języku, oraz relacji, które przedstawiają zależności i asocjacje pomiędzy faktami w bazie wiedzy.

Symboliczna reprezentacja wiedzy może przyjąć formę<sup>2</sup>:

- proceduralną – określa się w niej zbiór procedur, których działanie reprezentuje wiedzę w danej dziedzinie, charakteryzuje się dużą efektywnością reprezentowania procesów, ale wymaga dobrej znajomości funkcjonalnych powiązań między stanami procesów;
- deklaratywną – obejmuje reguły empiryczne jako środek reprezentujący relacje pomiędzy cechami warunków działania i symptomami stanu a cechami stanu obiektu, stanowi mniej precyzyjną formę reprezentacji wiedzy o stanie obiektu.

Reprezentacje niesymboliczne opierają się na obserwacjach i doświadczeniach zebranych z otaczającego świata. Wdraża się je za pomocą technik sztucznej inteligencji, do których można zaliczyć m.in.: sztuczne sieci neuronowe, algorytmy genetyczne, logikę rozmytą.

Proces organizacji wiedzy zebranej w bazie wiąże się z wyborem odpowiedniej metody reprezentacji wiedzy oraz weryfikacji bazy i mechanizmu

---

<sup>1</sup> Szkoła Główna Handlowa w Warszawie, Kolegium Analiz Ekonomicznych, Instytut Informatyki i Gospodarki Cyfrowej.

<sup>2</sup> M. Wyleżół, *Metody pozyskiwania procedur i relacji diagnostycznych od specjalistów w dziedzinie eksploatacji maszyn*, „Zeszyty Politechniki Śląskiej” 2000, z. 115.

wnioskowania. Do spotykanych w systemach diagnostycznych form reprezentacji wiedzy można zaliczyć przede wszystkim<sup>3</sup>:

- sieci semantyczne, określające relacje pomiędzy elementami dziedziny (węzłami sieci);
- trójki <obiekt, atrybut, wartość> jako szczególny przypadek sieci semantycznej;
- reguły wnioskowania, budowane w formie powiązań między grupą przesłanek i wynikającą z nich grupą konkluzji;
- warunki Horna, czyli wyrażenia w formie predykatów o strukturze zbliżonej do reguł wnioskowania z dodatkowymi restrykcjami (struktura reguły o jednym wniosku);
- ramy, grupujące dane i procedury w obiekty lub ramy;
- sieci neuronowe,
- logikę rozmytą.

Każda z tych form reprezentacji wiedzy może wiązać się w zadaniach diagnostycznych z dedykowanymi zastosowaniami oraz wyznaczać specyficzne cechy systemu diagnostycznego<sup>4</sup>. Znane są prace przedstawiające zastosowanie sieci neuronowych w systemach diagnostycznych, w których pełnią one rolę modeli diagnozowanych obiektów oraz klasyfikatorów analizowanych stanów obiektów<sup>5</sup>. W przypadku złożonych procesów przemysłowych dane, które pozyskuje się w czasie monitorowania, często charakteryzują się niepewnością i nieprecyzyjnością informacji o stanie procesu – w takich przypadkach wystarczającą jakość diagnozowania można uzyskać poprzez skonstruowanie bazy wiedzy z zastosowaniem reprezentacji opierającej się na logice rozmytej<sup>6</sup>.

---

<sup>3</sup> A.B. Badiru, J.Y. Cheung, *Fuzzy Engineering Expert Systems with Neural Network Applications*, John Wiley&Sons, Inc., New York 2002; M. Bazewicz, *Metody i techniki reprezentacji wiedzy w projektowaniu systemów*, Wydawnictwo Politechniki Wrocławskiej, Wrocław 1994.

<sup>4</sup> M. Damborg, L. Chen-Ching, *Artificial neural networks and expert systems in power system operations environment*, Proceedings of the 1992 Inns Summer Workshop: Neural Network Computing for the Electric Power Industry, Lawrence Erlbaum Associates, Publishers, Hillsdale 1993, s. 11–14.

<sup>5</sup> A. Pieczyński, *Reprezentacja wiedzy w diagnostycznym systemie ekspertowym*, Lubuskie Towarzystwo Naukowe, Zielona Góra 2003.

<sup>6</sup> A. Piegat, *Modelowanie i sterowanie rozmyte*, Akademicka Oficyna Wydawnicza EXIT, Warszawa 1999; R.R. Yager, D.P. Filev, *Podstawy modelowania i sterowania rozmytego*, WNT, Warszawa 1994; L.A. Zadeh, *Fuzzy probabilities and their role in decision analysis*, Proceedings of IFAC Symposium on Theory and Application of Digital Control, 5–7 January 1982, New Delhi, vol. 1, s. 5–11.

## 2. Pozyskiwanie wiedzy w systemach diagnostycznych

Proces akwizycji wiedzy obejmuje pozyskanie wolumenu wiedzy i doświadczenia, które odpowiadają zakresowi zadań systemu (danej dziedziny zastosowania) ze zidentyfikowanych źródeł wiedzy oraz zapisanie ich w bazie wiedzy w taki sposób, aby umożliwić skuteczne wspomaganie działania diagnosty podczas rozwiązywania problemów diagnostycznych z danego obszaru<sup>7</sup>.

Najistotniejsze źródła wiedzy to specjaliści-diagności, od których wiedzę pozyskuje się w sposób bezpośredni – poprzez ich udział w procesie akwizycji, lub w sposób pośredni – korzystając z profesjonalnej literatury<sup>8</sup>, oraz bazy danych, które zawierają wyniki obserwacji diagnozowanego obiektu (ich grupy) lub wyniki obliczeń symulacyjnych prowadzonych na podstawie odpowiedniego modelu. W drugim przypadku proces akwizycji wiedzy można realizować za pomocą metody indukcyjnej (maszynowej), opartej na przykładach sklasyfikowanych przez nauczyciela, oraz metody odkrywania zależności jakościowych i ilościowych (funkcyjnych) w bazach danych.

W metodzie indukcyjnej korzysta się z tzw. modelu atrybutowego, w którym dane uczące zapisywane są w jednym zbiorze jako wartości cech opisujących właściwości obiektu znajdującego się w zadanym stanie oraz wartości cechy decyzyjnej opisującej stan obiektu – przykładem takich podejść jest generowanie drzew decyzyjnych<sup>9</sup>, pozyskiwanie reguł oraz klasyfikatorów przybliżonych<sup>10</sup>, metody bazujące na sieciach neuronowych<sup>11</sup> oraz metody oparte na logice rozmytej<sup>12</sup>. W metodzie indukcyjnej realizuje się pozyskiwanie wiedzy już wcześniej

---

<sup>7</sup> W. Moczulski, *Metody pozyskiwania wiedzy dla potrzeb diagnostyki maszyn*, „Zeszyty Naukowe Politechniki Śląskiej – Mechanika” 1997, z. 130.

<sup>8</sup> M. Wyleżół, *Metody pozyskiwania wiedzy diagnostycznej od specjalistów*, V Krajowa Konferencja Naukowo-Techniczna „Diagnostyka procesów przemysłowych”, Łagów Lubuski, 17–19 września 2001, s. 233–236.

<sup>9</sup> J.R. Quinlan, *Programs for machine learning*, Morgan Kaufman, San Mateo 1993.

<sup>10</sup> W. Ziarko, N. Shan, *Database Mining Using Rough Sets*, Computer Science Department, University of Regina 1996.

<sup>11</sup> A. Allesandr, M. Delia, G. Graffione, T. Parissini, *Nonlinear Fault Detection by a Bank of Neural Estimators*, 4<sup>th</sup> IFAC Symposium on Fault Detection Supervision and Safety, Budapest, 14–16 June 2000, vol. 1, s. 440–445; J. Korbicz, *Sztuczne sieci neuronowe i ich zastosowanie w diagnostyce procesów przemysłowych*, „Pomiary, Automatyka, Kontrola” 1998, nr 4, s. 129–133.

<sup>12</sup> A. Pieczyński, *Diagnostyka obiektów przemysłowych z rozmytą bazą wiedzy*, III Krajowa Konferencja Naukowo-Techniczna „Diagnostyka procesów przemysłowych”, Jurata, 7–10 września 1998, s. 125–130.

odkrytej (w przeciwieństwie do jej akwizycji z baz danych, kiedy to pozyskuje się nową wiedzę), a celem procesu maszynowego uczenia się jest odpowiednia reprezentacja wiedzy w bazie. Źródłem użytecznej wiedzy o relacjach diagnostycznych mogą być diagnostyczne bazy danych – zawierają one bowiem wartości cech opisujących wejścia i wyjścia diagnozowanych obiektów, a odkrywanie wiedzy polega tutaj na poszukiwaniu regularności występujących w określonym zbiorze danych.

Jak wcześniej nadmieniono, proces pozyskiwania wiedzy z baz danych polega na pozyskiwaniu nowej wiedzy – na jej odkrywaniu. Odkrywanie wiedzy w bazach danych stanowi „nietrywialny proces identyfikowania ważnych, nowych, potencjalnie użytecznych i zrozumiałych wzorców w danych”<sup>13</sup>. Rozwój sztucznej inteligencji pozwolił na pojawienie się nowej dziedziny automatycznego odkrywania wiedzy w bazach danych i jej technologii eksploracji danych – jako jednego z elementów odkrywania wiedzy.

Operacje realizowane podczas procesu odkrywania wiedzy są następujące:

- wstępna selekcja danych pod kątem poszukiwanej wiedzy,
- przygotowanie danych – uzupełnienie braków oraz standaryzacja różnych formatów przechowywanych danych, a także ich odsumianie (czyszczenie),
- transformacja danych – konwersja danych na formę akceptowalną przez zastosowany system wydobywania wiedzy,
- eksploracja – poszukiwanie schematów, wykonywane przy wykorzystaniu różnych metod,
- prezentacja wiedzy – pozyskana wiedza może podlegać wizualizacji lub dalszej analizie w dowolnym programie wspomagającym wnioskowanie<sup>14</sup>.

W szerszym rozumieniu dziedzina eksploracji danych obejmuje część procesu transformacji oraz procedury eksploracji i prezentacji. Proces eksploracji danych ma dwa cele:

- przewidywanie – obejmuje zadanie wykorzystania określonych danych do prognozowania wartości innych zmiennych;
- opisywanie – polega na poszukiwaniu możliwych do zinterpretowania przez człowieka wzorców opisujących dane<sup>15</sup>.

---

<sup>13</sup> J.M. Żytkow, R. Zembowicz, *Database exploration in search of regularities*, „Journal of Intelligent Information Systems” 1993, vol. 2.

<sup>14</sup> G. Williams, M. Hegland, S. Roberts, *A Data Mining Tutorial*, Second IASTED International Conference on Parallel and Distributed Computing and Networks, Brisbane, 14–16 December 1998.

<sup>15</sup> A. Pieczyński, *Reprezentacja wiedzy...*

Do najczęstszych technik eksploracji danych, których wybór zależy od typu danych przechowywanych w bazie oraz od schematów zdefiniowanych przez użytkownika, należą<sup>16</sup>:

- klasyfikacja – polega na przyporządkowaniu klasyfikowanego elementu do klasy, do której odległość jest minimalna; można ją realizować w formie binarnej i wieloklasowej<sup>17</sup>. Wśród algorytmów klasyfikacji wyróżnia się<sup>18</sup>:
  - klasyfikację rozmytą – wyznacza się tutaj stopień przynależności każdego klasyfikowanego elementu do danej klasy,
  - klasyfikację dokładną – określa się oznaczenie klasy, do której dany element został zakwalifikowany (szczególna postać klasyfikacji rozmytej);
- regresja – polega na wyznaczeniu parametrów funkcji liniowej lub nieliniowej, która dla określonej danej wyznacza wartość typu rzeczywistego;
- grupowanie pojęciowe – stosowane do znalezienia skończonego zbioru klas obiektów w bazie danych posiadających podobne cechy;
- kojarzenie (asocjacja) – poszukiwanie elementów, które wiążą się z zadaniem zdarzeniem lub innym elementem; stosowane w tym celu algorytmy pozwalają wyznaczyć reguły wiążące te elementy.

Klasyfikacja i regresja są technikami eksploracji danych wykorzystywanymi najczęściej do tworzenia prognoz, natomiast grupowanie i kojarzenie – do opisu procesów zdefiniowanych za pomocą eksplorowanej bazy.

Każdy z przedstawionych algorytmów eksploracji danych składa się z:

- reprezentacji modelu, która zawiera możliwe do odkrycia wzorce;
- oceny jakości modelu otrzymanego w procesie odkrywania wiedzy;
- poszukiwania – zarówno parametrów, jak i modeli.

Metody stosowane w różnych algorytmach eksploracji danych nasuwają podział algorytmów na: drzewa decyzyjne, regresję liniową, nieliniową i klasyfikację, wnioskowanie z przykładów, probabilistyczne modele graficznej zależności oraz relacyjne metody uczenia<sup>19</sup>.

Problematyka akwizycji wiedzy z baz danych obejmuje odkrywanie zarówno ilościowych, jak i jakościowych zależności między atrybutami opisującymi diagnozowany obiekt. Wyznaczone w procesie odkrywania wiedzy zależności

<sup>16</sup> Ibidem.

<sup>17</sup> W. Cholewa, G. Urbanek, *Grupowanie i klasyfikacja elementów wielowymiarowych przestrzeni cech sygnałów diagnostycznych*, II Międzynarodowy Kongres Diagnostyki Technicznej „Diagnostyka 2000”, Warszawa, 19–22 września 2000.

<sup>18</sup> W. Pedrycz, *Conditional fuzzy clustering in the design of radial basis function neural networks*, „IEEE Transactions on Neural Networks” 1998, vol. 9, s. 601–612.

<sup>19</sup> A. Pieczyński, *Reprezentacja wiedzy...*

funkcjonalne można wykorzystać do prognozowania wewnętrznych stanów diagnozowanych systemów<sup>20</sup>.

Wyniki badań pozwalają stwierdzić, że odkrywanie wiedzy w bazach danych może być bardzo użyteczne do pozyskania wiedzy potrzebnej w procesie diagnostycznym. Stosując odpowiednie procedury wobec obszernych baz danych, można uzyskać wiedzę obejmującą szerokie obszary, o dużej wartości, akceptowalności i zrozumiałości dla człowieka. Cechy te wpływają na możliwość automatyzacji procesu wydobywania wiedzy. W celu uzyskania efektywnego systemu diagnostycznego proponuje się zastosowanie zróżnicowanych zintegrowanych form reprezentacji wiedzy<sup>21</sup>.

### 3. Zastosowanie sieci neuronowych i zbiorów rozmytych w wydobywaniu wiedzy i diagnostyce

Według A. Pieczyńskiego stosowanie **sięci neuronowych** w diagnostyce wiąże się z następującymi zadaniami:

- definiowaniem listy nieprawidłowości,
- wyznaczeniem typowych obrazów dla poszczególnych nieprawidłowości i stanu normalnego,
- wyborem struktury sieci i algorytmu uczenia,
- uczeniem sieci na bazie obrazów uczących,
- testowaniem sieci dla dowolnych stanów systemu<sup>22</sup>.

Do przykładowych zastosowań sieci neuronowych w przemyśle można zaliczyć m.in. system eksploatacji i konserwacji elektrociepłowni w bazach US Navy czy system prognozowania zapotrzebowania na energię użytkowany w elektrowni BC Aydro w Vancouver.

Sieci neuronowe stosuje się z sukcesem także przy wydobywaniu wiedzy z baz danych w zadaniach regresji i klasyfikacyjnych. Mają one jednak dosyć istotny mankament: są postrzegane jako czarne skrzynki, toteż mają nieczytelną

---

<sup>20</sup> W. Moczulski, D. Wachla, *Acquisition of diagnostic knowledge using discoveries in databases*, V Krajowa Konferencja Naukowo-Techniczna „Diagnostyka procesów przemysłowych”, Łagów Lubuski, 17–19 września 2001, s. 219–224.

<sup>21</sup> A. Pieczyński, *Reprezentacja wiedzy...*

<sup>22</sup> A. Pieczyński, W. Kastner, R. Hampel, *Fuzzy modelling of multidimensional non-linear processes – design and analysis of structures*, Proceedings of 7<sup>th</sup> Zittau Fuzzy Colloquium, Zittau, 8–10 September 1999, s. 85–101.

reprezentację wiedzy o wykrytych i zakodowanych powiązaniach między danymi w bazie. W celu zniwelowania tej wady proponuje się stosowanie różnych algorytmów, zdolnych do wydobywania symbolicznych reguł z utworzonej sieci neuronowej. Dobrą skuteczność wydobywania wiedzy z baz danych uzyskuje się przy zastosowaniu systemów hybrydowych. Ciekawym rozwiązaniem jest rozwiązanie wzorowane na procesie myślowym człowieka, w którym proponuje się zintegrowane działanie sieci neuronowej z systemem rozumowania opartego na pamięci MBR (*Memory-Based Reasoning*)<sup>23</sup>. W ten sposób zintegrowana struktura wynika z procesu myślowego ludzkiego mózgu, który jest wspierany pamięcią i strukturami sieci neuronów z wagami określonymi w procesie uczenia<sup>24</sup>.

Uzyskanie dobrej jakości modelu utrudnia dodatkowo wybór odpowiednich ciągów uczących, a niewłaściwie dobrane ciągi uczące skutkują tym, że uzyskany model wykazuje wrażliwość bardzo różniącą się od rzeczywistego systemu, a przy tym dobre wyniki testów zgodności. Jest to zwykle następstwem nieprawidłowego skomponowania ciągów uczących. Przy budowie modelu neuronowego istotna jest także wrażliwość modelu na poszczególne sygnały wejściowe<sup>25</sup>.

Względnie nowe podejście do jakościowych technik diagnostycznych opiera się na zastosowaniu **logiki rozmytej**<sup>26</sup>, obejmującej ostatnio coraz więcej obszarów. Można zauważyć szybki rozwój technik wydobywania wiedzy i diagnozowania procesów przy jej wykorzystaniu<sup>27</sup>. Procesy diagnostyczne opierają się nierzadko na wiedzy heurystycznej skorelowanej z rozmytą reprezentacją sygnałów opisujących stan diagnozowanego systemu<sup>28</sup>. Rozmytą reprezentację wiedzy można

---

<sup>23</sup> C.K. Shin, S.J. Yu, U.T. Yun, H.K. Kim, *A hybrid approach of neural network and memory based learning to data mining*, „IEEE Transactions on Neural Networks” 2000, vol. 11, no. 3, s. 637–646.

<sup>24</sup> A. Pieczyński, *Reprezentacja wiedzy...*

<sup>25</sup> S. Kornacki, A. Jankowska, *Neuronowe modele w monitorowaniu emisji toksyn*, V Krajowa Konferencja Naukowo-Techniczna „Diagnostyka procesów przemysłowych”, Łągow Lubuski, 17–19 września 2001, s. 157–160.

<sup>26</sup> Por. np.: J.M. Kościelny, *Zastosowanie logiki rozmytej w diagnostyce procesów przemysłowych*, Materiały IV Krajowej Konferencji „Diagnostyka techniczna urządzeń i systemów” DIAG’98, Szczecin – Międzyzdroje – Ystad, 14–18 września 1998, s. 235–242; J. Montmain, S. Gentil, *Decision-making in fault detection: A fuzzy approach*, TOOLDIAG’93, Proceedings of International Conference on Fault Diagnosis, Toulouse, 5–7 April 1993, s. 653–660; A. Pieczyński, *Zastosowanie modeli rozmytych w diagnozowaniu procesów spalania w zespole kocioł-turbina*, IV Krajowa Konferencja Naukowo-Techniczna „Diagnostyka procesów przemysłowych”, Kazimierz Dolny, 13–16 września 1999, s. 163–166.

<sup>27</sup> A. Pieczyński, *Reprezentacja wiedzy...*

<sup>28</sup> Por. np.: M. Ayoubi, *Fuzzy systems design based on a hybrid neural structure and application to the fault diagnosis of technical processes*, „Control Engineering Practice” 1996, vol. 4, no. 1, s. 35–42; P.P. Bonissone, V. Badami, K.H. Chiang, P.S. Jhedkar, K.W. Marcelle,

stosować w realizacji różnych zadań diagnostycznych<sup>29</sup>, np. na etapie wstępnym diagnozy spotyka się rozmytą reprezentację wartości zmiennych procesowych, co pozwala prowadzić diagnozowanie przy użyciu doradczych systemów ekspertowych<sup>30</sup>, bardziej elastycznych niż system diagnostyczny oparty na binarnych macierzach diagnostycznych<sup>31</sup>. Jednak w diagnostyce złożonych procesów taka reprezentacja wiedzy zazwyczaj nie jest wystarczająca<sup>32</sup>.

W obszarze wydobywania wiedzy w oparciu o logikę rozmytą buduje się metody klasyfikacji i grupowania cech analizowanych danych. Do znanych metod można zaliczyć metodę FCM (*Fuzzy C-Means*), realizującą zadanie klasyfikacji cech poprzez zdefiniowanie stopnia przynależności każdego punktu do analizowanych klastrów, natomiast zadanie grupowania danych można wykonać przy wykorzystaniu rozmytych sieci Kohonena (*Fuzzy Kohonen Nets*, FKN)<sup>33</sup>.

W systemach diagnostycznych rozmytą reprezentację wiedzy można stosować do realizacji m.in. następujących zadań diagnostycznych:

- prowadzenia procesu diagnozowania z wykorzystaniem doradczych systemów ekspertowych, gdy stosuje się rozmytą reprezentację zmiennych procesowych;
- wydzielenia stref odpowiadających prawidłowemu, nieprawidłowemu i niepewnemu funkcjonowaniu systemu, za pomocą rozmytej reprezentacji residuów;
- budowania macierzy diagnostycznych z rozmytą reprezentacją powiązań symptom – nieprawidłowość, jeżeli rozmyta reprezentacja jest wykorzystana do konstrukcji modelu diagnostycznego;

---

M.J. Schutten, *Industrial application of fuzzy logic at General Electric*, „Proceedings of the IEEE” 1995, vol. 83, no. 3, s. 450–465; J.M. Kościelny, M. Syfert, *Current Diagnostics of Power Boiler System with Use of Fuzzy Logic*, 4<sup>th</sup> IFAC Symposium on Fault Detection Supervision and Safety, Budapest, 14–16 June 2000, vol. 2, s. 681–686.

<sup>29</sup> Y. Ding, D. Wach, *A fuzzy diagnosis system for automatic classification of a coustic burst events in nuclear power plants*, Proceedings of IFAC Symposium on Fault Detection Supervision and Safety, Hull, 26–28 August 1997, vol. 2, s. 748–752; H. Furuta, *Comprehensive analysis for structural damage based upon fuzzy sets theory*, „Journal of Intelligent & Fuzzy Systems” 1993, vol. 1, s. 55–61.

<sup>30</sup> W. Cholewa, *Tablica ogłoszeń w diagnostycznych systemach doradczych*, „Pomiary, Automatyka, Kontrola” 1998, nr 4, s. 123–128; A. Pieczyński, *The application of the fuzzy neural detectors and fuzzy rule base for diagnostic process*, Proceedings of 6<sup>th</sup> Zittau Fuzzy Colloquium, Zittau, 3–4 September 1998, s. 147–152.

<sup>31</sup> J.M. Kościelny, *Diagnostyka zautomatyzowanych procesów przemysłowych*, Akademicka Oficyna Wydawnicza EXIT, Warszawa 2001.

<sup>32</sup> A. Pieczyński, *Reprezentacja wiedzy...*

<sup>33</sup> Ibidem.



- konstruowania modeli heurystycznych systemów w rozmytej reprezentacji wiedzy, co daje możliwość połączenia wiedzy eksperta z danymi<sup>34</sup>.

System diagnostyczny powinien charakteryzować się dużą niezawodnością działania, co oznacza co najmniej:

- wyprowadzanie prawidłowych konkluzji,
- minimalizowanie fałszywych komunikatów o nieprawidłowościach,
- odpowiednio krótki czas udzielania odpowiedzi.

W związku z powyższym warto rozważyć, czy taki system nie powinien mieć charakteru hybrydowego pod względem form reprezentacji wiedzy. Sieci neuronowe można wykorzystać do budowy modelu/modeli elementów składowych systemu, jednakże raczej w przypadku relatywnie mało złożonych systemów, gdyż przy systemach złożonych sieć musi być intensywnie uczona, przez co proces uczenia staje się trudny, a niekiedy nawet niemożliwy. Dla systemów złożonych zaleca się raczej dekompozycję systemu i stosowanie neuronowych wielomodeli, połączonych w różne struktury. Drugi obszar zastosowań sieci neuronowych w diagnostyce dotyczy konstrukcji klasyfikatorów stanu diagnozowanego systemu, ale i w tym przypadku sieci neuronowe mają ograniczone zastosowanie – w praktyce stwierdzono ich małą skuteczność w sytuacji nieprawidłowości wielokrotnych lub takich, które pojawiają się sekwencyjnie, co wymaga stosowania innych form reprezentacji wiedzy<sup>35</sup>.

#### 4. Podsumowanie

Z powodów nadmienionych powyżej coraz częściej rozpatruje się możliwość stosowania w systemach diagnostycznych reprezentacji wiedzy opartej na logice rozmytej. Za jej pomocą można skonstruować m.in. elastyczne tablice decyzyjne z określonymi poziomami ufności podejmowanych decyzji. Służą one także do budowy modeli dla systemów wielowymiarowych, co wymaga dużej ilości danych uczących w celu strojenia modelu, od jakości których – a w rezultacie od jakości modeli – zależy w dużym stopniu jakość procesu diagnozowania<sup>36</sup>.

---

<sup>34</sup> Por. W. Cholewa, op.cit.; J.M. Kościelny, *Metody detekcji uszkodzeń stosowane w diagnostyce procesów przemysłowych*, „Pomiary, Automatyka, Kontrola” 1998, nr 4, s. 134–139; J.M. Kościelny, *Diagnostyka...*; A. Pieczyński, *Reprezentacja wiedzy...*

<sup>35</sup> A. Pieczyński, *Reprezentacja wiedzy...*

<sup>36</sup> Ibidem.

Stosowanie metod sztucznej inteligencji w systemach diagnostycznych umożliwia poprawę jakości, efektywności i niezawodności procesów diagnostycznych. Można je wykorzystać do konstrukcji systemów sterowania, które tolerują w pewnym zakresie nieprawidłowości procesów, systemów diagnostyki zabezpieczeniowej oraz przewidywania stanów odbiegających od normy i zagrażających poprawnemu realizowaniu zadań diagnozowanego systemu<sup>37</sup>.

## Bibliografia

- Allesandr A., Delia M., Graffione G., Parissini T., *Nonlinear Fault Detection by a Bank of Neural Estimators*, 4<sup>th</sup> IFAC Symposium on Fault Detection Supervision and Safety, Budapest, 14–16 June 2000, vol. 1, s. 440–445.
- Ayoubi M., *Fuzzy systems design based on a hybrid neural structure and application to the fault diagnosis of technical processes*, „Control Engineering Practice” 1996, vol. 4, no. 1, s. 35–42.
- Badiru A.B., Cheung J.Y., *Fuzzy Engineering Expert Systems with Neural Network Applications*, John Willey&Sons, Inc., New York 2002.
- Bazewicz M., *Metody i techniki reprezentacji wiedzy w projektowaniu systemów*, Wydawnictwo Politechniki Wrocławskiej, Wrocław 1994.
- Bonissone P.P., Badami V., Chiang K.H., Jhedkar P.S., Marcelle K.W., Schutten M.J., *Industrial application of fuzzy logic at General Electric*, „Proceedings of the IEEE” 1995, vol. 83, no. 3, s. 450–465.
- Cholewa W., *Tablica ogłoszeń w diagnostycznych systemach doradczych*, „Pomiary, Automatyka, Kontrola” 1998, nr 4, s. 123–128.
- Cholewa W., Urbanek G., *Grupowanie i klasyfikacja elementów wielowymiarowych przestrzeni cech sygnałów diagnostycznych*, II Międzynarodowy Kongres Diagnostyki technicznej „Diagnostyka 2000”, Warszawa, 19–22 września 2000.
- Damborg M., Chen-Ching L., *Artificial neural networks and expert systems in power system operations environment*, Proceedings of the 1992 Inns Summer Workshop: Neural Network Computing for the Electric Power Industry, Lawrence Erlbaum Associates, Publishers, Hillsdale 1993, s. 11–14.
- Ding Y., Wach D., *A fuzzy diagnosis system for automatic classification of a coustic burst events in nuclear power plants*, Proceedings of IFAC Symposium on Fault Detection Supervision and Safety, Hull, 26–28 August 1997, vol. 2, s. 748–752.
- Furuta H., *Comprehensive analysis for structural damage based upon fuzzy sets theory*, „Journal of Intelligent & Fuzzy Systems” 1993, vol. 1, s. 55–61.

---

<sup>37</sup> Ibidem.

- Korbicz J., *Sztuczne sieci neuronowe i ich zastosowanie w diagnostyce procesów przemysłowych*, „Pomiary, Automatyka, Kontrola” 1998, nr 4, s. 129–133.
- Kornacki S., Jankowska A., *Neuronowe modele w monitorowaniu emisji toksyn*, V Krajowa Konferencja Naukowo-Techniczna „Diagnostyka procesów przemysłowych”, Łągów Lubuski, 17–19 września 2001, s. 157–160.
- Kościelny J.M., *Diagnostyka zautomatyzowanych procesów przemysłowych*, Akademicka Oficyna Wydawnicza EXIT, Warszawa 2001.
- Kościelny J.M., *Metody detekcji uszkodzeń stosowane w diagnostyce procesów przemysłowych*, „Pomiary, Automatyka, Kontrola” 1998, nr 4, s. 134–139.
- Kościelny J.M., *Zastosowanie logiki rozmytej w diagnostyce procesów przemysłowych*, Materiały IV Krajowej Konferencji „Diagnostyka techniczna urządzeń i systemów” DIAG’98, Szczecin – Międzyzdroje – Ystad, 14–18 września 1998, s. 235–242.
- Kościelny J.M., Syfert M., *Current Diagnostics of Power Boiler System with Use of Fuzzy Logic*, 4<sup>th</sup> IFAC Symposium on Fault Detection Supervision and Safety, Budapest, 14–16 June 2000, vol. 2, s. 681–686.
- Moczulski W., *Metody pozyskiwania wiedzy dla potrzeb diagnostyki maszyn*, „Zeszyty Naukowe Politechniki Śląskiej – Mechanika” 1997, z. 130.
- Moczulski W., Wachla D., *Acquisition of diagnostic knowledge using discoveries in databases*, V Krajowa Konferencja Naukowo-Techniczna „Diagnostyka procesów przemysłowych”, Łągów Lubuski, 17–19 września 2001, s. 219–224.
- Montmain J., Gentil S., *Decision-making in fault detection: A fuzzy approach*, TOOLDIAG’93, Proceedings of International Conference on Fault Diagnosis, Toulouse, 5–7 April 1993, s. 653–660.
- Pedrycz W., *Conditional fuzzy clustering in the design of radial basis function neural networks*, „IEEE Transactions on Neural Networks” 1998, vol. 9, s. 601–612.
- Pieczyński A., *Diagnostyka obiektów przemysłowych z rozmytą bazą wiedzy*, III Krajowa Konferencja Naukowo-Techniczna „Diagnostyka procesów przemysłowych”, Jurata, 7–10 września 1998, s. 125–130.
- Pieczyński A., *Reprezentacja wiedzy w diagnostycznym systemie ekspertowym*, Lubuskie Towarzystwo Naukowe, Zielona Góra 2003.
- Pieczyński A., *The application of the fuzzy neural detectors and fuzzy rule base for diagnostic process*, Proceedings of 6<sup>th</sup> Zittau Fuzzy Colloquium, Zittau, 3–4 September 1998, s. 147–152.
- Pieczyński A., *Zastosowanie modeli rozmytych w diagnozowaniu procesów spalania w zespole kocioł-turbina*, IV Krajowa Konferencja Naukowo-Techniczna „Diagnostyka procesów przemysłowych”, Kazimierz Dolny, 13–16 września 1999, s. 163–166.
- Pieczyński A., Kastner W., Hampel R., *Fuzzy modelling of multidimensional non-linear processes – design and analysis of structures*, Proceedings of 7<sup>th</sup> Zittau Fuzzy Colloquium, Zittau, 8–10 September 1999, s. 85–101.
- Pieगत A., *Modelowanie i sterowanie rozmyte*, Akademicka Oficyna Wydawnicza EXIT, Warszawa 1999.

- Qiunlan J.R., *Programs for machine learning*, Morgan Kaufman, San Mateo 1993.
- Shin C.K. Yu S.J., Yun U.T., Kim H.K., *A hybrid approach of neural network and memory based learning to data mining*, „IEEE Transactions on Neural Networks” 2000, vol. 11, no. 3, s. 637–646.
- Williams G., Hegland M., Roberts S., *A Data Mining Tutorial*, Second IASTED International Conference On Parallel and Distributed Computing and Networks, Brisbane, 14–16 December 1998.
- Wyleżół M., *Metody pozyskiwania procedur i relacji diagnostycznych od specjalistów w dziedzinie eksploatacji maszyn*, „Zeszyty Politechniki Śląskiej” 2000, z. 115.
- Wyleżół M., *Metody pozyskiwania wiedzy diagnostycznej od specjalistów*, V Krajowa Konferencja Naukowo-Techniczna „Diagnostyka procesów przemysłowych”, Łągow Lubuski, 17–19 września 2001, s. 233–236.
- Yager R.R., Filev D.P., *Podstawy modelowania i sterowania rozmytego*, WNT, Warszawa 1994.
- Zadeh L.A., *Fuzzy probabilities and their role in decision analysis*, Proceedings of IFAC Symposium on Theory and Application of Digital Control, New Delhi, 5–7 January 1982, vol. 1, s. 5–11.
- Ziarko W., Shan N., *Database Mining Using Rough Sets*, Computer Science Department, University of Regina 1996.
- Żytkow J.M., Zembowicz R., *Database exploration in search of regularities*, „Journal of Intelligent Information Systems” 1993, vol. 2.

\* \* \*

## **Methods of knowledge representation and acquisition in diagnostic systems**

### **Summary**

The aim of the article is to show the possibilities of representing and acquiring knowledge in order to implement it in diagnostic systems of artificial intelligence. Particular attention was also paid to neural networks and fuzzy sets used for knowledge extraction and diagnostics. The paper is a part of the project no. POIG.01.03.01–14–059/12.

**Keywords:** diagnostic systems, artificial intelligence, knowledge representation, knowledge acquisition