

# **ANALIZA SYSTEMOWA I ZARZĄDZANIE**

Książka jubileuszowa  
z okazji  
50-lecia pracy naukowej

**ROMANA KULIKOWSKIEGO**

Copyright © by Instytut Badań Systemowych PAN  
Warszawa 1999

**ISBN 83-85847-34-0**

Druk: "ARGRAF" Agencja Poligraficzno-Wydawnicza, Warszawa  
Skład: Barbara Kotuszewska

# PROCESY UCZENIA

## I METODA LOGICZNO-ALGEBRAICZNA

### W SYSTEMACH Z REPREZENTACJĄ WIEDZY

*Zdzisław Bubnicki*

*Institut Sterowania i Techniki Systemów  
Politechnika Wroclawska*

#### 1. Wstęp

Problematyka systemów wspomagających podejmowanie decyzji jest obecnie jednym z podstawowych działów ogólnej analizy systemowej, a zagadnienia związane z komputerową realizacją takich systemów stanowią ważny obszar w dziedzinie problemowo-zorientowanych systemów informatycznych. Interesujące i niełatwe problemy w tym zakresie formułowane są w szczególności dla systemów podejmowania decyzji z reprezentacją wiedzy. Niniejsze opracowanie dotyczy pewnej klasy takich systemów, w których statyczny obiekt podejmowania decyzji opisywany jest przez reprezentację wiedzy w formie relacji (relacyjna reprezentacja wiedzy) lub w formie zbioru faktów, tj. formuł logicznych podanych przez eksperta (logiczna reprezentacja wiedzy). Są to często występujące formy w komputerowych systemach ekspertowych [2], a w szczególności w systemach ekspertowych na potrzeby zarządzania [3].

Dla obiektu opisywanego tradycyjnym modelem funkcjonalnym  $y = \phi(x)$  problem decyzyjny może polegać na wyznaczeniu decyzji  $\bar{x}$  takiej, że  $\bar{y} = \phi(\bar{x})$  jest wymaganą wartością wyjścia. Dla obiektu opisywanego w formie rozpatrywanych tu reprezentacji wiedzy problem decyzyjny polega na wyznaczeniu **własności wejściowej** dotyczącej  $x$ , która implikuje wymaganą **własność wyjściową** dotyczącą  $y$ . Dla zadań analizy i podejmowania decyzji w systemach z logiczną reprezentacją wiedzy została opracowana tzw. **metoda logiczno-algebraiczna** [4+9], której idea polega na zastąpieniu indywidualnych koncepcji rozumowania bazujących na regułach dowodzenia przez zuniifikowane procedury algebraiczne bazujące na regułach algebry logiki. Rezultaty można traktować jak ujednoczenie i uogólnienie różnych indywidualnych algorytmów rozumowania dla rozpatrywanej klasy reprezentacji wiedzy. W pracach [10, 11, 12] przedstawiono koncepcje i algorytmy uczenia w różnych przypadkach z reprezentacją wiedzy zawierającą

nieznane parametry. Ogólna idea polega tu na walidacji i uaktualnianiu wiedzy na podstawie bieżących obserwacji i może być traktowana jak rozszerzenie tradycyjnej koncepcji adaptacji z wykorzystaniem bieżących rezultatów identyfikacji (np. [1]) na rozpatrywane przypadki niekonwencjonalnej reprezentacji wiedzy.

Celem obecnego opracowania jest uzupełnienie, ujednoczenie i uogólnienie rozpatrywanych wcześniej przypadków oraz ich ogólna charakterystyka nawiązująca do tradycyjnych koncepcji procesów uczenia w systemach podejmowania decyzji.

## 2. System z relacyjną reprezentacją wiedzy

Rozważmy system statyczny (styczny obiekt podejmowania decyzji), którego reprezentacja wiedzy ma formę relacji  $R(x, y, c) \in X \times Y$ , gdzie  $x \in X$  jest wektorem wejściowym,  $y \in Y$  – wektorem wyjściowym,  $c \in C$  – wektorem parametrów. Relacja ta może mieć postać zestawu nierówności, w których występują składowe wektorów  $x, y, c$ . Na przykład, dla systemu z  $k$  wejściami, jednym wyjściem i jednym parametrem

$$(x^{(1)})^2 + (x^{(2)})^2 + \dots + (x^{(k)})^2 + y^2 \leq c^2 \quad (1)$$

gdzie  $x = [x^{(1)} \ x^{(2)} \ \dots \ x^{(k)}]^T$ . Dla naszego systemu możemy sformułować następujący **problem podejmowania decyzji** (sterowania): Dla danego zbioru  $D_y \subset Y$  należy wyznaczyć największy zbiór  $D_x(c)$  taki, że spełniona jest implikacja

$$x \in D_x(c) \rightarrow y \in D_y$$

Własność  $y \in D_y$  określa wymaganie użytkownika. Łatwo zauważyć, że

$$D_x(c) = \{x \in X: D_y(x, c) \subseteq D_y\} \quad (2)$$

gdzie

$$D_y(x, c) = \{y \in Y: (x, y) \in R(x, y, c)\}$$

Załóżmy, że parametr  $c$  w reprezentacji wiedzy ma wartość  $c = \bar{c}$  i wartość ta jest nieznaną. Przez analogię do znanych koncepcji dla obiektów opisywanych w formie tradycyjnych modeli funkcjonalnych można zaproponować następujące koncepcje procesów uczenia.

## 2.1. Walidacja i uaktualnianie wiedzy o obiekcie w systemie otwartym

Idea polega na wykorzystaniu ciągu obserwacji

$$(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n), \bigwedge_i [(x_i, y_i) \in R(x, y, \bar{c})]$$

do estymacji nieznanego parametru  $\bar{c}$ . Po zakończeniu procesu obserwacji wyznacza się decyzję  $D_x(c)$  na podstawie rezultatu estymacji. W cytowanej literaturze jako oszacowanie  $\bar{c}$  zaproponowano brzeg  $\Delta_c(n)$  zbioru

$$D_c(n) = \{c \in C : \bigwedge_i [(x_i, y_i) \in R(x, y, c)]\}$$

w przypadku, gdy  $R(x, y, c)$  jest ciągłym i domkniętym obszarem w  $X \times Y$ .

W przykładzie (1)  $D_c(n) = [c_{min}, \infty)$  i  $\Delta_c(n) = \{c_{min}\}$ , gdzie

$$c_{min}^2 = \max_i (x_i^T x_i + y_i^2)$$

Jeśli punkty  $(x_i, y_i)$  pojawiają się losowo z  $R(x, y, \bar{c})$ , to przy pewnych dodatkowych założeniach można udowodnić, że  $\Delta_c(n)$  zdyga do  $\{\bar{c}\}$  z prawdopodobieństwem 1 – dla  $n \rightarrow \infty$ . Oszacowanie  $\Delta_c(n)$  można wyznaczać rekurencyjnie według algorytmu zawierającego dla kolejnych  $n$  walidację wiedzy i ewentualne jej uaktualnienie. Walidacja polega na sprawdzeniu warunku

$$\bigwedge_{c \in D_c(n-1)} [(x_n, y_n) \in R(x, y, c)]$$

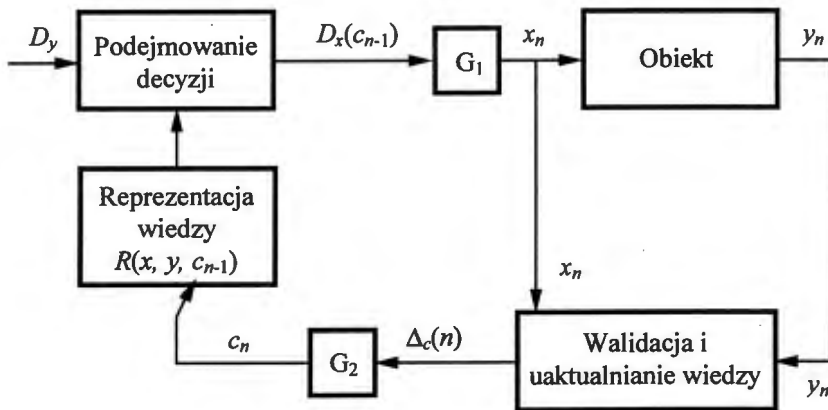
Jeśli warunek ten jest spełniony, to  $D_c(n) = D_c(n-1)$  i  $\Delta_c(n) = \Delta_c(n-1)$ . W przeciwnym razie następuje uaktualnienie wiedzy, tj. wyznaczenie nowego zbioru

$$D_c(n) = \{c \in D_c(n-1) : (x_n, y_n) \in R(x, y, c)\}$$

i wyznaczenie  $\Delta_c(n)$  jako brzegu  $D_c(n)$ . Po zakończeniu procesu uaktualniania wartość  $c_n$  może być wybrana losowo z  $\Delta_c(n)$  i wstawiona w miejsce  $\bar{c}$  do  $R(x, y, \bar{c})$  lub wprost do  $D_x(\bar{c})$ .

## 2.2. Walidacja i uaktualnianie wiedzy o obiekcie w systemie zamkniętym

Szacowanie  $\bar{c}$  może się odbywać na bieżąco dla kolejnych  $n$  w zamkniętym uczącym się systemie podejmowania decyzji (uczącym się systemie sterowania). Obecnie kolejne wartości  $x_n$  nie są losowane jak poprzednio, ale są wyznaczane jako decyzje na podstawie aktualnych wyników szacowania  $\bar{c}$ . W efekcie algorytm podejmowania decyzji jest następujący: Dla kolejnego  $n$  należy przeprowadzić walidację i ewentualnie uaktualnienie wiedzy oraz wyznaczyć  $\Delta_c(n)$  jak poprzednio, następnie wartość  $c_n$  wybraną losowo z  $\Delta_c(n)$  wstawić do  $D_x(c)$ , ze zbioru  $D_x(c_n)$  wybrać losowo decyzję  $x_{n+1}$ , którą należy podać na wejście obiektu. Para  $(x_{n+1}, y_{n+1})$  traktowana jest jako kolejny wynik obserwacji, dla którego wyznacza się następne oszacowanie. Schemat blokowy rozpatrywanego systemu decyzyjnego przedstawia rys. 1, na którym  $G_1$  i  $G_2$  oznaczają generatory liczb losowych. Dla konkretnego algorytmu należy zaproponować rozkłady prawdopodobieństwa, według których losuje się wartości  $c_n$  ze zbioru  $\Delta_c(n)$  oraz  $x_{n+1}$  ze zbioru  $D_x(c_n)$ .



Rys. 1

## 2.3. Walidacja i uaktualnianie wiedzy o podejmowaniu decyzji w systemie otwartym z nauczycielem

Realizacja tej koncepcji wymaga tzw. nauczyciela, który dla kolejnych wartości  $x_n$  stwierdza, czy  $x_n \in D_x(\bar{c})$ , tzn. czy dla decyzji  $x_n$  spełnione jest wymaganie  $y \in D_y$ . Problem szacowania  $\bar{c}$  można zatem rozważać jak problem rozpoznawania dla dwóch klas. Punkt  $x_{n+1}$  powinien być sklasyfikowany do klasy  $j=1$  jeśli  $x \in D_x(\bar{c})$  lub do klasy  $j=2$  jeśli  $x \notin D_x(\bar{c})$  – na podstawie ciągu uczącegogo

$$(x_1, j_1), (x_2, j_2), \dots, (x_n, j_n) = S_n \quad (3)$$

gdzie  $j_i \in \{1, 2\}$  jest rezultatem poprawnej klasyfikacji podanej przez nauczyciela. W pracy [11] jako oszacowanie  $\bar{c}$  zaproponowano zbiór

$$\bar{\Delta}_c(n) = \bar{D}_c(n) \cap \hat{D}_c(n)$$

gdzie

$$\bar{D}_c(n) = \{c \in C : \bar{x}_i \in D_x(c) \text{ dla każdego } \bar{x}_i \text{ w } S_n\}$$

$$\hat{D}_c(n) = \{c \in C : \hat{x}_i \in X - D_x(c) \text{ dla każdego } \hat{x}_i \text{ w } S_n\}$$

przez  $\bar{x}_i$  i  $\hat{x}_i$  oznaczono  $x_i$  w  $S_n$  dla którego odpowiednio  $j=1$  i  $j=2$ . Przy pewnych założeniach dotyczących rozkładu prawdopodobieństwa według którego losowo wybierane są wartości  $x_i$  z  $X$  można wykazać, że  $\bar{\Delta}_c(n)$  zdąży do  $\{\bar{c}\}$  z prawdopodobieństwem 1. Na przykład dla  $D_x(c)$  określonego nierównością

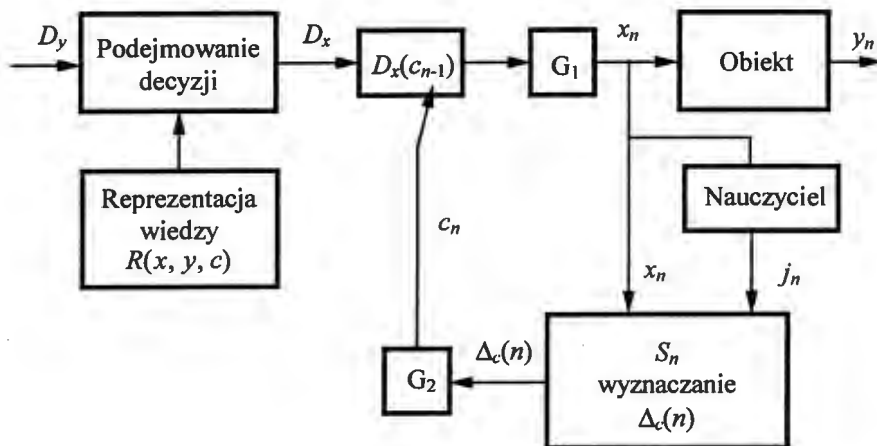
$$x^T x \leq \bar{c}^2$$

$$\bar{D}_c(n) = [c_{\min}, \infty), \quad \hat{D}_c(n) = [0, c_{\max}), \quad \Delta_c(n) = [c_{\min}, c_{\max})$$

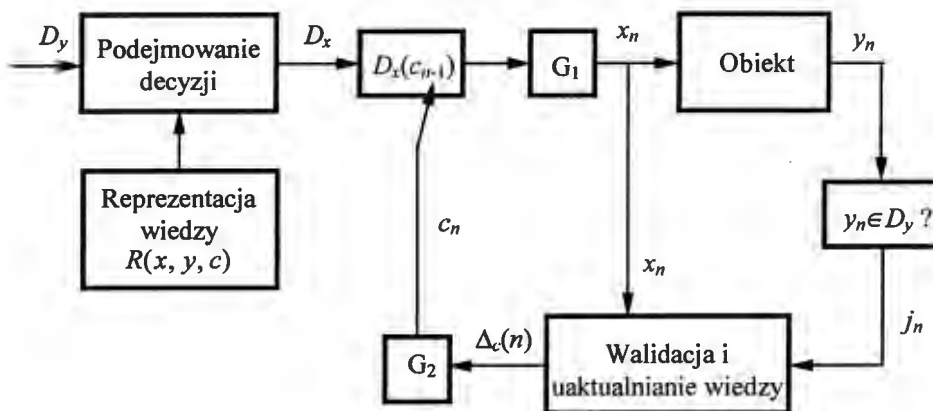
W odróżnieniu od koncepcji A – obecnie walidacji i ewentualnemu uaktualnianiu podlega wiedza o sposobie podejmowania decyzji, czyli zbiór  $D_x(c)$ . Algorytm rekurencyjny wyznaczania  $\bar{D}_c(n)$  i  $\hat{D}_c(n)$  jest analogiczny do algorytmu w przypadku A, w którym zamiast pary  $(x_n, y_n)$  występuje  $\bar{x}_n$  jeśli  $j=1$  lub  $\hat{x}_n$  jeśli  $j=2$  i zamiast zbioru  $R(x, y, c)$  w  $X \times Y$  występuje zbiór  $D_x(c)$  w  $X$ . Po zakończeniu procesu uczenia z końcowego zbioru  $\bar{\Delta}_c(n)$  należy wylosować  $c_n$  i wykorzystać do wyznaczania decyzji jak w przypadku A.

#### 2.4. Walidacja i uaktualnianie wiedzy o podejmowaniu decyzji w systemie zamkniętym z nauczycielem

Jest to koncepcja analogiczna do przypadku B. Obecnie kolejne wartości  $x_{n+1}$  są wyznaczane jako decyzje na podstawie aktualnych wyników szacowania  $\bar{c}$ , czyli są losowane ze zbioru  $D_x(c_n)$  dla aktualnej wartości  $c_n$  (rys. 2).



Rys. 2



Rys. 3

### 2.5. Walidacja i uaktualnianie wiedzy o podejmowaniu decyzji w systemie otwartym i zamkniętym bez nauczyciela

Koncepcje te można zrealizować wówczas, gdy możliwe jest testowanie własności  $y_i \in D_y$ . Dla stwierdzenia, czy  $x_i$  jest poprawną decyzją (tj. czy  $j_i=1$ ) należy podać  $x_i$  na wejście obiektu i stwierdzić, czy  $y_i \in D_y$ . Obiekt generujący  $y_i$  wraz z weryfikatorem własności  $y_i \in D_y$  zastępują tu nauczyciela podającego wartości  $j_i$  dla kolejnych  $x_i$  w ciągu uczącym (3). Algorytmy w systemie otwartym



i zamkniętym są tu takie, jak w przypadkach C i D z własnościami  $y_n \in D_y$  i  $y_n \notin D_y$  w miejsce bezpośrednio podawanych przez nauczyciela wartości  $j_n=1$  i  $j_n=2$ . Schemat blokowy systemu zamkniętego ilustruje rys. 3.

### 3. System z logiczną reprezentacją wiedzy

Dla systemu z relacyjną reprezentacją wiedzy w formie układu równości i nierówności wyznaczenie obszaru  $D_x(c)$  może być bardzo trudne i nie można tu sformułować uniwersalnego algorytmu. Algorytm taki może być sformułowany dla klasy systemów z tzw. relacyjną reprezentacją wiedzy w postaci zestawu faktów (formuł logicznych w logice 2-wartościowej) dotyczących  $x, y, c$  i ewentualnie wielkości pomocniczych. Wprowadzimy następujące oznaczenia:

$\alpha_{x_i}(x, c)$  – formuła elementarna (elementarna własność) dotycząca  $x$  i  $c$ ;

$$i=1, 2, \dots, n_1, \text{ np. } \alpha_{x_1}(x, c) = "x^T x \leq c^T c".$$

$\alpha_{w_r}(x, y, w, c)$  – formuła elementarna dotycząca  $x, y, w, c$ ;  $r=1, 2, \dots, n_2, w$

jest wektorem pomocniczych wielkości w reprezentacji wiedzy.

$\alpha_{y_s}(y, c)$  – formuła elementarna dotycząca  $y$  i  $c$ ;  $s=1, 2, \dots, n_3$ .

$\alpha_x = (\alpha_{x_1}, \dots, \alpha_{x_{n_1}})$ ,  $\alpha_w = (\alpha_{w_1}, \dots, \alpha_{w_{n_2}})$ ,  $\alpha_y = (\alpha_{y_1}, \dots, \alpha_{y_{n_3}})$ .

$\alpha = (\alpha_x, \alpha_w, \alpha_y)$  – ciąg wszystkich formuł elementarnych.

$F_j(\alpha)$  –  $j$ -ty fakt podany przez eksperta. Jest to formuła logiczna utworzona

z podciągu formuł elementarnych za pomocą operacji logicznych:  $\vee, \wedge, \neg, \rightarrow$ ;

$j=1, 2, \dots, k$ . Na przykład  $F_1 = \alpha_1 \wedge \alpha_2 \rightarrow \alpha_4$ ,  $F_2 = \alpha_3 \vee \alpha_2$ , gdzie

$\alpha_1 = "x^T x \leq c^T c"$ ,  $\alpha_2 = "$ temperatura jest mała lub  $y^T y \leq 3"$ ,  $\alpha_3 = "$  $y^T y = w^T x + c^T c"$ ,  $\alpha_4 = "$  $y^T y \geq 2c^T c"$ .

$$F(\alpha) = F_1(\alpha) \wedge F_2(\alpha) \wedge \dots \wedge F_k(\alpha).$$

$F_x(\alpha_x)$  – własność wejściowa, tj. formuła utworzona z  $\alpha_x$ .

$F_y(\alpha_y)$  – własność wyjściowa.

$a_m \in \{0, 1\}$  – wartość logiczna  $\alpha_m$ ,  $m=1, 2, \dots, n$ ,  $n=n_1+n_2+n_3$ .

$$a = (a_1, a_2, \dots, a_n).$$

$F(a)$  – wartość logiczna  $F(\alpha)$ . Zakładamy prawdziwość faktów, tj.  $F(a)=1$ .

$\langle \alpha, F(\alpha) \rangle = RW$  (reprezentacja wiedzy w formie logicznej).

Logiczna reprezentacja wiedzy jest w istocie specyficzną formą relacyjnej reprezentacji wiedzy, w której faktom  $F_i$  odpowiadają relacje

$$R_i(x, y, w, c) = \{(x, y, w) \in X \times Y \times W: F_i(a) = 1\}, \quad i \in \overline{1, k}$$

$$R(x, y, c) = \{(x, y) \in X \times Y: \bigvee_{w \in W} [(x, y, w) \in \bigcap_{i=1}^k R_i]\}$$

natomiast własność wejściową i wyjściową można przedstawić w postaci

$$x \in D_x(c), \quad y \in D_y(c)$$

gdzie

$$D_x(c) = \{x \in X: F_x(a_x) = 1\}, \quad D_y(c) = \{y \in Y: F_y(a_y) = 1\} \quad (4)$$

**Problem podejmowania decyzji** można zatem sformułować następująco: Dla danej wymaganej przez użytkownika własności wyjściowej  $F_y(\alpha_y)$  należy wyznaczyć najlepszą własność wejściową  $F_x(\alpha_x)$ , dla której spełniona jest implikacja  $F_x \rightarrow F_y$ . Przez najlepszą własność  $F_x$  rozumiemy taką, która jest implikowana przez każdą inną  $F_x$  implikującą  $F_y$  (odpowiada jej największy zbiór  $D_x$ ). Można pokazać [7, 8], że wyznaczenie  $F_x$  sprowadza się do rozwiązania względem  $\alpha_x$  dwóch układów równań

$$\left. \begin{array}{l} F(a_x, a_w, a_y) = 1 \\ F_y(a_y) = 1 \end{array} \right\}, \quad \left. \begin{array}{l} F(a_x, a_w, a_y) = 1 \\ F_y(a_y) = 0 \end{array} \right\} \quad (5)$$

Jeśli  $S_{x1}$ ,  $S_{x2}$  oznaczają odpowiednio zbiory rozwiązań pierwszego i drugiego równania, to  $F_x$  jest zdeterminowane przez  $S_x = S_{x1} - S_{x2}$  w taki sposób, że  $\alpha_x \in S_x \leftrightarrow F_x(\alpha_x) = 1$ ; np. jeśli  $\alpha_x = (\alpha_{x1}, \alpha_{x2}, \alpha_{x3})$  i  $S_x = \{(1, 0, 1), (0, 1, 1)\}$ , to

$$F_x(\alpha_x) = (\alpha_{x1} \wedge \neg \alpha_{x2} \wedge \alpha_{x3}) \vee (\neg \alpha_{x1} \wedge \alpha_{x2} \wedge \alpha_{x3})$$

Tak więc rozwiązanie naszego problemu sprowadza się do rozwiązania równań algebraicznych (5), gdzie  $F$ ,  $F_y$  są wyrażeniami algebraicznymi w algebrze logiki dwuwartościowej. Jest to podstawowa idea **metody logiczno-algebraicznej**, któ-

rej istotnym składnikiem jest również zastosowanie dekompozycji w zbiorze faktów i w konsekwencji rekurencyjnej procedury wyznaczania  $S_x$ . Dekompozycja ta jest następująca:

$$F(a) = \bar{F}_1(\bar{a}_0, \bar{a}_1) \wedge \bar{F}_2(\bar{a}_1, \bar{a}_2) \wedge \dots \wedge \bar{F}_p(\bar{a}_{p-1}, \bar{a}_p) \wedge \dots \wedge \bar{F}_N(\bar{a}_{N-1}, \bar{a}_N)$$

gdzie  $a = (a_x, a_w, a_y)$ ,  $\bar{a}_0 = (a_x, a_y)$ ,  $\bar{F}_p$  jest koniunkcją wszystkich faktów zawierających zmienne z ciągu  $\bar{a}_{p-1}$ , natomiast  $\bar{a}_p$  jest ciągiem pozostałych zmiennych występujących w  $\bar{F}_p$  ( $p = 1, 2, \dots, N$ ). Wówczas zbiór  $\bar{S}_0$  wszystkich rozwiązań  $(a_x, a_y)$  równania  $F(a_x, a_w, a_y) = 1$  można wyznaczyć według formuły rekurencyjnej

$$\bar{S}_{p-1} = \{\bar{a}_{p-1} \in S_{p-1} : \bigvee_{\bar{a}_p \in \bar{S}_p} [\bar{F}_p(\bar{a}_{p-1}, \bar{a}_p) = 1]\}$$

gdzie  $S_p$  jest zbiorem wszystkich ciągów  $\bar{a}_p$ ,  $p = N, N-1, \dots, 1$ ;  $\bar{S}_N = S_N$ .

W konsekwencji

$$S_x = \{a_x : \bigvee_{a_y \in S_y} (a_x, a_y) \in \bar{S}_0\} - \{a_x : \bigvee_{a_y \notin S_y} (a_x, a_y) \in \bar{S}_0\}$$

gdzie

$$S_y = \{a_y : F_y(a_y) = 1\}$$

Dokładniejszy opis tej metody wraz z przykładami, różnymi wersjami algorytmów oraz dedukcyjną i systemową interpretacją dekompozycji znaleźć można w cytowanej literaturze. Obecnie zwrócimy jedynie uwagę na to, że metodę tę można połączyć z przedstawionymi poprzednio metodami i procesami uczenia w przypadku nieznanymi parametrów  $c$ . Dotyczy to oczywiście przypadków C, D, i E, tj. walidacji i uaktualniania wiedzy o podejmowaniu decyzji. Algorytmy uczenia i podejmowania decyzji są takie same jak poprzednio, natomiast wyznaczanie  $D_x(c)$  na podstawie (2) – trudne i wymagające indywidualnych specyficznych algorytmów dla konkretnych postaci  $R$  – zastępuje się jednolitym uniwersalnym algorytmem wyznaczania  $F_x$  (i w konsekwencji  $D_x$ ), opartym na metodzie logiczno-algebraicznej. Z drugiej strony możliwości formułowania własności wejściowych i wyjściowych, czyli zbiorów  $D_x$  i  $D_y$  są tu ograniczone do takich, które mogą być sformułowane w postaci formuł logicznych  $F_x$  i  $F_y$  z użyciem formuł elementarnych  $\alpha_x$  i  $\alpha_y$  występujących w reprezentacji wiedzy.

#### 4. Charakterystyka ogólna i uwagi końcowe

Zestawienie w jednolitych ramach podstawowych koncepcji procesów uczenia w systemach podejmowania decyzji z relacyjną i logiczną reprezentacją wiedzy pozwala na następującą ogólną charakterystykę dotyczącą związków z koncepcjami tradycyjnymi oraz porównania różnych koncepcji:

1. Niezależnie od stosowanej terminologii (systemy adaptacyjne, uczące się, inteligentne itp.), rozpatrywane w różnych okresach i przez różnych autorów tzw. procesy uczenia (lub uczenia się) w systemach podejmowania decyzji sprowadzają się do czterech podstawowych idei: pasywnego lub aktywnego uaktualniania wiedzy o obiekcie podejmowania decyzji lub o sposobie podejmowania decyzji.

W tradycyjnych systemach adaptacyjnych uaktualnianie wiedzy o obiekcie oznacza tradycyjnie rozumianą identyfikację obiektu. W przypadku pasywnym podejmowanie decyzji następuje po zakończeniu procesu identyfikacji na podstawie rezultatów tej identyfikacji. W przypadku aktywnym kolejne wejścia obiektu wyznaczane są na podstawie aktualnych wyników identyfikacji (adaptacja z bieżącą identyfikacją). Dla rozpatrywanych w tej pracy niekonwencjonalnych opisów obiektu w formie relacyjnej reprezentacji wiedzy są to przypadki 2.1 i 2.2 przedstawione w p. 2.

W systemach tradycyjnych sposób podejmowania decyzji oznacza regułę decyzyjną, a jego polepszanie w rozpatrywanym tu problemie parametrycznym oznacza odpowiednią zmianę parametrów tej reguły. Może się to odbywać z tzw. nauczycielem („uczenie na przykładach”) lub z obiektem („uczenie na błędach”). W obu przypadkach możliwy jest sposób pasywny oraz aktywny (adaptacja poprzez strojenie reguły decyzyjnej). Dla rozpatrywanych w tej pracy obiektów są to odpowiednio przypadki 2.3 i 2.4 oraz przypadek 2.5 obejmujący dwie wersje: pasywną i aktywną.

2. Powyższe zestawienie pokazuje, że procesy uczenia w systemach podejmowania decyzji mogą być rozważane w sposób jednolity dla różnych form reprezentacji wiedzy o obiekcie lub o sposobie podejmowania decyzji. Rozpatrywaną tu relacyjną i logiczną reprezentację wiedzy można traktować jak uogólnienie przypadku klasycznego, w którym reprezentacja wiedzy ma postać tradycyjnego modelu funkcjonalnego. Różnym formom reprezentacji wiedzy muszą odpowiadać adekwatnie sformułowane zadania decyzyjne. Zestawione w pracy przypadki i dotyczące ich uwagi można łatwo rozszerzyć dla sytuacji w której wykorzystuje się wynik obserwacji dodatkowych wielkości wejściowych  $z$ . W przypadku tradycyjnym reprezentacja wiedzy jest modelem funkcjonalnym podającym zależność  $y$  od  $x$  i  $z$ . W przypadku relacyjnym jest to relacja pomiędzy  $x, z, y$  natomiast wynikiem obserwacji jest zbiór  $D_z$ . Dla logicznej reprezentacji wiedzy własność zaobserwowaną  $z \in D_z$  wyraża się w formie formuły logicznej  $F_z(\alpha_z)$ ,

gdzie  $\alpha_z$  oznacza ciąg formuł elementarnych dotyczących  $z$ , występujących w faktach, które składają się na reprezentację wiedzy. Wszystkie rozważania można uogólnić na przypadek dynamicznej reprezentacji wiedzy, w której relacje lub fakty dotyczą wyjścia, wejścia i stanu w kolejnych momentach [17].

3. Wyniki badań symulacyjnych pokazują na ogół wyższość wersji aktywnej nad pasywną (podobnie jak w przypadku tradycyjnym) przy odpowiednim sformułowaniu wskaźnika jakości dla ustalonego czasu trwania całej procedury. Komplikuje się natomiast problem zbieżności. W licznych badaniach symulacyjnych nie stwierdzono wprawdzie niezbieżności, ale nie udało się dotąd udowodnić zbieżności przy odpowiednich założeniach dotyczących rozkładów prawdopodobieństwa - podobnych do założeń w dowodach zbieżności dla wersji pasywnej.

4. W rozpatrywanych przykładach stwierdzono wyższość koncepcji walidacji i uaktualniania wiedzy o podejmowaniu decyzji (przypadki 2.3, 2.4 i 2.5) nad odpowiednimi przypadkami dotyczącymi wiedzy o obiekcie. Jest to dość oczywista ogólna prawidłowość w sytuacji, gdy sposób podejmowania decyzji został uzyskany na podstawie znanej formy reprezentacji wiedzy o obiekcie. Wówczas niepełna informacja o obiekcie (w naszym przypadku nieznaną parametr  $c$ ) "przenosi się" do reprezentacji wiedzy o sposobie podejmowania decyzji (w naszym przypadku  $D_x(c)$ ). Inne podejście polega na przyjęciu pewnej standardowej formy reprezentacji wiedzy o podejmowaniu decyzji bez sformułowania wiedzy o obiekcie. Nie ma wówczas podstaw do ogólnych stwierdzeń dotyczących porównania z podejściami wymienionymi poprzednio. Typowe rozwiązanie tego typu dla przypadku tradycyjnego polega na zastosowaniu sieci neuronalnej w adaptacyjnym systemie sterowania (np. [18]).

Metoda logiczno-algebraiczna została wykorzystana do opracowania i realizacji dwóch systemów ekspertowych ogólnego przeznaczenia: CONTROL-LOG i CLASS-LOG. Rozważania przedstawione w pracy pokazują w jaki sposób rozbudować można te systemy przez dodanie podprogramów uczenia dla zadania podejmowania decyzji przy nieznanach parametrach w reprezentacji wiedzy. Zauważmy na koniec, że w rozpatrywanych przypadkach zakładaliśmy brak informacji apriorycznej o nieznanach parametrach. W pracach [12+16] przedstawiono koncepcję tzw. **zmiennej niepewnej** określonej zbiorem wartości i rozkładem pewności podanym przez eksperta oraz zastosowanie tego formalizmu w systemach podejmowania decyzji z relacyjną i logiczną reprezentacją wiedzy. Interesujące i pożyteczne wydaje się opracowanie metod i algorytmów uczenia przy założeniu, że nieznanne parametry są wartościami zmiennych niepewnych i dana jest informacja aprioryczna w postaci rozkładów pewności dla tych parametrów.

## Literatura

1. BUBNICKI Z.: *Identification of Control Plants*. Elsevier; New York, Oxford, Amsterdam, 1980.
2. BUBNICKI Z.: *Wstęp do systemów ekspertowych*. PWN, Warszawa, 1990.
3. BUBNICKI Z.: *Podstawy informatycznych systemów zarządzania*. WPWr, Wrocław, 1993.
4. BUBNICKI Z.: *Algebraic approach to some class of reasoning problems*. Proc. of IFIP Workshop on Automated Reasoning, Beijing, 1992, s. 12-16.
5. BUBNICKI Z.: *Decomposition of a system described by logical model*. W: *Cybernetics and Systems Research*, Vol. 1, World Scientific, London, New Jersey, 1992, s. 121-128.
6. BUBNICKI Z.: *Rekurencyjne algorytmy rozwiązywania zadań z reprezentacją wiedzy w systemie ekspertowym*. Archiwum Informatyki Teoretycznej i Stosowanej, T. 3, z. 1-4, 1991, s. 133-145.
7. BUBNICKI Z.: *Logic-algebraic foundations of a class of knowledge based control systems*. Proc. of the II World Automation Congress, Vol. 4, TSI Press, Montpellier, 1996, s. 89-94.
8. BUBNICKI Z.: *Logic-algebraic method for a class of knowledge based systems*. W: *Computer Aided Systems Theory*. Lecture Notes in Computer Science, Springer Verlag, 1997, s. 420-427.
9. BUBNICKI Z.: *Logic-algebraic method for knowledge-based relation systems*, W: *Systems Analysis, Modelling and Simulation*, 1998 (w druku).
10. BUBNICKI Z.: *Knowledge updating in a class of knowledge-based learning control systems*. Systems Science, Vol. 23, nr 4, 1997, s. 19-36.
11. BUBNICKI Z.: *Learning processes and logic-algebraic method in knowledge-based control systems*. W: *Progress in System and Robot Analysis and Control Design*, Springer Verlag 1998 (w druku).
12. BUBNICKI Z.: *Uncertain variables and learning algorithms in knowledge-based control systems*. Artificial Life and Robotics, Vol. 3, Japan, 1998 (w druku).
13. BUBNICKI Z.: *Logic-algebraic approach to a class of knowledge based fuzzy control systems*. Proc. of European Control Conference ECC 97, Vol. 1, Brussels, 1997.
14. BUBNICKI Z.: *Uncertain variables and logic-algebraic method in knowledge based systems*. Proc. of International Conference on Intelligent Systems and Control, Halifax, Acta Press, 1998, s. 135-139.
15. BUBNICKI Z.: *Uncertain variables and their applications in uncertain control systems*. W: *Modelling, Identification and Control*, Acta Press, Zurich, 1998, s. 305-308.

16. BUBNICKI Z.: *Uncertain logics, variables and systems*. Proc. of The Third Workshop of The International Institute for General Systems Studies, Tianjin People's Publishing House, Beidaihe, Qinhuangdao, China, 1998, s. 7-14.
17. BUBNICKI Z.: *Logic-algebraic approach for a class of dynamical knowledge-based systems*. Proc. of IMACS Congress, vol. 4, Berlin, 1997, s. 101–106.
18. BUBNICKI Z.: *Adaptive control of operation systems using neural networks*. Proc. of XI Int. Conf. on Systems Engineering, USA, Nevada State University, Las Vegas, 1996, s. 945–951.

**ISBN 83-85847**